



Nonlinear Multi-Objective Optimization Model for Production Planning Based on Fuzzy Logic and Machine Learning

Zahra Saeidi-Mobarakeh¹ and Hossein Amoozad Khalili²

1. Department of Industrial Engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran. Email: z.saeedi2020@gmail.com
2. Corresponding author, Department of Industrial Engineering, sari Branch, Islamic Azad University, sari, Iran. Email: Amoozad92@yahoo.com

Article Info

Article type:
Research Article

Article history:

Received 16 Aug 2024
Received in revised form 2 Sep 2024
Accepted 15 Sep 2024
Published online 21 Sep 2024

Keywords:

Fuzzy logic,
Hybrid multi-objective metaheuristic algorithm,
Machine learning,
Multi-objective optimization.

ABSTRACT

This research introduces a nonlinear multi-objective optimization model designed for simultaneously optimizing profit and customer satisfaction in production systems. The problem under investigation involves optimization in complex and uncertain production conditions, constrained by resources and time. The proposed model utilizes nonlinear objective functions and a detailed analysis of operational conditions to provide optimal solutions for managers. Fuzzy logic is employed to manage demand uncertainty, which is then combined with machine learning algorithms such as neural networks and reinforcement learning to create an intelligent and flexible model that effectively adapts to sudden changes in dynamic environments. The model leverages the integration of the Non-dominated Sorting Genetic Algorithm IV (NSGA-IV) and Variable Selection Network (VSN) within a hybrid framework, offering an advanced and multifaceted approach to solving complex multi-objective optimization problems. The Pareto-optimal results obtained from this model demonstrate its efficient and optimal performance. Key findings from this research suggest that the proposed model can serve as a practical and strategic resource for managers and decision-makers in optimizing production and enhancing customer satisfaction in uncertain and dynamic conditions.

Cite this article: Saeidi-Mobarakeh, Z. & Amoozad Khalili, H. (2024). Nonlinear Multi-Objective Optimization Model for Production Planning Based on Fuzzy Logic and Machine Learning. *Engineering Management and Soft Computing*, 10 (1). 155-189. DOI: <https://doi.org/10.22091/jemsc.2024.11186.1197>



© The Author(s)
DOI: <https://doi.org/10.22091/jemsc.2024.11186.1197>

Publisher: University of Qom

مدل بهینه‌سازی چندهدفه غیر خطی برنامه‌ریزی تولید براساس منطق فازی و یادگیری ماشین

زهرا سعیدی مبارکه^۱ و حسین عموزاد خلیلی^۲

۱. استادیار، گروه مهندسی صنایع، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران رایانامه: z.saeedi2020@gmail.com

۲. نویسنده مسئول، استادیار، گروه مهندسی صنایع، واحد ساری، دانشگاه آزاد اسلامی، ساری، ایران. (نویسنده مسئول مکاتبات) رایانامه: amoozad92@yahoo.com

اطلاعات مقاله	چکیده
<p>نوع مقاله: مقاله پژوهشی</p> <p>تاریخ دریافت: ۱۴۰۳/۰۵/۲۶</p> <p>تاریخ بازنگری: ۱۴۰۳/۰۶/۱۳</p> <p>تاریخ پذیرش: ۱۴۰۳/۰۶/۲۵</p> <p>تاریخ انتشار: ۱۴۰۳/۰۶/۳۱</p> <p>کلیدواژه‌ها: الگوریتم فراابتکاری ترکیبی چندهدفه، بهینه‌سازی چندهدفه، منطق فازی، یادگیری ماشین.</p>	<p>این تحقیق، به معرفی یک مدل بهینه‌سازی چندهدفه غیرخطی می‌پردازد که برای بهینه‌سازی همزمان سود و رضایت مشتری در سیستم‌های تولیدی طراحی شده است. مسئله موردبررسی شامل بهینه‌سازی در شرایط پیچیده و نامطمئن تولید است که با محدودیت‌های منابع و زمان مواجه است. مدل پیشنهادی با بکارگیری توابع هدف غیرخطی و تحلیل دقیق شرایط عملیاتی، راه‌حل‌های بهینه‌ای را برای مدیران ارائه می‌دهد. برای مدیریت عدم قطعیت در تقاضا، از منطق فازی استفاده شده است. این منطق فازی با الگوریتم‌های یادگیری ماشین نظیر شبکه‌های عصبی و یادگیری تقویتی ترکیب شده است تا مدلی هوشمند و انعطاف‌پذیر ایجاد شود که به‌طور موثری با تغییرات ناگهانی در محیط‌های پویا سازگار می‌شود. این مدل از ترکیب الگوریتم‌های ژنتیک مرتب‌سازی غیرمسلط چهارم (NSGA-IV) و شبکه انتخاب متغیر (VSN) در یک چارچوب ترکیبی بهره می‌برد و رویکردی پیشرفته و چندوجهی برای حل مسائل پیچیده بهینه‌سازی چندهدفه ارائه می‌کند. نتایج پارتو-بهینه حاصل از این مدل، نشان‌دهنده عملکرد کارآمد و بهینه آن است. یافته‌های کلیدی این تحقیق نشان می‌دهد که مدل پیشنهادی می‌تواند به‌عنوان منبع کاربردی و راهبردی برای مدیران و تصمیم‌گیران در بهینه‌سازی تولید و ارتقای رضایت مشتری در شرایط نامطمئن و پویا مورد استفاده قرار گیرد.</p>

استناد: سعیدی مبارکه، زهرا؛ عموزاد خلیلی، حسین. (۱۴۰۳). «مدل بهینه‌سازی چندهدفه غیرخطی برنامه‌ریزی تولید براساس منطق فازی و یادگیری

ماشین». *مدیریت مهندسی و رایانش نرم، دوره ۱۰ (۱)*. صص: ۱۸۹-۱۵۵. <https://doi.org/10.22091/jemsc.2024.11186.1197>



۱) مقدمه

در دنیای پر از تغییرات سریع و پیچیدگی‌های فزاینده، برنامه‌ریزی تولید به یکی از مهمترین و پیچیده‌ترین چالش‌های مدیریت زنجیره تامین تبدیل شده‌است (لورنت-لیوا و همکاران، ۲۰۲۴). از آنجاییکه تصمیم‌گیری در این حوزه به‌طور مستقیم بر بهره‌وری، کیفیت و رضایت مشتری تاثیر می‌گذارد، استفاده از مدل‌های بهینه‌سازی پیشرفته که توانایی مدیریت همزمان چندین هدف متناقض را داشته باشند، ضروری به‌نظر می‌رسد (لورنز و همکاران، ۲۰۲۴). مدل‌های بهینه‌سازی چندهدفه غیرخطی به‌عنوان یک ابزار پیشرفته برای مقابله با این چالش‌ها، به‌خوبی توانایی پاسخگویی به نیازهای پیچیده و تغییرات سریع محیط‌های تولیدی را دارند (راشد و همکاران، ۲۰۲۴).

در بسیاری از موارد، برنامه‌ریزی تولید با عدم قطعیت‌هایی همراه است که به‌طور مستقیم بر توانایی مدل‌ها در ارائه راه‌حل‌های بهینه تاثیر می‌گذارد. این عدم قطعیت‌ها می‌تواند از تغییرات ناگهانی در تقاضا و منابع، نوسانات بازار و حتی رخداد‌های غیرمنتظره مانند بحرآنها‌های جهانی نشأت بگیرد (جوادی گرگری و همکاران، ۲۰۲۴). در این راستا، استفاده از منطق فازی به‌عنوان یک ابزار موثر برای مدل‌سازی این عدم قطعیت‌ها، می‌تواند به بهبود تصمیم‌گیری‌های تولیدی کمک کند. منطق فازی با ارائه یک چارچوب انعطاف‌پذیر برای تحلیل داده‌های غیرقطعی و مبهم، امکان تصمیم‌گیری‌های بهینه و کارآمد را در شرایط پیچیده فراهم می‌آورد (نرانگ و همکاران، ۲۰۲۴).

علاوه بر این، با توجه به پیچیدگی‌های موجود در فرآیندهای تولیدی و نیاز به تحلیل داده‌های گسترده و پیچیده، استفاده از الگوریتم‌های یادگیری ماشین مانند شبکه‌های عصبی و یادگیری تقویتی نیز به یکی از رویکردهای موثر برای بهبود دقت و کارایی مدل‌های بهینه‌سازی تبدیل شده‌است (آزودو و همکاران، ۲۰۲۴). این الگوریتم‌ها با توانایی در شناسایی الگوهای پیچیده در داده‌ها و ارائه پیش‌بینی‌های دقیق، به مدل‌های بهینه‌سازی کمک می‌کنند تا به‌صورت هوشمندانه‌تری با تغییرات و چالش‌های موجود در محیط‌های تولیدی سازگار شوند. (کریستین و همکاران، ۲۰۲۴)

در این تحقیق، یک مدل بهینه‌سازی چندهدفه غیرخطی برای برنامه‌ریزی تولید پیشنهاد شده‌است که با استفاده از ترکیب منطق فازی و الگوریتم‌های یادگیری ماشین، به بهبود کارایی و دقت در فرآیندهای تولیدی می‌پردازد. این مدل با هدف افزایش سود و رضایت مشتری و با در نظر گرفتن محدودیت‌های غیرخطی مربوط به منابع و زمان، شرایط عملیاتی را به‌طور دقیق تحلیل کرده و بهینه‌ترین راهکارها را برای مدیران ارائه می‌دهد. به‌علاوه، استفاده از ترکیب الگوریتم‌های NSGA-IV و VSN در این مدل، به‌عنوان یک رویکرد پیشرفته و چندوجهی برای حل مسائل پیچیده بهینه‌سازی چندهدفه، امکان دستیابی به نتایج پارتو-بهینه را فراهم می‌کند که نشان‌دهنده کارایی و عملکرد بالای مدل پیشنهادی است.

این مدل با ارائه نتایجی که می‌تواند به‌عنوان راهنمای کاربردی برای مدیران و تصمیم‌گیران در بهینه‌سازی تولید و ارتقاء رضایت مشتری در شرایط نامطمئن و پویا مورد استفاده قرار گیرد، نشان‌دهنده قابلیت‌های گسترده و انعطاف‌پذیری بالای آن در مواجهه با چالش‌های مختلف در حوزه برنامه‌ریزی تولید است. این تحقیق می‌تواند به‌عنوان یک مرجع کاربردی در مدیریت زنجیره تامین و برنامه‌ریزی تولید در صنایع مختلف مورد توجه قرار گیرد.

برای درک بهتر چالش‌های پیش‌روی برنامه‌ریزی تولید و یافتن راه‌حل‌های موثر، مبانی تئوری مدل‌های بهینه‌سازی چندهدفه غیرخطی، منطق فازی و یادگیری ماشین باید به‌طور دقیق بررسی شوند. این مبانی علمی به‌طور شفاف نشان داده خواهد شد که چگونه پایه‌های علمی لازم برای توسعه مدل‌های بهینه‌سازی فراهم می‌آید و چگونه تعامل و کاربرد این رویکردها در مدیریت پیچیدگی‌های تولید به‌طور موثر روشن می‌شود. با بررسی این مبانی، ویژگی‌های کلیدی، مزایا و محدودیت‌های هر یک از این ابزارها به‌طور عمیق‌تر مورد تحلیل قرار خواهد گرفت و به بهبود مدل‌های پیشنهادی برای مواجهه با چالش‌های واقعی تولید، پرداخته خواهد شد. در ادامه به تفصیل، به بررسی مبانی تئوری این رویکردها پرداخته خواهد شد.

۲) مبانی تئوری موضوع تحقیق

توضیح مبانی تئوری: بخش مقدمه به تفصیل به مبانی تئوری مدل‌های بهینه‌سازی چندهدفه غیرخطی، منطق فازی، و یادگیری ماشین پرداخته‌است. این توضیحات شامل معرفی مفاهیم کلیدی و نحوه کاربرد آنها در تولید است.

مبناهای علمی: تاکید بر نحوه تعامل منطق فازی با مدل‌های بهینه‌سازی و تاثیر یادگیری ماشین بر بهبود دقت مدل‌ها به‌عنوان مبانی علمی، مورد بررسی قرار گرفته‌است.

۳) اهمیت مسئله مورد مطالعه

تاکید بر اهمیت موضوع: بخش مقدمه به‌وضوح اهمیت بهینه‌سازی تولید در شرایط پیچیده و نامطمئن را بیان کرده‌است. این اهمیت به‌ویژه در زمینه تاثیر مستقیم بر بهره‌وری، کیفیت و رضایت مشتری مورد توجه قرار گرفته‌است.

تشریح چالش‌ها و نیازها: مشکلات ناشی از عدم قطعیت‌ها و پیچیدگی‌های موجود در فرآیندهای تولید به‌عنوان دلایل ضرورت استفاده از مدل‌های پیشرفته، به‌وضوح توضیح داده شده‌اند.

۴) جایگاه در ادبیات تحقیق

پیشرفت‌های علمی اخیر: به ذکر پیشرفت‌های اخیر در زمینه مدل‌های بهینه‌سازی چندهدفه، منطق فازی و یادگیری ماشین پرداخته شده‌است. این بخش به بررسی تحقیقات قبلی و جایگاه مدل‌های جدید در مقایسه با روش‌های سنتی می‌پردازد.

ترکیب رویکردها: در مقدمه، به ترکیب نوآورانه الگوریتم‌های VSN و NSGA-IV با منطق فازی و یادگیری ماشین به‌عنوان یک پیشرفت در زمینه تحقیق و تحلیل اشاره شده‌است.

۵) پیشینه تحقیق

برنامه‌ریزی تولید به‌طور سنتی با استفاده از مدل‌های قطعی، مدیریت شده‌است اما با افزایش پیچیدگی و تغییرپذیری در محیط‌های تولیدی، محدودیت‌های این روش‌ها به‌وضوح آشکار شده‌است. معرفی مدل‌های بهینه‌سازی چندهدفه غیرخطی، همراه با پیشرفت‌هایی در منطق فازی و یادگیری ماشین، نمایانگر یک تکامل مهم در مواجهه با این چالش‌هاست (ژانگ و

همکاران، ۲۰۲۴). در این بخش، به بررسی مطالعات موجود در زمینه‌های مختلف مرتبط با موضوع مقاله پرداخته شده است (جدول ۱).

۵-۱) بهینه‌سازی چندهدفه غیرخطی

بهینه‌سازی چندهدفه غیرخطی شامل بهینه‌سازی همزمان چندین هدف است که اغلب به صورت پیچیده و غیرخطی با یکدیگر ارتباط دارند. در زمینه برنامه‌ریزی تولید، این اهداف می‌تواند شامل کاهش هزینه‌ها، افزایش بهره‌وری تولید و اطمینان از کیفیت بالای خروجی‌ها باشد. تکنیک‌های بهینه‌سازی کلاسیک مانند برنامه‌ریزی خطی ابتدا برای رسیدن به این اهداف بکار گرفته شده‌اند. با این حال، با پیچیده‌تر شدن سیستم‌های تولید، این روش‌ها به دلیل محدودیت‌هایشان در مدیریت غیرخطی بودن و اهداف متناقض چندگانه، ناکارآمد بوده‌اند (شارما و همکاران، ۲۰۲۳). پیشرفت‌های اخیر به معرفی الگوریتم‌های پیچیده‌تری اشاره داشته است که قادر به پیمایش در فضا‌های راه‌حل چندبعدی پیچیده هستند. تکنیک‌هایی مانند الگوریتم‌های تکاملی از جمله الگوریتم‌های ژنتیک (GA) و بهینه‌سازی ازدحام ذرات (PSO)، در حل مسائل بهینه‌سازی چندهدفه غیرخطی با کاوش در دامنه وسیعی از راه‌حل‌های ممکن و شناسایی بهترین تبادل‌ها بین اهداف متناقض، امیدبخش بوده‌اند (یان و همکاران، ۲۰۲۱؛ الفتح و همکاران، ۲۰۲۳). همچنین الگوریتم‌های ابتکاری چندهدفه ترکیبی به دلیل قابلیت‌های منحصربه‌فردشان در حل مسائل پیچیده بهینه‌سازی به‌ویژه در شرایطی که اهداف متضاد وجود دارد، مورد توجه قرار گرفته‌اند. این الگوریتم‌ها با ترکیب ویژگی‌های الگوریتم‌های مختلف، قادر به ارائه راه‌حل‌های بهینه و کارا در مسائل چندهدفه هستند. تحقیقات در این حوزه به بررسی و توسعه الگوریتم‌های جدید و ترکیبی پرداخته و کاربردهای مختلفی را در زمینه‌های مختلف بهینه‌سازی ارائه داده‌اند. چند نمونه از تحقیقات عبارتند از: کارهای عبدالله و همکاران (۲۰۲۱)، نیلی و همکاران (۲۰۲۱)، آلا و همکاران (۲۰۲۴)، سوتلو-سالاس و همکاران (۲۰۲۴)، ژو و همکاران (۲۰۲۴)، پرهی و پنیگراهی (۲۰۲۴)، نصیری و همکاران (۲۰۲۴) و به‌ار و همکاران (۲۰۲۴).

۵-۲) منطق فازی در برنامه‌ریزی تولید

منطق فازی راهی برای مدیریت عدم قطعیت و نادقیق بودن ذاتی در برنامه‌ریزی تولید ارائه می‌دهد. برخلاف منطق دودویی کلاسیک، منطق فازی امکان حقایق جزئی را فراهم می‌کند و می‌تواند اطلاعات مبهم و ذهنی را مدل‌سازی کند. این ویژگی به‌ویژه در محیط‌های دنیای واقعی که داده‌های دقیق ممکن است در دسترس نباشد یا نیاز به ادغام دانش کارشناسی وجود دارد، مفید است.

تحقیقات نشان داده‌اند که منطق فازی می‌تواند با ارائه درک بهتر از محدودیت‌ها و اهداف تولید، تصمیم‌گیری را بهبود بخشد. به‌عنوان مثال: قوانین و سیستم‌های استنتاج فازی می‌توانند نیازهای تولید مبهم و پیش‌بینی‌های تقاضای نادقیق را مدل‌سازی کنند و به بهینه‌سازی‌های انعطاف‌پذیر و تطبیق‌پذیرتری منجر شوند (جوادی گرگری و سیف برقی، ۲۰۲۰). مطالعات نشان داده‌اند که یکپارچه‌سازی منطق فازی با مدل‌های بهینه‌سازی باعث بهبود مقاومت و تصمیم‌گیری در شرایط عدم قطعیت می‌شود که این امر منطق فازی را به ابزاری ارزشمند برای برنامه‌ریزی تولید مدرن تبدیل می‌کند. از جمله این

تحقیقات می‌توان به کارهای کالیپرومال و داس (۲۰۲۲)، علی‌نژاد و همکاران (۲۰۲۲)، توانا و همکاران (۲۰۲۳) و خلیل‌فرد و همکاران (۲۰۲۴) اشاره کرد.

۳-۵) بهبودهای یادگیری ماشین

یکپارچه‌سازی یادگیری ماشین با مدل‌های بهینه‌سازی چندهدفه غیرخطی، برنامه‌ریزی تولید را پیشرفته‌تر کرده‌است. الگوریتم‌های یادگیری ماشین، می‌توانند مدل‌های بهینه‌سازی را با شناسایی الگوها و همبستگی‌ها در داده‌ها که ممکن است توسط روش‌های سنتی نادیده گرفته شوند، بهبود بخشند (ایفائی و همکاران، ۲۰۲۳). به‌عنوان مثال: تحلیل پیش‌بینی می‌تواند دقت پیش‌بینی تقاضا را بهبود بخشد درحالی‌که یادگیری تقویتی می‌تواند برنامه‌های تولیدی را با یادگیری و تطبیق مداوم با داده‌های جدید بهینه‌سازی کند (پاسپولیتی و همکاران، ۲۰۲۴). هم‌افزایی بین یادگیری ماشین و مدل‌های بهینه‌سازی چندهدفه، رویکردی قدرتمند برای مواجهه با پیچیدگی‌های محیط‌های تولید مدرن ارائه می‌دهد. چند نمونه از تحقیقات عبارتند از: زو و همکاران (۲۰۲۱)، لی و همکاران (۲۰۲۲)، وانگ و همکاران (۲۰۲۴) و کیم و همکاران (۲۰۲۴).

۴-۵) پیشرفت و یکپارچه‌سازی

یکپارچه‌سازی منطق فازی و یادگیری ماشین در مدل‌های بهینه‌سازی چندهدفه غیرخطی، نمایانگر یک پیشرفت مهم در برنامه‌ریزی تولید است. روش‌های اولیه به مدل‌های قطعی با پارامترهای ثابت، وابسته بودند که برای تطبیق با پیچیدگی‌های دنیای واقعی ناکافی هستند. معرفی منطق فازی امکان مدیریت بهتر عدم قطعیت‌ها را فراهم کرد درحالی‌که یادگیری ماشین با ارائه بینش‌های داده‌محور به بهبود دقت مدل‌ها کمک کرد (دوآن و همکاران، ۲۰۲۴).

جدول ۵. مرور ادبیاتی

نویسنده/ نویسندگان	اهداف بهینه‌سازی	بیان مسئله	پارامترهای عدم قطعیت	سایر ویژگی‌ها
عبدالله و همکاران (2021)	بازایی مواد و انرژی، سودآوری مالی، حداقل‌سازی ردپای کربن	مدل‌سازی ریاضی غیرخطی	تخصیص جریان‌های زباله به امکانات مختلف مدیریتی در امارات	تخصیص جریان‌های زباله به امکانات مدیریتی خاص
زو و همکاران (2021)	حرکت تطبیقی مجموعه پارتو، محیط پویا	یادگیری تقویتی	تغییرات محیطی	الگوریتم یادگیری ماشین
نیلی و همکاران (2021)	طراحی شبکه زنجیره تامین پایدار	مدل برنامه‌ریزی غیرخطی با اعداد صحیح مختلط، روش محدودیت-ε افزوده	جریان معکوس در زنجیره تامین	بررسی یک مورد واقعی در ایران
لی و همکاران (2022)	تقلید فیزیک حرارت شهری، بهینه‌سازی اقدامات محیطی شهری	یادگیری ماشین، الگوریتم ژنتیک چندهدفه	شاخص‌های زیست محیطی	جانشین‌های یادگیری ماشینی
کالیپرومال و داس (2022)	مدیریت ابهام در مسائل برنامه‌ریزی غیرخطی	مدل فازی، توابع عضویت فازی ذوزنقه‌ای، ضرایب لاگرائتی فازی	شرایط لازم و کافی در برنامه‌ریزی فازی	پیاده‌سازی در LINGO

نویسنده/ نویسندگان	اهداف بهینه‌سازی	بیان مسئله	پارامترهای عدم قطعیت	سایر ویژگی‌ها
علی‌نژاد و همکاران (۲۰۲۲)	زنجیره تامین حلقه بسته پایدار، کاهش ردپای کربن	برنامه‌ریزی خطی فازی، Lp-metric	تقاضای فازی، نرخ بازده	مسئله چند دوره‌ای چندمحصولی
توانا و همکاران (2023)	به حداکثر رساندن رضایت کلی، تعیین مختصات بهینه ایستگاه مترو	حداکثر وزنی، فرآیند تحلیل سلسله‌مراتبی فازی دوزنقه‌ای	اهداف فازی حجمی نوع ۱ و ۲	مطالعه موردی ایستگاه مترو
آلا و همکاران (2024)	بهینه‌سازی خدمات بهداشتی و درمانی، بهبود نتایج اجتماعی	NSGA-، MOGWO II، روش فازی	ویژگی‌های بهداشتی و اجتماعی	مدل چند مرحله‌ای برای شبکه خدمات بهداشتی
سوتلو-سالاس و همکاران (2024)	زمان تخلیه، پوشش، بودجه سرمایه‌گذاری	روش جمع وزنی	برنامه‌ریزی سرمایه‌گذاری برای تخلیه در سونامی	مکان-تخصیص پناهگاه عمودی
خلیلی‌فرد و همکاران (2024)	مسیریابی خودرو سبز، مصرف سوخت، زنجیره تامین حلقه بسته	مدل ریاضی زنجیره تامین حلقه بسته، مسیریابی خودرو	شرایط کلی نامشخص	ترویج اقتصاد دایره‌ای
ژو و همکاران (2024)	تخصیص گیت فرودگاه، بهبود عملکرد الگوریتم ژنتیک	RPIP-GA، یادگیری معکوس، جهش احتمال فاصله‌ای، مکانیسم فاگوستوز	همگرایی آهسته، بهینه محلی	ناریوهای مهندسی واقعی
پرهی و پنیگرایی (2024)	تنظیم دقیق الگوریتم‌های یادگیری ماشین	بهینه‌سازی جستجوی بازپخت شبیه‌سازی شده فاخته	فضای متا پارامتر	پیش‌بینی دقیق
نصیری و همکاران (2024)	مدیریت مدل‌های چندهدفه در مقیاس بزرگ، بهینه‌سازی پویایی پیچیده	MOACO، NSGA-II	انعطاف‌پذیری، پایداری	بهینه‌سازی پروفایل مصرف انرژی
به‌ارا و همکاران (2024)	بهبود زمان‌بندی، همگرایی سریعتر GWO مبتنی بر GA	بهینه‌سازی گرگ خاکستری (GWO)، الگوریتم ژنتیک (GA)	مقیاس بزرگ	کارآیی بالا در زمان‌بندی
ونگ و همکاران (2024)	پیش‌بینی نیروی باد، حل مشکلات تداخل نویز و بار محاسباتی	یادگیری ماشین، استراتژی داده عمیق، الگوریتم شغال طلایی	داده‌های غیرخطی و خطی	بهینه‌سازی داده‌های باد
کیم و همکاران (2024)	پیش‌بینی وضعیت جوی، بهینه‌سازی تخصیص منابع	الگوریتم‌های فراابتکاری، مدل‌های یادگیری عمیق	تغییرات جوی	مدل‌سازی مقیاس بزرگ

۵-۵) شکاف‌های تحقیقاتی و نوآوری‌های پیشنهادی

در سال‌های اخیر، بهینه‌سازی چندهدفه، منطق فازی و یادگیری ماشین به‌طور گسترده‌ای در برنامه‌ریزی تولید مورد استفاده قرار گرفته‌اند. با وجود پیشرفت‌های قابل توجه در این زمینه، هنوز برخی شکاف‌های تحقیقاتی باقی مانده‌اند که نیاز به

توجه و بررسی دارند. از جمله این شکاف‌ها، کمبود مدل‌های غیرخطی، عدم استفاده ترکیبی از منطق فازی و یادگیری ماشین و نیاز به الگوریتم‌های هیبریدی کارآمد است.

مدل‌های بهینه‌سازی تولید اغلب خطی هستند و در مواجهه با پیچیدگی‌های واقعی و نوسانات محیط تولیدی عملکرد مناسبی ندارند. این امر نشان‌دهنده نیاز به توسعه مدل‌های غیرخطی است که بتوانند تغییرات پیچیده و عدم قطعیت‌ها را به خوبی مدیریت کنند. در این مقاله، به توسعه یک مدل بهینه‌سازی چندهدفه غیرخطی پرداخته شده است که قادر است نوسانات محیط تولیدی را مدیریت کرده و اهداف متضاد را به طور همزمان بهینه‌سازی کند.

علاوه بر این، ترکیب منطق فازی و یادگیری ماشین یکی دیگر از شکاف‌های تحقیقاتی است درحالی‌که هر یک از این روش‌ها به طور جداگانه در برنامه‌ریزی تولید مورد بررسی قرار گرفته‌اند. ترکیب این دو به منظور بهبود دقت و کارایی مدل‌های بهینه‌سازی، کمتر مورد توجه قرار گرفته است. این مقاله با استفاده از منطق فازی برای مدیریت عدم قطعیت‌ها و اطلاعات مبهم و ترکیب آن با الگوریتم‌های یادگیری ماشین، به بهبود دقت و کارایی مدل‌های بهینه‌سازی پرداخته است. در نهایت بسیاری از الگوریتم‌های بهینه‌سازی چندهدفه موجود، از نظر کارایی و سرعت نیاز به بهبود دارند. این مقاله به طراحی و پیاده‌سازی الگوریتم‌های هیبریدی پرداخته است که ترکیبی از الگوریتم‌های تکاملی و یادگیری ماشین هستند و کارایی بالاتری نسبت به الگوریتم‌های موجود دارند. این نوآوری‌ها در کنار هم به بهبود دقت، کارایی و پایداری مدل‌های بهینه‌سازی تولید در مواجهه با عدم قطعیت‌ها و پیچیدگی‌های محیط‌های تولیدی کمک کرده و می‌توانند به تصمیم‌گیرندگان در یافتن راه‌حل‌های بهینه و پایدار برای مسائل پیچیده برنامه‌ریزی تولید یاری رسانند.

۶ بیان مسئله و مدل‌سازی ریاضی

در دنیای مدرن تولید، برنامه‌ریزی تولید یکی از چالش‌های اساسی در مدیریت زنجیره تامین است که نیازمند مدل‌های بهینه‌سازی پیشرفته برای مدیریت همزمان چندین هدف و محدودیت می‌باشد. این تحقیق به بررسی و ارائه یک مدل بهینه‌سازی چندهدفه غیرخطی می‌پردازد که به‌ویژه برای پاسخ به این چالش‌ها طراحی شده است. در این بخش، ما ویژگی‌ها، محدودیت‌ها و جزئیات مسئله مورد مطالعه را به تفصیل شرح خواهیم داد.

ویژگی‌های مسئله مورد مطالعه:

۱) چندهدفه‌بودن و پیچیدگی غیرخطی: مسئله برنامه‌ریزی تولید در این تحقیق به صورت چندهدفه و غیرخطی مدل‌سازی شده است. اهداف اصلی این مدل شامل افزایش سود و رضایت مشتری است که به طور همزمان با محدودیت‌های پیچیده منابع و زمان، مورد بررسی قرار می‌گیرند. این مدل با هدف بهینه‌سازی همزمان معیارهای متناقض طراحی شده و نیازمند الگوریتم‌های بهینه‌سازی پیشرفته برای دستیابی به تعادل بهینه میان اهداف متضاد می‌باشد.

۲) مدیریت عدم قطعیت‌ها: در این تحقیق، عدم قطعیت‌ها در سیستم‌های تولیدی به‌ویژه در زمینه تقاضا از طریق منطق فازی مدل‌سازی شده است. مدل‌سازی تقاضا به صورت فازی به این دلیل انجام شده است که تقاضاها به طور ذاتی غیرقطعی و دارای تغییرات غیرقابل پیش‌بینی هستند. منطق فازی با استفاده از توابع عضویت،

عدم قطعیت‌های تقاضا را به‌طور نرم و تدریجی مدیریت می‌کند. به این ترتیب، مدل‌سازی فازی امکان تحلیل دقیق‌تر و پیش‌بینی‌های بهتری را فراهم می‌آورد که می‌تواند به تصمیم‌گیری‌های بهینه در شرایط عدم قطعیت کمک کند. این روش نسبت به روش‌های دیگر مانند مدل‌های قطعی یا مبتنی بر توزیع‌های احتمالی، مزایای قابل توجهی دارد زیرا به‌جای استفاده از مقادیر دقیق، به‌صورت مجموعه‌ای از مقادیر ممکن و درجات عضویت عمل می‌کند که باعث انعطاف‌پذیری بیشتر و دقت بالاتر در مدل‌سازی می‌شود.

۳) الگوریتم‌های بهینه‌سازی ترکیبی: مدل پیشنهادی شامل ترکیبی از الگوریتم‌های VSN و NSGA-IV به‌عنوان بخشی از چارچوب ترکیبی است. این الگوریتم‌ها به‌طور خاص برای حل مسائل پیچیده بهینه‌سازی چندهدفه طراحی شده‌اند و به تولید نتایج پارتو-بهینه در شرایط مختلف کمک می‌کنند. ویژگی‌های خاص این الگوریتم‌ها و نحوه تعامل آنها در چارچوب مدل به تفصیل توضیح داده شده است.

محدودیت‌های مسئله مورد مطالعه:

۱) محدودیت‌های محاسباتی: به دلیل پیچیدگی‌های مدل غیرخطی و چندهدفه، فرآیند حل بهینه‌سازی نیازمند زمان و منابع محاسباتی قابل توجهی است. این امر ممکن است محدودیت‌هایی در کاربرد مدل برای مسائل با مقیاس بزرگتر و در سناریوهای صنعتی واقعی ایجاد کند.

۲) قابلیت تعمیم‌پذیری: یکی دیگر از محدودیت‌ها، قابلیت تعمیم‌پذیری مدل به انواع مختلف محیط‌های تولیدی است. با توجه به پیچیدگی‌های خاص هر محیط تولیدی، ممکن است نیاز به تنظیمات و بهینه‌سازی‌های اضافی برای کاربرد مدل در صنایع مختلف وجود داشته باشد.

۳) مدیریت چندوجهی اهداف متناقض: مدل‌های بهینه‌سازی چندهدفه غیرخطی به‌طور معمول نیازمند مدیریت همزمان اهداف متناقض هستند که ممکن است منجر به پیچیدگی‌های بیشتر در فرآیند تصمیم‌گیری شود. این مسئله نیاز به استفاده از روش‌های پیشرفته‌تر برای تحلیل و مدیریت تعارضات میان اهداف مختلف دارد.

در ادامه، برای بیان و تحلیل ملموس مسئله، از مدل‌سازی ریاضی استفاده شده است. در حالت کلی، مدل‌های ریاضی چندهدفه به‌ویژه مدل‌های غیرخطی، توانایی درک و مدیریت همزمان چندین معیار عملکرد را در محیط‌های پیچیده و پویای تولید دارند (جوادی گرگری و همکاران، ۲۰۲۱). برخلاف روش‌های دیگر مانند شبیه‌سازی یا تحلیل‌های مبتنی بر تجربیات گذشته که اغلب نیازمند داده‌های فراوان و زمان‌بر هستند، مدل‌های ریاضی امکان تحلیل دقیق و بهینه‌سازی همزمان چندین متغیر را فراهم می‌کنند. این مدل‌سازی‌ها به‌ویژه در مواجهه با عدم قطعیت‌ها و نیازهای چندوجهی تصمیم‌گیری، قادرند راه‌حل‌های بهینه و کارآمدتری ارائه دهند که مستقیماً به بهبود عملکرد سیستم‌های تولیدی منجر می‌شود (آردتا و همکاران، ۲۰۲۴). در این بخش، به توسعه مدل ریاضی پرداخته می‌شود که هدف این مدل‌سازی بهینه‌سازی همزمان اهداف متضاد مانند افزایش درآمد و کاهش زمان تحویل با حفظ کیفیت محصول و کنترل عدم قطعیت است. این مدل شامل سه بخش اصلی است: تعریف اهداف و محدودیت‌ها، استفاده از منطق فازی برای مدیریت عدم قطعیت‌ها و ترکیب الگوریتم‌های یادگیری ماشین برای بهبود دقت و کارایی مدل.

۱-۶) تعریف اهداف و محدودیت‌ها

مدل بهینه‌سازی چندهدفه شامل مجموعه‌ای از اهداف و محدودیت‌ها است که باید به‌طور همزمان بهینه‌سازی شوند. جدول (۲) تشریح شناسه‌ها، متغیرها و پارامترها برای ایجاد یک زمینه کامل برای مدل پیشنهادی است.

جدول ۶. شناسه‌های مدل‌سازی

پارامترها			
R	کل منابع موجود	p_i	قیمت فروش محصول i
T	کل زمان موجه	c_i	هزینه تولید محصول i
CA_i	ظرفیت تولید محصول i	r_i	میزان منابع موردنیاز برای تولید هر واحد محصول i
α_i	ضریب تاثیر مقدار تولید بر رضایت مشتری برای محصول i	t_i	زمان موردنیاز برای تولید هر واحد محصول i
β_i	ضریب تاثیر تاخیر تحویل بر رضایت مشتری برای محصول i	D_i	تقاضای محصول i
متغیرها			
x_i	مقدار تولید محصول i	d_i	مقدار تولید با تاخیر برای محصول i

توابع هدف مدل پیشنهادی، در ادامه بیان شده‌است:

$$z_1 = \max(\sum_i p_i x_i - c_i x_i^{1.1}) \quad (1)$$

$$z_2 = \max(\sum_i \alpha_i \ln(x_i + 1) - \beta_i \ln(\frac{1}{d_i + \varepsilon})) \quad (2)$$

تابع هدف z_1 نشانگر بیشینه کردن سود است که به صورت تفاضل هزینه از درآمد مدل‌سازی شده‌است. این تابع شامل درآمد و هزینه‌های تولید است که با استفاده از توان ۱.۱ برای هزینه‌ها به‌طور غیرخطی مدل‌سازی شده‌اند. این مدل‌سازی نشان‌دهنده افزایش نمایی هزینه‌ها با افزایش تولید است که با واقعیت‌های تولید سازگار است (پکوسکو و همکاران، ۲۰۲۳). این انتخاب براساس پژوهش‌های جدید در زمینه بهینه‌سازی غیرخطی و مدیریت هزینه‌ها صورت گرفته‌است. همانطور که در تحقیقات ارائه شده توسط تنگ و تومیلین (2008) و گو و وانگ (۲۰۲۳) مشخص است، هزینه‌های تولید و مدیریت منابع در بسیاری از موارد به صورت غیرخطی و با افزایش تولید، افزایش می‌یابند. افزایش پیچیدگی در مدیریت منابع و چالش‌های عدم قطعیت، به افزایش هزینه‌ها به صورت غیرخطی منجر می‌شود. طبق مطالعات انجام شده، استفاده از توان غیرخطی ۱.۱ در مدل‌های بهینه‌سازی می‌تواند دقت بیشتری در توصیف هزینه‌های تولید و مدیریت منابع به همراه داشته باشد به‌ویژه در محیط‌های پیچیده و پویا. این مطالعات نشان می‌دهد که مدل‌سازی غیرخطی هزینه‌ها می‌تواند به بهبود دقت و انعطاف‌پذیری مدل‌های بهینه‌سازی در شرایط مختلف منجر شود.

تابع هدف z_2 نشان‌دهنده بیشینه کردن رضایت مشتری است که به صورت ترکیبی از مقدار تولید و تاخیر در تحویل مدل‌سازی شده‌است. عبارت اول تابع دوم از تابع لگاریتمی برای مقدار تولید، نشان‌دهنده افزایش رضایت مشتری با افزایش تولید است در حالیکه نشان‌دهنده تاثیر منفی تاخیر بر رضایت مشتری است که با استفاده از لگاریتم معکوس به مدل اضافه

شده است. در اینجا، ε یک مقدار کوچک است که برای جلوگیری از تقسیم بر صفر اضافه شده است. این روش باعث می شود که تاثیر تاخیر به صورت معکوس و در مقیاس مناسب برای مقایسه با تاثیرات دیگر پارامترها در تابع هدف قرار گیرد.

محدودیت های مدل سازی:

$$\sum_i r_i x_i^{1.1} \leq R \quad (۳)$$

$$\sum_i t_i x_i^{1.1} \leq T \quad (۴)$$

$$x_i \leq CA_i \quad \forall i \in I \quad (۵)$$

$$x_i \geq D_i \quad \forall i \in I \quad (۶)$$

$$x_i \geq 0 \quad \forall i \in I \quad (۷)$$

$$d_i \geq 0 \quad \forall i \in I \quad (۸)$$

رابطه (۳) منظور مدل سازی مصرف منابع در فرآیند تولید طراحی شده است. در واقع، هنگامی که تولید افزایش می یابد، نیاز به منابع نیز به صورت غیرخطی افزایش می یابد. استفاده از $x_i^{1.1}$ برای منابع نشان دهنده آن است که با افزایش تولید i ، مصرف منابع به طور نمایی افزایش می یابد. این امر می تواند به دلیل عوامل مختلفی مانند نیاز به مواد اولیه، انرژی و نیروی کار اضافی باشد که به طور غیرخطی با تولید مرتبط است. این محدودیت به تصمیم گیرندگان کمک می کند تا مدیریت دقیقی بر روی منابع داشته باشند و از فراتر رفتن از ظرفیت های موجود جلوگیری کنند. رابطه (۴) به منظور مدل سازی زمان مورد نیاز برای تولید محصولات در نظر گرفته شده است. زمان تولید با افزایش حجم تولید به طور نمایی افزایش می یابد. به عبارت دیگر، با افزایش مقدار تولید x_i ، زمان تولید بیشتر از آنچه که به طور خطی انتظار می رود، افزایش می یابد. این افزایش می تواند ناشی از پیچیدگی های بیشتری مانند تنگناهای تولید، نیاز به تنظیمات بیشتر و زمان لازم برای هماهنگی های عملیاتی باشد. این محدودیت به تعیین میزان تولیدی که می توان در زمان معین انجام داد، کمک می کند و به جلوگیری از تجاوز به زمان های معین شده کمک می کند. رابطه (۵) نشان دهنده این است که تولید هر محصول نباید بیشتر از ظرفیت آن محصول باشد. درحقیقت این رابطه به حفظ محدودیت های فیزیکی و عملیاتی کمک می کند و از تولید بیش از حد که ممکن است منجر به مشکلات کیفیت و نقص های تولید شود، جلوگیری می کند. رابطه (۶) تضمین می کند که تولید به میزان تقاضا یا بیشتر از آن باشد. رابطه (۷) نشان می دهد که تاخیرهای تحویل باید غیرمنفی باشند زیرا منفی بودن تاخیر معنای واقعی ندارد و نشان دهنده تحویل زودتر از موعد است. این محدودیت به حفظ منطقی بودن مدل و جلوگیری از نتایج غیرواقعی کمک می کند. محدودیت (۸) اطمینان حاصل می کند که مقادیر تولید منفی نباشند؛ مقادیر تولید نمی توانند منفی باشند زیرا تولید منفی به معنای برداشت از تولیدات موجود است که به طور واقعی امکان پذیر نیست. این محدودیت به حفظ منطقی بودن و واقعی بودن مدل کمک می کند.

۲-۶) استفاده از منطق فازی برای مدیریت عدم قطعیت

مدیریت عدم قطعیت فازی در بهینه سازی به عنوان ابزاری برای مدل سازی نوسانات و عدم قطعیت ها در داده ها و پارامترها بکار می رود (سها و همکاران، ۲۰۲۳). در این مدل، منطق فازی به ویژه برای مدیریت عدم قطعیت های موجود در

تقاضا استفاده می‌شود. به منظور مدل‌سازی عدم قطعیت‌های موجود در تقاضا، از منطق فازی استفاده می‌شود. تقاضای فازی \bar{D}_i با استفاده از تابع عضویت تعریف می‌شود که در این تحقیق تابع عضویت تقاضا به صورت تابع مثلثی (a_i, b_i, c_i) تعریف شده است (ندیم و همکاران، ۲۰۲۴).

$$\mu_{x_i}(\bar{D}_i) = \begin{cases} 0 & \bar{D}_i \leq a_i \text{ or } \bar{D}_i \geq c_i \\ \frac{D_i - a_i}{b_i - a_i} & a_i < \bar{D}_i \leq b_i \\ \frac{c_i - D_i}{c_i - b_i} & b_i < \bar{D}_i < c_i \end{cases} \quad (9)$$

که در آن $\mu_{x_i}(\bar{D}_i)$ تابع عضویت مثلثی برای تقاضای محصول i است.

تابع عضویت مثلثی به تصمیم‌گیرندگان کمک می‌کند تا به طور موثر با عدم قطعیت‌های تقاضا مقابله کنند و تولید را به گونه‌ای تنظیم کنند که تغییرات احتمالی در تقاضا به بهترین شکل مدیریت شود. با استفاده از منطق فازی مثلثی، مدل بهینه‌سازی قادر است به دقت بیشتری به تقاضای فازی پاسخ دهد و تولید را به نحوی تنظیم کند که با عدم قطعیت‌های بازار سازگار باشد و از این طریق هزینه‌ها و منابع را بهینه مدیریت کند (کوشارتانتو، ۲۰۲۴).

۳-۶) فازی زدایی مقادیر غیر قطعی فازی

برای دیفازی کردن داده‌ها و تبدیل آنها به مقادیر دقیق‌تر در تحلیل و مدل‌سازی، یکی از روش‌های مناسب، استفاده از روش "میانگین وزنی توابع عضویت (Weighted Average of Membership Functions)" است. این روش به طور خاص برای تبدیل داده‌های فازی به مقادیر دقیق در موقعیت‌های مختلف استفاده می‌شود. روش میانگین وزنی توابع عضویت، روشی است که در آن برای تبدیل داده‌های فازی به مقادیر دقیق و قطعی، از توابع عضویت فازی استفاده می‌شود. این روش با استفاده از توابع عضویت، مقادیر فازی را به مقادیر غیر فازی تبدیل می‌کند. به طور خاص، این روش به دنبال یافتن یک مقدار نقطه‌ای دقیق است که نمایانگر یک میانگین وزنی از مقادیر مختلف در مجموعه فازی باشد. مراحل اجرای روش به شرح زیر می‌باشد:

- (۱) **تعیین توابع عضویت:** برای هر داده فازی، توابع عضویت که تعیین‌کننده درجات عضویت در مجموعه فازی هستند، مشخص می‌شود. این توابع معمولاً به صورت توابع مثلثی، ذوزنقه‌ای یا گوسی تعریف می‌شوند.
- (۲) **محاسبه میانگین وزنی:** برای هر عنصر داده، میانگین وزنی با توجه به درجات عضویت آن محاسبه می‌شود. به این صورت که مقادیر مختلف داده به همراه درجات عضویتشان جمع شده و براساس این درجات وزندهی می‌شود.
- (۳) **تبدیل به مقدار قطعی:** پس از محاسبه میانگین وزنی، مقدار نهایی به دست آمده به عنوان مقدار دقیق برای داده فازی استفاده می‌شود.

تابع ریاضی جهت محاسبه میانگین وزنی توابع عضویت، طبق عبارت (۱۲) محاسبه می‌شود.

$$\text{مقدار فازی زدایی شده} = \frac{\sum_i \mu_i(D) D_i}{\sum_i \mu_i(D)} \quad (12)$$

که در آن، $\mu_i(D)$ درجه عضویت برای مقدار D_i است و D_i مقدار تقاضا در مجموعه فازی می باشد.

۴-۶ ترکیب الگوریتم‌های یادگیری ماشین برای بهبود دقت و کارایی مدل

در این مدل بهینه‌سازی، الگوریتم‌های یادگیری ماشین برای بهبود دقت و کارایی استفاده می شوند. استفاده از یادگیری ماشین در این مدل به منظور پیش‌بینی بهتر تقاضا، بهینه‌سازی پارامترهای مدل و ارتقای دقت تصمیم‌گیری‌ها بکار می‌رود. شبکه‌های عصبی مصنوعی (ANNs) برای پیش‌بینی تقاضا و بهینه‌سازی پارامترهای مدل استفاده می‌شوند که به یادگیری روابط پیچیده میان متغیرها و پیش‌بینی دقیق‌تر مقادیر بهینه کمک می‌کنند (اعلم و همکاران، ۲۰۲۴). مدل ANN به صورت رابطه (۱۳) تعریف می‌شود:

$$ANN(X) = f(X, \theta) \quad (13)$$

که در آن ورودی‌های مدل است. f تابع شبکه عصبی است که خروجی را تولید می‌کند و θ پارامترهای یادگیری (وزن‌ها و بایاس‌ها) است که طی فرآیند آموزش بهینه می‌شوند.

شبکه‌های عصبی با استفاده از داده‌های تاریخی و آموزشی می‌توانند به پیش‌بینی تقاضا و شبیه‌سازی رفتار سیستم کمک کنند. در مدل‌های شبکه عصبی مصنوعی (ANN)، تابع هزینه به‌عنوان معیاری برای ارزیابی عملکرد مدل و بهینه‌سازی پارامترها استفاده می‌شود. یکی از رایج‌ترین توابع هزینه، تابع هزینه میانگین مربعات خطا (Mean Squared Error) است که به صورت رابطه 14 تعریف می‌شود (مناذو، ۲۰۲۴):

$$J(\theta) = \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(x^i) - y^i)^2 \quad (14)$$

که در آن، $J(\theta)$ تابع هزینه است و میزان دقت پیش‌بینی‌های شبکه عصبی را اندازه‌گیری می‌کند. θ پارامترهای (وزن‌ها و بایاس‌ها) شبکه عصبی است که در حال بهینه‌سازی هستند و m تعداد نمونه‌های آموزشی است. $h_{\theta}(x^i)$ پیش‌بینی انجام‌شده توسط شبکه عصبی برای i است و y^i مقدار واقعی خروجی برای نمونه i است.

همچنین در الگوریتم‌های یادگیری تقویتی (RL)، هدف بهینه‌سازی فرآیند تولید و تصمیم‌گیری است. این الگوریتم‌ها از طریق تعامل با محیط و دریافت پاداش‌ها و تنبیه‌ها، استراتژی‌های بهینه برای تصمیم‌گیری را می‌یابند در الگوریتم‌های یادگیری تقویتی، برای بهینه‌سازی فرآیندها و تصمیم‌گیری، چند مفهوم کلیدی وجود دارد که باید به‌درستی مشخص شوند:

- $R(s, a)$ پاداش دریافتی برای اقدام a در وضعیت s است.
- مقدار γ : مقداری بین ۰ و ۱ است که برای کاهش تاثیر پاداش‌های آینده استفاده می‌شود؛ اگر γ نزدیک به ۱ باشد، پاداش‌های آینده اهمیت بیشتری خواهند داشت؛ اگر نزدیک به ۰ باشد، تاثیر پاداش‌های آینده کمتر است.
- اقدام a : اقدامی که عامل یادگیرنده در وضعیت s انتخاب می‌کند.

تابع ارزش $Q(s, a)$ میزان ارزش اقدام a در وضعیت s را برآورد می‌کند و به شکل عبارت ۱۵ محاسبه می‌شود (گوا و همکاران، ۲۰۲۴):

$$Q(s, A) = R(s, a) + \gamma \sum_{s'} P(s' | s, a) \max_a Q(s', a) \quad (15)$$

در این معادله، $R(s, a)$ پاداش دریافتی برای اقدام a در وضعیت s است؛ γ عامل تخفیف است که تاثیر پاداش‌های آینده را کاهش می‌دهد ($P(s' | s, a)$ احتمال انتقال به وضعیت s' پس از اقدام a در وضعیت s است) و $\max_a Q(s', a)$ بیشترین مقدار تابع ارزش در وضعیت s' برای تمام اقدامات ممکن a' است. الگوریتم‌های یادگیری تقویتی به تصمیم‌گیرندگان کمک می‌کنند تا بهترین اقدامات را برای بهینه‌سازی فرآیند تولید و کاهش هزینه‌ها انتخاب کنند (سانگ و همکاران، ۲۰۲۴).

۵-۶ ترکیب الگوریتم‌های یادگیری ماشین و مدل بهینه‌سازی

ترکیب الگوریتم‌های یادگیری ماشین با مدل‌های بهینه‌سازی به بهبود دقت و کارایی مدل کمک می‌کند (لی و همکاران، ۲۰۲۴). در این مدل، بهینه‌سازی با استفاده از نتایج حاصل از شبکه‌های عصبی و یادگیری تقویتی به صورت عبارت ۱۶ انجام می‌شود:

$$\text{Optimize (ANN, RL, Fuzzy) = Combined Model} \quad (16)$$

که در آن:

ANN: استفاده از شبکه‌های عصبی برای پیش‌بینی تقاضا و بهینه‌سازی پارامترها.

RL: استفاده از الگوریتم‌های یادگیری تقویتی برای بهینه‌سازی فرآیند تولید و تصمیم‌گیری.

Fuzzy: استفاده از منطق فازی برای مدیریت عدم قطعیت‌ها و تنظیم پارامترهای مدل.

۶-۶ نرمالیزه کردن مدل ارائه شده

در فرآیند بهینه‌سازی، توابع هدف معمولاً شامل چندین پارامتر با مقادیر و واحدهای مختلف هستند. این تنوع در مقیاس و واحدها می‌تواند منجر به ارزیابی ناعادلانه برخی از پارامترها و توابع هدف شود (چن و همکاران، ۲۰۲۴). به همین دلیل، نرمالیزه کردن مستقیم توابع هدف به دلیل تفاوت‌های موجود در مقیاس و واحد، ممکن است به نتایج غیرقابل مقایسه و تحلیل نادرست منجر شود (نیکسون و همکاران، ۲۰۲۴). همچنین در ترکیب الگوریتم‌های یادگیری ماشین و مدل‌های بهینه‌سازی، نرمالیزه کردن پارامترها و توابع هدف نقش مهمی در بهبود دقت و کارایی مدل ایفا می‌کند (یوسف زاده و همکاران، ۲۰۲۴). این فرآیند به دلیل تفاوت‌های مقیاس و واحد در توابع هدف مختلف اهمیت دارد و نرمالیزه کردن آنها به منظور مقایسه و ترکیب منصفانه نتایج در مدل‌های بهینه‌سازی، ضروری است (افضل و همکاران، ۲۰۲۴). بدون نرمالیزه کردن، تفاوت‌های مقیاس می‌توانند مشکلاتی را در ارزیابی و ترکیب نتایج ایجاد کنند. برای حل این مشکل، معمولاً پارامترهای ورودی به توابع هدف نرمالیزه می‌شوند تا همه ورودی‌ها به یک مقیاس مشابه تبدیل شوند. این روش باعث

می‌شود که تابع هدف به‌طور یکنواخت و منصفانه محاسبه شود که به نوبه خود بهبود کارایی الگوریتم‌های بهینه‌سازی و امکان مقایسه دقیق‌تر نتایج را فراهم می‌آورد (هوانگ و همکاران، ۲۰۲۳).

برای نرمالیزه کردن پارامترها در تابع هدف، از عبارت 17 استفاده می‌شود (هوانگ و همکاران، ۲۰۲۴):

$$\text{Normalized Parameter} = \frac{\text{Parameter}_{\text{actual}} - \text{Parameter}_{\text{min}}}{\text{Parameter}_{\text{max}} - \text{Parameter}_{\text{min}}} \quad (17)$$

۷ روش‌های حل

بهینه‌سازی مسائل پیچیده در حوزه‌های مختلف، به روش‌های پیشرفته‌ای نیاز دارد که بتوانند به‌طور همزمان چندین هدف را بهینه کنند. این گونه مسائل اغلب شامل اهداف متعارضی هستند که بهینه‌سازی یک هدف ممکن است منجر به تضعیف اهداف دیگر شود. به همین دلیل، استفاده از الگوریتم‌های چندهدفه (Multi-objective Algorithms) که قادر به یافتن مجموعه‌ای از راه‌حل‌های بهینه پارتو (Pareto-optimal Solutions) هستند، بسیار حیاتی است (راجوار و همکاران، ۲۰۲۳).

الگوریتم‌های چندهدفه فراابتکاری (Meta-heuristic Multi-objective Algorithms) به دلیل توانایی بالای خود در جستجوی فضای راه‌حل و یافتن تعادل میان اهداف مختلف، مورد توجه بسیاری از پژوهشگران و متخصصان قرار گرفته‌اند (وانگ و همکاران، ۲۰۲۳). این الگوریتم‌ها با ترکیب مفاهیم بهینه‌سازی و تکنیک‌های فراابتکاری، می‌توانند راه‌حل‌های موثری برای مسائل پیچیده ارائه دهند. در این راستا، استفاده از الگوریتم‌های (Non-dominated Sorting Genetic Algorithm IV) و (Variable sorting for normalization) VSN به‌عنوان دو نمونه بارز از الگوریتم‌های چندهدفه، می‌تواند نتایج قابل توجهی در بهینه‌سازی مسائل چندهدفه فراهم کند (ژانگ و همکاران، ۲۰۲۴). ادغام الگوریتم‌های NSGA-IV و VSN در یک چارچوب ترکیبی نمایانگر رویکردی پیشرفته و چندوجهی برای حل مسائل پیچیده بهینه‌سازی چندهدفه است. هر یک از این الگوریتم‌ها دارای توانمندی‌های خاصی هستند که در کنار یکدیگر نه تنها محدودیت‌هایشان را کاهش می‌دهند بلکه باعث تقویت عملکرد یکدیگر می‌شوند. این ترکیب هوشمندانه، از قدرت مرتب‌سازی غیرمغلوب و حفظ تنوع در NSGA-IV بهره می‌برد و آن را با قابلیت‌های پیمایش کارآمد و مدیریت دقیق فضای راه‌حل در VSN تلفیق می‌کند. به واسطه این هم‌افزایی، الگوریتم ترکیبی می‌تواند بهبود چشمگیری در کارایی و اثربخشی فرآیند بهینه‌سازی ایجاد کرده و به نتایج دقیق‌تر و متنوع‌تر دست یابد. به‌عنوان نمونه: استراتژی‌های انتخاب NSGA-IV و روش‌های پیمایش VSN می‌توانند به شکلی یکپارچه با هم ترکیب شوند تا راه‌حل‌های بهینه‌تری برای مسائل پیچیده فراهم آورند.

الگوریتم NSGA-IV به دلیل ساختار پیشرفته‌اش در مدیریت بهینه‌سازی چندهدفه شناخته شده است. از مزایای کلیدی این الگوریتم می‌توان به توانایی در ایجاد و حفظ مجموعه‌ای از راه‌حل‌های پارتو و استفاده از الگوریتم‌های انتخابی و رتبه‌بندی متنوع برای بهبود همزمان چندین هدف اشاره کرد. این ویژگی‌ها باعث می‌شود که NSGA-IV بتواند تعادل موثری میان اهداف متضاد برقرار کند و فضای جستجو را به‌طور گسترده‌تری پوشش دهد. با این حال، یکی از کمبودهای این الگوریتم، نیاز به زمان و منابع محاسباتی زیاد برای اجرای کامل فرآیندهای انتخاب و رتبه‌بندی است. همچنین NSGA-

IV ممکن است در بهینه‌سازی محلی و جزئیات دقیق‌تر راه‌حل‌ها به اندازه کافی قوی نباشد و نیاز به بهبودهای بیشتری در این زمینه داشته باشد. نمودار این الگوریتم در شکل (۱) نشان داده شده است (خان، ۲۰۲۲).

1	ایجاد جمعیت اولیه
2	ارزیابی جمعیت بر اساس توابع هدف
3	مرتب‌سازی افراد جمعیت بر اساس ترتیب نامسلط
4	تعیین فاصله ازدحامی برای هر فرد جهت حفظ تنوع در جمعیت
5	انتقال افراد برگزیده به نسل بعدی
6	ارزیابی نسل جدید (فرزندان) بر اساس توابع هدف
7	ترکیب جمعیت والدین و فرزندان
8	مرتب‌سازی افراد جمعیت ترکیبی بر اساس ترتیب نامسلط
9	تعیین فاصله ازدحامی برای جمعیت ترکیبی
10	انتخاب جمعیت جدید از میان جمعیت ترکیبی
11	بررسی شرط خاتمه
12	در صورت برقرار نبودن شرط خاتمه، شروع دوباره از مرحله 1

شکل ۱. الگوریتم NSGA-IV

الگوریتم VSN یکی از الگوریتم‌های جستجوی محلی قوی است که برای بهینه‌سازی مسائل مختلف بکار می‌رود. از مزایای این الگوریتم می‌توان به توانایی در جستجوی سیستماتیک و انعطاف‌پذیری آن در بررسی نواحی مختلف فضای جستجو اشاره کرد. VSN قادر است با تغییرات در همسایگی‌های مختلف بهبودهای دقیق و موثری را در راه‌حل‌های بهینه ایجاد کند. این ویژگی باعث می‌شود که VNS به‌عنوان یک ابزار قوی در بهینه‌سازی محلی عمل کند. با این حال، کمبود اصلی این الگوریتم این است که ممکن است نتواند به‌طور کامل به بهینه‌سازی چندهدفه پردازد و به‌دلیل تمرکز عمده بر جستجوی محلی، ممکن است دچار محدودیت‌های جدی در پوشش فضای جستجو و تنوع راه‌حل‌ها شود. نمودار این الگوریتم در شکل (۲) نشان داده شده است (شین و همکاران، ۲۰۲۳).

1	ایجاد رامحل اولیه
2	جستجو در اطراف رامحل فعلی برای پیدا کردن رامحل بهتر
3	تعیین بهترین همسایگی
4	انتقال راه حل فعلی به بهترین همسایگی
5	جستجوی مجدد محلی در اطراف رامحل جدید
6	بررسی معیارهای پذیرش
7	به روز رسانی راه حل
8	بررسی شرط خاتمه
9	خاتمه به شرط برقرار بودن شرط خاتمه؛ در غیر این صورت شروع از 2



شکل ۲. الگوریتم VNS

ترکیب NSGA-IV و VNS می‌تواند به‌عنوان یک رویکرد هیبریدی موثر در بهینه‌سازی چندهدفه عمل کند. این ترکیب بهره‌برداری همزمان از قدرت‌های هر دو الگوریتم را به ارمغان می‌آورد. NSGA-IV می‌تواند بطور کلی فضای جستجو را پوشش دهد و مجموعه‌ای از راه‌حل‌های بهینه را ایجاد کند. درحالی‌که VNS می‌تواند بر روی این راه‌حل‌ها تمرکز کرده و از طریق جستجوی محلی، دقت و کیفیت آنها را بهبود بخشد. این رویکرد هیبریدی می‌تواند مشکلات و کمبودهای هر یک از الگوریتم‌ها را جبران کند بطوریکه NSGA-IV به‌دلیل توانایی در بهینه‌سازی چندهدفه و VNS به‌دلیل بهبودهای محلی، با هم ترکیب شده و یک الگوریتم قوی‌تر و دقیق‌تر را ارائه دهند. این ترکیب همچنین می‌تواند منجر به بهبود عملکرد، کاهش زمان محاسباتی و افزایش دقت نتایج در مسائل پیچیده بهینه‌سازی شود. بخش ۴.۱ مراحل کلی الگوریتم ترکیبی NSGA-IV و VNS را شرح داده‌است.

۷-۱) اجرای الگوریتم ترکیبی و مدل چندهدفه ارائه‌شده

ترکیب الگوریتم‌ها طبق مراحل زیر انجام می‌شود:

۷-۱-۱) مرحله ۱: تعریف اهداف و محدودیت‌ها

اهداف و محدودیت‌ها براساس مدل مشخص می‌شوند.

۷-۱-۲) مرحله ۲: استفاده از NSGA-IV

الگوریتم NSGA-IV برای یافتن مجموعه‌ای از راه‌حل‌های بهینه در فضای چندهدفه استفاده می‌شود. این الگوریتم به‌دلیل قابلیت‌های خود در حفظ تنوع و یافتن راه‌حل‌های بهینه، به‌عنوان پایه‌ای برای حل مدل انتخاب می‌شود.

۷-۱-۳) مرحله ۳: استفاده از VNS برای جستجوی محلی

پس از اجرای اولیه NSGA-IV، الگوریتم VNS برای بهبود نتایج به‌دست‌آمده و جستجوی دقیق‌تر در فضای راه‌حل‌ها استفاده می‌شود. این مرحله شامل مراحل زیر است:

انتقال به بهترین همسایگی: بهترین راه‌حل‌های به‌دست‌آمده از NSGA-IV انتخاب می‌شوند و همسایگی آنها بررسی می‌شود.

جستجوی محلی: در هر همسایگی، جستجوی محلی برای یافتن راه‌حل‌های بهتر انجام می‌شود.

بررسی معیار پذیرش: راه‌حل‌های جدید براساس معیارهای تعیین‌شده ارزیابی می‌شوند و در صورت بهبود، پذیرفته می‌شوند.

به‌روزرسانی راه‌حل: راه‌حل‌های پذیرفته‌شده به‌عنوان راه‌حل‌های جدید به‌روزرسانی می‌شوند.

تنظیم ساختار همسایگی: ساختار همسایگی براساس راه‌حل‌های جدید تنظیم می‌شود و فرآیند جستجوی محلی ادامه می‌یابد.

۷-۱-۴) مرحله ۴: استفاده از یادگیری ماشین برای پیش‌بینی و بهینه‌سازی

شبکه‌های عصبی و الگوریتم‌های یادگیری تقویتی به مدل اضافه می‌شود تا پیش‌بینی تقاضا و بهینه‌سازی پارامترها را بهبود بخشد. ANN برای پیش‌بینی تقاضا و بهینه‌سازی پارامترها استفاده می‌شود درحالی‌که RL برای بهینه‌سازی تصمیم‌گیری و فرآیند تولید بکار می‌رود.

۷-۱-۵) مرحله ۵: مدل‌سازی فازی

برای مدیریت عدم قطعیت‌های تقاضا، مدل‌سازی فازی بکار می‌رود تا دقت و کارایی مدل بهبود یابد.

۷-۱-۶) مرحله ۶: ادغام نتایج :

نتایج به دست آمده از الگوریتم‌های مختلف ترکیب شده و بهینه‌ترین راه‌حل‌ها استخراج می‌شود. استفاده از الگوریتم ترکیبی NSGA-IV و VNS همراه با یادگیری ماشین و مدل‌سازی فازی، یک رویکرد جامع و قدرتمند برای حل مسائل بهینه‌سازی چندهدفه ارائه می‌دهد. این ترکیب نه تنها به حفظ تنوع و یافتن راه‌حل‌های بهینه کمک می‌کند بلکه با بهبود جستجوی محلی و مدیریت عدم قطعیت‌ها، کارایی و دقت مدل به‌طور قابل توجهی افزایش می‌یابد. مزایا و نیاز به این ترکیب، در جدول (۳) شرح داده شده‌است.

جدول ۷. مزایا و الزام ترکیب Optimize (ANN, RL, Fuzzy) با الگوریتم ترکیبی VNS و NSGA-IV

مزایای ترکیب Optimize (ANN, RL, Fuzzy) با الگوریتم ترکیبی VNS و NSGA-IV	
بهبود کارایی جستجو	ترکیب NSGA-IV و VSN باعث می‌شود که الگوریتم ترکیبی بتواند فضای راه‌حل را به‌صورت جامع‌تر و کارآمدتر جستجو کند. NSGA-IV به یافتن راه‌حل‌های پارتو کمک می‌کند و VSN با پیمایش در فضای راه‌حل، این نتایج را بهبود می‌بخشد.
حفظ تنوع بهتر	ترکیب این دو الگوریتم کمک می‌کند تا تنوع در جمعیت بهتری حفظ شود و از همگرایی زود هنگام جلوگیری گردد. این امر به یافتن طیف گسترده‌تری از راه‌حل‌های بهینه کمک می‌کند.
مدیریت عدم قطعیت‌ها	با استفاده از الگوریتم ترکیبی NSGA-IV و VSN، می‌توان عدم قطعیت‌های موجود در داده‌ها و تصمیمات را بهتر مدیریت کرد.
نیاز به ترکیب Optimize (ANN, RL, Fuzzy) با الگوریتم ترکیبی VNS و NSGA-IV	
پیچیدگی مسائل چندهدفه	مسائل پیچیده چندهدفه نیاز به رویکردهای جامع و کارآمد دارند که بتوانند بهینه‌سازی چندین هدف را به‌صورت همزمان انجام دهند. ترکیب NSGA-IV و VSN با مدل‌های یادگیری ماشین و منطق فازی می‌تواند این نیاز را برآورده کند.
بهبود دقت و کارایی	ترکیب این الگوریتم‌ها به بهبود دقت و کارایی در یافتن راه‌حل‌های بهینه کمک می‌کند و می‌تواند به نتایج بهتری در بهینه‌سازی مسائل پیچیده منجر شود.

۸) ارزیابی محاسباتی و آزمایش‌های آماری

ادغام NSGA-IV و VNS با ترکیب آنها با ANN، Fuzzy و RL یک تلاش استراتژیک برای استفاده از نقاط قوت هر الگوریتم منفرد به منظور حل مسائل بهینه‌سازی چندهدفه است. این ترکیب به دلیل پیچیدگی ذاتی مسائل بهینه‌سازی، نیازمند بررسی دقیق و بهینه‌سازی پارامترهای الگوریتم‌هاست که تاثیر مستقیمی بر عملکرد و همگرایی الگوریتم ترکیبی دارد.

یکی از ابزارهای پرکاربرد برای بهینه‌سازی این پارامترها، روش تاگوچی است که به دلیل کارایی بالا در طراحی آزمایشی و بهینه‌سازی پارامترها شناخته شده است. روش تاگوچی مبتنی بر اصل طراحی قوی است و هدف آن به حداقل رساندن تغییرات و بهینه‌سازی عملکرد است. این روش از طریق تغییرات سیستماتیک پارامترهای ورودی در چارچوب طراحی آزمایشی عمل می‌کند. با استفاده از اصول طراحی قوی تاگوچی، می‌توان تنظیمات بهینه پارامترها را شناسایی و تنظیم کرد که این به نوبه خود عملکرد کلی و اثربخشی الگوریتم ترکیبی را در حل مسائل پیچیده بهینه‌سازی چندهدفه افزایش می‌دهد.

پارامترهای کلیدی در این ادغام شامل:

- ۱) جمعیت اولیه در NSGA-IV: تعیین اندازه جمعیت اولیه به طور مستقیم بر تنوع و کارایی جستجو تاثیر می‌گذارد. جمعیت بزرگتر می‌تواند تنوع ژنتیکی را افزایش داده و به جستجوی گسترده‌تر در فضای راه‌حل کمک کند.
 - ۲) احتمال تقاطع (Crossover Probability) در NSGA-IV: این پارامتر تعیین می‌کند که چه تعداد از راه‌حل‌ها با هم تقاطع داشته باشند. تقاطع باعث ایجاد راه‌حل‌های جدید و تنوع در جمعیت می‌شود.
 - ۳) احتمال جهش (Mutation Probability) در NSGA-IV: این پارامتر میزان تغییر در راه‌حل‌های فرزندان را تعیین می‌کند و می‌تواند به جلوگیری از همگرایی زودرس به سمت بهینه‌های محلی کمک کند.
 - ۴) تعداد همسایگان (Neighborhood Size) در VNS: این پارامتر اندازه همسایگی که در هر مرحله از جستجوی VNS بررسی می‌شود را تعیین می‌کند. بزرگتر بودن اندازه همسایگی می‌تواند به بهبود جستجو در فضای راه‌حل کمک کند اما همچنین ممکن است زمان محاسباتی بیشتری نیاز داشته باشد.
 - ۵) تابع عضویت (Membership Function) در Fuzzy: برای مدل‌سازی عدم قطعیت‌ها و ابهامات در مسئله استفاده می‌شود. انتخاب مناسب تابع عضویت می‌تواند تاثیر بسزایی در دقت و صحت نتایج داشته باشد.
 - ۶) پارامترهای یادگیری (Learning Parameters) در RL: این پارامترها شامل نرخ یادگیری و نرخ تخفیف می‌شوند که بهینه‌سازی مناسب آنها می‌تواند به بهبود فرآیند یادگیری و تصمیم‌گیری منجر شود.
 - ۷) معیار ارزیابی (Evaluation Criteria) در ANN: برای ارزیابی و انتخاب راه‌حل‌ها بکار می‌رود. معیارهای ارزیابی مناسب می‌توانند به بهبود کیفیت تصمیم‌گیری و انتخاب بهترین راه‌حل‌ها کمک کنند.
- با استفاده از این پارامترها و بکارگیری روش تاگوچی برای بهینه‌سازی آنها، محققان می‌توانند یک الگوریتم ترکیبی قدرتمند و موثر برای حل مسائل پیچیده بهینه‌سازی چندهدفه توسعه دهند.

۸-۱) تنظیم پارامترهای الگوریتم‌ها

برای دستیابی به بهترین عملکرد از الگوریتم‌های استفاده‌شده در این پژوهش، تنظیم پارامترها به وسیله روش‌های ترکیبی شامل جستجوی شبکه‌ای (Grid Search) و بهینه‌سازی تجربی (Experimental Optimization) انجام شده است.

(۱) **جستجوی شبکه‌ای (Grid Search):** در مرحله اول از روش جستجوی شبکه‌ای برای تنظیم پارامترهای کلیدی هر الگوریتم استفاده شد. در این روش، مقادیر مختلفی برای هر پارامتر در یک فضای گسسته در نظر گرفته شد و ترکیب‌های مختلف این پارامترها به صورت سیستماتیک بررسی شدند. هدف از این مرحله شناسایی مجموعه‌ای از پارامترها بود که بهترین نتایج را در مواجهه با داده‌های اولیه به دست آورد.

(۲) **بهینه‌سازی تجربی (Experimental Optimization):** پس از شناسایی محدوده‌های مناسب برای هر پارامتر از طریق جستجوی شبکه‌ای، از بهینه‌سازی تجربی برای تنظیم دقیق‌تر پارامترها استفاده شد. در این مرحله مجموعه‌ای از آزمایش‌ها بر روی نمونه داده‌های مختلف انجام شد و عملکرد الگوریتم‌ها با تنظیمات پارامتری مختلف مورد ارزیابی قرار گرفت. برای این منظور، معیارهای عملکرد مختلفی مانند میانگین زمان اجرا، تنوع جمعیت و کیفیت راه‌حل‌های نهایی مورد استفاده قرار گرفت.

(۳) تنظیم پارامترها در الگوریتم‌های خاص:

- **NSGA-IV:** پارامترهای کلیدی مانند اندازه جمعیت (Population Size)، تعداد نسل‌ها (Generations)، احتمال جهش (Mutation Probability) و احتمال تقاط (Crossover Probability) براساس نتایج بهینه‌سازی تجربی تنظیم شدند. این پارامترها به گونه‌ای تنظیم شدند که تعادل مناسبی بین اکتشاف (Exploration) و بهره‌برداری (Exploitation) در فضای جستجو حفظ شود.
 - **VNS:** پارامترهای الگوریتم VNS شامل ساختار همسایگی (Neighborhood Structure) و معیارهای پذیرش (Acceptance Criteria) با توجه به نتایج حاصل از آزمایش‌های مختلف بهینه‌سازی شدند. در اینجا هدف اصلی بهبود جستجوی محلی و افزایش دقت در فضای راه‌حل‌ها بود.
 - **شبکه‌های عصبی مصنوعی (ANN) و یادگیری تقویتی (RL):** پارامترهای مدل‌های یادگیری ماشین نیز با استفاده از بهینه‌سازی تجربی تنظیم شدند. برای ANN، پارامترهایی مانند نرخ یادگیری (Learning Rate)، تعداد لایه‌ها (Epochs) بهینه‌سازی شدند. برای RL، پارامترهایی همچون نرخ بهره‌وری (Exploration Rate) تخفیف (Discount Factor) با توجه به هدف بهینه‌سازی بلندمدت تنظیم شدند.
 - **مدل‌سازی فازی:** پارامترهای مربوط به مدل‌سازی فازی نیز با استفاده از ترکیبی از دانش کارشناسی و آزمایش‌های تجربی تنظیم شدند. این شامل تنظیم محدوده‌های فازی برای متغیرهای ورودی و خروجی مدل و انتخاب قوانین فازی مناسب بود.
- این رویکرد ترکیبی، اطمینان حاصل می‌کند که پارامترهای مورد استفاده بهینه‌سازی شده و قادر به تولید نتایج با کیفیت بالا در مسائل بهینه‌سازی چندهدفه هستند.

۸-۲) حل مثال‌های عددی

در این بخش مدل ارائه شده و جزئیات عملیاتی و چالش‌های موجود را با دقت مورد بررسی قرار می‌دهد. مدل و الگوریتم پیشنهادی با استفاده از ۱۵ مثال در اندازه‌های کوچک، متوسط و بزرگ اعتبارسنجی و بهینه‌سازی می‌شود که امکان تحلیل

جامع در مقیاس‌های مختلف داده و ارائه بینش‌هایی درباره عملکرد و کاربرد روش‌های پیشنهادی در داده‌های مختلف را فراهم می‌کند. پارامترها در جدول (۴) ارائه شده‌اند.

پیاده‌سازی الگوریتم با استفاده از کتابخانه PPGMO در پایتون، به‌ویژه PyGMO انجام شده‌است که به دلیل تطبیق‌پذیری و کارآیی‌اش در بهینه‌سازی چندهدفه شهرت دارد. PyGMO مجموعه‌ای متنوع از الگوریتم‌ها، قابلیت‌های محاسبات موازی برای افزایش کارآیی و معماری ماژولار برای سفارشی‌سازی را فراهم می‌آورد که آن را به ابزاری جامع برای مواجهه با چالش‌های بهینه‌سازی چندهدفه تبدیل می‌کند.

جدول ۸. پارامترهای مدل و روش حل

پارامتر	بازه تصادفی	پارامتر	بازه تصادفی
R	[1000, 10000]	جمعیت اولیه در NSGA-IV	[50, 150]
T	[20,100]	احتمال تقاطع در NSGA-IV	[0.4, 0.8]
CA_i	[50, 150]	احتمال جهش در NSGA-IV	[0.01, 0.1]
α_i	[0.3,0.6]	تعداد همسایگان در VNS	[3,7]
β_i	[0.3,0.6]	نرخ یادگیری در ANN	[0.8,0.9]
نرخ بهره وری در RL	[0.1, 0.2]	نرخ تخفیف در RL	[0.9, 0.95]
p_i	[50,70,100]	ε	0.001
c_i	[15, 45]	$P(s' s, a)$	[0.1,0.3]
r_i	[25,55]	γ	اندازه کوچک=0.85 اندازه متوسط=0.93 اندازه بزرگ=0.95
t_i	[10,30]	i	اندازه کوچک=۱۰ اندازه متوسط=۲۵ اندازه بزرگ=۵۰
\bar{D}_i	اندازه کوچک=(50,150,300) اندازه متوسط=(200,400,600) اندازه بزرگ=(500,750, 1000)	تعداد لایه‌ها در ANN	[3,5]


نتایج به‌دست‌آمده از بکارگیری الگوریتم ترکیبی برای حل مدل با استفاده از هر الگوریتم مجزا، در جدول (۵) خلاصه شده‌است. با الگوریتم‌های تعیین‌شده نتایج همچنین برای مقایسه آسانتر به‌صورت بصری در شکل (۳) نشان داده شده‌است. لازم به ذکر است که نتایج، مقدار نرمالیزه‌شده توابع است و زمان اعلام‌شده برحسب دقیقه می‌باشد.

جدول ۹. نتایج مثال‌های عددی

اندازه	شماره	تابع هدف	NSGA-IV	VNS	آلگوریتم ترکیبی پیشنهادی
کوچک	۱	Z_1	۰.۷۰	۰.۷۴	۰.۸۹
		Z_2	۰.۷۴	۰.۸۰	۰.۹۲
	زمان اجرای کد	۱.۴۳	۱.۳۴	۱.۱۵	
۲	Z_1	۰.۷۲	۰.۷۹	۰.۹۳	

اندازه	شماره	تابع هدف	NSGA-IV	VNS	آلگوریتم ترکیبی پیشنهادی	
متوسط	۳	Z_2	۰.۸۱	۰.۸۵	۰.۹۱	
		زمان اجرای کد	۱.۳۶	۱.۲۷	۱.۰۲	
		Z_1	۰.۷۶	۰.۸۱	۰.۹۰	
	۴	Z_2	۰.۷۹	۰.۸۹	۰.۹۴	
		زمان اجرای کد	۲.۰۲	۱.۵۴	۱.۳۳	
		Z_1	۰.۶۰	۰.۶۵	۰.۷۱	
	۵	Z_2	۰.۶۲	۰.۶۶	۰.۷۹	
		زمان اجرای کد	۱.۴۹	۱.۴۱	۱.۲۶	
		Z_1	۰.۷۱	۰.۷۵	۰.۸۳	
	بزرگ	۱	Z_2	۰.۹۰	۰.۹۰	۰.۹۴
			زمان اجرای کد	۱.۵۳	۱.۴۲	۱.۲۱
			Z_1	۰.۶۹	۰.۷۲	۰.۸۴
		۲	Z_2	۰.۷۹	۰.۸۰	۰.۹۱
			زمان اجرای کد	۲.۴۱	۲.۱۴	۲.۰۸
			Z_1	۰.۷۸	۰.۷۹	۰.۸۲
۳		Z_2	۰.۹۰	۰.۹۱	۰.۹۳	
		زمان اجرای کد	۲.۱۱	۲.۰۴	۱.۵۸	
		Z_1	۰.۶۳	۰.۷۶	۰.۸۰	
۴		Z_2	۰.۸۲	۰.۸۵	۰.۹۱	
		زمان اجرای کد	۲.۴۰	۲.۱۵	۲.۰۰	
		Z_1	۰.۷۹	۰.۸۱	۰.۸۴	
۵		Z_2	۰.۸۳	۰.۸۸	۰.۹۳	
		زمان اجرای کد	۲.۵۷	۲.۳۲	۲.۱۶	
		Z_1	۰.۶۹	۰.۷۲	۰.۸۸	
بزرگ	۱	Z_2	۰.۸۴	۰.۸۷	۰.۹۴	
		زمان اجرای کد	۲.۵۱	۲.۳۳	۲.۱۶	
		Z_1	۰.۶۸	۰.۷۱	۰.۸۵	
	۲	Z_2	۰.۷۲	۰.۷۷	۰.۸۷	
		زمان اجرای کد	۴.۰۸	۳.۵۴	۳.۲۵	
		Z_1	۰.۷۲	۰.۷۸	۰.۸۲	
	۳	Z_2	۰.۷۹	۰.۸۳	۰.۹۱	
		زمان اجرای کد	۳.۵۹	۳.۴۶	۳.۰۳	
		Z_1	۰.۷۱	۰.۷۵	۰.۸۰	
	۴	Z_2	۰.۶۸	۰.۷۰	۰.۷۷	
		زمان اجرای کد	۴.۰۲	۳.۵۱	۳.۰۱	
		Z_1	۰.۶۷	۰.۷۲	۰.۸۹	

اندازه	شماره	تابع هدف	NSGA-IV	VNS	آلگوریتم ترکیبی پیشنهادی
۵	Z ₂	زمان اجرای کد	۰.۶۲	۰.۶۹	۰.۸۱
		Z ₁	۰.۷۵	۰.۷۹	۰.۸۸
	Z ₂	۰.۷۰	۰.۷۵	۰.۸۳	
	زمان اجرای کد	۴.۱۷	۳.۴۳	۳.۳۹	
	Z ₁	۰.۷۱	۰.۷۵	۰.۸۵	
میانگین	Z ₂	زمان اجرای کد	۰.۷۷	۰.۸۱	۰.۸۹
	Z ₁	زمان اجرای کد	۲.۶۶	۲.۳۹	۲.۱۸



شکل ۳. مقایسه نتایج مثال‌های عددی

در مقایسه نتایج سه الگوریتم مختلف NSGA-IV، VNS و الگوریتم ترکیبی پیشنهادی مشاهده می‌شود که الگوریتم پیشنهادی، عملکرد بهتری در بهینه‌سازی توابع هدف دارد. میانگین نتایج برای این توابع نشان می‌دهد که الگوریتم پیشنهادی با میانگین ۰.۸۵ برای هدف اول و ۰.۸۹ برای تابع دوم به ترتیب نسبت به NSGA-IV با میانگین ۰.۷۱ و ۰.۷۷ و VNS با میانگین ۰.۷۵ و ۰.۸۱ عملکرد بهتری ارائه می‌دهد. این بهبود در نتایج توابع هدف نشان می‌دهد که الگوریتم پیشنهادی به خوبی توانسته است با ترکیب الگوریتم‌های یادگیری ماشین و بهینه‌سازی، دقت و کارایی بیشتری را در مقایسه با سایر روش‌ها فراهم آورد.

همچنین زمان اجرای کدها برای الگوریتم پیشنهادی به طور متوسط کمتر از دو الگوریتم دیگر بوده است. میانگین زمان اجرای کد برای الگوریتم پیشنهادی برابر با ۲.۱۸ دقیقه است که در مقایسه با NSGA-IV با میانگین ۲.۶۶ دقیقه و VNS با میانگین ۲.۳۹ دقیقه نشان‌دهنده کارایی بیشتر الگوریتم پیشنهادی است. این کاهش زمان اجرا در الگوریتم پیشنهادی می‌تواند بهینه‌سازی موثرتر منابع و افزایش سرعت اجرای مدل‌ها را نشان دهد که این امر در کاربردهای واقعی و زمانی که سرعت محاسبات اهمیت بالایی دارد، بسیار مفید خواهد بود.

۸-۳) معیارهای ارزیابی کیفی چندهدفه

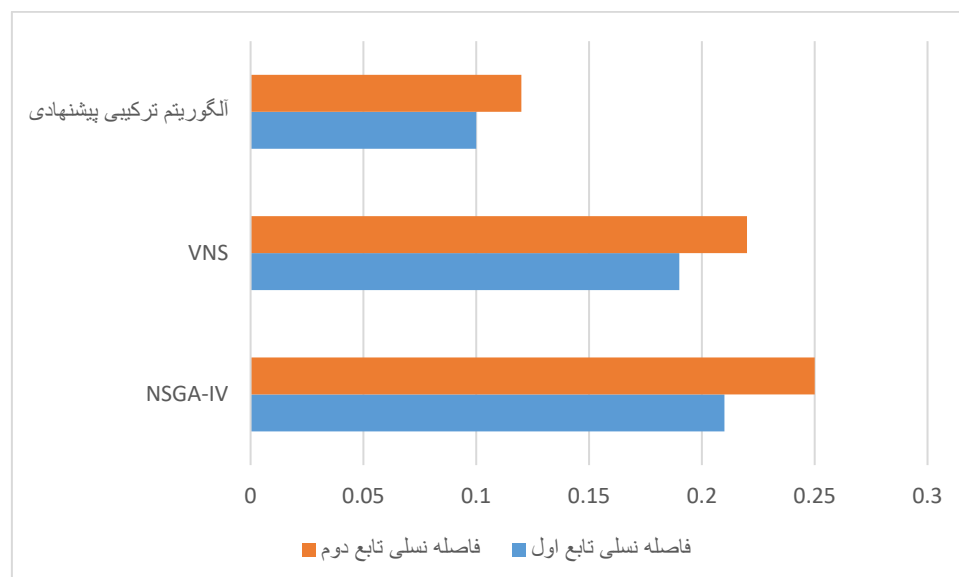
ارزیابی معیارهای چندهدفه برای بررسی الگوریتم‌های بهینه‌سازی، انتخاب الگوریتم مناسب، تنظیم دقیق پارامترها و ایجاد معیارهای استاندارد اهمیت زیادی دارد. این معیارها یک روش استاندارد شده برای ارزیابی میزان تقریب الگوریتم به جبهه واقعی پارتو ارائه می‌دهند. دانشی که از این تحلیل به دست می‌آید، به پیشرفت تحقیقات، تصمیم‌گیری آگاهانه برای محققان و کاربران، درک رفتار الگوریتم و در نهایت بهبود اثربخشی راه‌حل‌های بهینه‌سازی در محیط‌های عملی کمک می‌کند (گرگری و پورجواد، ۲۰۲۰). برای ارزیابی عملکرد الگوریتم پیشنهادی و مقایسه کارایی آن با الگوریتم‌های تک‌هدفه، استفاده از معیارهای ارزیابی چندهدفه ضروری است (نصیری و همکاران، ۲۰۲۴). این معیارها بینش‌هایی را در مورد توانایی الگوریتم برای متعادل کردن اهداف متضاد به صورت موثر ارائه می‌دهند. در این مقاله، معیارهای فاصله نسلی (GD) و نسبت خطا (ER) بررسی شده‌اند.

۸-۳-۱) فاصله نسلی (Generational Distance: GD)

فاصله نسلی به عنوان معیاری برای ارزیابی میزان نزدیکی راه‌حل‌ها در جبهه پارتوی حاصل به جبهه واقعی پارتو عمل می‌کند (کالیتا و همکاران، ۲۰۲۴). به صورت ریاضی، این معیار به صورت عبارت (۱۸) نمایش داده می‌شود:

$$GD = \sqrt{\frac{1}{|PF_{true}|} \sum_{i=1}^{|PF_{true}|} d_i^2} \quad (18)$$

در این معادله d_i ، فاصله اقلیدسی هر راه‌حل در جبهه واقعی پارتو تا نزدیک‌ترین همسایه‌اش در جبهه پارتوی حاصل را نشان می‌دهد. مقدار کمتر GD به معنای همگرایی دقیق‌تر جبهه پارتوی حاصل به جبهه واقعی پارتو است.



شکل ۴. مقایسه نتایج فاصله نسلی

براساس نتایج ارائه شده در شکل (۴)، الگوریتم پیشنهادی ترکیبی چندهدفه در مقایسه با NSGA-IV و VNS برتری واضحی از نظر معیار فاصله نسلی (GD) نشان می‌دهد. مقدارهای کمتر GD به معنای عملکرد بهتر و فاصله کمتر به جبهه


بهینه است. این برتری در عملکرد الگوریتم ترکیبی نشان‌دهنده توانایی بالای آن در تولید راه‌حل‌های نزدیک‌تر به جبهه واقعی پارتو در داده‌ها و توابع مختلف است.

۸-۳-۲) نسبت خطا (Error Ratio: ER)

نسبت خطا یک معیار عملکرد است که برای ارزیابی دقت مجموعه‌ای از تقریب‌ها که معمولاً از یک الگوریتم بهینه‌سازی چندهدفه به دست می‌آید، نسبت به جبهه پارتوی واقعی استفاده می‌شود (جیانگ و همکاران، ۲۰۲۴). رابطه ریاضی نسبت خطا به شکل عبارت (۱۹) بیان می‌شود:

$$ER = \frac{\text{Area between the true Pareto front and the approximation set}}{\text{Total area of the true Pareto front}} \quad (19)$$

در معادله ۱۹، "مساحت بین جبهه پارتوی واقعی و مجموعه تقریب" به ناحیه‌ای اشاره دارد که در آن مجموعه تقریب از جبهه پارتوی واقعی انحراف دارد. "کل مساحت جبهه پارتوی واقعی" نیز فضای کاملی را که جبهه پارتوی واقعی پوشش می‌دهد، شامل می‌شود. مقدار کمتر نسبت خطا، نشان‌دهنده تقریب دقیق‌تر است که به معنای انحراف کمتر از جبهه پارتوی واقعی است. این معیار به صورت کمی نشان می‌دهد که راه‌حل‌های تولیدشده چقدر بهینه‌سازی اهداف را نسبت به جبهه پارتوی واقعی به درستی انجام داده‌اند.



شکل ۵. مقایسه نتایج نسبت خطا

مطابق نتایج نمودار (۵) در تحلیل نتایج مربوط به نسبت خطا برای سه الگوریتم VNS، NSGA-IV و الگوریتم ترکیبی پیشنهادی، مشاهده می‌شود که الگوریتم ترکیبی پیشنهادی در هر دو تابع هدف عملکرد بهتری نسبت به دو الگوریتم دیگر دارد. برای تابع هدف اول، نسبت خطای الگوریتم ترکیبی برابر با ۰.۰۶ است که به مراتب کمتر از مقادیر ۰.۱۴ و ۰.۰۹ به دست آمده برای الگوریتم‌های NSGA-IV و VNS است. این کاهش قابل توجه در نسبت خطا نشان‌دهنده دقت بیشتر الگوریتم ترکیبی در تقریب جبهه پارتوی واقعی است. همچنین در تابع هدف دوم، الگوریتم ترکیبی با نسبت خطای

۰.۰۳ بهترین عملکرد را نشان می‌دهد در حالیکه NSGA-IV و VNS به ترتیب نسبت‌های خطای ۰.۱۸ و ۰.۱۲ را به دست آورده‌اند. این نتایج به وضوح نشان می‌دهد که ترکیب الگوریتم‌ها منجر به بهبود دقت و کارایی در حل مسائل چندهدفه شده و توانسته‌است تقریب بهتری از جبهه پارتوی واقعی ارائه دهد.

بطور کلی، با توجه به نتایج به دست آمده از دو معیار نسبت خطا (ER) و فاصله نسلی (GD)، مشخص است که الگوریتم ترکیبی پیشنهادی در حل مسائل چندهدفه عملکرد برتری نسبت به الگوریتم‌های NSGA-IV و VNS دارد. مقادیر پایین‌تر ER و GD برای هر دو تابع هدف نشان‌دهنده دقت بیشتر الگوریتم ترکیبی در تقریب جبهه پارتوی واقعی و نزدیکی بیشتر نتایج حاصل به پاسخ‌های بهینه است. این بهبودها نشان می‌دهد که الگوریتم ترکیبی پیشنهادی توانسته‌است از نقاط قوت هر دو الگوریتم NSGA-IV و VNS بهره‌برداری کرده و نتایج دقیق‌تری را در مقایسه با الگوریتم‌های منفرد ارائه دهد. بنابراین می‌توان نتیجه‌گیری کرد که الگوریتم ارائه‌شده، ابزار مناسبی برای بهینه‌سازی چندهدفه است و توانسته‌است با دقت و کارایی بالاتر، عملکرد بهتری را نسبت به روش‌های موجود ارائه کند.


۸-۴ تجزیه و تحلیل حساسیت

در این بخش، به تحلیل حساسیت مدل و الگوریتم ارائه‌شده، پرداخته شده‌است. هدف از این تحلیل، بررسی عملکرد مدل و الگوریتم در شرایط مختلف و ارزیابی تاثیر تغییرات پارامترهای کلیدی بر نتایج به دست آمده است. این فرآیند به منظور اطمینان از پایداری و قابلیت اعتماد مدل و همچنین شناسایی نقاطی که نیاز به بهبود دارند، انجام می‌شود. تحلیل حساسیت می‌تواند به تصمیم‌گیرندگان کمک کند تا در شرایط ناپایدار یا تغییرات محیطی، تصمیمات بهتری اتخاذ کنند و بهبودهای لازم را در مدل و الگوریتم اعمال نمایند (موست و ویل، ۲۰۲۴). در این تحقیق، با آنالیز حساسیت روی مقادیر پارامترهای زمان تولید، مقدار منابع مصرفی و نرخ یادگیری ANN، به بررسی و آنالیز مدل و راه‌حل ارائه‌شده پرداخته شده‌است.

۸-۴-۱ تحلیل حساسیت طبق تغییرات پارامتر زمان تولید

در این تحلیل، انتظار می‌رفت که با تغییر زمان تولید (چه کاهش و چه افزایش)، عملکرد الگوریتم‌ها در بهینه‌سازی توابع هدف دستخوش تغییر شود. بطور خاص انتظار می‌رفت که کاهش زمان تولید، به دلیل فشار زمانی کمتر بر روی سیستم، باعث بهبود عملکرد الگوریتم‌ها شود و افزایش زمان تولید نیز به دلیل افزایش هزینه‌های زمانی، عملکرد را کاهش دهد. نتایج به دست آمده از تحلیل حساسیت، طبق شکل (۶) نشان می‌دهد که این انتظارات تا حد زیادی محقق شده‌اند. در شرایط کاهش ۱۰ درصدی زمان تولید، الگوریتم ترکیبی پیشنهادی توانسته بهترین عملکرد را در هر دو تابع هدف نشان دهد. به‌ویژه در تابع هدف دوم که نشان‌دهنده کاهش هزینه‌ها و افزایش سود است، این الگوریتم با کسب امتیاز ۰.۹۶ نشان‌دهنده توانایی خود در بهینه‌سازی شرایط با زمان تولید کمتر بوده‌است. این نتیجه مطابق انتظار است چراکه کاهش زمان تولید می‌تواند به بهره‌وری بیشتر و کاهش هزینه‌ها منجر شود و در نهایت منجر به افزایش سود می‌گردد. از سوی دیگر، افزایش ۱۰ درصدی زمان تولید نیز به نتایج مورد انتظار منجر شده‌است. در این شرایط، الگوریتم ترکیبی پیشنهادی همچنان عملکرد بهتری نسبت به دو الگوریتم دیگر دارد اما امتیازات آن در هر دو تابع هدف کاهش یافته‌اند. این کاهش در نتایج نشان می‌دهد که با افزایش زمان تولید، هزینه‌ها افزایش یافته و سود نهایی کاهش پیدا کرده‌است. به عبارت دیگر، افزایش زمان

تولید منجر به افزایش هزینه‌های عملیاتی شده و عملکرد بهینه‌سازی را تحت تاثیر قرار داده‌است. بطور کلی، این تحلیل حساسیت نشان می‌دهد که مدل پیشنهادی توانسته به خوبی با تغییرات زمان تولید سازگار شود و به نتایج قابل انتظار دست یابد. الگوریتم ترکیبی پیشنهادی در هر دو شرایط کاهش و افزایش زمان تولید، عملکرد بهتری نسبت به الگوریتم‌های NSGA-IV و VNS داشته‌است که نشان‌دهنده پایداری و انعطاف‌پذیری بالای آن در مواجهه با تغییرات زمانی است.



شکل ۶. تحلیل حساسیت بر اساس تغییرات زمان تولید محصولات

۸-۴-۲) تحلیل حساسیت طبق تغییرات منابع مصرفی

در تحلیل حساسیت مرتبط با تغییرات منابع مصرفی، انتظار می‌رفت که تغییرات در دسترسی به منابع مصرفی (چه کاهش و چه افزایش) به طور قابل توجهی بر عملکرد الگوریتم‌ها تاثیر بگذارد. علی‌الخصوص کاهش منابع مصرفی می‌تواند محدودیت‌هایی را بر بهینه‌سازی تحمیل کند و افزایش منابع مصرفی، دسترسی به فرصت‌های بیشتری برای بهینه‌سازی را فراهم نماید.


نتایج تحلیل مطابق شکل (۷) نشان می‌دهد که با کاهش ۱۰ درصدی منابع مصرفی، عملکرد الگوریتم‌ها تحت تاثیر قرار گرفته‌است. الگوریتم ترکیبی پیشنهادی در هر دو تابع هدف عملکرد بهتری نسبت به دو الگوریتم دیگر داشته‌است ولی امتیازات کسب‌شده در هر دو تابع هدف کاهش یافته‌اند. به‌ویژه در تابع هدف اول (که شامل ماکزیمم‌سازی سود است)، الگوریتم ترکیبی امتیاز ۰.۸ را کسب کرده که نسبت به حالت بدون تغییر (۰.۸۹) کاهش داشته‌است. این نتایج مطابق با انتظار است زیرا کاهش منابع مصرفی منجر به افزایش محدودیت‌ها و کاهش توانایی در بهینه‌سازی شده‌است. از سوی دیگر، افزایش ۱۰ درصدی منابع مصرفی باعث بهبود عملکرد الگوریتم‌ها شده‌است. در این شرایط، الگوریتم ترکیبی پیشنهادی بهترین عملکرد را در هر دو تابع هدف نشان داده‌است. این الگوریتم در تابع هدف اول به امتیاز ۰.۹۲ و

در تابع هدف دوم به امتیاز ۰.۹۱ دست یافته‌است که نشان‌دهنده استفاده موثرتر از منابع اضافی برای بهبود سود و کاهش هزینه‌هاست. این نتایج نیز مطابق انتظار است زیرا افزایش منابع مصرفی فرصت‌های بیشتری برای بهینه‌سازی فراهم می‌کند و در نهایت به نتایج بهتری منجر می‌شود.

بطور کلی نتایج این تحلیل حساسیت نشان می‌دهد که مدل پیشنهادی با تغییرات منابع مصرفی سازگار است و می‌تواند با تغییرات مختلف در دسترسی به منابع، به نتایج قابل قبولی دست یابد. الگوریتم ترکیبی پیشنهادی در هر دو شرایط کاهش و افزایش منابع مصرفی، عملکرد بهتری نسبت به الگوریتم‌های NSGA-IV و VNS نشان داده‌است که نشان‌دهنده انعطاف‌پذیری و کارایی بالای آن در مواجهه با تغییرات منابع مصرفی است.

البته افزایش منابع مصرفی می‌تواند دو روی سکه باشد: از یک سو، ممکن است به افزایش کارایی، کاهش زمان تولید و بهبود کیفیت محصول منجر شود اما از سوی دیگر؛ اگر این افزایش منابع به صورت غیرمدیریت‌شده انجام شود، می‌تواند به اسراف و هدررفت منابع نیز بیانجامد. در تحلیل حساسیت، باید به این نکته توجه کرد که هرچند افزایش منابع می‌تواند نتایج مثبتی داشته باشد اما بدون مدیریت صحیح، می‌تواند هزینه‌های غیرضروری را افزایش دهد و بهینه‌سازی کلی سیستم را تحت‌الشعاع قرار دهد.

این مسئله اهمیت مدیریت منابع را برجسته می‌کند زیرا هرگونه افزایش در منابع مصرفی باید به‌طور دقیق مدیریت شود تا از هدررفتن آنها جلوگیری شود و همچنین اطمینان حاصل گردد که سیستم به شکل بهینه و کارآمد عمل می‌کند. این امر به‌ویژه در مواردیکه منابع محدود هستند یا هزینه‌های آنها بالاست، از اهمیت بیشتری برخوردار می‌شود. بنابراین تحلیل حساسیت نه تنها به شناسایی تاثیرات مثبت افزایش منابع کمک می‌کند بلکه بر ضرورت مدیریت دقیق آنها برای جلوگیری از عواقب منفی نیز تاکید دارد.




شکل ۷. تحلیل حساسیت براساس تغییرات منابع مصرفی

۸-۴-۳) تحلیل حساسیت طبق تغییرات نرخ یادگیری ANN

در این بخش، تحلیل حساسیت براساس تغییرات نرخ یادگیری در شبکه‌های عصبی مصنوعی (ANN) انجام می‌شود. نرخ یادگیری که به‌عنوان یکی از پارامترهای کلیدی در آموزش شبکه‌های عصبی شناخته می‌شود، تاثیر مستقیم و قابل توجهی بر عملکرد و کارایی مدل‌های ANN دارد. هدف از این تحلیل، بررسی تاثیرات مختلف نرخ یادگیری بر دقت پیش‌بینی و قابلیت تعمیم مدل است. نرخ یادگیری که معمولاً به‌عنوان یک پارامتر ثابت در طول فرآیند آموزش استفاده می‌شود، سرعت به‌روزرسانی وزن‌های شبکه را تعیین می‌کند. تغییرات در نرخ یادگیری می‌تواند تاثیرات مختلفی بر روی آموزش و عملکرد مدل داشته باشد. برای این منظور، نرخ یادگیری در مقادیر مختلف انتخاب و آزمایش شد تا تاثیرات آن بر معیارهای عملکرد مدل تحلیل گردد. تحلیل حساسیت براساس تغییرات پارامتر نرخ یادگیری در شبکه‌های عصبی مصنوعی (ANN) نشان می‌دهد که تغییرات نرخ یادگیری (چه کاهش و چه افزایش) به‌طور محسوسی بر عملکرد الگوریتم‌ها در بهینه‌سازی توابع هدف تاثیر گذاشته‌است. به‌ویژه انتظار می‌رفت که کاهش نرخ یادگیری، به‌دلیل فراهم کردن زمان بیشتری برای تنظیم وزن‌ها، به بهبود عملکرد الگوریتم‌ها منجر شود درحالی‌که افزایش نرخ یادگیری، به‌دلیل سرعت بالاتر در همگرایی، می‌توانست منجر به کاهش دقت شود. نتایج به‌دست آمده از تحلیل حساسیت، مطابق با شکل (۸) نشان می‌دهد که این انتظارات بطور کلی محقق شده‌اند. در شرایط کاهش نرخ یادگیری، "الگوریتم ترکیبی پیشنهادی" بهترین عملکرد را در هر دو تابع هدف نشان داده‌است. به‌ویژه در تابع هدف دوم که به بهینه‌سازی هزینه‌ها و افزایش سود مربوط است، این الگوریتم با کسب امتیاز حدود ۰.۸، توانایی خود را در سازگاری با نرخ یادگیری کمتر به نمایش گذاشته‌است. این نتیجه مطابق با انتظار است زیرا کاهش نرخ یادگیری باعث می‌شود که شبکه عصبی فرصت بیشتری برای بهینه‌سازی دقیق وزن‌ها داشته باشد که این موضوع به بهبود نتایج نهایی منجر می‌شود. ازسوی دیگر؛ افزایش نرخ یادگیری نیز به نتایج موردانتظار منجر شده‌است. در این شرایط، "الگوریتم ترکیبی پیشنهادی" همچنان عملکرد بهتری نسبت به دو الگوریتم دیگر دارد اما امتیازات آن در هر دو تابع هدف کاهش یافته‌اند. این کاهش در نتایج نشان می‌دهد که افزایش نرخ یادگیری، به‌دلیل سرعت بالاتر در تنظیم وزن‌ها، ممکن است منجر به همگرایی زودرس و افت عملکرد نهایی شود.

بطور کلی این تحلیل حساسیت نشان می‌دهد که "الگوریتم ترکیبی پیشنهادی" توانسته به‌خوبی با تغییرات نرخ یادگیری سازگار شود و به نتایج قابل‌انتظار دست یابد. این الگوریتم در هر دو شرایط کاهش و افزایش نرخ یادگیری، عملکرد بهتری نسبت به الگوریتم‌های "NSGA-IV" و "VNS" داشته‌است که نشان‌دهنده پایداری و انعطاف‌پذیری بالای آن در مواجهه با تغییرات نرخ یادگیری است.



شکل ۸. تحلیل حساسیت براساس تغییرات نرخ یادگیری ANN

۹) مفاهیم و اهمیت مدیریتی

یافته‌های این پژوهش از اهمیت استراتژیک و عملیاتی بالایی برای مدیران و تصمیم‌گیران سازمانی برخوردار است. این تحقیق با تاکید بر کارآمدی مدل‌های بهینه‌سازی به‌ویژه الگوریتم ترکیبی پیشنهادی، نشان می‌دهد که این رویکرد می‌تواند به‌عنوان ابزاری موثر در مدیریت بهینه منابع و زمان در سازمان‌ها مورد استفاده قرار گیرد. در محیط‌های کسب‌وکار کنونی که با محدودیت منابع و فشارهای مداوم برای افزایش بهره‌وری مواجه هستند، نتایج پژوهش حاکی از آن است که الگوریتم ترکیبی پیشنهادی به‌طور قابل توجهی عملکرد بهتری نسبت به سایر الگوریتم‌ها در شرایط متغیر زمانی و تغییرات منابع مصرفی ارائه می‌دهد.

این موضوع برای مدیران به معنای این است که الگوریتم ترکیبی پیشنهادی می‌تواند به‌عنوان یک ابزار راهبردی در فرآیندهای تصمیم‌گیری و بهینه‌سازی تولید بکار گرفته شود. به‌ویژه در شرایطی که سازمان‌ها با تغییرات ناگهانی در زمان تولید یا مصرف منابع مواجه می‌شوند، استفاده از این الگوریتم به آنها امکان می‌دهد تا با انعطاف‌پذیری بیشتری به این تغییرات پاسخ دهند و پایداری عملیاتی خود را حفظ کنند. نتایج این تحقیق می‌تواند به مدیران کمک کند تا راهبردهایی را توسعه دهند که با استفاده از این الگوریتم، توانایی سازمان را در مواجهه با تغییرات غیرمنتظره افزایش داده و بهره‌وری را به حداکثر برسانند.

در نهایت این پژوهش به مدیران نشان می‌دهد که مدل‌های بهینه‌سازی به‌ویژه الگوریتم‌های ترکیبی، چگونه می‌توانند به تصمیم‌گیری‌های بهینه‌تر و ارتقای عملکرد کلی سازمان منجر شوند. اهمیت این موضوع در محیط‌های کسب‌وکار پیچیده و پویا بیش از پیش نمایان است، زیرا سسازمان‌ها نیاز دارند تا با بکارگیری ابزارهای پیشرفته و کارآمد، به‌سرعت به تغییرات پاسخ دهند و در عین حال به اهداف استراتژیک خود دست یابند. بهره‌گیری از چنین مدل‌هایی می‌تواند نقش کلیدی در ارتقای توان رقابتی و پایداری بلندمدت سازمان‌ها ایفا کند.

۱۰) نتیجه‌گیری

در این تحقیق، مدل بهینه‌سازی چندهدفه غیرخطی با تمرکز بر افزایش سود و رضایت مشتری و همچنین معرفی محدودیت‌های غیرخطی برای منابع و زمان، به‌طور جامع و دقیقی به نیازهای واقعی و پیچیده سیستم‌های تولیدی پاسخ داده‌است. مدل ارائه‌شده با در نظر گرفتن هزینه‌ها و نیازهای منابع و تحلیل دقیق شرایط عملیاتی، قادر به ارائه راه‌حل‌های بهینه و موثر برای مدیران بوده‌است. به‌ویژه استفاده از منطق فازی برای مدیریت عدم قطعیت‌ها در تقاضا و ترکیب این رویکرد با الگوریتم‌های یادگیری ماشین مانند شبکه‌های عصبی و یادگیری تقویتی منجر به توسعه مدلی هوشمند و قابل انعطاف شده‌است که توانایی واکنش سریع به تغییرات ناگهانی در محیط‌های پویا را دارد. این ویژگی‌ها به مدل کمک کرده‌اند تا با شرایط متغیر و پیش‌بینی‌ناپذیر سازگار شود و عملکرد بهینه‌تری را در مواجهه با عدم قطعیت‌ها از خود نشان دهد. به‌علاوه نرمالیزه کردن پارامترها و توابع هدف به‌عنوان یکی از مراحل کلیدی فرآیند بهینه‌سازی، دقت و امکان مقایسه عادلانه نتایج را افزایش داده‌است و به ارائه نتایج منسجم و قابل اعتماد کمک کرده‌است. ترکیب الگوریتم‌های NSGA-IV و VSN در چارچوبی ترکیبی، با بهره‌گیری از قابلیت‌های یادگیری ماشین و منطق فازی، رویکردی پیشرفته و چندوجهی برای حل مسائل پیچیده بهینه‌سازی چندهدفه فراهم آورد. این ترکیب، با استفاده از توانمندی‌های هر دو الگوریتم و بهره‌برداری از قابلیت‌های یادگیری ماشین و منطق فازی، نتایج پارتنو-بهینه‌ای را به دست داد که نشان‌دهنده عملکرد بهینه و کارآمد مدل پیشنهادی است. نتایج تحقیق حاضر بر اهمیت خاصیت انطباق‌پذیری و دقت مدل در شرایط پویا و نامطمئن تاکید دارد و می‌تواند به‌عنوان راهنمای عملی ارزشمندی برای مدیران و تصمیم‌گیران در بهینه‌سازی تولید و افزایش رضایت مشتری در چنین شرایطی مورد استفاده قرار گیرد. این مدل به‌ویژه در موقعیت‌هایی که منابع محدود یا هزینه‌های بالایی دارند، توانایی شناسایی و مدیریت دقیق منابع و کاهش هدررفت آنها را فراهم می‌آورد که از مهمترین دستاوردهای این تحقیق است.

۱۰-۱) محدودیت‌ها و تحقیقات آتی

هرچند مدل بهینه‌سازی چندهدفه‌ای که در این تحقیق ارائه شد، دستاوردهای قابل توجهی در بهینه‌سازی تولید و افزایش رضایت مشتری به‌همراه داشته است اما محدودیت‌هایی نیز وجود دارد که باید در نظر گرفته شوند.

محدودیت‌ها

پیچیدگی محاسباتی: استفاده از الگوریتم‌های پیچیده مانند NSGA-IV و VSN به‌همراه روش‌های یادگیری ماشین و منطق فازی ممکن است منجر به پیچیدگی محاسباتی بالایی شود. این مسئله ممکن است در مقیاس‌های بزرگتر یا در محیط‌های با داده‌های بسیار زیاد، زمان و منابع قابل توجهی را طلب کند.

مدل‌سازی دقیق تقاضا: اگرچه منطق فازی به مدیریت عدم قطعیت‌ها کمک می‌کند اما دقت مدل‌سازی تقاضا همچنان بستگی به کیفیت داده‌های ورودی دارد. در شرایطی که داده‌های ورودی دارای نویز یا کمبود اطلاعات باشند، عملکرد مدل ممکن است تحت تاثیر قرار گیرد.

تعمیم‌پذیری مدل: مدل پیشنهادی ممکن است بطور خاص برای شرایط و ویژگی‌های سیستم‌های تولیدی مورد مطالعه، طراحی شده باشد. تعمیم‌پذیری این مدل به سایر صنایع یا محیط‌های تولیدی با ویژگی‌های متفاوت ممکن است نیاز به تنظیمات و تعدیلات خاصی داشته باشد.

تحقیقات آتی

(۱) بهبود الگوریتم‌ها و روش‌ها: تحقیقات آینده می‌تواند بر روی بهینه‌سازی و بهبود الگوریتم‌های NSGA-IV و VSN تمرکز کند علی‌الخصوص با هدف کاهش پیچیدگی محاسباتی و افزایش کارایی در مقیاس‌های بزرگتر. همچنین توسعه و ادغام روش‌های جدید یادگیری ماشین و منطق فازی می‌تواند به بهبود دقت و عملکرد مدل کمک کند.

(۲) پیشرفت در داده‌کاوی و جمع‌آوری داده: تحقیقات آتی می‌تواند بر روی بهبود تکنیک‌های جمع‌آوری و پردازش داده تمرکز کند تا دقت پیش‌بینی و مدل‌سازی تقاضا را افزایش دهد. استفاده از تکنیک‌های نوین داده‌کاوی و تحلیل داده‌های بزرگ می‌تواند به بهبود عملکرد مدل کمک کند.

(۳) بررسی تعمیم‌پذیری مدل: بررسی و آزمایش مدل پیشنهادی در صنایع و محیط‌های تولیدی مختلف می‌تواند به ارزیابی قابلیت تعمیم‌پذیری آن کمک کند. این تحقیقات می‌تواند شامل آزمایش مدل در شرایط واقعی و متغیر باشد تا قابلیت انطباق و عملکرد آن در زمینه‌های مختلف ارزیابی شود.

(۴) توسعه ابزارهای تصمیم‌گیری تعاملی: ایجاد و توسعه ابزارهای تصمیم‌گیری تعاملی مبتنی بر مدل‌های بهینه‌سازی و یادگیری ماشین می‌تواند به مدیران و تصمیم‌گیران در استفاده بهینه از مدل‌های پیچیده کمک کند و فرآیندهای تصمیم‌گیری را بهبود بخشد.

با توجه به این محدودیت‌ها و فرصت‌های تحقیقاتی، مطالعات آینده می‌توانند به توسعه و ارتقای مدل‌های بهینه‌سازی و کاربردهای آن در زمینه‌های مختلف تولید و مدیریت منابع کمک کنند.

منابع

- Abdallah, M., Hamdan, S., & Shabib, A. (2021). A multi-objective optimization model for strategic waste management master plans. *Journal of Cleaner Production*, 284, 124714. <https://doi.org/10.1016/j.jclepro.2020.124714>
- Afzal, S., Shokri, A., Ziapour, B. M., Shakibi, H., & Sobhani, B. (2024). Building energy consumption prediction and optimization using different neural network-assisted models; comparison of different networks and optimization algorithms. *Engineering Applications of Artificial Intelligence*, 127, 107356. <https://doi.org/10.1016/j.engappai.2023.107356>
- Ala, A., Goli, A., Mirjalili, S., & Simic, V. (2024). A fuzzy multi-objective optimization model for sustainable healthcare supply chain network design. *Applied Soft Computing*, 150, 111012. <https://doi.org/10.1016/j.asoc.2023.111012>
- Alinezhad, M., Mahdavi, I., Hematian, M., & Tirkolaee, E. B. (2022). A fuzzy multi-objective optimization model for sustainable closed-loop supply chain network design in food industries. *Environment, Development and Sustainability*, 1-28. <https://doi.org/10.1007/s10668-021-01809-y>
- Ardanta, M. A., Fauzi, A., Patimah, P., Khadijah, F., Sihombing, Y. T., Hasan, F. S., & Rahmawati, D. (2024). Optimization of Business Decision Accuracy through the Application of Mathematical Economics. *International Journal of Advanced Multidisciplinary*, 2(4), 866-885. <https://doi.org/10.38035/ijam.v2i4.447>
- Azevedo, B. F., Rocha, A. M. A., & Pereira, A. I. (2024). Hybrid approaches to optimization and machine learning methods: a systematic literature review. *Machine Learning*, 1-43. <https://doi.org/10.1007/s10994-023-06467-x>
- Behera, I., & Sobhanayak, S. (2024). Task scheduling optimization in heterogeneous cloud computing environments: A hybrid GA-GWO approach. *Journal of Parallel and Distributed Computing*, 183, 104766. <https://doi.org/10.1016/j.jpdc.2023.104766>

- Chen, L., Fan, H., & Zhu, H. (2024). Multi-objective optimization of cancer treatment using the multi-objective gray wolf optimizer (MOGWO). *Multiscale and Multidisciplinary Modeling, Experiments and Design*, 7(3), 1857-1866. <https://doi.org/10.1007/s41939-023-00307-0>
- Duan, F., Eslami, M., Khajehzadeh, M., Basem, A., Jasim, D. J., & Palani, S. (2024). Optimization of a photovoltaic/wind/battery energy-based microgrid in distribution network using machine learning and fuzzy multi-objective improved Kepler optimizer algorithms. *Scientific Reports*, 14(1), 13354. <https://doi.org/10.1038/s41598-024-64234-x>
- Elfatih, N. M., Ali, E. S., & Saeed, R. A. (2023). Navigation and Trajectory Planning Techniques for Unmanned Aerial Vehicles Swarm. In *Artificial Intelligence for Robotics and Autonomous Systems Applications* (pp. 369-404). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-031-28715-2_12.
- Gargari, F. J., & Pourjavad, E. (2020, December). Supplier Selection and Order Allocation Under Disruption: Multi-Objective Evolutionary Algorithms. In *2020 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)*, 868-872. IEEE. [10.1109/IEEM45057.2020.9309949](https://doi.org/10.1109/IEEM45057.2020.9309949)
- Guo, Z., & Wang, H. (2023). Implications on managing inventory systems for products with stock-dependent demand and nonlinear holding cost via the adaptive EOQ policy. *Computers & Operations Research*, 150, 106080. <https://doi.org/10.1016/j.cor.2022.106080>
- Hong, Y., Linton, O., McCabe, B., Sun, J., & Wang, S. (2024). Kolmogorov–Smirnov type testing for structural breaks: A new adjusted-range based self-normalization approach. *Journal of Econometrics*, 238(2), 105603. <https://doi.org/10.1016/j.jeconom.2023.105603>
- Huang, L., Qin, J., Zhou, Y., Zhu, F., Liu, L., & Shao, L. (2023). Normalization techniques in training dnns: Methodology, analysis and application. *IEEE transactions on pattern analysis and machine intelligence*, 45(8), 10173-10196. [10.1109/TPAMI.2023.3250241](https://doi.org/10.1109/TPAMI.2023.3250241)
- Javadi Gargari, F., Saeidi-Mobarakeh, Z., & Amoozad Khalili, H. (2024). A Multi-objective Leagile Demand-Driven Optimization Model incorporating a Reliable Omnichannel Retailer: A Case Study. *Journal of Industrial Engineering International*, 2(2). <https://sanad.iau.ir/Journal/jiei/Article/1105240>
- Ifaei, P., Nazari-Heris, M., Charmchi, A. S. T., Asadi, S., & Yoo, C. (2023). Sustainable energies and machine learning: An organized review of recent applications and challenges. *Energy*, 266, 126432. <https://doi.org/10.1016/j.energy.2022.126432>
- Javadi Gargari, F., Sayad, M., Posht Mashhadi, S. A., Sadriani, A., Nedjati, A., & Yousefi Golafshani, T. (2021). Five-Echelon Multiobjective Health Services Supply Chain Modeling under Disruption. *Mathematical Problems in Engineering*, 2021(1), 5587392. <https://doi.org/10.1155/2021/5587392>
- Javadi Gargari, F., & Seifbarghy, M. (2020). Solving multi-objective supplier selection and quota allocation problem under disruption using a scenario-based approach. *Engineering Review: Međunarodni časopis namijenjen publiciranju originalnih istraživanja s aspekta analize konstrukcija, materijala i novih tehnologija u području strojarstva, brodogradnje, temeljnih tehničkih znanosti, elektrotehnike, računarstva i građevinarstva*, 40(3), 78-89. <https://doi.org/10.30765/er.40.3.08>
- Jiang, C., Xie, J., & Ye, T. (2024). Network structure guided multi-objective optimization approach for key entity identification. *Applied Soft Computing*, 151, 111115. <https://doi.org/10.1016/j.asoc.2023.111115>
- Kalita, K., Ramesh, J. V. N., Cepova, L., Pandya, S. B., Jangir, P., & Abualigah, L. (2024). Multi-objective exponential distribution optimizer (MOEDO): a novel math-inspired multi-objective algorithm for global optimization and real-world engineering design problems. *Scientific reports*, 14(1), 1816. <https://doi.org/10.1038/s41598-024-52083-7>
- Kaliyaperumal, P., & Das, A. (2022). A mathematical model for nonlinear optimization which attempts membership functions to address the uncertainties. *Mathematics*, 10(10), 1743. <https://doi.org/10.3390/math10101743>
- Khalili-Fard, A., Parsaee, S., Bakhshi, A., Yazdani, M., Aghsami, A., & Rabbani, M. (2024). Multi-objective optimization of closed-loop supply chains to achieve sustainable development goals in uncertain environments. *Engineering Applications of Artificial Intelligence*, 133, 108052. <https://doi.org/10.1016/j.engappai.2024.108052>
- Khan, A. S. (2022). Problem-Specific Heuristics for Diagnosability and Inventory Analysis in a Reconfigurable Manufacturing System. *IEEE Access*, 10, 70032-70052. [10.1109/ACCESS.2022.3187812](https://doi.org/10.1109/ACCESS.2022.3187812)
- Kristian, A., Goh, T. S., Ramadan, A., Erica, A., & Sihotang, S. V. (2024). Application of ai in optimizing energy and resource management: Effectiveness of deep learning models. *International Transactions on Artificial Intelligence*, 2(2), 99-105. <https://doi.org/10.33050/italic.v2i2.530>
- Kushartanto, A. I. (2024, February). Comparative Analysis Various Membership Functions Based on Neural Networks for Prediction of Students Graduation. In *2024 2nd International Conference on Software Engineering and Information Technology (ICoSEIT)* (pp. 299-304). IEEE. [10.1109/ICoSEIT60086.2024.10497491](https://doi.org/10.1109/ICoSEIT60086.2024.10497491)
- Li, P., Xu, T., Wei, S., & Wang, Z. H. (2022). Multi-objective optimization of urban environmental system design using machine learning. *Computers, Environment and Urban Systems*, 94, 101796. <https://doi.org/10.1016/j.compenvurbysys.2022.101796>
- Li, X., Wang, Z., Yang, C., & Bozkurt, A. (2024). An advanced framework for net electricity consumption prediction: Incorporating novel machine learning models and optimization algorithms. *Energy*, 296, 131259. <https://doi.org/10.1016/j.energy.2024.131259>

- Lorente-Leyva, L. L., Alemany, M. M. E., & Peluffo-Ordóñez, D. H. (2024). A conceptual framework for the operations planning of the textile supply chains: Insights for sustainable and smart planning in uncertain and dynamic contexts. *Computers & Industrial Engineering*, 187, 109824. <https://doi.org/10.1016/j.cie.2023.109824>
- Lorenz, R., Kraus, M., Wolf, H., Feuerriegel, S., & Netland, T. H. (2024). Selecting advanced analytics in manufacturing: a decision support model. *Production Planning & Control*, 35(7), 711-724. <https://doi.org/10.1080/09537287.2022.2126951>
- Most, T., & Will, J. (2024). Sensitivity analysis using the Metamodel of Optimal Prognosis. *arXiv preprint arXiv:2408.03590*. <https://doi.org/10.48550/arXiv.2408.03590>
- Mu'azu, M. A. (2023). Hybridized artificial neural network with metaheuristic algorithms for bearing capacity prediction. *Ain Shams Engineering Journal*, 14(5), 101980. <https://doi.org/10.1016/j.asej.2022.101980>
- Nadeem, A., Rizvi, A. A., & Noor, M. Y. (2024). Applying a Higher Number of Output Membership Functions to Enhance the Precision of a Fuzzy System. *IEEE Transactions on Emerging Topics in Computational Intelligence*. [10.1109/TETCI.2024.3425309](https://doi.org/10.1109/TETCI.2024.3425309)
- Narang, D., Madaan, J., Chan, F. T., & Chungcharoen, E. (2024). Managing open loop water resource value chain through IoT focused decision and information integration (DII) modelling using fuzzy MCDM approach. *Journal of Environmental Management*, 350, 119609. <https://doi.org/10.1016/j.jenvman.2023.119609>
- Nili, M., Seyedhosseini, S. M., Jabalameli, M. S., & Dehghani, E. (2021). A multi-objective optimization model to sustainable closed-loop solar photovoltaic supply chain network design: A case study in Iran. *Renewable and sustainable energy reviews*, 150, 111428. <https://doi.org/10.1016/j.rser.2021.111428>
- Nixon, M. P., Gloor, G. B., & Silverman, J. D. (2024). Beyond Normalization: Incorporating Scale Uncertainty in Microbiome and Gene Expression Analysis. *Biorxiv*. <https://doi.org/10.1101/2024.04.01.587602>
- Parhi, S. K., & Panigrahi, S. K. (2024). Alkali-silica reaction expansion prediction in concrete using hybrid metaheuristic optimized machine learning algorithms. *Asian Journal of Civil Engineering*, 25(1), 1091-1113. <https://doi.org/10.1007/s42107-023-00799-8>
- Pasupuleti, V., Thuraka, B., Kodete, C. S., & Malisetty, S. (2024). Enhancing supply chain agility and sustainability through machine learning: Optimization techniques for logistics and inventory management. *Logistics*, 8(3), 73. <https://doi.org/10.3390/logistics8030073>
- Pokushko, M., Stupina, A., Medina-Bulo, I., Ezhemanskaya, S., Kuzmich, R., & Pokushko, R. (2023). Algorithm for Application of a Basic Model for the Data Envelopment Analysis Method in Technical Systems. *Algorithms*, 16(10), 460. <https://doi.org/10.3390/a16100460>
- Rajwar, K., Deep, K., & Das, S. (2023). An exhaustive review of the metaheuristic algorithms for search and optimization: taxonomy, applications, and open challenges. *Artificial Intelligence Review*, 56(11), 13187-13257. <https://doi.org/10.1007/s10462-023-10470-y>
- Rashed, N. A., Ali, Y. H., Rashid, T. A., & Salih, A. (2024). Unraveling the Versatility and Impact of Multi-Objective Optimization: Algorithms, Applications, and Trends for Solving Complex Real-World Problems. *arXiv preprint arXiv:2407.08754*. <https://doi.org/10.48550/arXiv.2407.08754>
- Saha, C., Jana, D. K., & Duary, A. (2023). Enhancing production inventory management for imperfect items using fuzzy optimization strategies and Differential Evolution (DE) algorithms. *Franklin Open*, 5, 100051. <https://doi.org/10.1016/j.fraope.2023.100051>
- Sharma, V., Raj, A., & Chakraborty, A. (2023). Analysis of power dynamics in sustainable supply chain under non-linear demand setup. *Operations Management Research*, 16(1), 18-32. <https://doi.org/10.1007/s12063-022-00268-6>
- Song, Y., Wu, Y., Guo, Y., Yan, R., Suganthan, P. N., Zhang, Y., ... & Feng, Q. (2024). Reinforcement learning-assisted evolutionary algorithm: A survey and research opportunities. *Swarm and Evolutionary Computation*, 86, 101517. <https://doi.org/10.1016/j.swevo.2024.101517>
- Sotelo-Salas, C., Monardes-Concha, C. A., Pérez-Galarce, F., & Santa González, R. (2024). A multi-objective optimization model for planning emergency shelters after a tsunami. *Socio-Economic Planning Sciences*, 93, 101909. <https://doi.org/10.1016/j.seps.2024.101909>
- Tang, C., & Tomlin, B. (2008). The power of flexibility for mitigating supply chain risks. *International journal of production economics*, 116(1), 12-27. <https://doi.org/10.1016/j.ijpe.2008.07.008>
- Tavana, Madjid, Hosein Arman, Abdollah Hadi-Vencheh, and Sadegh Mansoori. "A fuzzy multi-objective optimization model for sustainable location planning using volumetric fuzzy sets." *Annals of Operations Research* (2023): 1-29. <https://doi.org/10.1007/s10479-023-05505-0>
- Wang, J., Qian, Y., Zhang, L., Wang, K., & Zhang, H. (2024). A novel wind power forecasting system integrating time series refining, nonlinear multi-objective optimized deep learning and linear error correction. *Energy Conversion and Management*, 299, 117818. <https://doi.org/10.1016/j.enconman.2023.117818>
- Wang, Z., Pei, Y., & Li, J. (2023). A survey on search strategy of evolutionary multi-objective optimization algorithms. *Applied Sciences*, 13(7), 4643. <https://doi.org/10.3390/app13074643>
- Xin, X. Y., Ma, J., Liu, H. Q., Gu, Y. J., Wang, Y. F., & Cui, H. Z. (2023). A simple Pb-doping to achieve bonding evolution, VS_n and resonant level shifting for regulating thermoelectric transport behavior of SnTe. *Journal of Materials Science & Technology*, 151, 66-72. <https://doi.org/10.1016/j.jmst.2022.12.021>

- Yan, M., Yuan, H., Xu, J., Yu, Y., & Jin, L. (2021). Task allocation and route planning of multiple UAVs in a marine environment based on an improved particle swarm optimization algorithm. *EURASIP Journal on Advances in Signal Processing*, 2021, 1-23. <https://doi.org/10.1186/s13634-021-00804-9>
- Yousefzadeh, R., Kazemi, A., & Al-Maamari, R. S. (2024). Application of power-law committee machine to combine five machine learning algorithms for enhanced oil recovery screening. *Scientific Reports*, 14(1), 9200. <https://doi.org/10.1038/s41598-024-59387-8>
- Zhang, W., Xiao, G., Gen, M., Geng, H., Wang, X., Deng, M., & Zhang, G. (2024). Enhancing multi-objective evolutionary algorithms with machine learning for scheduling problems: recent advances and survey. *Frontiers in Industrial Engineering*, 2, 1337174. <https://doi.org/10.3389/fieng.2024.1337174>
- Zhu, Z., Li, X., Chen, H., Zhou, X., & Deng, W. (2024). An effective and robust genetic algorithm with hybrid multi-strategy and mechanism for airport gate allocation. *Information Sciences*, 654, 119892. <https://doi.org/10.1016/j.ins.2023.119892>
- Zou, F., Yen, G. G., Tang, L., & Wang, C. (2021). A reinforcement learning approach for dynamic multi-objective optimization. *Information Sciences*, 546, 815-834. <https://doi.org/10.1016/j.ins.2020.08.101>