

Mathematical Modeling of Dynamic Pricing in a Multi-Channel Supply Chain Considering Strategic Customers

Mona Jamdar¹, Mohammad Sheikhalishahi^{2*}, Ata Allah Taleizadeh²

¹ Industrial Engineering Group, Alborz Campus, University of Tehran, Tehran, Iran

² School of Industrial Engineering, College of Engineering, University of Tehran, Tehran, Iran

* Corresponding author email address: m.alishahi@ut.ac.ir

Article Info

Article type:

Original Research

How to cite this article:

Jamdar, M., Sheikhalishahi, M., & Taleizadeh, A. A. (2025). Mathematical Modeling of Dynamic Pricing in a Multi-Channel Supply Chain Considering Strategic Customers. *Journal of Technology in Entrepreneurship and Strategic Management*, 4(4), 1-28.



© 2025 the authors. Published by KMAN Publication Inc. (KMANPUB), Ontario, Canada. This is an open access article under the terms of the Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0) License.

ABSTRACT

This study aims to develop a mixed-integer linear optimization model for dynamic pricing in multi-channel supply chains while explicitly incorporating the behavior of strategic customers. A nonlinear dynamic pricing model was formulated to capture multiple sales channels, strategic and non-strategic customer classes, transportation modes, capacity constraints, daily price fluctuation limits, utility thresholds, and market-share requirements. The nonlinearities were addressed using separable quadratic transformation, piecewise linear approximation, and auxiliary variables, resulting in a solvable mixed-integer linear program. The model was validated using GAMS and the CPLEX solver. To handle large-scale instances, three metaheuristic algorithms—Genetic Algorithm (GA), Particle Swarm Optimization (PSO), and Grey Wolf Optimizer (GWO)—were designed, tuned, and benchmarked. The results indicate that the proposed model efficiently predicts optimal prices, realized demand, and sales volumes across time periods, significantly improving overall supply chain profitability. Sensitivity analysis revealed that transportation capacity, price sensitivity parameters, and base utility values are the most influential factors on profit. Among the solution methods, GWO produced the highest-quality solutions, with less than 0.02% deviation from the exact GAMS results, although it required slightly longer computation times compared to GA and PSO. The findings demonstrate that integrating strategic customer behavior with multi-channel dynamic pricing requires a comprehensive mathematical framework. The proposed model effectively captures the interplay among price, demand, utility, and supply constraints, providing a robust decision-support tool for firms operating in volatile markets. Furthermore, metaheuristic methods—especially GWO—offer reliable and scalable solutions for large real-world applications.

Keywords: Dynamic pricing; Multi-channel supply chain; Strategic customers; Genetic Algorithm; Particle Swarm Optimization; Grey Wolf Optimizer

Extended Abstract

Introduction

Dynamic pricing in multi-channel supply chains has become a central strategic tool for firms facing increasingly volatile markets, diverse customer preferences, and differentiated service levels across sales platforms. The complexity of modern supply networks—comprising online marketplaces, offline retail, direct manufacturer channels, and third-party platforms—necessitates pricing mechanisms capable of responding to real-time fluctuations in demand, operational constraints, and consumer behavior. Prior research emphasizes that multi-channel environments create interdependencies between channels, requiring pricing rules that account for cross-channel demand interactions, market power imbalances, and varying cost structures (Cai et al., 2019). Furthermore, dynamic market conditions such as holiday seasons, peak travel windows, and unexpected shocks amplify the need for responsive pricing strategies capable of reallocating demand across channels (Raju et al., 2025).

A critical dimension added to this complexity is the presence of strategic customers—consumers who actively anticipate future prices, compare options across channels, and adjust purchasing timing to maximize perceived utility. Studies show that these consumers behave far differently from non-strategic buyers and frequently delay purchases or switch channels to exploit expected price drops (He et al., 2023; Yan et al., 2022). Multi-period pricing is therefore required to account not only for current demand but also for anticipated consumer reactions. Such behavior has been shown to influence revenue outcomes significantly, making traditional static pricing approaches insufficient in predicting actual demand (Li et al., 2015). This implies that dynamic pricing models must embed forward-looking components, utility thresholds, and differentiated demand elasticities to accurately represent real market conditions.

Additionally, prior literature highlights the importance of channel power and contract structures in shaping pricing decisions. For example, research in pharmaceutical and retail systems demonstrates that stronger channels often impose higher margins or control pricing dynamics to their advantage, while weaker channels rely on differentiation or discounting to remain competitive (Ram et al., 2024; Wen et al., 2025). Competitive pricing models in dual-channel settings further show that manufacturer–retailer conflicts, asymmetric information, and heterogeneous cost structures alter equilibrium prices and impact total supply chain profitability (Chen et al., 2022; Li & Mizuno, 2022). These insights reinforce the need for pricing frameworks that incorporate channel heterogeneity and market power asymmetry.

Environmental sustainability and green consumer preferences add another layer of complexity to pricing. Recent works reveal that low-carbon and environmentally conscious consumers increasingly influence channel choice and willingness to pay (Das et al., 2023; Song et al., 2023). In contexts such as food supply chains or systems offering sustainable alternatives, green preference has been shown to alter both elasticities and equilibrium pricing in dual-channel models (Musavi et al., 2022). Therefore, pricing systems must integrate utility parameters reflective of diverse consumer groups—green, strategic, and traditional.

In terms of methodological evolution, optimization models for pricing have transitioned from simple analytical forms toward sophisticated computational approaches that incorporate uncertainty, multi-level decision structures, and robust or fuzzy parameters. Robust-fuzzy optimization has proven particularly suitable for complex supply networks with uncertain demand and price-sensitive customers (Ghahremani-Nahr & Ghaderi, 2022; Ghahremani-Nahr et al., 2025). Meanwhile, machine learning approaches are increasingly used to estimate dynamic demand patterns and improve predictive accuracy in multi-channel environments (Ghaffari et al., 2025). Still, despite these advances, many existing models fail to

simultaneously integrate strategic customer behavior, multi-channel price elasticity, capacity constraints, and utility-threshold purchase decisions into a unified operational framework.

To solve large-scale dynamic pricing problems, scholars have explored the use of heuristic and metaheuristic optimization algorithms such as Genetic Algorithms (GA), Particle Swarm Optimization (PSO), and Grey Wolf Optimizer (GWO). GA-based optimization, grounded in evolutionary theory, offers strong global search capabilities and avoids local optima (Sivanandam & Deepa, 2008). PSO is praised for its fast convergence and suitability for continuous search spaces (Wang et al., 2018). GWO, inspired by grey wolf hunting behavior, has recently demonstrated exceptional performance in identifying near-optimal solutions in complex optimization landscapes (Modak et al., 2025). These methods have shown advantages over classical solvers, particularly when problems include nonlinearity, mixed-integer variables, and multidimensional constraints.

Given the above, the literature consistently calls for pricing models that integrate (1) multi-channel demand interactions, (2) strategic customer behavior, (3) capacity and price-bound constraints, and (4) metaheuristic solution frameworks to handle real-world computational complexity. Addressing these gaps, the present study develops a mathematically rigorous, linearized dynamic pricing model for multi-channel supply chains that incorporates threshold utilities, channel-specific base utilities, differentiated elasticities for strategic and non-strategic consumers, and day-to-day price fluctuation limits, while evaluating the performance of GA, PSO, and GWO in solving the large-scale model. This integrated view aligns directly with previous research calling for unified, operational, and computationally tractable frameworks for dynamic pricing in modern supply chains (Hong et al., 2020; Hu et al., 2023; Kaul, 2023; Ma et al., 2020; Wang et al., 2021; Yeh et al., 2022).

Methods and Materials

The study constructs a multi-period dynamic pricing model for a multi-channel supply chain that includes transportation modes, customer service classes (strategic and non-strategic), and two distinct sales channels. A nonlinear mixed-integer formulation incorporating utility-threshold demand functions, price elasticities, daily price fluctuation limits, and channel-specific base utilities was developed. To address nonlinearity, separable quadratic transformations and piecewise linear approximations were applied, enabling reformulation into a mixed-integer linear program.

The model was validated using a small-scale numerical example solved by the GAMS/CPLEX optimizer. To evaluate performance in large problem sizes, three metaheuristic algorithms—GA, PSO, and GWO—were implemented. Parameter tuning was performed using a Taguchi-based design, and each algorithm was executed on fifteen numerical instances of increasing dimensionality. Performance was assessed based on total profit optimization and computational time.

Findings

The model successfully predicted optimal prices, realized demand, and sales quantities across time periods. In the validation using GAMS, the model produced a total profit of 83,736 units. Analysis revealed that strategic customers were assigned higher optimal prices than non-strategic customers, yet they still exhibited higher average demand, producing a mean sales volume of 46.03 units versus 30.29 units for non-strategic buyers. Strategic customers also generated higher average optimal prices (66.08 versus 57.29).

Sensitivity analysis showed that increasing transportation capacity led to substantial improvements in total profit, with a 30% capacity increase yielding a 6.24% rise in profit. Reducing price sensitivity (elasticity) significantly increased profitability—particularly among strategic customers—while increases in base utility parameters resulted in dramatic profit growth of up to 33.48%.

In large-scale problem instances, all three algorithms achieved high-quality results. GWO consistently produced the best solutions, with its results deviating less than 0.02% from the optimal GAMS benchmark. PSO achieved the lowest computational time, while GA performed competitively, occasionally finding the exact optimal solution. Statistical t-test analysis indicated no significant difference in mean profit among the three algorithms, despite GWO outperforming others on average.


Discussion and Conclusion

The results confirm that dynamic pricing in multi-channel environments requires simultaneous consideration of strategic customer behavior, channel heterogeneity, and operational constraints. The model demonstrated strong predictive capacity in estimating realized demand, identifying optimal prices, and balancing supply constraints. The significantly higher purchased quantities and prices among strategic customers highlight their central role in revenue generation and underscore the need for differentiated pricing strategies.

The sensitivity findings indicate that operational levers such as capacity management and consumer utility enhancement can be as influential as price adjustments in improving profitability. This underscores the managerial relevance of integrating service quality, platform experience, and channel design into pricing decisions.

Finally, the comparative performance of metaheuristic algorithms illustrates their value for solving real-world large-scale pricing problems. GWO's superior accuracy and PSO's computational efficiency suggest that organizations can deploy these approaches depending on whether solution quality or runtime is prioritized.

Overall, the study presents a unified, operational dynamic pricing framework capable of addressing the multifaceted challenges of contemporary multi-channel supply chains, and offers computationally feasible methods suitable for industry-scale application.



مدل سازی ریاضی قیمت گذاری پویا در زنجیره تأمین چند کاناله با لحاظ کردن مشتریان استراتژیکی

مونا جمع دار^۱، محمد شیخ علیشاهی^{۲*}، عطااله طالعی زاده^۳

۱. دانشجوی دکتری، گروه مهندسی صنایع، پردیس البرز، دانشگاه تهران، تهران، ایران
۲. استادیار، دانشکده مهندسی صنایع، دانشکده گان فنی، دانشگاه تهران، تهران، ایران

*ایمیل نویسنده مسئول: m.alishahi@ut.ac.ir

چکیده

اطلاعات مقاله

نوع مقاله

پژوهشی اصیل

نحوه استناد به این مقاله:

جمع دار، مونا، شیخ علیشاهی، محمد، و طالعی زاده، عطااله. (۱۴۰۴). مدل سازی ریاضی قیمت گذاری پویا در زنجیره تأمین چندکاناله با لحاظ کردن مشتریان استراتژیکی. *تکنولوژی در کار آفرینی و مدیریت استراتژیک*، ۴(۴)، ۲۸-۱.



© ۱۴۰۳ تمامی حقوق انتشار این مقاله متعلق به نویسنده است. انتشار این مقاله به صورت دسترسی آزاد مطابق با گواهی (CC BY-NC 4.0) صورت گرفته است.

این پژوهش با هدف توسعه یک مدل ریاضی خطی عدد صحیح برای قیمت گذاری پویا در زنجیره تأمین چندکاناله با در نظر گرفتن رفتار مشتریان استراتژیک انجام شده است. این مطالعه ابتدا یک مدل غیرخطی قیمت گذاری پویا را شامل کانال های فروش متعدد، طبقات مشتریان استراتژیک و غیر استراتژیک، ظرفیت حمل و نقل، محدودیت نوسان قیمت، آستانه مطلوبیت و الزامات سهم بازار توسعه می دهد. سپس با استفاده از تکنیک تبدیل درجه دو، تقریب خطی تکه ای و معرفی متغیرهای کمکی، مدل به صورت یک برنامه ریزی خطی عدد صحیح مختلط باز نویسی می شود. برای اعتبار سنجی، مدل با نرم افزار GAMS و حل گر CPLEX حل شده و برای حل مسائل بزرگ، سه الگوریتم فراابتکاری GA، PSO و GWO طراحی، مقایسه و تنظیم شدند. نتایج نشان داد مدل ارائه شده قادر است قیمت بهینه، تقاضای بالفعل و حجم فروش را در دوره های زمانی مختلف با دقت بالا پیش بینی کند و سود زنجیره تأمین را به طور معناداری افزایش دهد. تحلیل حساسیت مشخص کرد که ظرفیت حمل و نقل، ضرایب حساسیت قیمتی و پارامترهای پایه مطلوبیت بیشترین اثر را بر سود دارند. در حل مسائل بزرگ، الگوریتم GWO بهترین کیفیت پاسخ را ارائه داد و اختلاف آن با جواب دقیق GAMS کمتر از ۰.۰۲٪ بود، هرچند زمان حل آن نسبت به GA و PSO بیشتر بود. این پژوهش نشان می دهد ترکیب رفتار استراتژیک مشتریان با ساختار چندکاناله و قیمت گذاری پویا نیازمند یک مدل جامع و قابل حل است. مدل پیشنهادی با شبیه سازی دقیق تعاملات قیمت، تقاضا و محدودیت های عرضه، ابزار تصمیم گیری معتبری برای شرکت ها فراهم می کند و استفاده از الگوریتم های فراابتکاری، به ویژه GWO، امکان حل مسائل بزرگ مقیاس را به صورت کارا فراهم می کند.

کلیدواژگان: قیمت گذاری پویا؛ زنجیره تأمین چندکاناله؛ مشتریان استراتژیک؛ الگوریتم ژنتیک؛ بهینه سازی ازدحام ذرات؛ بهینه سازی گرگ خاکستری

مقدمه

در دهه‌های اخیر، زنجیره‌های تأمین چندکاناله به یکی از الگوهای غالب در بازارهای رقابتی تبدیل شده‌اند و شرکت‌ها برای پاسخ‌گویی به نیازهای متنوع مشتریان، گسترش دامنه فروش و بهبود سودآوری، ناچار به بهره‌گیری از کانال‌های موازی شامل فروش حضوری، آنلاین، پلتفرم‌های واسطه و شبکه‌های اجتماعی شده‌اند (Cai et al., 2019). این گسترش کانال‌ها از یک سو انعطاف‌پذیری عرضه و دسترسی را افزایش می‌دهد و از سوی دیگر پیچیدگی‌های جدیدی را در تصمیم‌گیری‌های قیمتی ایجاد می‌کند، زیرا هر کانال ویژگی‌های هزینه‌ای، ترجیحات مشتری و الگوهای تقاضای متفاوتی دارد (Ram et al., 2024). در چنین ساختاری، تصمیم‌گیری قیمتی یک موضوع صرفاً عملیاتی نیست، بلکه به مسئله‌ای راهبردی تبدیل می‌شود که می‌تواند بر سهم بازار، رفتار رقابتی، سودآوری کوتاه‌مدت و پایداری بلندمدت کسب‌وکار تأثیر بگذارد (Wen et al., 2025). این پیچیدگی زمانی تشدید می‌شود که رفتار آینده‌نگر مشتریان استراتژیک نیز وارد مدل شود؛ مشتریانی که تصمیم خرید خود را براساس پیش‌بینی قیمت آینده، مقایسه کانال‌ها و تحلیل شرایط بازار تنظیم می‌کنند (Yan et al., 2022). حضور این گروه، ضرورت توسعه مدل‌هایی را دوچندان می‌کند که بتوانند تصمیم‌های قیمتی را با نگاه پویا و چندبعدی مدیریت کنند.

گسترش فناوری‌های دیجیتال و داده‌محور نیز ابعاد جدیدی به مسئله قیمت‌گذاری افزوده است. در محیط‌های مدرن کسب‌وکار، تقاضا نه تنها تحت تأثیر قیمت، بلکه متأثر از کیفیت خدمات دیجیتال، سرعت واکنش بازار، تجربه مشتری و شخصی‌سازی خدمات است (Kaul, 2023). این تحول موجب شده است که شرکت‌ها نه تنها به رقابت مستقیم در قیمت بپردازند، بلکه در زمینه شفافیت اطلاعات، کیفیت خدمات و ادراک مطلوبیت نیز رقابت کنند. به‌ویژه در زنجیره‌های همه‌کاناله، ادغام اطلاعات تقاضا در کانال‌های مختلف و تعیین قیمت‌های هدفمند مبتنی بر الگوهای تقاضا، روندی حیاتی برای بقا و توسعه محسوب می‌شود (Liu et al., 2024). علاوه بر این، توسعه داده‌های کلان و الگوریتم‌های پیشرفته، امکان تحلیل دقیق‌تری از رفتار مشتریان و پیش‌بینی پویای تقاضا را فراهم کرده و اهمیت مدل‌های قیمت‌گذاری مبتنی بر داده را افزایش داده است (Ghaffari et al., 2025).

در این میان، رفتار مشتریان استراتژیک اهمیت روزافزون یافته است. این گروه از مشتریان برخلاف مشتریان معمولی، تصمیم خرید خود را به تعویق می‌اندازند یا به کانال‌های دیگر منتقل می‌کنند تا به قیمت بهینه دست یابند (He et al., 2023). آن‌ها قیمت‌های گذشته، روند قیمتی بازار و کیفیت خدمات هر کانال را تحلیل می‌کنند و براساس مطلوبیت پیش‌بینی‌شده تصمیم‌گیری می‌نمایند (Li et al., 2015). این رفتار موجب می‌شود که مدل‌های قیمت‌گذاری صرفاً مبتنی بر شرایط فعلی بازار قادر به پیش‌بینی دقیق الگوهای تقاضا نباشند. از این رو، پژوهش‌های اخیر به ضرورت توسعه مدل‌های پویا که بتوانند رفتار آینده‌نگر مشتریان را در ساختار مدل‌سازی تقاضا لحاظ کنند، به شدت تأکید دارند (Song et al., 2023).

علاوه بر این، متغیرهایی مانند قدرت کانال، الگوهای رقابتی و تفاوت در ساختار هزینه، از جمله عواملی هستند که قیمت‌گذاری در زنجیره‌های چندکاناله را پیچیده می‌کنند. مطالعات اخیر نشان داده‌اند که قدرت نسبی هر کانال—اعم از کانال فیزیکی، آنلاین یا پلتفرم‌های ثالث—می‌تواند بر ساختار قیمت‌گذاری به شکل معناداری تأثیر بگذارد و هماهنگی میان کانال‌ها را دشوار سازد (Wen et al., 2025). برای مثال، کانال‌هایی که قدرت بیشتری در بازار دارند می‌توانند قیمت‌های بالاتری اعمال کنند یا سهم بیشتری از درآمد را مطالبه نمایند (Sarkar & Pal, 2021). این در حالی است که کانال‌های ضعیف‌تر often نیازمند اعمال تخفیف یا ارائه خدمات جانبی هستند تا بتوانند سهم بازار خود را حفظ کنند (Putri & Pulansari, 2025). چنین پویایی‌هایی موجب می‌شود که قیمت‌گذاری یکنواخت در تمامی کانال‌ها نه تنها ناکارآمد باشد، بلکه احتمالاً موجب از دست رفتن سودآوری و ایجاد اختلال در ترکیب تقاضا گردد (Ram et al., 2024).

از سوی دیگر، پژوهش‌های اخیر بر نقش بازی‌های قیمت‌گذاری در ساختار دوکاناله تأکید کرده‌اند، جایی که تولیدکننده و خرده‌فروش هر یک اهداف متفاوتی را دنبال می‌کنند و این تضاد می‌تواند از هماهنگی زنجیره جلوگیری کند (Chen et al., 2022). معمولاً تولیدکننده تمایل دارد قیمت عمده‌فروشی را افزایش دهد تا سود خود را بهینه کند، در حالی که خرده‌فروش به دنبال تعیین قیمت نهایی پایین‌تر برای جذب مشتری و افزایش فروش است. این تعارض ممکن است منجر به نتایج ناکارآمد در سطح کل زنجیره شود (Li & Mizuno, 2022). توسعه مدل‌های پویا که بتوانند هماهنگی میان این دو بازیگر را تقویت کنند، یکی از مسیرهای مهم پژوهشی در سال‌های اخیر بوده است. یکی از چالش‌های اساسی دیگر، اثرات ویژگی‌های زمانی بر تقاضا و قیمت‌گذاری است. بازارها در دوره‌های فصلی، دوره‌های دارای نوسان شدید یا شرایط بحرانی (مانند همه‌گیری‌ها) رفتار متفاوتی از خود نشان می‌دهند (Raju et al., 2025). در این حالت، مدل‌های قیمت‌گذاری باید بتوانند نوسانات تقاضا را به‌صورت پویا منعکس کنند و راهبردهای مناسب را برای دوره‌های مختلف ارائه دهند. پژوهش‌های اخیر نشان داده‌اند که در دوران بحران، کانال‌های فروش مختلف رفتارهای متفاوتی از خود نشان می‌دهند و مصرف‌کنندگان نسبت به تغییرات قیمت حساسیت بیشتری پیدا می‌کنند (Raju et al., 2025). در نتیجه، بهره‌گیری از مدل‌هایی که بر اساس تحلیل دوره‌ای و چندمرحله‌ای طراحی شده‌اند ضرورتی کلیدی است (He et al., 2023).

از سوی دیگر، پژوهش‌ها بر اهمیت ادغام پایداری، کاهش آلاینده‌گی و رفتارهای سبز در مدل‌های قیمت‌گذاری تأکید کرده‌اند (Das et al., 2023). در بسیاری از صنایع، مصرف‌کنندگان نسبت به جنبه‌های محیط‌زیستی حساس شده‌اند و این عامل می‌تواند بر تمایل پرداخت آن‌ها تأثیر بگذارد. چنین ترجیحاتی، کانال‌هایی را جذاب‌تر می‌کند که با اصول کم‌کربن یا خدمات پایدار همسو باشند (Song et al., 2023). به همین دلیل، مدل‌های قیمت‌گذاری چندکاناله نیازمند در نظر گرفتن ابعاد رفتاری و محیط‌زیستی هستند تا سیاست‌های قیمتی با واقعیت‌های نوین بازار هماهنگ باشند.

افزون بر این، ادغام عدم قطعیت در داده‌ها، شوک‌های تقاضا و نوسانات بازار از چالش‌های کلیدی در مدل‌های تصمیم‌گیری پیشرفته است. پژوهش‌های مبتنی بر بهینه‌سازی قوی و فازی نشان داده‌اند که نادیده گرفتن عدم قطعیت می‌تواند منجر به نتایج غیرواقعی و آسیب‌پذیری تصمیم‌ها در شرایط واقعی شود (Ghahremani-Nahr & Ghaderi, 2022). مدل‌های جدیدتر تلاش کرده‌اند که با ادغام روش‌های فازی، عدم قطعیت موجود در تقاضا، هزینه‌ها و سهم بازار را بهتر مدیریت کنند و تصمیم‌های قیمتی را بهبود بخشند (Ghahremani-Nahr et al., 2025). همچنین مدل‌های قیمت‌گذاری مبتنی بر یادگیری ماشین نشان داده‌اند که داده‌های واقعی می‌توانند برای اصلاح و به‌روزرسانی پویای پارامترها به کار گرفته شوند، که این موضوع دقت تصمیم‌گیری را افزایش می‌دهد (Ghaffari et al., 2025).

از میان روش‌های محاسباتی نیز، الگوریتم‌های فراابتکاری به‌عنوان ابزارهای کارآمد برای حل مدل‌های پیچیده قیمت‌گذاری شناخته می‌شوند. این الگوریتم‌ها توانایی بالایی در جستجوی فضای وسیع تصمیم و یافتن پاسخ‌های نزدیک به بهینه دارند. الگوریتم‌های تکاملی مانند الگوریتم ژنتیک (Sivanandam & Deepa, 2008)، الگوریتم‌های مبتنی بر رفتار پرندگان مانند PSO (Wang et al., 2018) و الگوریتم‌های نوظهوری مانند GWO در بسیاری از مطالعات برای حل مسائل پیچیده قیمت‌گذاری مورد استفاده قرار گرفته‌اند. مطالعات نشان داده‌اند که انتخاب الگوریتم مناسب و تنظیم دقیق پارامترهای آن بر اساس روش‌های طراحی آزمایش مانند تاکوچی می‌تواند عملکرد حل را به‌طور چشمگیری بهبود بخشد (Nikzad et al., 2025). با توجه به NP-hard بودن بسیاری از مدل‌های قیمت‌گذاری چندکاناله، این الگوریتم‌ها به ابزاری ضروری برای حل مسائل در مقیاس واقعی تبدیل شده‌اند.

بر همین اساس، پژوهش‌های اخیر کوشیده‌اند تا مدل‌های قیمت‌گذاری را به‌گونه‌ای طراحی کنند که بتوانند تعاملات میان قیمت، تقاضا، موجودی، سهم بازار و رفتار مشتریان را به‌صورت یکپارچه مدیریت کنند. برای نمونه، پژوهش‌های انجام‌شده در زنجیره‌های دارویی نشان

داده‌اند که قدرت کانال و سیاست‌های بیمه‌ای می‌توانند رفتار قیمتی را تحت تأثیر قرار دهند و رقابت میان کانال‌ها لزوماً موجب کاهش قیمت نمی‌شود (Wen et al., 2025). در مقابل، در صنایع فصلی یا کالاهای فسادپذیر، قیمت‌گذاری پویا در دوره‌های مختلف می‌تواند سودآوری را افزایش دهد و مدیریت ظرفیت را بهبود بخشد (Modak et al., 2025). همچنین در زنجیره‌های باز و بسته، مدل‌های ترکیبی مکان-موجودی-قیمتی توانسته‌اند اثربخشی شبکه را در شرایط عدم قطعیت افزایش دهند (Aliahmadi et al., 2023).

با توجه به مجموعه چالش‌ها و فرصت‌های یادشده، نیاز به یک مدل ریاضی دقیق که بتواند ویژگی‌های واقعی زنجیره‌های چندکاناله شامل محدودیت ظرفیت، نوسان قیمت، رفتار استراتژیک مشتریان، اختلاف قدرت کانال‌ها و تعامل پویای تقاضا را با دقت شبیه‌سازی کند به وضوح احساس می‌شود. از این رو، پژوهش حاضر تلاش می‌کند تا با بهره‌گیری از چارچوب‌های پیشرفته بهینه‌سازی و روش‌های فراابتکاری، مدلی یکپارچه برای قیمت‌گذاری پویا در ساختارهای پیچیده ارائه دهد. بر این اساس، هدف این پژوهش ارائه یک مدل ریاضی پویا و کارآمد برای قیمت‌گذاری در زنجیره تأمین چندکاناله با لحاظ رفتار استراتژیک مشتریان و ارزیابی عملکرد الگوریتم‌های فراابتکاری در حل این مدل است.

روش پژوهش

هدف اصلی این بخش، ارائه یک مدل قیمت‌گذاری پویا در زنجیره تأمین چند کاناله است. تعیین قیمت‌های بهینه و حجم فروش در زنجیره تأمین چندکاناله در میان ابعاد مختلف شامل انواع وسایل حمل‌ونقل، طبقات خدماتی مشتریان (استراتژیکی و غیر استراتژیکی) و کانال‌های فروش در یک دوره تصمیم‌گیری چند روزه است. این مدل تغییرات تقاضای مشتریان، محدودیت ظرفیت، و الزامات سهم بازار را در نظر گرفته و در عین حال از محدودیت‌های قیمتی و دامنه نوسان روزانه نیز پیروی می‌کند. در این مقاله، ترجیحات مشتری و حساسیت قیمتی مختص هر کانال فروش برآورد می‌گردد و امکان تنظیم پویای قیمت را بر اساس فصلی بودن، تعطیلات و تغییرات تقاضا ناشی از رویدادها فراهم است.

تابع هدف در نظر گرفته شده برای مدل ریاضی، بیشینه‌سازی درآمد می‌باشد که در کنار این تابع هدف، مدل محدودیت‌هایی را برای حفظ حداقل سهم بازار در میان وسایل حمل‌ونقل و طبقات خدماتی لحاظ می‌کند تا جایگاه رقابتی شرکت حفظ شود. به صورتی که فرض می‌شود که تقاضا تابعی قطعی از قیمت و زمان است و بین وسایل، طبقات و کانال‌ها مستقل در نظر گرفته می‌شود. همچنین تصمیمات خرید مشتریان بر اساس تابع مطلوبیتی آستانه‌ای مدل‌سازی شده‌اند که با توجه به قیمت و ویژگی‌های کانال فروش تغییر می‌کند.

طراحی مدل فوق بر اساس مفروضات زیر امکان پذیر است:

- انواع مختلفی از وسایل نقلیه و طبقات خدماتی مشتریان (استراتژیکی و غیر استراتژیکی) در نظر گرفته شده است که هرکدام دارای کشش قیمتی و تابع مطلوبیت مجزایی هستند.
- افق زمانی در نظر گرفته شده چند روزه است.
- کانال‌های مختلف فروش در نظر گرفته شده است که هرکدام پارامترهای مطلوبیت خاص خود را دارند.
- تقاضا به صورت تابع خطی قطعی از قیمت در نظر گرفته شده است و پارامترهای آن با زمان تغییر می‌کنند. کشش‌های قیمتی میان طبقات استراتژیکی و غیر استراتژیکی متفاوت است.
- محدودیت ظرفیت هر وسیله نقلیه ثابت است.

- نوسانات روزانه قیمت حداکثر $\pm 10\%$ تعیین شده و برای هر وسیله و طبقه، حداقل و حداکثر قیمت از پیش تعریف شده است.
 - هر وسیله و طبقه خدماتی باید حداقل سهم بازار مشخصی را حفظ کند تا با اهداف رقابتی شرکت هماهنگ باشد.
- با توجه به مفروضات فوق و همچنین هدف اصلی از ارائه مدل ریاضی، نمادهای زیر تعریف شده است.

اندیس ها

$v \in \{1, 2, \dots, V\}$	اندیس وسیله نقلیه	v
$c \in \{1, 2, \dots, C\}$	اندیس طبقه خدماتی مشتریان	c
$s \in \{1, 2, \dots, S\}$	اندیس کانال فروش	s
$t \in \{1, 2, \dots, T\}$	اندیس دوره زمانی	t

پارامترها

k_v	ظرفیت وسیله نقلیه v ام
$p_{v,c,t}^{min}, p_{v,c,t}^{max}$	حدود پایین و بالای قیمت برای وسیله نقلیه v ام با طبقه خدماتی مشتریان c ام در دوره t ام
$Q_{v,c,s,t}^{min}, Q_{v,c,s,t}^{max}$	حدود پایین و بالای حجم فروش برای وسیله نقلیه v ام با طبقه خدماتی مشتریان c ام از طریق کانال فروش s ام در دوره t ام
$\alpha_{s,t}, \gamma_{s,t}$	پارامترهای پایه مطلوبیت برای کانال فروش s ام در دوره t ام
$\beta_{c_1}, \delta_{c_2}$	ضرایب حساسیت قیمتی برای طبقات مشتریان استراتژیکی و غیر استراتژیکی
$\epsilon_{c,s,t}$	آستانه مطلوبیت لازم برای خرید توسط طبقه خدماتی مشتریان c ام از طریق کانال فروش s ام در دوره t ام
$M_{v,c}$	حداقل سهم بازار مورد نیاز برای وسیله نقلیه v ام با طبقه خدماتی مشتریان c ام

متغیرهای تصمیم

$P_{v,c,t}$	قیمت برای وسیله نقلیه v ام با طبقه خدماتی مشتریان c ام در دوره t ام
$B_{v,c,s,t}$	حجم فروخته شده برای وسیله نقلیه v ام با طبقه خدماتی مشتریان c ام از طریق کانال فروش s ام در دوره t ام
$D_{v,c,s,t}$	تقاضای بالفعل برای وسیله نقلیه v ام با طبقه خدماتی مشتریان c ام از طریق کانال فروش s ام در دوره t ام

با توجه به نمادهای تعریف شده و بر اساس مفروضات ارائه شده، مدل برنامه ریزی غیر خطی عدد صحیح مختلط برای مسئله قیمت گذاری پویا در زنجیره تامین چند کاناله با حضور مشتریان استراتژیک به شرح زیر است:

$$Max Profit = \sum_v \sum_c \sum_s \sum_t P_{v,c,t} B_{v,c,s,t} \quad (1)$$

s. t.:

$$\sum_c B_{v,c,s,t} \leq k_v, \quad \forall v, t, s \quad (2)$$

$$B_{v,c,s,t} \leq D_{v,c,s,t}, \quad \forall v, c, s, t \quad (3)$$

$$P_{v,c,t}^{min} \leq P_{v,c,t} \leq P_{v,c,t}^{max}, \quad \forall c, v, t \quad (4)$$

$$\sum_s \sum_t B_{v,c,s,t} \geq M_{v,c}, \quad \forall c, v \quad (5)$$

$$U_{v,c_1,s,t}(p) = \alpha_{s,t} - \beta_{c_1} \cdot P_{v,c,t}, \quad \forall v, c_1, s, t \quad (6)$$

$$U_{v,c_2,s,t}(p) = \gamma_{s,t} - \delta_{c_2} \cdot P_{v,c,t}, \quad \forall v, c_2, s, t \quad (7)$$

$$D_{v,c_1,s,t}(p) = \max(0, U_{v,c_1,s,t}(p) - \varepsilon_{c_1,s,t}), \quad \forall v, c_1, s, t \quad (8)$$

$$D_{v,c_2,s,t}(p) = \max(0, U_{v,c_2,s,t}(p) - \varepsilon_{c_2,s,t}), \quad \forall v, c_2, s, t \quad (9)$$

$$B_{v,c,s,t}, D_{v,c,s,t}, P_{v,c,t} \geq 0, \quad (10)$$

رابطه (۱) تابع هدف مسئله را نشان میدهد که شامل بیشینه سازی درآمد کل حاصل از فروش در تمامی حالات حمل و نقل، طبقات خدمات مشتریان، کانال های فروش و دوره های زمانی است. رابطه (۲) تضمین میکند که کل فروش انجام شده از ظرفیت موجود برای هر روش حمل و نقل تجاوز نمیکند. رابطه (۳) تضمین میکند که فروش از تقاضای بالقوه برای هر ترکیبی از روش حمل و نقل، طبقه خدمات مشتریان، کانال های فروش و دوره های زمانی فراتر نرود. رابطه (۴) قیمت هر واحد را در محدوده از قبل تعریف شده محدود میکند. رابطه (۵) نشان میدهد که هر روش حمل و نقل و هر طبقه خدمات مشتریان، حداقل سهم بازار خود را برآورد میکنند. رابطه (۶) و (۷) مدل سازی مطلوبیت مشتری به عنوان تابعی از قیمت بلیط و ویژگی های کانال فروش، که رابطه بین قیمت، رضایت مشتری و احتمال خرید برای طبقات مختلف خدمات را نشان می دهد. رابطه (۸) و (۹) تقاضای بالقوه را با استفاده از توابع مطلوبیت تخمین می زند و تضمین می کند که نوسانات قیمت به طور دقیق در تخمین های تقاضای پیش بینی شده منعکس می شوند. رابطه (۱۰) نوع متغیر تصمیم گیری را نشان می دهد.

با توجه به ضرب دو متغیر پیوسته در تابع هدف، از تکنیک تبدیل درجه دو جداپذیر برای رفع این مشکل و خطی سازی مدل استفاده می کنیم. به طور دقیق تر، جمله حاصل ضرب با استفاده از تفاضل مربعات دو متغیر کمکی y_1 و y_2 بیان می شود؛ این دو متغیر به ترتیب به عنوان نیم جمع و نیم تفاضل متغیرهای اصلی تعریف می شوند. عبارت های درجه دو حاصل، یعنی y_1^2 و y_2^2 ، سپس با استفاده از توابع خطی تکه ای تقریب زده می شوند. این کار امکان بازنویسی مدل را به صورت یک برنامه ریزی خطی عدد صحیح مختلط فراهم می کند که می تواند توسط حل گره های تجاری نظیر *gams* به صورت کارآمد حل شود.

برای این منظور روابط زیر تعریف می شود:

$$y_{1\ v,c,s,t} = \frac{1}{2}(P_{v,c,t} + B_{v,c,s,t}), \quad \forall v, c, s, t \quad (11)$$

$$y_{2\ v,c,s,t} = \frac{1}{2}(P_{v,c,t} - B_{v,c,s,t}), \quad \forall v, c, s, t \quad (12)$$

با استفاده از روابط فوق $P_{v,c,t}$ و $B_{v,c,s,t}$ میتوانند به صورت زیر بازنویسی شوند.

$$y_{1\ v,c,s,t}^2 - y_{2\ v,c,s,t}^2 := P_{v,c,t} B_{v,c,s,t} \quad (13)$$

این تبدیل، جمله دوخطی را به تفاضل دو تابع درجه دو تک متغیره تبدیل می کند که هر کدام تنها به یک متغیر کمکی وابسته اند.

این ساختار برای اعمال تقریب خطی تکه ای به هر عبارت درجه دو به صورت جداگانه ضروری است. برای تضمین دقت تقریب، کران هایی برای

متغیرهای کمکی بر اساس کران‌های پایین و بالای شناخته‌شده متغیرهای تصمیم اصلی تعریف می‌کنیم. این کران‌ها باعث می‌شوند مقادیر تقریب‌زده‌شده در طول فرایند بهینه‌سازی در بازه‌های مجاز و قابل تفسیر باقی بمانند:

$$\frac{1}{2}(p_{v,c,t}^{min} + Q_{v,c,s,t}^{min}) \leq y_{1\ v,c,s,t} \leq \frac{1}{2}(p_{v,c,t}^{min} + Q_{v,c,s,t}^{min}) \quad (14)$$

$$\frac{1}{2}(p_{v,c,t}^{min} - Q_{v,c,s,t}^{min}) \leq y_{2\ v,c,s,t} \leq \frac{1}{2}(p_{v,c,t}^{min} - Q_{v,c,s,t}^{min}) \quad (15)$$

این کران‌ها تضمین می‌کنند که متغیرهای کمکی در دامنه‌های معتبر باقی بمانند، امری که برای دقت تقریب و همچنین امکان پذیری کلی فرایند بهینه‌سازی ضروری است. برای عبارات درجه‌دو $y_{1\ v,c,s,t}^2$ و $y_{2\ v,c,s,t}^2$ از تقریب خطی تکه‌ای استفاده می‌کنیم. فرض کنید N تعداد نقاط شکست برای عملیات تقریب باشد. برای هر متغیر کمکی y_k (که k نمایانگر y_1 یا y_2)، دامنه متغیر به N بازه با فاصله‌های یکنواخت تقسیم می‌شود:

• نقاط شکست: $b_0, b_1, \dots, b_N$ که b_0 کران پایین و b_N کران بالا است.

• λ_i : وزن تخصیص یافته به نقطه شکست i ، $\forall i \in \{0, 1, \dots, N\}$

برای حفظ یکپارچگی ساختاری تقریب خطی بخش‌بخش، محدودیت‌های مجموعه مرتب ویژه نوع ۲ را اعمال می‌کنیم. این محدودیت‌ها تضمین می‌کنند که تقریب، ساختار تابع درجه‌دو زیربنایی را رعایت کند.

$$\sum_{i=0}^N \lambda_i = 1 \quad (16)$$

$$y_k = \sum_{i=0}^N \lambda_i b_i \quad (17)$$

$$y_k^2 = \sum_{i=0}^N \lambda_i b_i^2 \quad (18)$$

در روابط فوق حداقل دو λ_i باید غیر صفر باشد.

این محدودیت هم‌جواری برای حفظ درون‌یابی خطی میان نقاط شکست بسیار مهم است. این محدودیت تضمین می‌کند که جمله‌های درجه‌دو از طریق ترکیب‌های محدب به‌درستی تقریب زده شوند، در حالی که ساختار کلی خطی مدل بهینه‌سازی حفظ می‌شود.

محدودیت‌های (۸) و (۹) شامل یک عبارت غیرخطی هستند که یک عملگر ماکسیمم را در بر می‌گیرد و همین باعث ایجاد غیرخطی بودن مدل می‌شود. برای خطی‌سازی این محدودیت‌ها، یک متغیر کمکی پیوسته $\phi_{v,c,s,t}$ ، یک متغیر دودویی $y_{v,c,s,t} \in \{0, 1\}$ معرفی می‌کنیم و محدودیت‌های زیر را برای همه شاخص‌های v, c, s, t اضافه می‌کنیم تا توابع تقاضا مبتنی بر مطلوبیت را جایگزین کنیم:

$$\phi_{v,c_1,s,t} = U_{v,c_1,s,t}(p) - \varepsilon_{c_1,s,t}, \quad \forall v, c_1, s, t \quad (19)$$

$$\phi_{v,c_2,s,t} = U_{v,c_2,s,t}(p) - \varepsilon_{c_2,s,t}, \quad \forall v, c_2, s, t \quad (20)$$

سپس محدودیت‌های خطی زیر را معرفی می‌کنیم تا عملگر «ماکسیمم» را نمایش دهیم.

$$\phi_{v,c,s,t} \geq U_{v,c,s,t}(p) - \varepsilon_{c,s,t}, \quad \forall v, c, s, t \quad (21)$$

$$\phi_{v,c,s,t} \geq 0, \quad \forall v, c, s, t \quad (22)$$

$$\phi_{v,c,s,t} \leq U_{v,c,s,t}(p) - \varepsilon_{c,s,t} + M(1 - y_{v,c,s,t}), \quad \forall v, c, s, t \quad (23)$$

$$\phi_{v,c,s,t} \leq M y_{v,c,s,t}, \quad \forall v, c, s, t \quad (24)$$

$$y_{v,c,s,t} \in \{0,1\}, \quad \forall v, c, s, t \quad (25)$$

در اینجا، M یک ثابت به اندازه کافی بزرگ است که حد بالایی برای عبارت اختلاف مطلوبیت ایجاد می کند. این محدودیت ها تضمین می کنند که $\phi_{v,c,s,t}$ برابر با بخش مثبت شکاف مطلوبیت یا صفر باشد و بدین ترتیب عملگر «ماکسیمم» را در نسخه خطی شده به درستی بازتولید می کنند. با توجه به روابط فوق، مدل خطی سازی شده به شرح زیر است:

$$\text{Max Profit} = \sum_v \sum_c \sum_s \sum_t y_{1v,c,s,t}^2 - y_{2v,c,s,t}^2 \quad (26)$$

s. t.:

$$\sum_c B_{v,c,s,t} \leq k_v, \quad \forall v, t, s \quad (27)$$

$$B_{v,c,s,t} \leq D_{v,c,s,t}, \quad \forall v, c, s, t \quad (28)$$

$$p_{v,c,t}^{\min} \leq P_{v,c,t} \leq p_{v,c,t}^{\max}, \quad \forall c, v, t \quad (29)$$

$$\sum_s \sum_t B_{v,c,s,t} \geq M_{v,c}, \quad \forall c, v \quad (30)$$

$$U_{v,c_1,s,t}(p) = \alpha_{s,t} - \beta_{c_1} \cdot P_{v,c,t}, \quad \forall v, c_1, s, t \quad (31)$$

$$U_{v,c_2,s,t}(p) = \gamma_{s,t} - \delta_{c_2} \cdot P_{v,c,t}, \quad \forall v, c_2, s, t \quad (32)$$

$$y_{1v,c,s,t} = \frac{1}{2}(P_{v,c,t} + B_{v,c,s,t}), \quad \forall v, c, s, t \quad (33)$$

$$y_{2v,c,s,t} = \frac{1}{2}(P_{v,c,t} - B_{v,c,s,t}), \quad \forall v, c, s, t \quad (34)$$

$$\frac{1}{2}(p_{v,c,t}^{\min} + Q_{v,c,s,t}^{\min}) \leq y_{1v,c,s,t} \leq \frac{1}{2}(p_{v,c,t}^{\min} + Q_{v,c,s,t}^{\min}) \quad (35)$$

$$\frac{1}{2}(p_{v,c,t}^{\min} - Q_{v,c,s,t}^{\min}) \leq y_{2v,c,s,t} \leq \frac{1}{2}(p_{v,c,t}^{\min} - Q_{v,c,s,t}^{\min}) \quad (36)$$

$$\sum_{i=0}^N \lambda_i = 1 \quad (37)$$

$$y_k = \sum_{i=0}^N \lambda_i b_i \quad (38)$$

$$y_k^2 = \sum_{i=0}^N \lambda_i b_i^2 \quad (39)$$

$$\phi_{v,c,s,t} \geq U_{v,c,s,t}(p) - \varepsilon_{c,s,t}, \quad \forall v, c, s, t \quad (40)$$

$$\phi_{v,c,s,t} \geq 0, \quad \forall v, c, s, t \quad (41)$$

$$\phi_{v,c,s,t} \leq U_{v,c,s,t}(p) - \varepsilon_{c,s,t} + M(1 - y_{v,c,s,t}), \quad \forall v, c, s, t \quad (42)$$

$$\phi_{v,c,s,t} \leq M y_{v,c,s,t}, \quad \forall v, c, s, t \quad (43)$$

$$y_{v,c,s,t} \in \{0,1\}, \quad \forall v, c, s, t \quad (44)$$

$$B_{v,c,s,t} \geq 0, P_{v,c,t} \geq 0 \quad (45)$$

$$\lambda_i \geq 0, \quad \forall i \in \{1,2\} \quad (46)$$

در ادامه به ارائه روش‌های حل مسئله شامل معرفی الگوریتم‌های فرا ابتکاری و طراحی راه حل اولیه برای مسئله قیمت گذاری پویا در زنجیره تامین چند کاناله پرداخته شده است.

در این بخش به ارائه روش‌های حل مسئله شامل الگوریتم‌های فرا ابتکاری ژنتیک (GA)، بهینه سازی ازدحام ذرات (PSO) و بهینه سازی گرگ خاکستری (GWO) است. همه الگوریتم‌های فرا ابتکاری برای اجرا، نیازمند طراحی راه حل اولیه می‌باشد. از این رو ابتدا به طراحی راه حل اولیه پرداخته شده است.

در این بخش به طراحی راه حل اولیه مسئله پرداخته شده است. راه حل اولیه مسئله شامل ۲ بخش مختلف می‌باشد. در بخش اول، راه حل مسئله شامل اعداد تصادفی به اندازه $V \times C \times T$ می‌باشد. این داده‌های تصادفی نشان دهنده قیمت فروش محصولات است که باید در بازه بین $[p_{v,c,t}^{min}, p_{v,c,t}^{max}]$ تولید گردد. گام‌های رمزگشایی بخش اول به صورت زیر است:

- مقدار $U_{v,c,s,t}$ از رابطه (۵) و (۶) محاسبه می‌شود.
- مقدار $D_{v,c,s,t}$ از رابطه (۸) و (۹) محاسبه می‌شود.

در بخش دوم، راه حل مسئله شامل اعداد تصادفی به اندازه $V \times C \times S \times T$ می‌باشد. این داده‌های تصادفی نشان دهنده حجم فروش محصولات است. داده‌های باید به صورتی باشد که محدودیت‌های (۲)، (۳) و (۵) برقرار باشد.

پس از محاسبه مقادیر متغیرهای $P_{v,c,t}$ و $B_{v,c,s,t}$ تابع هدف مسئله محاسبه می‌گردد.

الگوریتم ژنتیک یکی از روش‌های بهینه‌سازی و جستجوی تصادفی است که از فرآیندهای تکاملی در طبیعت الهام گرفته و توسط جان هالند معرفی شد. این الگوریتم بر پایه مفاهیمی مانند انتخاب طبیعی، جهش و ترکیب ژنتیکی عمل می‌کند و هدف آن یافتن بهترین یا تقریباً بهترین پاسخ برای مسائل پیچیده و غیرخطی است. هر راه‌حل در قالب یک کروموزوم (G_i) نمایش داده می‌شود و مجموعه‌ای از این کروموزوم‌ها $\{G_1, G_2, \dots, G_N\}$ به عنوان جمعیت اولیه در نظر گرفته می‌شوند. در هر نسل، کروموزوم‌ها بر اساس میزان برازندگی خود انتخاب می‌شوند و با اعمال عملگرهای جهش و ترکیب ژنتیکی، نسل بعدی تولید می‌گردد. احتمال انتخاب کروموزوم G_i از جمعیت به صورت زیر محاسبه می‌شود (سیواندام و دیپا، ۲۰۰۸):

$$P(G_i) = \frac{f(G_i)}{\sum_{j=1}^N f(G_j)} \quad (47)$$


که $f(G_i)$ مقدار برازندگی کروموزوم G_i است. الگوریتم ژنتیک به دلیل توانایی جستجوی گسترده و اجتناب نسبی از بهینه‌های

محلی در مسائل مهندسی، برنامه‌ریزی، یادگیری ماشین و طراحی سیستم‌ها کاربرد فراوان دارد.

در شکل (۱) و (۲) عملگرهای ترکیب دو نقطه‌ای و جهش تک نقطه‌ای به کار رفته در این الگوریتم، نشان داده شده است.

شکل ۱

عملگر ترکیب دو نقطه‌ای در الگوریتم ژنتیک




مطابق با شکل (۱) مشاهده می‌شود، دو نقطه از کروموزوم در ژن‌های والد ۱ و ۲ انتخاب و جای ژن‌ها در کروموزوم فرزندان ۱ و ۲

جابجا می‌گردد.

شکل ۲

عملگر جهش تک نقطه‌ای در الگوریتم ژنتیک



مطابق با شکل (۲) در عملگر جهش تک نقطه‌ای، یک ژن از کروموزوم والد انتخاب شده و مقدار آن زن در کروموزوم فرزندان، کلاً

عوض می‌شود و مقدار جدیدی جایگزین می‌گردد.

الگوریتم بهینه‌سازی ازدحام ذرات یک روش بهینه‌سازی مبتنی بر جمعیت است که از رفتار اجتماعی گروه‌های حیوانات مانند پرندگان و ماهی‌ها الهام گرفته شده است. در این الگوریتم، هر راه‌حل به عنوان یک ذره با موقعیت x_i و سرعت v_i نمایش داده می‌شود. هر ذره با توجه به تجربه شخصی خود (بهترین موقعیت شخصی $pbest_i$) و بهترین موقعیت کشف‌شده توسط کل جمعیت (بهترین موقعیت جهانی $gbest$) حرکت می‌کند. به‌روزرسانی سرعت و موقعیت ذرات به شکل زیر انجام می‌شود (وانگ و همکاران، ۲۰۱۸):

$$v_i(t+1) = w * v_i(t) + c_1 * r_1 * (pbest_i - x_i(t)) + c_2 * r_2 * (gbest - x_i(t)) \quad (48)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (49)$$

 که در آن w ضریب اینرسی، c_1 و c_2 ضرایب شتاب شخصی و اجتماعی و r_1, r_2 اعداد تصادفی در بازه $[0,1]$ هستند. این الگوریتم

به دلیل سادگی، سرعت همگرایی بالا و نیاز به تعداد کم پارامتر، در مسائل بهینه‌سازی پیوسته، یادگیری ماشین، مهندسی و طراحی سیستم‌ها بسیار مورد استفاده قرار می‌گیرد.

الگوریتم بهینه‌سازی گرگ خاکستری یک روش بهینه‌سازی جمعیتی است که رفتار شکار گرگ‌های خاکستری را مدل‌سازی می‌کند.

جمعیت گرگ‌ها به سه گروه اصلی تقسیم می‌شوند: α (بهترین راه‌حل)، β (دومین بهترین) و δ (سومین بهترین)، و بقیه گرگ‌ها (w) از این رهبران پیروی می‌کنند. موقعیت هر گرگ نسبت به رهبران به‌روزرسانی می‌شود تا به سمت طعمه (بهینه‌یابی تابع هدف) حرکت کند. معادلات اصلی به صورت زیر هستند (قهرمانی نهر و قادری، ۲۰۲۲):

$$\vec{D}_\alpha = |\vec{C}_1 * \vec{X}_\alpha - \vec{X}| \quad (50)$$

$$\vec{D}_\beta = |\vec{C}_2 * \vec{X}_\beta - \vec{X}| \quad (51)$$

$$\vec{D}_\delta = |\vec{C}_3 * \vec{X}_\delta - \vec{X}| \quad (52)$$

$$\vec{X}(t+1) = \frac{(\vec{X}_1 + \vec{X}_2 + \vec{X}_3)}{3} \quad (53)$$

که $\vec{X}_\alpha, \vec{X}_\beta, \vec{X}_\delta$ موقعیت رهبران و $\vec{C}_1, \vec{C}_2, \vec{C}_3$ بردارهای تصادفی برای ایجاد تنوع هستند. این الگوریتم به دلیل سادگی، همگرایی سریع و توانایی اجتناب از بهینه‌های محلی در مسائل مهندسی، یادگیری ماشین و طراحی سیستم‌ها کاربرد وسیع دارد.

پیش از به کارگیری الگوریتم‌های فراابتکاری برای حل مسائل، ضروری است که پارامترهای اولیه این الگوریتم‌ها به صورت بهینه تنظیم شوند. تنظیم دقیق پارامترها موجب افزایش کارایی الگوریتم و دستیابی سریع‌تر به پاسخ‌های بهینه در فضای مسأله می‌شود. به طور معمول، مقادیر بهینه پارامترها با استفاده از روش تاگوچی مشخص می‌شوند؛ این روش با بهره‌گیری از طراحی آزمایش‌ها و تحلیل واریانس، امکان تعیین سیستماتیک پارامترهای بهینه را فراهم کرده و تاثیر هر پارامتر بر عملکرد الگوریتم را نشان می‌دهد (نیکزاد و همکاران، ۲۰۲۵). نتایج حاصل از این تنظیمات در جدول ۱ ارائه شده است.

جدول ۱

سطوح عامل بهینه برای الگوریتم‌های فراابتکاری

پارامترها	Max it	N pop	p_m	p_c	w	c_1	c_2	A	C
GA	۳۰۰	۱۵۰	۰.۹۵	۰.۰۵	-	-	-	-	-
PSO	۳۰۰	۱۵۰	-	-	۰.۹۵	۱.۵	۲	-	-
GWO	۳۰۰	۱۵۰	-	-	-	-	-	۰.۴	۰.۹

یافته‌ها

در این بخش به تجزیه و تحلیل نتایج شامل بررسی خروجی‌های مدل ریاضی قیمت گذاری پویا در زنجیره تامین چند کاناله با حضور مشتریان استراتژیک پرداخته شده است. از این رو جهت اعتبار سنجی مدل ریاضی از نرم افزار تجاری GAMS و سولور Cplex استفاده شده است. در ادامه به منظور حل مدل ریاضی در اندازه‌های مختلف و بزرگتر از الگوریتم‌های فرا ابتکاری پیشنهادی استفاده شده است. به منظور اعتبار سنجی مدل ریاضی از نرم افزار تجاری GAMS استفاده شده است. با توجه به مدل توسعه یافته و خطی سازی شده از سولور Cplex استفاده شده است. از این رو یک مثال عددی در سایز کوچک متناسب با داده‌های ارائه شده در جدول (۲) طراحی و خروجی‌های مدل ریاضی نشان داده شده است. مثال عددی ارائه شده شامل ۳ نوع وسیله/مدنقلیه (زمینی، دریایی، هوایی)، ۲ طبقه خدماتی مشتریان (مشتریان استراتژیکی و غیر استراتژیکی)، ۲ نوع کانال فروش (آنلاین و آفلاین) و ۳ دوره زمانی (۳ روز) در نظر گرفته شده است.

جدول ۲

داده های استفاده شده در مثال عددی ساینز کوچک

پارامتر	طبقه خدماتی مشتریان	زمینی	دریایی	هوایی
k_v	-	۵۹	۱۳۳	۱۰۱
$M_{v,c}$	غیر استراتژیکی	۰.۲۰۹	۰.۲۵۸	۰.۱۳۵
	استراتژیکی	۰.۱۰۶	۰.۱۱۵	۰.۲۰۵
$P_{v,c,t}^{min}$	غیر استراتژیکی	روز ۱ = ۴۴.۰۹۱	روز ۱ = ۶۰.۰۱۷	روز ۱ = ۷۱.۱۷۸
		روز ۲ = ۴۳.۳۷۷	روز ۲ = ۹۹.۸۴۹	روز ۲ = ۳۲.۷۶۱
		روز ۳ = ۳۷.۹۲۴	روز ۳ = ۶۶.۲۹۹	روز ۳ = ۴۰.۰۰۶
	استراتژیکی	روز ۱ = ۴۷.۹۸۶	روز ۱ = ۹۹.۲۹۱	روز ۱ = ۷۳.۵۱۴
		روز ۲ = ۸۸.۵۰۲	روز ۲ = ۸۰.۹۸۰	روز ۲ = ۵۴.۸۲۹
		روز ۳ = ۲۵.۳۶۹	روز ۳ = ۳۰.۴۵۵	روز ۳ = ۴۸.۷۷۶
پارامتر	نوع کانال فروش	روز ۱	روز ۲	روز ۳
$\alpha_{s,t}$	آنلاین	۸۷.۵۰۲	۸۱.۷۸۱	۸۰.۳۴۱
	آفلاین	۸۵.۸۵۱	۸۶.۲۱۲	۸۳.۸۹۴
$\gamma_{s,t}$	آنلاین	۸۳.۵۸۷	۸۲.۴۳۰	۸۲.۴۶۴
	آفلاین	۸۱.۳۰۵	۸۹.۳۳۴	۸۳.۷۹۹
$\epsilon_{c,s,t}$	آنلاین	غیر استراتژیک = ۵.۶۲۷	غیر استراتژیک = ۸.۷۴۴	غیر استراتژیک = ۵.۳۴۶
		استراتژیک = ۷.۴۹۹	استراتژیک = ۵.۷۵۶	استراتژیک = ۵.۸۷۱
	آفلاین	غیر استراتژیک = ۶.۰۱۰	غیر استراتژیک = ۵.۰۲۵	غیر استراتژیک = ۶.۳۴۸
		استراتژیک = ۶.۶۵۳	استراتژیک = ۶.۵۸۵	استراتژیک = ۶.۶۱۰

علاوه بر موارد فوق، $P_{v,c,t}^{max} = 1.1P_{v,c,t}^{min}$ ، β_{c1} برابر با ۰.۶۷۰ و δ_{c2} برابر با ۰.۳۸۰ در نظر گرفته شده است. با توجه به داده های ارائه شده فوق، سود کل کسب شده برابر با ۸۳۷۳۶.۳۴۱ واحد می باشد. لذا تقاضای بالقول، قیمت بدست آمده و حجم فروش بدست آمده به شرح زیر می باشد.

جدول ۳

قیمت فروش بدست آمده از حل مثال عددی ساینز کوچک

طبقه خدماتی مشتریان	زمینی	دریایی	هوایی
غیر استراتژیکی	روز ۱ = ۴۸.۵۰۰	روز ۱ = ۶۰.۳۳۸	روز ۱ = ۷۱.۱۷۸
	روز ۲ = ۴۷.۷۱۵	روز ۲ = ۹۹.۸۴۹	روز ۲ = ۳۶.۰۳۸
	روز ۳ = ۴۱.۷۱۷	روز ۳ = ۶۶.۲۹۹	روز ۳ = ۴۴.۰۰۷
استراتژیکی	روز ۱ = ۵۲.۷۸۵	روز ۱ = ۹۹.۲۹۱	روز ۱ = ۸۰.۸۶۶
	روز ۲ = ۹۷.۳۵۲	روز ۲ = ۸۹.۰۷۸	روز ۲ = ۶۰.۳۱۱
	روز ۳ = ۲۷.۹۰۶	روز ۳ = ۳۳.۵۰۱	روز ۳ = ۵۳.۶۵۴

جدول ۴

تقاضای بالفعل بدست آمده از حل مثال عددی ساینز کوچک

روش حمل و نقل	طبقه خدمات مشتریان	نوع کانال فروش	روز ۱	روز ۲	روز ۳
زمینی	غیر استراتژیک	آنلاین	۴۹.۳۷۸	۴۱.۰۶۶	۴۷.۰۴۳
		آفلاین	۴۷.۳۴۴	۴۹.۲۱۶	۴۹.۵۹۴
	استراتژیک	آنلاین	۵۶.۰۲۸	۳۹.۶۷۸	۶۵.۹۸۹
		آفلاین	۵۴.۵۹۲	۴۵.۷۵۴	۶۶.۵۸۴
دریایی	غیر استراتژیک	آنلاین	۴۱.۴۴۶	۶.۱۳۴	۳۰.۵۷۲
		آفلاین	۳۹.۴۱۲	۱۴.۲۸۴	۳۳.۱۲۳
	استراتژیک	آنلاین	۳۸.۳۵۵	۴۲.۸۲۲	۶۳.۸۶۲
		آفلاین	۳۶.۹۱۹	۴۸.۸۹۸	۵۴.۴۵۸
هوایی	غیر استراتژیک	آنلاین	۳۴.۱۸۳	۴۸.۸۹۰	۴۵.۵۰۹
		آفلاین	۳۲.۱۴۹	۵۷.۰۴۰	۴۸.۰۵۹
	استراتژیک	آنلاین	۴۵.۳۵۷	۵۳.۷۵۴	۵۶.۲۰۴
		آفلاین	۴۳.۹۲۱	۵۹.۸۳۰	۵۶.۷۹۹

جدول ۵

حجم فروش بدست آمده از حل مثال عددی ساینز کوچک

روش حمل و نقل	طبقه خدمات مشتریان	نوع کانال فروش	روز ۱	روز ۲	روز ۳
زمینی	غیر استراتژیک	آنلاین	۲.۹۷۲	۱۹.۳۲۲	۴۷.۰۴۳
		آفلاین	۴.۴۰۸	۱۳.۲۴۶	۴۹.۵۹۴
	استراتژیک	آنلاین	۵۶.۰۲۸	۳۹.۶۷۸	۱۱.۹۵۷
		آفلاین	۵۴.۵۹۲	۴۵.۷۵۴	۹.۴۰۶
دریایی	غیر استراتژیک	آنلاین	۴۱.۴۴۶	۶.۱۳۴	۳۰.۵۷۲
		آفلاین	۳۹.۴۱۲	۱۴.۲۸۴	۳۳.۱۲۳
	استراتژیک	آنلاین	۳۸.۳۵۵	۴۲.۸۲۲	۶۳.۸۶۲
		آفلاین	۳۶.۹۱۹	۴۸.۸۹۸	۶۴.۴۵۸
هوایی	غیر استراتژیک	آنلاین	۳۴.۱۸۳	۴۷.۲۴۶	۴۴.۷۹۶
		آفلاین	۳۲.۱۴۹	۴۱.۱۷۰	۴۴.۲۰۱
	استراتژیک	آنلاین	۴۵.۳۵۷	۵۳.۷۵۴	۵۶.۲۰۴
		آفلاین	۴۳.۹۲۱	۵۹.۸۳۰	۵۶.۷۹۹

با توجه به جداول فوق مشاهده میشود، میانگین حجم فروش برای مشتریان استراتژیکی برابر با ۴۶.۰۳۳ و برای مشتریان غیر استراتژیکی برابر با ۳۰.۲۹۵ است. همچنین میانگین قیمت فروش نیز برای مشتریان استراتژیکی برابر با ۶۶.۰۸۲ و برای مشتریان غیر استراتژیکی برابر با ۵۷.۲۹۳ است.

در ادامه به تحلیل حساسیت مدل ریاضی و مقدار تابع سود کسب شده به ازای تغییرات در پارامترهای اصلی مسئله پرداخته شده است. در ابتدا مقدار سود کسب شده به ازای تغییرات ۱۰٪، ۲۰٪ و ۳۰٪ ظرفیت وسایل نقلیه مورد بررسی قرار گرفته و تغییرات در جدول زیر نشان داده شده است.

جدول ۶


تغییرات سود کسب شده در ظرفیت های مختلف حمل و نقل

تغییرات ظرفیت حمل و نقل	سود کسب شده	تغییرات سود
-۳۰٪	۷۳۱۵۵.۴۲۲	-۱۲.۶۳۶٪
-۲۰٪	۷۷۴۷۰.۷۲۱	-۷.۴۸۲٪
-۱۰٪	۸۰۶۳۵.۸۷۰	-۳.۷۰۲٪
بدون تغییر	۸۳۷۳۶.۳۴۱	بدون تغییر
+۱۰٪	۸۵۸۲۵.۳۷۵	+۲.۴۹۴٪
+۲۰٪	۸۷۴۹۷.۹۶۵	+۴.۴۸۲٪
+۳۰٪	۸۸۹۶۲.۵۹۰	+۶.۲۴۱٪

نتایج نشان میدهد با افزایش ۳۰٪ در ظرفیت حمل و نقل زمینی، دریایی و هوایی، سود کسب شده ۶.۲۴۱٪ افزایش یافته است. این موضوع به دلیل امکان حمل و نقل و فروش کالای بیشتر به مشتریان استراتژیکی و غیر استراتژیکی بوده است. از سوی دیگر با تغییر در ضرایب حساسیت قیمتی برای طبقات مشتریان استراتژیکی و غیر استراتژیکی، سود کسب شده در شکل (۳) نشان داده شده است.

شکل ۳

تغییرات سود کسب شده در ضرایب حساسیت قیمتی مختلف



نتایج نشان میدهد با کاهش ۳۰٪ ضریب حساسیت قیمتی مشتریان غیر استراتژیکی، سود کسب شده ۱۱.۸۸٪ و مشتریان استراتژیکی ۹.۲۹٪ افزایش یافته است. همچنین با کاهش ۲۰٪ این ضریب برای مشتریان غیر استراتژیکی، مسئله ناموجه بوده است. این مسئله نشان میدهد که رابطه معکوس بین ضرایب حساسیت قیمتی و سود کسب شده وجود دارد. در نهایت در جدول (۷) تغییرات سود کسب شده به ازای تغییرات در پارامترهای پایه مطلوبیت برای مشتریان استراتژیکی و غیر استراتژیکی نشان داده شده است.

جدول ۷


تغییرات سود کسب شده در پارامترهای پایه مطلوبیت مختلف

α	سود کسب شده	تغییرات سود	γ	سود کسب شده	تغییرات سود
۰٪	۸۳۷۳۶.۳۴۱	-	۰٪	۸۳۷۳۶.۳۴۱	-
+۱۰٪	۸۹۰۱۳.۶۲۵	+۶.۳۰٪	+۱۰٪	۹۰۳۴۰.۴۳۷	+۷.۸۸٪
+۲۰٪	۹۴۲۳۴.۰۱۸	+۱۲.۵۳٪	+۲۰٪	۹۶۷۲۶.۸۵۳	+۱۵.۵۱٪
+۳۰٪	۹۹۵۲۲.۳۸۷	+۱۸.۸۵٪	+۳۰٪	۱۰۲۵۲۵.۳۱۵	+۲۲.۴۳٪
+۴۰٪	۱۰۴۰۵۵.۱۵۹	+۲۴.۲۶٪	+۴۰٪	۱۰۷۵۹۸.۶۱۰	+۲۸.۴۹٪
+۵۰٪	۱۰۷۹۹۴.۸۹۲	+۲۸.۹۷٪	+۵۰٪	۱۱۱۷۷۲.۲۳۷	+۳۳.۴۸٪

جدول (۷) نشان میدهد که با افزایش پارامتر پایه مطلوبیت برای مشتریان غیر استراتژیکی به اندازه ۵۰٪، سود کسب شده ۲۸.۹۷٪ افزایش یافته است در حالی که با افزایش این مقدار برای مشتریان استراتژیکی، سود کسب شده ۳۳.۴۸٪ افزایش یافته است. در شکل (۴) نیز روند تغییرات سود کسب شده به ازای پارامترهای پایه مطلوبیت مختلف نشان داده شده است.

شکل ۴

تغییرات سود کسب شده در پارامترهای پایه مطلوبیت مختلف



پس از تحلیل حساسیت و بررسی متغیرهای مسئله، به دلیل $NP-Hard$ بودن مدل ریاضی ارائه شده در این مقاله، جهت تجزیه و تحلیل مثال‌های عددی در اندازه‌های بزرگتر از الگوریتم‌های فرا ابتکاری استفاده شده است. از این رو در ادامه ۱۵ مثال عددی در اندازه‌های مختلف طراحی و در جدول (۸) نشان داده شده است. اندازه اولین مثال عددی برابر با اندازه مثال عددی ارائه شده در بخش قبل می‌باشد. هم چنین حدود بازه‌ای پارامترهای مسئله نیز در جدول (۹) نشان داده شده است.

جدول ۸

اندازه مثال های عددی در سایزهای مختلف

مسئله نمونه	$ V $	$ C $	$ S $	$ T $	مسئله نمونه	$ V $	$ C $	$ S $	$ T $
۱	۳	۲	۲	۳	۹	۶	۶	۸	۱۶
۲	۳	۳	۳	۴	۱۰	۷	۷	۱۰	۱۸
۳	۳	۳	۳	۵	۱۱	۸	۸	۱۰	۲۰
۴	۴	۴	۳	۶	۱۲	۹	۹	۱۲	۲۲
۵	۴	۴	۴	۸	۱۳	۱۰	۱۰	۱۵	۲۴
۶	۵	۵	۶	۱۰	۱۴	۱۲	۱۲	۱۸	۲۷
۷	۵	۵	۶	۱۲	۱۵	۱۵	۱۵	۲۰	۳۰
۸	۶	۶	۸	۱۴					

جدول ۹

حدود بازه ای پارامترهای مسئله

پارامتر	حدود بازه ای	پارامتر	حدود بازه ای
k_v	$\sim U[40,150]$	$\alpha_{s,t}, \gamma_{s,t}$	$\sim U[80,90]$
$p_{v,c,t}^{min}$	$\sim U[20,100]$	β_{c_1}	0.670
$p_{v,c,t}^{max}$	$1.1 * p_{v,c,t}^{min}$	δ_{c_2}	0.380
$Q_{v,c,s,t}^{min}$	$\sim U[10,50]$	$M_{v,c}$	$\sim U[0.1,0.3]$
$Q_{v,c,s,t}^{max}$	$1.1 * Q_{v,c,s,t}^{min}$	$\varepsilon_{c,s,t}$	$\sim U[5,10]$

با توجه به اندازه های ارائه شده و همچنین حدود بازه ای پارامترهای مسئله، به تجزیه و تحلیل مثال های عددی پرداخته شده است. از این رو هر مثال عددی ۳ بار توسط هر الگوریتم فرا ابتکاری اجرا و بهترین سود کسب شده از هر الگوریتم، به عنوان بهترین عملکرد الگوریتم در هر مثال عددی در نظر گرفته شده است. در جدول (۱۰) سود کسب شده از هر مثال عددی به همراه زمان حل الگوریتم ها نشان داده شده است.

جدول ۱۰

سود کسب شده و زمان حل روش های پیشنهادی در هر مثال عددی

مسئله نمونه	سود کسب شده	زمان حل			
		GA	PSO	GWO	PSO
۱	۸۳۷۳۶.۳۴	۸۳۷۲۶.۳۴	۸۳۷۲۳.۴۹	۱۵.۳۶	۱۴.۳۵
۲	۹۲۲۰۴.۶۴	۹۲۳۲۳.۴۶	۹۲۳۷۰.۶۸	۱۶.۱۸	۱۵.۱۱
۳	۱۰۱۵۱۹.۰۱	۱۰۱۶۴۷.۳۹	۱۰۱۷۱۶.۸۶	۱۷.۵۹	۱۶.۴۴
۴	۱۱۱۳۲۹.۶۵	۱۱۱۳۴۹.۲۶	۱۱۱۵۱۵.۶۱	۱۹.۷۵	۱۸.۴۵
۵	۱۲۱۹۳۷.۵۸	۱۲۲۱۲۰.۶۸	۱۲۲۲۴۰.۶۷	۲۲.۸۸	۲۱.۳۷
۶	۱۳۴۴۳۵.۰۷	۱۳۴۶۸۳.۲۴	۱۳۴۸۰۷.۸۸	۲۷.۰۱	۲۵.۲۴
۷	۱۴۸۲۲۰.۸۸	۱۴۸۳۲۹.۹۷	۱۴۸۶۶۸.۶۵	۳۲.۴۵	۳۰.۳۱
۸	۱۶۳۶۱۷.۴۹	۱۶۳۶۴۴.۲۰	۱۶۴۱۲۲.۲۱	۴۰.۲۵	۳۷.۶۱
۹	۱۸۰۲۷۸.۱۰	۱۸۰۲۵۶.۹۱	۱۸۰۶۲۷.۴۷	۵۱.۱۰	۴۷.۷۴


۷۶.۸۰	۶۲.۴۱	۶۶.۸۰	۱۹۸۴۷۵.۱۵	۱۹۸۱۲۷.۱۳	۱۹۸۰۴۲.۴۳	۱۰
۱۰۳.۱۴	۸۳.۸۱	۸۹.۷۱	۲۱۹۲۷۹.۱۰	۲۱۹۰۴۹.۵۴	۲۱۸۷۹۵.۸۵	۱۱
۱۴۱.۸۰	۱۱۵.۲۳	۱۲۳.۳۴	۲۴۱۹۶۴.۹۰	۲۴۱۵۶۴.۲۲	۲۴۰۷۹۴.۷۳	۱۲
۲۰۰.۳۳	۱۶۲.۷۸	۱۷۴.۲۴	۲۶۶۳۰۶.۷۷	۲۶۵۱۲۲.۸۰	۲۶۳۸۷۲.۴۷	۱۳
۲۸۹.۵۹	۲۳۵.۳۱	۲۵۱.۸۸	۲۹۳۹۷۳.۵۵	۲۹۲۴۷۵.۵۷	۲۹۱۱۷۳.۱۶	۱۴
۴۲۵.۷۶	۳۴۵.۹۶	۳۷۰.۳۱	۳۲۷۳۸۰.۲۸	۳۲۵۶۸۳.۶۱	۳۲۴۱۲۲.۰۸	۱۵

بر اساس جدول فوق مشاهده می‌شود که عملکرد الگوریتم *GWO* در دستیابی به جواب بهینه، بهتر از دو الگوریتم *GA* و *PSO* بوده است. هر چند زمان حل در این الگوریتم بالاتر بوده است. به طور میانگین مشاهده می‌گردد که سود کسب شده توسط الگوریتم *GA* برابر با ۱۷۸۲۷۱.۹۷، الگوریتم *PSO* برابر با ۱۷۸۶۷۳.۶۲ و الگوریتم *GWO* برابر با ۱۷۹۱۴۴.۸۸ است. در حالی که میانگین زمان حل تمامی مسائل نمونه با *GA* برابر با ۸۷.۹۲، *PSO* برابر با ۸۲.۱۴ و *GWO* برابر با ۱۰۱.۰۹ است.

با مقایسه نتایج بدست آمده از الگوریتم‌های فرا ابتکاری در اولین مثال عددی با سود کسب شده توسط نرم افزار *GAMS*، مشاهده می‌گردد که درصد اختلاف نسبی بین مقدار بهینه و الگوریتم *GA* برابر با ۰ درصد، الگوریتم *PSO* برابر ۰.۰۱۱ درصد و الگوریتم *GWO* برابر با ۰.۰۱۵۳ درصد است. این نتایج نشان میدهد که عملکرد الگوریتم‌های فرا ابتکاری عالی بوده و حتی الگوریتم *GA* به مقدار بهینه نیز دست یافته است. بر این اساس در شکل (۵) همگرایی الگوریتم‌های فرا ابتکاری در دستیابی به جواب نزدیک به بهینه در اولین مثال عددی نشان داده شده است.

شکل ۵

همگرایی الگوریتم‌های فرا ابتکاری در کسب سود بهینه در اولین مثال عددی




نتایج شکل (۵) نشان میدهد که الگوریتم *GWO* بر خلاف عدم دستیابی به جواب بهینه، خیلی زودتر از دیگر الگوریتم‌ها به همگرایی رسیده است. این نشان دهنده قدرت جستجوی بالای الگوریتم *GWO* در دستیابی به جواب‌های نزدیک به بهینه است.

شکل (۶) و (۷) مقدار سود کسب شده و همچنین زمان حل هر مسئله نمونه را با الگوریتم‌های فراابتکاری نشان می‌دهد.

شکل ۶

سود کسب شده در مسائل نمونه مختلف




شکل (۶) نشان می‌دهد با افزایش تعداد دوره ها، وسایل حمل و نقل و همچنین کانالهای فروش، سود کسب شده نیز متعاقبا افزایش

یافته است.

شکل ۷

زمان حل مسائل نمونه مختلف



همچنین شکل (۷) نشان میدهد که با افزایش اندازه مسئله، زمان حل به صورت نمایی افزایش یافته است. این روند در بین هر سه الگوریتم یکسان بوده که نشان دهنده *NP-Hard* بودن مسئله نیز است.

از آنجایی که الگوریتم‌های مختلف از حیث سود کسب شده و زمان حل عملکردهای مختلف دارند، جهت مقایسه بهتر عملکرد الگوریتم‌ها از آزمون آماری *T-test* در سطح اطمینان ۹۵٪ استفاده شده است تا معناداری و عدم معناداری اختلاف میانگین‌های سود کسب شده و زمان حل بین دو به دوی الگوریتم‌ها مشخص شود. جدول (۱۱) خلاصه‌ای از نتایج آزمون *T-test* را در سطح اطمینان ۹۵٪ برای بررسی اختلاف معناداری شاخص‌ها نشان میدهد.

جدول ۱۱

از نتایج آزمون *T-test* را در سطح اطمینان ۹۵٪ برای بررسی اختلاف معناداری شاخص‌ها

شاخص	الگوریتم‌ها	اختلاف میانگین	یازه اطمینان ۹۵٪	T-Value	P-Value
سود کسب شده	GA-PSO	۴۰۲	(۵۶۴۸۹ ، -۵۷۲۹۲)	۰.۰۱	۰.۹۸۹
	GA-GWO	۸۷۶	(۵۷۹۴۵ ، -۵۶۱۹۹)	۰.۰۳	۰.۹۷۵
	PSO-GWO	۴۷۱	(۵۷۷۱۸ ، -۵۶۷۷۶)	۰.۰۲	۰.۹۸۷
زمان حل	GA-PSO	۵.۸	(۸۰.۹ ، -۶۹.۴)	۰.۱۶	۰.۸۷۶
	GA-GWO	۱۳.۲	(۹۶.۸ ، -۷۰.۵)	۰.۳۲	۰.۷۴۹
	PSO-GWO	۱۸.۹	(۱۰۰.۴ ، -۶۲.۶)	۰.۴۸	۰.۶۳۷

با توجه به مقدار *P-Value* در بین شاخص‌های بدست آمده که مقداری بزرگتر از ۰.۰۵ را دارد؛ نشان دهنده عدم وجود اختلاف معناداری در بین میانگین شاخص‌ها در بین الگوریتم‌ها فرابتکاری است. از این رو میتوان بیان کرد که عملکرد تمامی الگوریتم‌ها فرابتکاری در حل مدل ریاضی ارائه شده بالاست. هرچند الگوریتم *GWO* بهترین میانگین سود کسب شده را در بین دیگر الگوریتم‌ها دارد.

بحث و نتیجه‌گیری

نتایج این پژوهش تصویری روشن از پیچیدگی و پویایی قیمت‌گذاری در زنجیره‌های تأمین چندکاناله ارائه می‌دهد؛ به‌ویژه هنگامی که مشتریان استراتژیک با رفتار آینده‌نگر نیز بخشی از ساختار بازار باشند. تحلیل داده‌های به‌دست‌آمده نشان داد که مدل ارائه‌شده توانسته است تقاضای بالفعل، قیمت‌های بهینه و حجم فروش را با دقت بالا پیش‌بینی کند و هم‌زمان در چارچوب محدودیت‌های قیمتی، سهم بازار و ظرفیت حمل‌ونقل عمل نماید. این یافته‌ها با توجه به ادبیات موجود قابل تحلیل است، زیرا بسیاری از پژوهش‌ها تأکید کرده‌اند که در بازارهای چندکاناله، تصمیم‌های قیمتی تنها به قیمت فعلی وابسته نیست، بلکه به ویژگی‌های کانال، رفتار مشتریان و پویایی تقاضا بستگی دارد (Cai et al., 2019). نتایج این تحقیق نیز این نکته را تأیید می‌کند که کانال‌ها نقش کلیدی در شکل‌دهی رفتار خرید دارند و ترکیب قیمت، زمان و ویژگی‌های کانال می‌تواند الگوی فروش را به‌شکل معناداری تغییر دهد.

یکی از مهم‌ترین یافته‌های پژوهش آن بود که مشتریان استراتژیک نسبت به تغییرات قیمت واکنش متفاوتی نشان می‌دهند و میانگین قیمت بهینه برای این گروه بالاتر از مشتریان غیر استراتژیک تعیین شده است. این نتیجه با مطالعاتی همسو است که نشان می‌دهند مشتریان استراتژیک، باوجود حساسیت به آینده قیمت، حاضرند برای کسب مطلوبیت بالاتر (نظیر کیفیت خدمات یا تجربه خرید بهتر) قیمت‌های بیشتری پرداخت کنند (He et al., 2023). این رفتار، تأثیر قابل‌توجهی بر سودآوری زنجیره دارد، زیرا این دسته از مشتریان سهم مؤثرتری

در کل فروش ایفا می کنند. پژوهش های پیشین نیز بیان کرده اند که رفتار آینده نگر مشتریان می تواند ساختار قیمت گذاری را دستخوش تغییر کند و شرکت ها باید از طریق مدل سازی دقیق، راهبردهای سازگار با رفتار پیش بینی شده مشتریان تدوین کنند (Li, Yan et al., 2022). یافته های این پژوهش، ضمن تأیید این موضوع، نشان می دهد که قیمت گذاری پویا برای مشتریان استراتژیک نه تنها ضروری، بلکه در بسیاری از موارد سودآورتر از قیمت گذاری یکنواخت است.

تحلیل نتایج نشان داد که ظرفیت حمل و نقل نیز یکی از متغیرهای بسیار اثرگذار بر سودآوری است. در تحلیل حساسیت مشاهده شد که با افزایش ظرفیت، سود زنجیره تأمین به صورت تقریباً خطی افزایش یافته و تا بیش از شش درصد رشد داشته است. این نتیجه با پژوهش هایی سازگار است که نشان داده اند ظرفیت عرضه، محدودیتی ساختاری است که مستقیماً بر نرخ پاسخ دهی کانال ها و سطح خدمت اثر می گذارد و در نهایت سود را تحت تأثیر قرار می دهد (Ram et al., 2024). در مدل های چندکاناله نیز ذکر شده است که ظرفیت نه تنها عرضه کل را مشخص می کند، بلکه الگوی تخصیص فروش میان کانال ها را بازتنظیم می کند و می تواند منجر به بهبود ترکیب درآمدی شود (Chen et al., 2022). یافته های این پژوهش نشان می دهد که افزایش ظرفیت موجب می شود کانال های دارای تقاضای بالا (به ویژه کانال های آنلاین) بتوانند حجم بیشتری از مشتریان را جذب کنند و در نتیجه سود کل افزایش می یابد.

یکی دیگر از نتایج مهم پژوهش، اثرگذاری چشمگیر ضرایب حساسیت قیمتی بر سود بود. کاهش حساسیت قیمتی منجر به افزایش معنادار سود شد؛ به ویژه در گروه مشتریان استراتژیک. این یافته با نتایج پژوهش هایی همخوان است که بیان می کنند رابطه معکوسی میان حساسیت به قیمت و سود وجود دارد، زیرا هرچه مشتریان کمتر به تغییرات قیمت واکنش نشان دهند، امکان تعیین قیمت های پایدار و بهینه بیشتر می شود (Rahmani & Pashapour, 2024). به ویژه در بازارهای نسبتاً پایدار، شرکت ها می توانند با مدیریت برداشت مشتری از کیفیت خدمات و ارزش محصول، حساسیت قیمتی را کاهش دهند (Das et al., 2023). نتایج این پژوهش نیز همین نکته را تأیید می کند، زیرا نشان می دهد کاهش حساسیت قیمتی مشتریان استراتژیک می تواند سودزایی سیستم را تا سطح قابل توجهی ارتقا دهد.

افزون بر این، نتایج نشان داد که افزایش پارامترهای مطلوبیت پایه، اثر بسیار بیشتری بر سود دارد. این یافته با پژوهش هایی مطابقت دارد که نشان داده اند مطلوبیت ادراک شده مشتریان از کانال فروش، رابطه مستقیمی با تمایل پرداخت و احتمال خرید دارد (Song et al., 2023). در بسیاری از مدل های پویا و داده محور نیز تأکید شده است که بهبود تجربه مشتری، سهولت دسترسی، کیفیت خدمات پشتیبانی و اعتبار کانال می تواند مطلوبیت پایه را افزایش داده و تقاضا را تقویت کند (Kaul, 2023). در این پژوهش افزایش مطلوبیت پایه تا ۳۳ درصد باعث رشد سود شد که نتایج مطالعات مبتنی بر یادگیری ماشین در حوزه قیمت گذاری نیز چنین مسیری را تأیید می کنند (Ghaffari et al., 2025).

مقایسه روش های حل نیز نتایج ارزشمندی ارائه داد. الگوریتم GWO بهترین عملکرد را در دستیابی به مقادیر نزدیک به بهینه نشان داد، هرچند زمان حل آن نسبت به GA و PSO بیشتر بود. این موضوع با مطالعاتی همخوان است که توانایی GWO در همگرایی سریع و یافتن پاسخ های نزدیک به بهینه را تأیید کرده اند (Wang et al., 2018). در مقابل، الگوریتم PSO زمان حل کمتر و دقت قابل قبولی داشت که با یافته های پژوهشی مربوط به سرعت همگرایی PSO سازگار است (Wang et al., 2018). عملکرد الگوریتم ژنتیک نیز همان گونه که ادبیات اشاره کرده است، در پیدا کردن پاسخ های باکیفیت پایدار خوب بوده و در برخی موارد حتی قادر به یافتن پاسخ بهینه نیز بوده است (Sivanandam & Deepa, 2008). نتایج این پژوهش نشان می دهد که در مسائل بزرگ مقیاس، استفاده ترکیبی از این الگوریتم ها یا انتخاب الگوریتم بهینه سازی متناسب با وضعیت مسئله می تواند عملکرد حل را بهبود بخشد.

افزون بر این، یافته‌های پژوهش در مقایسه با اثرات ساختاری کانال‌های مختلف نیز قابل تحلیل است. مشابه آنچه در مطالعات چندکاناله ذکر شده، نتایج نشان داد کانال‌های آنلاین نسبت به تغییرات قیمت واکنش سریع‌تر و حجم فروش بیشتری دارند (Wang et al., 2021). این موضوع با مطالعاتی همسو است که بیان می‌کنند مشتریان آنلاین از نظر سرعت مقایسه قیمت و واکنش به تغییرات، فعال‌تر عمل می‌کنند (Hong et al., 2020). از سوی دیگر، نقش کانال‌های آفلاین نیز همچنان مهم است؛ به‌ویژه در طبقات مشتریانی که تمایل بیشتری به بررسی حضوری یا اعتماد بیشتر به خدمات سنتی دارند (Musavi et al., 2022). این پژوهش نشان داد که اگرچه کانال آنلاین سهم بیشتری از تقاضای بالقوه را جذب می‌کند، اما وجود هم‌زمان هر دو کانال باعث تعادل در جذب مشتریان در سطوح مختلف حساسیت می‌شود. نتایج همچنین نشان داد که مدل پیشنهادی قادر است نوسانات قیمتی را در دوره‌های زمانی مختلف مدیریت کند و ضمن رعایت محدودیت‌های نوسان قیمت، قیمت‌های بهینه را تنظیم نماید. این یافته با پژوهش‌هایی سازگار است که تأکید می‌کنند تغییرات بیش از حد قیمت موجب بی‌اعتمادی مشتریان و کاهش فروش می‌شود (Zhang & Zhang, 2022). به‌ویژه در بازارهای فصلی یا دارای نوسانات شدید، ثبات نسبی قیمت یک عامل کلیدی در حفظ مشتریان است (Hu et al., 2023). مدل حاضر با کنترل نوسانات قیمت و استفاده از توابع مطلوبیت آستانه‌ای توانسته است به‌گونه‌ای عمل کند که هم پویایی لازم را داشته باشد و هم از رفتار ناگهانی قیمت جلوگیری کند.

در بخش تقاضا نیز نتایج نشان می‌دهد که تقاضای بالفعل در هر دوره به‌شدت از پارامترهای مطلوبیت و قیمت تأثیر می‌پذیرد. این نتیجه را می‌توان با مطالعات مربوط به تصمیم‌گیری مشتریان در بازارهای پویا همسو دانست که نشان می‌دهند ترکیب قیمت، زمان و تجربه مشتری عوامل کلیدی در شکل‌دهی تقاضا هستند (Ma, 2020; Li & Mizuno, 2022). یکی از دستاوردهای مدل این است که توانسته است تقاضا را بر اساس توابع مطلوبیت آستانه‌ای با دقت بالا تخمین بزند. پژوهش‌های پیشین نیز نشان داده‌اند که مدل‌سازی دقیق مطلوبیت می‌تواند رفتار کانال‌ها را بهتر توضیح دهد و به افزایش سود کمک کند (Yeh et al., 2022).

نتیجه مهم دیگر پژوهش آن است که الگوریتم GWO در مقایسه با دیگر روش‌های بهینه‌سازی فرامتابی، توانست در کمترین تعداد تکرار به جواب نزدیک به بهینه برسد. این نتیجه با پژوهش‌هایی همسو است که گزارش کرده‌اند ساختار سلسله‌مراتبی و انعطاف‌پذیر GWO توانایی بالایی در جستجوی محیط‌های پیچیده دارد (Modak et al., 2025). در سوی مقابل، الگوریتم PSO نیز کارایی بالایی از نظر سرعت حل نشان داد، که این نیز با مطالعاتی هم‌خوان است که PSO را برای مسائل پیوسته با فضای جستجوی گسترده مناسب می‌دانند (Wang et al., 2018). همچنین الگوریتم ژنتیک در برخی مثال‌ها موفق به یافتن مقدار بهینه GAMS شد که بر قدرت این الگوریتم در یافتن جواب‌های کیفی تأکید دارد (Sivanandam & Deepa, 2008). این مقایسه نشان می‌دهد که استفاده از روش‌های فراابتکاری نه‌تنها عملکرد حل مدل را افزایش می‌دهد، بلکه می‌تواند در کاربردهای عملی با ابعاد بسیار بزرگ نیز مؤثر باشد.

در مجموع، نتایج این تحقیق بیانگر آن است که مدل توسعه‌یافته قادر است پیچیدگی‌های قیمت‌گذاری چندکاناله را همچون رفتار استراتژیک مشتریان، محدودیت ظرفیت، نوسانات زمانی قیمت و تفاوت‌های کانالی مدیریت کند. یافته‌ها همچنین نشان دادند که در ساختارهای پیچیده، استفاده از الگوریتم‌های فراابتکاری می‌تواند کارآمدی حل را افزایش دهد و تحلیل حساسیت ارائه‌شده نیز مسیری کاربردی برای مدیران فراهم می‌کند تا اثرات متغیرهای کلیدی را بهتر درک کنند و سیاست‌های قیمتی دقیق‌تری تدوین نمایند.

این پژوهش، هرچند از یک مدل ریاضی جامع و روش‌های حل قدرتمند بهره می‌برد، اما محدودیت‌هایی نیز دارد. نخست، مدل بر اساس تقاضای قطعی بنا شده و نوسانات واقعی بازار که ممکن است ناشی از رویدادهای غیرمنتظره، تغییرات فصلی یا عوامل رفتاری باشند در قالب عدم قطعیت تصادفی به‌طور کامل لحاظ نشده است. دوم، ساختار رقابتی میان چند تولیدکننده یا چند پلتفرم فروش در مدل فعلی گنجانده

نشده و مدل تنها به یک زنجیره چندکاناله واحد پرداخته است. سوم، داده‌های مورد استفاده در مثال‌های عددی به صورت مصنوعی شبیه‌سازی شده‌اند و ممکن است پیچیدگی‌های تقاضا و رفتار واقعی مشتریان در بازارهای پویا را به طور کامل بازنمایی نکنند.

برای تحقیقات آتی، پیشنهاد می‌شود که مدل با افزودن عدم قطعیت در تقاضا، قیمت رقبا و ظرفیت توسعه یابد و از روش‌های بهینه‌سازی تصادفی و استوار برای تحلیل شرایط واقعی‌تر استفاده شود. همچنین مدل می‌تواند به محیط‌های رقابتی چندتولیدکننده یا چندپلتفرمی تعمیم یابد تا اثرات رقابت قیمتی و تعاملات استراتژیک بهتر تحلیل شود. به کارگیری یادگیری ماشین برای پیش‌بینی تقاضا و استفاده از داده‌های واقعی پلتفرم‌های فروش دیجیتال نیز می‌تواند موجب ارتقای دقت مدل شود. در نهایت، افزودن سیاست‌های تبلیغات و ترویج در کنار قیمت‌گذاری می‌تواند چشم‌انداز جامع‌تری از تصمیم‌گیری‌های همزمان فراهم سازد.

برای مدیران زنجیره تأمین، پیشنهاد می‌شود از مدل‌های پویا برای تعیین قیمت‌های روزانه استفاده کنند تا تأثیر رفتار مشتریان استراتژیک بهتر مدیریت شود. همچنین بهبود تجربه مشتری و افزایش مطلوبیت کانال می‌تواند سودآوری را حتی بیش از تغییرات قیمت افزایش دهد؛ بنابراین سرمایه‌گذاری در کیفیت خدمات، شفافیت اطلاعات و کاهش زمان ارائه خدمات توصیه می‌شود. بهره‌گیری از الگوریتم‌های فراابتکاری—به ویژه در مسائل بزرگ و پیچیده—ابزاری مطمئن و قابل اتکا برای تصمیم‌گیری فراهم می‌کند. در نهایت، تحلیل حساسیت باید به عنوان بخشی ثابت از فرآیند تصمیم‌گیری مورد استفاده قرار گیرد تا اثرات تغییرات ناگهانی بازار بر سودآوری پیشاپیش شناسایی شود.

تقدیر و تشکر

از تمامی کسانی که در انجام این مطالعه همراهی نمودند تشکر و قدردانی می‌گردد.

تعارض منافع

در انجام مطالعه حاضر، هیچ گونه تضاد منافی وجود ندارد.

مشارکت نویسندگان

در نگارش این مقاله تمامی نویسندگان نقش یکسانی ایفا کردند.

موازین اخلاقی

در پژوهش حاضر تمامی موازین اخلاقی رعایت گردیده است.

شفافیت داده‌ها

داده‌ها و مآخذ پژوهش حاضر در صورت درخواست از نویسنده مسئول و ضمن رعایت اصول کپی رایت ارسال خواهد شد.

حامی مالی

این پژوهش حامی مالی نداشته است.

References

- Aliahmadi, A., Ghahremani-Nahr, J., & Nozari, H. (2023). Pricing decisions in the closed-loop supply chain network, taking into account the queuing system in production centers. *Expert Systems with Applications*, 212, 118741. <https://doi.org/10.1016/j.eswa.2022.118741>
- Cai, G. G., Dai, Y., & Zhang, W. (2019). Modeling multichannel supply chain management with marketing mixes: a survey. In *Handbook of research on distribution channels*. Edward Elgar Publishing. <https://doi.org/10.4337/9780857938602.00016>
- Chen, Z. S., Wu, S., Govindan, K., Wang, X. J., Chin, K. S., & Martínez, L. (2022). Optimal pricing decision in a multi-channel supply chain with a revenue-sharing contract. *Annals of Operations Research*, 318(1), 67-102. <https://doi.org/10.1007/s10479-022-04748-7>
- Das, R., Barman, A., Roy, B., & De, P. K. (2023). Pricing and greening strategies in a dual-channel supply chain with cost and profit sharing contracts. *Environment, Development & Sustainability*, 25(6). <https://doi.org/10.1007/s10668-022-02255-0>
- Ghaffari, A., Afsharian, M., & Taleizadeh, A. A. (2025). A Machine Learning Approach to Dynamic Pricing in Multi-Channel Transportation Supply Chains. *Supply Chain Analytics*, 100151. <https://doi.org/10.1016/j.sca.2025.100151>
- Ghahremani-Nahr, J., & Ghaderi, A. (2022). Robust-fuzzy optimization approach in design of sustainable lean supply chain network under uncertainty. *Computational and applied mathematics*, 41(6), 255. <https://doi.org/10.1007/s40314-022-01936-w>
- Ghahremani-Nahr, J., Nozari, H., & Szmelter-Jarosz, A. (2025). Location-inventory-pricing model in closed-loop supply chain network under the robust-fuzzy optimisation method. *Supply Chain Forum: An International Journal*, 26(3), 329-344. <https://doi.org/10.1080/16258312.2024.2440300>
- He, P., Zhang, G., Wang, T. Y., & Si, Y. (2023). Optimal two-period pricing strategies in a dual-channel supply chain considering market change. *Computers & Industrial Engineering*, 179, 109193. <https://doi.org/10.1016/j.cie.2023.109193>
- Hong, X., Zhuoran, X., Zhifeng, L., & Ruidi, X. (2020). Research on multi-channel pricing decision of cluster supply chain. 2020 Chinese Control And Decision Conference (CCDC),
- Hu, W., Ding, J., Yin, P., & Liang, L. (2023). Dynamic pricing and sales effort in dual-channel retailing for seasonal products. *Journal of Industrial & Management Optimization*, 19(2). <https://doi.org/10.3934/jimo.2022005>
- Kaul, D. (2023). Ai-driven real-time inventory management in hotel reservation systems: Predictive analytics, dynamic pricing, and integration for operational efficiency. *Emerging Trends in Machine Intelligence and Big Data*, 15(10), 66-80. https://www.researchgate.net/publication/394015205_AI-Driven_Real-Time_Inventory_Management_in_Hotel_Reservation_Systems_Predictive_Analytics_Dynamic_Pricing_and_Integration_for_Operational_Efficiency
- Li, M., & Mizuno, S. (2022). Dynamic pricing and inventory management of a dual-channel supply chain under different power structures. *European Journal of Operational Research*, 303(1), 273-285. <https://doi.org/10.1016/j.ejor.2022.02.049>
- Li, T., Sethi, S. P., & He, X. (2015). Dynamic pricing, production, and channel coordination with stochastic learning. *Production and Operations Management*, 24(6), 857-882. <https://doi.org/10.1111/poms.12320>
- Liu, S., Wang, J., Wang, R., Zhang, Y., Song, Y., & Xing, L. (2024). Data-driven dynamic pricing and inventory management of an omni-channel retailer in an uncertain demand environment. *Expert Systems with Applications*, 244, 122948. <https://doi.org/10.1016/j.eswa.2023.122948>
- Ma, J., Zhang, F., & Jiang, H. (2020). Dynamic pricing game under different channel power structures in a closed-loop supply chain. *International Journal of Bifurcation and Chaos*, 30(04), 2050052. <https://doi.org/10.1142/S0218127420500522>
- Modak, I., Bardhan, S., & Giri, B. C. (2025). Dynamic pricing and preservation strategy for a two-echelon perishable supply chain model with price and time sensitive demand: I. Modak et al. *Operational Research*, 25(3), 79. <https://doi.org/10.1007/s12351-025-00954-w>
- Musavi, M., Taleizadeh, A. A., Bozorgi-Amiri, A., & Moshtagh, M. S. (2022). Pricing decisions of organic and conventional products in a dual-channel competitive food supply chain. *Annals of Operations Research*, 1-37. <https://doi.org/10.1007/s10479-022-05009-3>
- Nikzad, M. H., Heidari-Rarani, M., & Mirkhalaf, M. (2025). A novel Taguchi-based approach for optimizing neural network architectures: Application to elastic short fiber composites. *Composites Science and Technology*, 259, 110951. <https://doi.org/10.1016/j.compscitech.2024.110951>
- Putri, N. P., & Pulansari, F. (2025). Pricing Strategy Analysis Based on Dual Channel Supply Chain (DCSC) Model Concept. *Afebi Management and Business Review*, 10(1), 64-76. <https://www.journal.afebi.org/index.php/ambr/article/view/952>
- Rahmani, D., & Pashapour, A. (2024). Dynamic pricing decision for new and returned products in a dual-channel supply chain based on customer segmentation. *Soft Computing*, 28(23), 13205-13224. <https://doi.org/10.1007/s00500-024-10310-3>
- Raju, S., Rofin, T. M., & Kumar, S. P. (2025). Pricing strategies for dual-channel supply chain members under pandemic demand disruptions. *Operational Research*, 25(2), 58. <https://doi.org/10.1007/s12351-025-00935-z>
- Ram, B., Lai, K. K., & Xiao, F. (2024). Retail reimagined: pricing optimization in single channel, multi-channel and omni-channel retailing. *Annals of Operations Research*, 1-26. <https://doi.org/10.1007/s10479-024-06305-w>
- Sarkar, A., & Pal, B. (2021). Competitive pricing strategies of multi channel supply chain under direct servicing by the manufacturer. *RAIRO-Operations Research*, 55, S1849-S1873. <https://doi.org/10.1051/ro/2020063>

- Sivanandam, S. N., & Deepa, S. N. (2008). Genetic algorithm optimization problems. In *Introduction to genetic algorithms* (pp. 165-209). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-73190-0_7
- Song, C. J., Xu, B. J., & Xu, L. (2023). Dual-channel supply chain pricing decisions for low-carbon consumers: A review. *Journal of intelligent management decision*, 2(2), 57-65. <https://doi.org/10.56578/jimd020202>
- Wang, D., Tan, D., & Liu, L. (2018). Particle swarm optimization algorithm: an overview. *Soft Computing*, 22(2), 387-408. <https://doi.org/10.1007/s00500-016-2474-6>
- Wang, Y., Chen, B., & Simchi-Levi, D. (2021). Multimodal dynamic pricing. *Management Science*, 67(10), 6136-6152. <https://doi.org/10.1287/mnsc.2020.3819>
- Wen, Y., Wei, Y., & Yu, X. (2025). Multi-channel pricing strategies for pharmaceutical supply chains considering channel power and price competition. *PLoS One*, 20(5), e0322143. <https://doi.org/10.1371/journal.pone.0322143>
- Yan, K., Liu, S., Zuo, M., Zheng, J., & Xu, Y. (2022). Dual-Channel Supply Chain Pricing Decisions under Discounted Advertising Value. *Systems*, 10(3), 76. <https://doi.org/10.3390/systems10030076>
- Yeh, W. C., Liu, Z., Yang, Y. C., & Tan, S. Y. (2022). Solving dual-channel supply chain pricing strategy problem with multi-level programming based on improved simplified swarm optimization. *Technologies*, 10(3), 73. <https://doi.org/10.3390/technologies10030073>
- Zhang, Y., & Zhang, T. (2022). Complex dynamics of pricing game model in a dual-channel closed-loop supply chain with delay decision. *International Journal of Bifurcation and Chaos*, 32(01), 2250013. <https://doi.org/10.1142/S0218127422500134>