

## Designing a Predictive Model for Product Acceptance Rate in Lean Manufacturing Using an Artificial Neural Network

Mehrnaz Bahramzad<sup>1</sup>, Sadegh Abedi<sup>2,\*</sup>, Reza Ehtesham Rasi<sup>2</sup>

<sup>1</sup> Ph.D. Student, Department of Industrial Management, Qazvin Branch, Islamic Azad University, Qazvin, Iran

<sup>2</sup> Assistant Professor, Department of Industrial Management, Qazvin Branch, Islamic Azad University, Qazvin, Iran

<sup>3</sup> Associate Professor, Department of Industrial Management, Qazvin Branch, Islamic Azad University, Qazvin, Iran

### HIGHLIGHTS

- Identification of six key variables as model inputs for predicting product acceptance in lean manufacturing.
- Use of an artificial neural network to analyze complex and nonlinear relationships.
- Development of a data-driven model to support more accurate decision-making for quality improvement and waste reduction.

### ARTICLE INFO

#### Article history:

Article Type: Research paper

Received: 25 November 2025

Revised: 6 February 2026

Accepted: 28 March 2026

Available online: 30 April 2026

\*Correspondence:

[abedi.sadegh@iau.ac.ir](mailto:abedi.sadegh@iau.ac.ir)

#### How to cite this article:

Bahramzad, M., Abedi, S., & Rasi, R. E. (2027). Designing a predictive model for product acceptance rate in lean manufacturing using an artificial neural network. *System Engineering and Productivity*, 6 (4), 55-80.

#### Keywords:

Lean Manufacturing

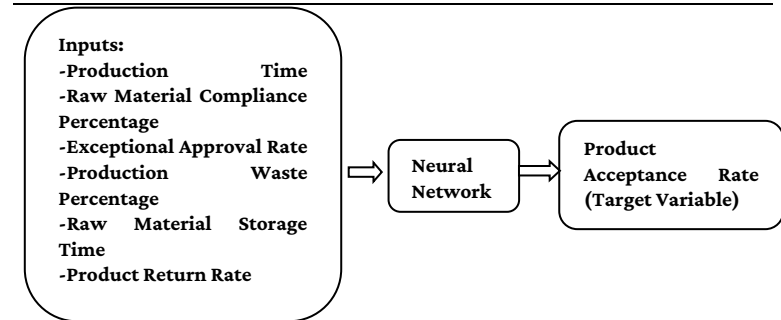
Product Acceptance

Artificial Neural Network

Production Quality

Predictive Model

### GRAPHICAL ABSTRACT



### ABSTRACT

The aim of the present study is to develop a data-driven and predictive model for forecasting the product acceptance rate in a lean manufacturing environment using an artificial neural network. In the first step, potential variables influencing product acceptance were identified through a systematic review of the literature and by eliciting the opinions of experts in lean manufacturing and quality management. The final selection of input variables was then carried out using the fuzzy Delphi method. Subsequently, 4,800 data records extracted from food industry production lines over a two-year period were used as the quantitative data for the study. The predictive model was designed and trained based on a feedforward artificial neural network, and its performance was compared with several benchmark regression models, including linear regression, decision tree, random forest, and support vector machine. The results showed that the artificial neural network model, with a coefficient of determination of 0.88, achieved higher predictive accuracy than the benchmark models and demonstrated a strong capability in modeling nonlinear relationships between quality- and process-related variables and the product acceptance rate. Furthermore, variable importance analysis revealed that raw material quality and the percentage of production waste played the most significant roles in predicting the product acceptance rate. The findings indicate that improving a single factor in isolation does not guarantee an increase in product acceptance, and that sustainable outcomes can only be achieved through the simultaneous management of multiple key variables.

## 1. Introduction

In recent decades, manufacturing industries—particularly the food sector—have been confronted with increasing pressure to improve product quality, reduce waste, enhance productivity, and respond quickly to market fluctuations (Al-Shboul, 2025; Abedi et al., 2025). The complexity of production processes, the vast amount of operational data, and the stringent requirements of quality standards have made traditional quality-control and decision-making approaches inadequate for today's competitive environment (Batwara et al., 2025). Under such conditions, lean manufacturing is recognized as one of the most effective managerial approaches, as it focuses on eliminating waste, improving value flow, and enhancing efficiency, thus playing a crucial role in optimizing production systems. At the same time, Total Quality Management, as a complementary framework, emphasizes continuous improvement, employee involvement, and data-driven decision-making, providing a strong foundation for elevating product and process quality (Sundararajan & Terkar, 2022). In parallel with these developments, the rapid advancement of intelligent technologies and machine-learning capabilities has enabled the analysis of complex production data and the high-accuracy prediction of operational outcomes. Artificial neural networks, as one of the most powerful tools in machine learning, possess the ability to model nonlinear and multidimensional relationships, making them highly effective in industrial environments—particularly in predicting quality- and performance-related behaviors. Integrating such technologies with lean-manufacturing principles has opened new opportunities for developing intelligent predictive systems capable of extracting hidden patterns from production data and forecasting product-quality outcomes before defects occur (Sunmola et al., 2024). Accordingly, the foundation of the present research lies at the intersection of three core domains: lean manufacturing, Total Quality Management, and machine learning. The study focuses on designing a predictive model for product acceptance in lean production lines—one that can address existing challenges in the food industry related to quality variability, waste levels, and product acceptance rates from a data-driven perspective (Tavana et al., 2025). The importance of this research stems from the fact that many manufacturing firms still struggle with high waste, fluctuations in raw-material quality, product nonconformity, customer returns, and limited ability to predict production outcomes. (Synnes & Welo, 2022). In an environment marked by intense competition, rapid demand changes, and strict regulatory requirements, relying on reactive or experience-based decisions not only increases costs and time but may also reduce productivity and

damage brand credibility. Therefore, the need for predictive, data-driven models capable of estimating product quality and acceptance before defects occur has become a managerial and operational necessity. In the food industry, where safety and quality sensitivities are high, the inability to anticipate product behavior can reduce customer satisfaction, increase rework costs, and even threaten consumer health (Ferrazzi et al., 2025). On the other hand, lean manufacturing can only reach its maximum efficiency when decisions are predictive and based on real-time analysis rather than final inspection results. Artificial neural networks, through their ability to analyze complex patterns and accurately model relationships between production variables, enable organizations to forecast product quality at early stages and prevent costly errors and waste. Thus, the necessity of this research lies in providing a scientific, operational, data-driven model that equips production and quality managers with the ability to intervene before problems occur and increase product acceptance levels (Deshmukh et al., 2022; Batista et al., 2021; Habib et al., 2023; Hariyani et al., 2023; Hossain & Purdy, 2023; Huang et al., 2024; Jing et al., 2021; Kosasih et al., 2023; Lakshmanan et al., 2023; Liakos et al., 2025; Limon-Romero et al., 2025; Marodin et al., 2018).

This study directly responds to the practical needs of industry to develop intelligent tools for quality and production management that align with lean and data-driven approaches. Although lean manufacturing and Total Quality Management have been extensively examined in existing literature, few studies have developed predictive models for product acceptance using real production data. Most prior studies rely on linear statistical methods that are unable to model the nonlinear and multidimensional nature of production data. Moreover, the integrated use of artificial neural networks with selected lean-production indicators for predicting product acceptance has not yet been comprehensively and practically explored in the food industry. The main problem addressed in this research emerges from the fact that, in many production facilities—especially in food manufacturing—decisions regarding product acceptance or rejection are still made based on end-stage inspection, while the factors influencing product acceptance, such as raw-material quality, waste levels, storage duration, and process conditions, have complex nonlinear interactions. The absence of a predictive, data-driven model for estimating this behavior leads to increased waste and reduced quality. Therefore, the main objective of this research is to design an intelligent artificial neural network model that can predict product-acceptance rates before production is completed, using key lean-production indicators, and thus enable timely intervention and proactive decision-making by managers. In the remainder of the paper, Section 2 presents the theoretical foundations of lean

manufacturing, Total Quality Management, and machine-learning applications in quality prediction. Section 3 explains the research methodology, including data-collection procedures, variable selection, and neural-network model structure. Section 4 provides the modeling results and evaluates the neural network's performance in predicting product-acceptance rates. Section 5 discusses the findings and outlines managerial and practical implications. Finally, Section 6 presents the conclusions and suggests directions for future research.

## 2. Methodology

This study adopts a systematic mixed-method research design to develop a predictive model for product acceptance in lean manufacturing environments. The research is applied in nature and aims to create a practical model for improving product quality and reducing waste in the food industry. Data were collected at two levels: qualitative insights from industry experts to identify key factors influencing product acceptance, and 4,800 real production records containing variables such as waste levels, processing times, quality-test results, and acceptance rates. In the qualitative phase, a fuzzy Delphi approach was used to evaluate expert opinions and prioritize critical indicators under conditions of uncertainty. In the quantitative phase, these indicators were validated using real production data and incorporated into a machine-learning model. Data collection was conducted through library research, semi-structured expert interviews, and extraction of historical quality-control data from production systems. Expert participants were selected through purposive sampling based on experience and technical expertise in lean production and quality management. Quantitative data underwent preprocessing, including cleaning, normalization, and removal of outliers, before being modeled using an Artificial Neural Network to capture nonlinear relationships. Model performance was evaluated through accuracy, MAE, MSE and  $R^2$ . The multi-stage methodology ensured that the final model was both theoretically grounded and capable of real-world industrial application.

## 3. Results and Discussion

The results of the neural network model indicate that product acceptance in lean manufacturing is strongly influenced by a combination of key process and quality variables. Among these, raw-material quality showed the highest importance, confirming that the quality of inputs plays a decisive role in determining final product conformity. Daily production waste also demonstrated a significant impact, reflecting the direct relationship between process efficiency and product acceptance. Variables such as production-shift time and raw-material

storage duration showed moderate effects, suggesting that operational timing and material handling conditions influence product quality in indirect yet meaningful ways. Exceptional approval rate and customer return rate were found to have lower relative importance, although their contribution to overall product performance remains noticeable. The neural network successfully captured nonlinear patterns within the dataset, outperforming traditional linear methods and validating the suitability of machine-learning models for predicting quality outcomes. These findings emphasize the need for predictive, data-driven decision-making in lean systems and highlight the practical value of integrating intelligent models into production planning and quality management.

## 4. Conclusions

This study developed an intelligent predictive model to estimate product acceptance in lean manufacturing environments using real operational data and machine-learning techniques. The findings highlight that raw-material quality and production waste are the most influential factors shaping acceptance outcomes, while other process variables also contribute through complex nonlinear interactions. The neural network demonstrated strong predictive capability, showing clear advantages over traditional analytical approaches. The results underscore the importance of shifting from reactive quality assessment to proactive, data-driven decision-making. The proposed model provides a practical tool for improving quality control, reducing waste, and enhancing operational performance across food-production systems.

## Funding

This research received no external funding.

## Author contributions

All authors have had equal roles and contributions to the article.

## Conflicts of interest

There are no conflicts of interest associated with this research.

## Acknowledgments

We are grateful to all colleagues who provided insights and expertise that greatly assisted this research. We also thank the anonymous reviewers for their valuable suggestions to improve the paper.

## References

- Abedi, S., Karimi, M. R., & Alinezhad, A. (2025). Predicting and Analyzing Pathways toward Sustainable Development of the Mining Sector under the NZE Scenario: An Integrated Approach Using Fuzzy MCDM and

- ANFIS. *Journal of Mining and Environment* (In Persian).  
<https://doi.org/10.22044/jme.2025.16846.3304>
- Al-Shboul, M. D. A. (2025). Assessing sustainability of green supply chain performance: The roles of agile innovative products, business intelligence readiness, innovative supply chain process integration, and lean supply chain capability as a mediating factor. *Journal of Open Innovation: Technology, Market, and Complexity*, 11(1), 100476.  
<https://doi.org/10.1016/j.joitmc.2025.100476>
- Batista, L. F., Marques, C. S., Pires, A. C. S., Minim, L. A., Soares, N. F. F., & Vidigal, M. C. T. R. (2021). Artificial neural networks modeling of non-fat yogurt texture properties: Effect of process conditions and food composition. *Food and Bioprocess Technology*, 126, 164–174.  
<https://doi.org/10.1016/j.fbp.2021.01.002>
- Batwara, A., Kediya, S., & Kayande, R. A. (2025). An analytical framework for optimizing supply chain operations with lean practices. *Supply Chain Analytics*, 11, 100145.  
<https://doi.org/10.1016/j.sca.2025.100145>
- Deshmukh, M., Gangele, A., Gope, D. K., & Dewangan, S. (2022). Study and implementation of lean manufacturing strategies: A literature review. *Materials Today: Proceedings*, 62(3), 1489–1495.  
<https://doi.org/10.1016/j.matpr.2022.02.155>
- Ferrazzi, M., Costa, F., Frecassetti, S., & Portioli-Staudacher, A. (2025). Unlocking synergies in lean manufacturing for enhanced environmental performance: A cross-sector investigation through fuzzy DEMATEL. *Cleaner Logistics and Supply Chain*, 15, 100219.  
<https://doi.org/10.1016/j.clscn.2025.100219>
- Habib, M. A., Rizvan, R., & Ahmed, S. (2023). Implementing lean manufacturing for improvement of operational performance in a labeling and packaging plant: A case study in Bangladesh. *Results in Engineering*, 17, 100818.  
<https://doi.org/10.1016/j.rineng.2022.100818>
- Hariyani, D., Mishra, S., Sharma, M. K., & Hariyani, P. (2023). A study of the barriers to the adoption of integrated sustainable-green-lean-six sigma-agile manufacturing system (ISGLSAMS) in Indian manufacturing organizations. *Cleaner Waste Systems*, 5, 100098.  
<https://doi.org/10.1016/j.clwas.2023.100098>
- Hossain, M. M., & Purdy, G. (2023). Integration of Industry 4.0 into lean production systems: a systematic literature review. *Manufacturing Letters*, 35, 1347-1357.  
<https://doi.org/10.1016/j.mfglet.2023.08.098>
- Huang, X., You, Y., Zeng, X., Liu, Q., Dong, H., Qian, M., Xiao, S., Yu, L., & Hu, X. (2024). Back propagation artificial neural network (BP-ANN) for prediction of the quality of gamma-irradiated smoked bacon. *Food Chemistry*, 437(Part 1), 137806.  
<https://doi.org/10.1016/j.foodchem.2023.137806>
- Jing, S., Feng, Y., & Yan, J. (2021). Path selection of lean digitalization for traditional manufacturing industry under heterogeneous competitive position. *Computers & Industrial Engineering*, 161, 107631.  
<https://doi.org/10.1016/j.cie.2021.107631>
- Kosasih, W., Pujawan, I. N., Karningsih, P. D., & Shee, H. (2023). Integrated lean-green practices and supply chain sustainability framework. *Cleaner and Responsible Consumption*, 11, 100143.  
<https://doi.org/10.1016/j.clrc.2023.100143>
- Lakshmanan, R., Nyamekye, P., Virolainen, V. M., & Piili, H. (2023). The convergence of lean management and additive manufacturing: Case of manufacturing industries. *Cleaner Engineering and Technology*, 13, 100620.  
<https://doi.org/10.1016/j.clet.2023.100620>
- Liakos, K. G., Athanasiadis, V., Bozinou, E., & Lalas, S. I. (2025). Machine learning for quality control in the food industry: A review. *Foods*, 14(19), 3424. <https://doi.org/10.3390/foods14193424>
- Limon-Romero, J., García-Alcaraz, J. L., Gastelum-Acosta, C., Antony, J., Baez-Lopez, Y., & Tortorella, G. (2025). Toward the successful adoption of Lean Six Sigma in manufacturing organizations: proposing a causal model. *International Journal of Productivity and Performance Management*, 74(6), 1897-1918.  
<https://doi.org/10.1108/IJPPM-07-2024-0436>
- Marodin, G., Frank, A. G., Tortorella, G. L., & Netland, T. (2018). Lean product development and lean manufacturing: Testing moderation effects. *International Journal of Production Economics*, 203, 301-310.  
<https://doi.org/10.1016/j.ijpe.2018.07.009>
- Sundararajan, N., & Terkar, R. (2022). Improving productivity in fastener manufacturing through the application of Lean-Kaizen principles. *Materials Today: Proceedings*, 62, 1169-1178.  
<https://doi.org/10.1016/j.matpr.2022.04.350>
- Sunmola, F., Mbafotu, O. R., Salihu-Yusuf, M. L., & Sunmola, H. O. (2024). Lean green practices in automotive components manufacturing. *Procedia Computer Science*, 232, 2001-2008.  
<https://doi.org/10.1016/j.procs.2024.02.022>
- Synnes, E. L., & Welo, T. (2022). Using lean to transform the product development process in a marine company: A case study. *Procedia CIRP*, 109, 623-628.  
<https://doi.org/10.1016/j.procir.2022.05.304>

Tavana, M., Di Caprio, D., & Rostamkhani, R. (2025). A total quality management action plan assessment model in supply chain management using the lean and agile scores. *Journal of Innovation & Knowledge*, 10(1), 100633.  
<https://doi.org/10.1016/j.jik.2024.100633>

## طراحی مدل پیش‌بینی نرخ پذیرش محصول در تولید ناب با استفاده از شبکه عصبی مصنوعی

مهرناز بهرام‌زاد<sup>۱</sup>، صادق عابدی<sup>۲\*</sup>، رضا احتشام رائی<sup>۳</sup>

<sup>۱</sup> دانشجوی دکتری، گروه مدیریت صنعتی، دانشکده مدیریت، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران

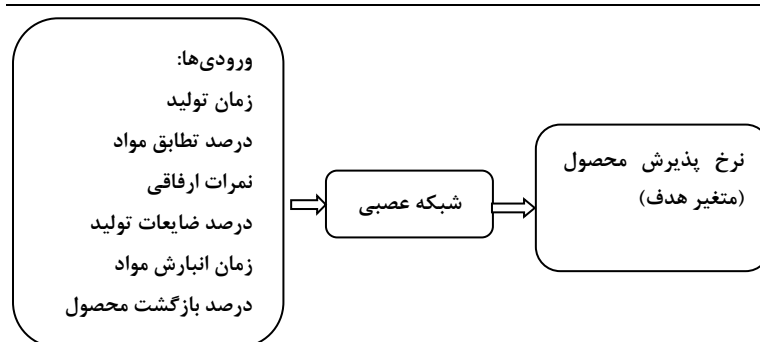
<sup>۲</sup> استادیار، گروه مدیریت صنعتی، دانشکده مدیریت، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران

<sup>۳</sup> دانشیار، گروه مدیریت صنعتی، دانشکده مدیریت، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران

### برجسته‌ها

- شناسایی شش متغیر کلیدی به‌عنوان ورودی مدل برای پیش‌بینی نرخ پذیرش محصول در تولید ناب
- استفاده از شبکه عصبی برای تحلیل روابط پیچیده و غیرخطی
- ارائه یک مدل داده‌محور جهت تصمیمات دقیق‌تری برای بهبود کیفیت و کاهش ضایعات

### چکیده گرافیکی



### مشخصات مقاله

#### تاریخچه مقاله:

نوع مقاله: پژوهشی

دریافت: ۱۴۰۴/۰۹/۰۸

بازنگری: ۱۴۰۴/۱۱/۱۷

پذیرش: ۱۴۰۴/۰۱/۰۸

ارائه برخط: ۱۴۰۵/۰۲/۱۰

\*نویسنده مسئول:

[abedi.sadegh@iau.ac.ir](mailto:abedi.sadegh@iau.ac.ir)

#### کلیدواژه‌ها:

تولید ناب  
پذیرش محصول  
شبکه عصبی مصنوعی  
کیفیت تولید  
مدل پیش‌بینی

### چکیده

هدف پژوهش حاضر طراحی یک مدل داده‌محور و پیش‌بینانه برای پیش‌بینی نرخ پذیرش محصول در محیط تولید ناب با استفاده از شبکه عصبی مصنوعی است. در گام نخست، متغیرهای بالقوه مؤثر بر پذیرش محصول از طریق مرور نظام‌مند ادبیات و اخذ دیدگاه خبرگان حوزه تولید ناب و مدیریت کیفیت شناسایی شد. سپس، انتخاب نهایی متغیرهای ورودی با بهره‌گیری از روش دلفی فازی انجام گرفت. در ادامه، ۴۸۰۰ داده استخراج‌شده از خطوط تولید صنایع غذایی طی یک بازه زمانی دوساله به‌عنوان داده‌های کمی پژوهش مورد استفاده قرار گرفت. مدل پیش‌بینی بر پایه شبکه عصبی مصنوعی پیش‌خور طراحی و آموزش داده شد و عملکرد آن با چند مدل رگرسیونی مرجع شامل رگرسیون خطی، درخت تصمیم، جنگل تصادفی و ماشین بردار پشتیبان مقایسه گردید. نتایج نشان داد که مدل شبکه عصبی مصنوعی با ضریب تعیین ۰/۸۸، عملکرد دقیق‌تری نسبت به مدل‌های مرجع دارد و توانایی بالایی در مدل‌سازی روابط غیرخطی میان متغیرهای کیفی و فرایندی و نرخ پذیرش محصول ارائه می‌دهد. همچنین تحلیل اهمیت متغیرها نشان داد کیفیت مواد اولیه و درصد ضایعات تولید بیشترین نقش را در پیش‌بینی نرخ پذیرش محصول ایفا می‌کنند. یافته‌ها بیانگر آن است که بهبود تک‌بعدی یک عامل به‌تنهایی تضمین‌کننده افزایش پذیرش محصول نیست و مدیریت هم‌زمان چند متغیر کلیدی برای دستیابی به نتایج پایدار ضروری است.

## ۱- مقدمه

بازگشت محصولات از مشتری و ضعف در قابلیت پیش‌بینی خروجی‌های تولید مواجه هستند.

در محیطی که رقابت شدید، تغییرات سریع تقاضا و الزامات قانونی سخت‌گیرانه وجود دارد، اتخاذ تصمیمات واکنشی یا مبتنی بر تجربه، نه تنها هزینه‌زا و زمان‌بر است، بلکه می‌تواند به کاهش اعتبار برند و کاهش بهره‌وری منجر شود (Ferrazzi et al., 2025). در صنایع غذایی که حساسیت‌های ایمنی و کیفیت در آن‌ها بسیار بالاست، عدم توانایی در پیش‌بینی رفتار محصولات می‌تواند منجر به کاهش رضایت مشتری، افزایش هزینه‌های دوباره‌کاری و حتی تهدید سلامت مصرف‌کننده شود. از سوی دیگر، تولید ناب تنها زمانی می‌تواند به حداکثر کارایی خود برسد که تصمیم‌گیری‌ها مبتنی بر داده و تحلیل پیش‌نگرانه باشد، نه بر مبنای بررسی نتایج نهایی تولید باشد (Sahoo, 2020).

بیان مسئله اصلی این پژوهش از آنجا نشأت می‌گیرد که در بسیاری از واحدهای تولیدی، به‌ویژه صنایع غذایی، تصمیم‌گیری درباره پذیرش یا رد محصول همچنان بر پایه ارزیابی‌های پایانی و واکنشی انجام می‌شود، درحالی‌که عوامل مؤثر بر پذیرش محصول مانند کیفیت مواد اولیه، میزان ضایعات، زمان انبارش و شرایط تولید دارای روابط پیچیده و غیرخطی هستند و نبود یک مدل داده‌محور برای پیش‌بینی این رفتار موجب افزایش ضایعات و کاهش کیفیت می‌شود.

از این‌رو هدف اصلی پژوهش آن است که مدلی مبتنی بر یادگیری ماشین طراحی کند تا بتواند با استفاده از شاخص‌های کلیدی تولید ناب، نرخ پذیرش محصول را قبل از تکمیل فرآیند تولید با دقت بالا پیش‌بینی کرده و امکان مداخله بهنگام و تصمیم‌گیری پیش‌نگر را برای مدیران فراهم سازد. در ادامه ساختار مقاله در بخش دوم، ادبیات نظری مرتبط با تولید ناب، مدیریت کیفیت جامع و کاربردهای یادگیری ماشین در پیش‌بینی کیفیت مرور می‌شود. بخش سوم به تشریح روش‌شناسی پژوهش شامل مراحل گردآوری و آماده‌سازی داده‌ها، انتخاب شاخص‌ها و ساختار مدل اختصاص دارد. در بخش چهارم، نتایج مدل‌سازی ارائه و عملکرد مدل در پیش‌بینی نرخ پذیرش محصول تحلیل می‌شود. در بخش پنجم، یافته‌ها تفسیر شده و پیامدهای مدیریتی و کاربردی پژوهش بیان می‌گردد.

در دهه‌های اخیر، صنایع تولیدی به‌ویژه در بخش مواد غذایی با فشار فزاینده‌ای برای ارتقای کیفیت، کاهش ضایعات، افزایش بهره‌وری و پاسخ‌گویی سریع به نوسانات بازار مواجه شده‌اند. پیچیدگی فرآیندهای تولید، گستردگی داده‌های عملیاتی و الزامات سخت‌گیرانه استانداردهای کیفی باعث شده است که رویکردهای سنتی کنترل کیفیت و تصمیم‌گیری دیگر پاسخ‌گوی نیازهای رقابتی امروز نباشند (Hariyani et al., 2023). در چنین شرایطی، تولید ناب به‌عنوان یکی از کارآمدترین رویکردهای مدیریتی شناخته می‌شود که با تمرکز بر حذف اتلاف، بهبود جریان ارزش و افزایش کارایی، نقشی اساسی در بهینه‌سازی سیستم‌های تولیدی ایفا می‌کند (Elnadi et al., 2025). هم‌زمان با این تحولات، توسعه فناوری‌های هوشمند و قابلیت‌های یادگیری ماشین زمینه را برای تحلیل داده‌های پیچیده تولید و پیش‌بینی نتایج عملیاتی با دقت بالا فراهم کرده است (Tavana et al., 2025).

شبکه‌های عصبی مصنوعی به‌عنوان یکی از قدرتمندترین ابزارهای یادگیری ماشین توانایی مدل‌سازی روابط غیرخطی و چندبعدی را دارند و می‌توانند در محیط‌های صنعتی، به‌ویژه در پیش‌بینی رفتارهای کیفی و عملیاتی، عملکردی بسیار کارآمد داشته باشند. ترکیب این فناوری با اصول تولید ناب فرصت تازه‌ای برای ایجاد سیستم‌های هوشمند پیش‌بینی‌کننده فراهم کرده است که قادرند الگوهای پنهان در داده‌های تولیدی را استخراج کرده و کیفیت خروجی‌های تولید را پیش از وقوع خطا پیش‌بینی کنند (Bueno et al., 2023). در نتیجه، زمینه پژوهش حاضر بر تقاطع دو حوزه کلیدی تولید ناب و یادگیری ماشین استوار است که تمرکز آن بر طراحی مدلی پیش‌بینانه برای نرخ پذیرش محصول در خطوط تولید ناب می‌باشد؛ مدلی که بتواند چالش‌های جاری صنایع غذایی را در زمینه کیفیت، ضایعات و پذیرش محصول از منظر داده‌محور حل‌وفصل کند. اهمیت این پژوهش از آنجا ناشی می‌شود که بسیاری از صنایع تولیدی هنوز به‌طور کامل با چالش ضایعات بالا، نوسانات کیفیت مواد اولیه، عدم انطباق محصولات با استانداردهای کیفی،

## ۲- ادبیات و پیشینه پژوهش

### ۲-۱- ادبیات پژوهش

تولید ناب<sup>۱</sup> به‌عنوان یکی از جامع‌ترین و تأثیرگذارترین رویکردهای مدیریتی در حوزه تولید، بر پایه فلسفه حذف اتلاف‌ها، افزایش ارزش‌آفرینی برای مشتری و ایجاد جریان یکنواخت و کارآمد در فرآیندهای تولیدی شکل گرفته است. نظریه‌های بنیادین تولید ناب ریشه در نظام تولید تویوتا دارند و بر اصولی همچون جریان ارزش<sup>۲</sup>، حذف اتلاف‌ها<sup>۳</sup>، بهبود مستمر<sup>۴</sup>، تولید به هنگام، استانداردسازی کار و کیفیت در منبع تأکید دارند (Bueno et al., 2023). ادبیات پژوهش نشان می‌دهد که اجرای تولید ناب تنها به کاهش ضایعات محدود نمی‌شود، بلکه تأثیر مستقیم بر ثبات کیفیت، کاهش نوسانات فرایندی، افزایش قابلیت پیش‌بینی خروجی‌ها و بهبود شاخص‌های کلیدی تولید دارد. در بسیاری از پژوهش‌های داخلی و خارجی، ابعاد تولید ناب شامل فرآیندهای جریان مواد، کیفیت، نگهداری بهره‌ور فراگیر، SS، ارتباطات داخلی، زمان‌سنجی و کاهش توقفات، مدیریت موجودی، و رهبری ناب موردبررسی قرار گرفته‌اند و نتایج حاکی از آن است که عملکرد کیفی و نرخ پذیرش محصول مستقیماً تحت تأثیر این ابعاد قرار دارد. از منظر نظری نیز تولید ناب بیان می‌کند که هرگونه ناکارآمدی در بخش‌هایی مانند کیفیت مواد اولیه، زمان‌های انبارش، گردش موجودی، توقفات تولید و میزان ضایعات، به‌صورت مستقیم احتمال رد شدن محصول در مرحله کنترل کیفیت یا بازار را افزایش می‌دهد. پایه نظری این رویکرد بر این اصل استوار است که کیفیت نهایی محصول برآیند رفتار فرآیندهای درونی و میزان انطباق آن‌ها با استانداردهای ناب است. بنابراین، ادبیات پژوهشی مرتبط با تولید ناب تأکید دارد که ارزیابی کیفیت و پذیرش محصول نباید صرفاً در پایان خط تولید انجام شود، بلکه باید بر اساس شاخص‌های فرایندی و عملیاتی در طول مسیر تولید پیش‌بینی شود؛ زیرا تولید ناب زمانی به بیشترین اثربخشی می‌رسد که سازمان توانایی پیش‌بینی‌پذیری کیفیت، کنترل لحظه‌ای فرآیند و

پیشگیری از خطا را داشته باشد، نه صرفاً اقدام پس از وقوع آن مورد نظر می‌باشد (Ojha & Venkatesh, 2021).

### • پذیرش محصول

پذیرش محصول یکی از شاخص‌های کلیدی عملکرد در صنایع تولیدی است که بیان می‌کند چه درصدی از محصولات تولیدشده توانسته‌اند استانداردهای کیفی، الزامات فرایندی و انتظارات بازار را برآورده کنند. در ادبیات پژوهش، پذیرش محصول نتیجه نهایی تعامل میان کیفیت مواد اولیه، ثبات فرایند تولید، شرایط نگهداری، میزان ضایعات، کنترل کیفیت در مبدأ و بازخوردهای مشتری شناخته می‌شود. این مفهوم صرفاً یک خروجی کمی نیست، بلکه نشان‌دهنده بلوغ سیستم تولید و میزان انطباق آن با اصول کیفیت و بهره‌وری است (Utama & Abirfatin, 2023). پژوهش‌ها نشان می‌دهند که پذیرش محصول تحت تأثیر مجموعه‌ای از عوامل پیچیده و غیرخطی قرار دارد؛ عواملی مانند کیفیت ورودی‌ها، نوسانات تولید، زمان انبارش مواد اولیه، خطاهای فرایندی، شرایط محیطی، الگوهای بسته‌بندی و حتی رفتار تیم‌های عملیاتی. در رویکردهای نوین مدیریت عملیات، پذیرش محصول تنها به‌عنوان یک نتیجه نهایی پایانی تحلیل نمی‌شود، بلکه به‌عنوان شاخصی پیش‌بینی‌پذیر در طول مسیر تولید مورد توجه قرار می‌گیرد. این دیدگاه بیان می‌کند که اگر بتوان بر اساس داده‌های فرایندی، احتمال پذیرش یا رد محصول را پیش از تکمیل تولید تخمین زد، سازمان قادر خواهد بود با اصلاح به‌موقع فرایند، کاهش ضایعات، افزایش کیفیت و بهبود تصمیم‌گیری، عملکرد خود را به‌شکل چشمگیری ارتقا دهد. از این منظر، پذیرش محصول نه یک معیار ایستا، بلکه یک خروجی پویا و متأثر از رفتار کل سیستم تولید است (Boumsisse et al., 2025).

### ۲-۲- بررسی پژوهش‌های پیشین

در سال‌های اخیر، تولید ناب به‌عنوان یکی از رویکردهای کلیدی در بهبود عملکرد فرآیندهای تولیدی، کاهش اتلاف و ارتقای کیفیت مورد توجه گسترده پژوهشگران قرار گرفته است. مطالعات متعددی نشان داده‌اند که به‌کارگیری اصول تولید ناب می‌تواند منجر به بهبود شاخص‌های کیفیت، بهره‌وری و عملکرد عملیاتی در

<sup>1</sup> Lean Production

<sup>2</sup> Value Stream

<sup>3</sup> Muda Elimination

<sup>4</sup> Kaizen

توسعه یافته‌اند (Cui et al., 2023؛ Shi et al., 2024). با وجود آنکه در برخی مطالعات محدود، شبکه عصبی مصنوعی برای پیش‌بینی پذیرش مصرف‌کننده در محصولات غذایی به کار گرفته شده است (BahramParvar et al., 2014؛ Yu et al., 2018؛ Alfiani et al., 2024). تمرکز این پژوهش‌ها عمدتاً بر ارزیابی‌های حسی و پاسخ مستقیم مصرف‌کننده بوده و کمتر به مدل‌سازی نرخ پذیرش محصول بر مبنای شاخص‌های عملیاتی و فرایندی تولید پرداخته‌اند. از این رو، کاربرد داده‌محور شبکه‌های عصبی در تحلیل نرخ پذیرش محصول به‌عنوان خروجی سیستمی در چارچوب تولید ناب همچنان با خلأ پژوهشی مواجه است. در مجموع، مرور پیشینه پژوهش نشان می‌دهد که اگرچه تولید ناب و شبکه‌های عصبی مصنوعی هر یک به‌طور مستقل نقش مهمی در بهبود کیفیت و عملکرد داشته‌اند، پژوهشی که این دو رویکرد را به‌صورت یکپارچه برای پیش‌بینی نرخ پذیرش محصول در صنعت مواد غذایی به کار گیرد، در ادبیات موجود مشاهده نمی‌شود. این خلأ پژوهشی، ضرورت انجام مطالعه حاضر را برجسته می‌سازد. به‌منظور تبیین جایگاه پژوهش حاضر در میان مطالعات پیشین و شناسایی خلأهای موجود در ادبیات، جدول ۱ به خلاصه‌ای از پژوهش‌های مرتبط اختصاص داده شده است. این جدول امکان مقایسه نظام‌مند رویکردها، حوزه‌های کاربردی و تمرکز موضوعی مطالعات پیشین را فراهم می‌کند و مبنایی برای برجسته‌سازی نوآوری و تمایز پژوهش حاضر فراهم می‌سازد.

مرور نظام‌مند پیشینه پژوهش نشان می‌دهد که مطالعات پیشین را می‌توان به دو جریان اصلی تقسیم کرد. جریان نخست، پژوهش‌هایی هستند که بر پیاده‌سازی تولید ناب، بهبود کیفیت فرایند و ارتقای بهره‌وری عملیاتی تمرکز داشته‌اند. این مطالعات، اگرچه نقش مهمی در تبیین اثرات تولید ناب بر عملکرد سازمانی و کیفی ایفا کرده‌اند، عمدتاً از رویکردهای مفهومی، تجربی یا آماری کلاسیک بهره‌گرفته و فاقد استفاده از روش‌های یادگیری ماشین و مدل‌های پیش‌بینی غیرخطی بوده‌اند. علاوه بر این، تمرکز این پژوهش‌ها بیشتر بر صنایع عمومی یا مهندسی بوده و صنعت مواد غذایی و ویژگی‌های خاص آن، به‌ویژه حساسیت کیفیت محصول و رفتار بازار، به‌طور محدود مورد توجه قرار گرفته است. از منظر سطح تصمیم‌گیری

سازمان‌های تولیدی شود (Marodin et al., 2018؛ Ojha & Venkatesh, 2022؛ Sahoo, 2020). همچنین برخی پژوهش‌ها با تمرکز بر موانع و الزامات پیاده‌سازی تولید ناب، بر نقش عوامل سازمانی، مدیریتی و فرهنگی در موفقیت این رویکرد تأکید کرده‌اند (Amani et al., 2020؛ Ranjbar Zarenagh et al., 2024). در کنار این مطالعات، پژوهش‌هایی نیز به بررسی ارتباط تولید ناب با پایداری و عملکرد زیست‌محیطی پرداخته‌اند و نشان داده‌اند که هم‌افزایی میان تولید ناب و رویکردهای سبز می‌تواند به بهبود هم‌زمان عملکرد اقتصادی و زیست‌محیطی منجر شود (Sunmola et al., 2024؛ Al-Shboul, 2025).

با این حال، اغلب این پژوهش‌ها از روش‌های تحلیلی سنتی، مدل‌های مفهومی یا رویکردهای آماری کلاسیک استفاده کرده و فاقد بهره‌گیری از روش‌های پیشرفته داده‌محور بوده‌اند. از سوی دیگر، با گسترش کاربرد یادگیری ماشین در صنایع مختلف، شبکه‌های عصبی مصنوعی به‌عنوان ابزاری قدرتمند برای مدل‌سازی روابط غیرخطی و پیچیده در حوزه کیفیت محصولات غذایی مورد استفاده قرار گرفته‌اند. مطالعات متعددی از کاربرد شبکه عصبی مصنوعی برای پیش‌بینی ویژگی‌های کیفی محصولات غذایی نظیر بافت، طعم، رنگ و سایر شاخص‌های فیزیکی و شیمیایی بهره‌برده‌اند و نتایج آن‌ها حاکی از دقت بالای این روش‌ها در پیش‌بینی کیفیت محصول است (Deng et al., 2023؛ Huang et al., 2024؛ Zhu et al., 2021؛ Batista et al., 2021). همچنین برخی پژوهش‌ها با استفاده از مدل‌های یادگیری ماشین، کنترل کیفیت و پایش هوشمند محصولات غذایی را بررسی کرده‌اند (Gorbachev et al., 2022؛ Liakos et al., 2025). با وجود پیشرفت‌های قابل‌توجه در این حوزه، تمرکز عمده این مطالعات بر کیفیت فنی محصول بوده و کمتر به ارتباط میان متغیرهای فرایندی و پیامدهای بازار توجه شده است. به‌طور خاص، مفهوم نرخ پذیرش محصول به‌عنوان شاخصی جامع که هم‌زمان کیفیت محصول، کارایی فرایند و انتظارات بازار را منعکس کند، در پژوهش‌های پیشین به‌صورت کمی و داده‌محور مدل‌سازی نشده است. افزون بر این، مطالعات مبتنی بر کاربرد شبکه عصبی مصنوعی در صنایع غذایی عمدتاً فاقد چارچوب تولید ناب بوده و این دو جریان پژوهشی به‌صورت مجزا

ویژگی‌های فیزیکی، شیمیایی یا حسی محصولات غذایی نظیر بافت، رنگ، ماندگاری و ترکیبات شیمیایی تمرکز داشته‌اند و نتایج آن‌ها نشان‌دهنده توان بالای شبکه‌های عصبی در مدل‌سازی روابط غیرخطی داده‌های پیچیده غذایی است.

نیز، این دسته از مطالعات عمدتاً در سطح فرایندی و عملیاتی باقی‌مانده و ارتباط مستقیمی با پیامدهای بازاری و پذیرش محصول برقرار نکرده‌اند. در جریان دوم، پژوهش‌هایی قرار دارند که از یادگیری ماشین و شبکه‌های عصبی مصنوعی برای پیش‌بینی کیفیت محصولات غذایی استفاده کرده‌اند. این مطالعات عمدتاً بر پیش‌بینی

جدول ۱. خلاصه پیشینه پژوهش

Table 1. Summary of previous studies

مرجع	صنعت: مواد غذایی	روش: یادگیری ماشین	تکنیک: ANN	چارچوب: تولید ناب	خروجی (کیفیت/پذیرش)	مدل: سطح تصمیم‌گیری	یکپارچگی Lean-ML
Al-Shboul, 2025	×	×	×	×	کیفیت	فرایندی	×
Alivardilou & Ahmadvand, 2023	×	×	×	×	عملکرد فرایند	فرایندی	×
Amani et al., 2020	×	×	×	×	کیفیت	فرایندی	×
Esmaili et al., 2021	×	×	×	×	کیفیت	فرایندی	×
Banaei & Maleki, 2021	×	×	×	×	عملکرد فرایند	فنی	×
Marodin et al., 2018	×	×	×	✓	کیفیت	فرایندی	×
Ojha & Venkatesh, 2022	×	×	×	✓	کیفیت	فرایندی	×
Ranjbar Zarenagh et al., 2024	×	×	×	×	کیفیت	فرایندی	×
Sahoo, 2020	×	×	×	✓	کیفیت	فرایندی	×
Sunmola et al., 2024	×	×	×	✓	کیفیت	فرایندی	×
Sundararajan & Terkar, 2022	×	×	×	✓	کیفیت	فرایندی	×
Synnes & Welo, 2022	×	×	×	×	کیفیت	فرایندی	×
Deng et al., 2023	✓	✓	✓	✓	کیفیت محصول	فنی	×
Huang et al., 2024	✓	✓	✓	✓	کیفیت محصول	فنی	×
Yang et al., (2025)	✓	✓	×	✓	کیفیت محصول	فنی	×
Batista et al., 2021	✓	✓	✓	✓	کیفیت محصول	فنی	×
Zhu et al., 2021	✓	✓	✓	✓	کیفیت محصول	فنی	×
Dębska & Guzowska-Świder, 2011	✓	✓	✓	✓	کیفیت محصول	فنی	×
Cui et al., 2023	✓	✓	×	✓	کیفیت محصول	فنی	×
Shi et al., 2024	✓	✓	✓	✓	کیفیت محصول	فنی	×
Liakos et al., 2025	✓	✓	×	✓	کیفیت محصول	فنی	×
Alsaedi et al., 2024	✓	✓	✓	✓	کیفیت محصول	فنی	×
Gorbachev et al., 2022	✓	✓	✓	✓	کیفیت محصول	فنی	×
Yu et al., 2018	✓	✓	✓	×	پذیرش مصرف‌کننده	بازاری	×
BahramParvar et al., 2014	✓	✓	✓	×	پذیرش محصول	بازاری	×
Alfiani et al., 2024	✓	✓	✓	×	پذیرش مصرف‌کننده	بازاری	×
تحقیق حاضر	✓	✓	✓	✓	نرخ پذیرش محصول	بازاری-فرایندی	یکپارچه

غذایی گردآوری شد. خبرگان به صورت هدفمند انتخاب شدند و ویژگی‌های آن‌ها شامل حداقل مدرک تحصیلی کارشناسی ارشد، بیش از ۱۰ سال سابقه حرفه‌ای مرتبط، تجربه عملی در خطوط تولید صنایع غذایی و آشنایی با سیستم‌های کنترل کیفیت و تصمیم‌گیری صنعتی بوده است. در مرحله کمی، داده‌های واقعی تولید از سیستم‌های کنترل کیفیت شرکت گروه زر و در یک بازه زمانی دوساله استخراج شد. این داده‌ها شامل اطلاعات روزانه مرتبط با شاخص‌های کیفی، فرایندی و عملیاتی خطوط تولید و نرخ پذیرش محصول بوده است. در این پژوهش، از شبکه عصبی پیش‌خور چندلایه<sup>۵</sup> برای مدل‌سازی رابطه غیرخطی میان متغیرهای تولید ناب و نرخ پذیرش محصول استفاده گردید. در فرآیند تنظیم ابر پارامترهای مدل، ساختار شبکه شامل یک لایه ورودی، دو لایه پنهان و یک لایه خروجی است. تعداد نورون‌های لایه ورودی برابر با تعداد متغیرهای ورودی نهایی استخراج شده از روش دلفی فازی تعیین شد و لایه خروجی شامل یک نورون با خروجی پیوسته برای پیش‌بینی نرخ پذیرش محصول در بازه ۰ تا ۱۰۰ درصد در نظر گرفته شد. برای تعیین معماری بهینه شبکه، تعیین تعداد لایه‌ها و نورون‌های شبکه عصبی از طریق فرآیند تنظیم ابر پارامترها با استفاده از رویکرد Grid Search انجام شد. در این فرآیند، ساختارهای مختلف شامل یک و دو لایه پنهان با تعداد نورون‌های متغیر در بازه مشخص تعریف و با استفاده از داده‌های اعتبارسنجی ارزیابی شدند. معیار انتخاب، کمینه‌سازی خطای اعتبارسنجی (Validation Loss) و بهبود شاخص‌های RMSE و R<sup>2</sup> بود. ساختار نهایی شامل دو لایه پنهان با ۱۲ و ۸ نورون به دلیل عملکرد پایدارتر و تعمیم‌پذیری بالاتر انتخاب گردید. در لایه‌های پنهان از تابع فعال‌سازی ReLU به دلیل توانایی بالا در مدل‌سازی روابط غیرخطی و پایداری محاسباتی استفاده شد، درحالی‌که برای لایه خروجی از تابع فعال‌سازی خطی متناسب با ماهیت رگرسیونی متغیر هدف بهره گرفته شد. فرآیند آموزش شبکه با استفاده از الگوریتم پس‌انتشار خطا و بهینه‌ساز Adam انجام گرفت. نرخ یادگیری اولیه برابر با ۰/۰۱ در نظر گرفته شد و آموزش مدل طی ۱۰۰ دوره<sup>۶</sup> اجرا گردید. معیار توقف

اگرچه در برخی مطالعات محدود، شبکه‌های عصبی برای پیش‌بینی پذیرش یا پسند مصرف‌کننده در محصولات غذایی به کار گرفته شده‌اند، این پژوهش‌ها عمدتاً بر ارزیابی‌های حسی و داده‌های مصرف‌کننده متمرکز بوده و فاقد پیوند با شاخص‌های عملیاتی تولید ناب بوده‌اند. بررسی پیشینه حاکی از آن است که تاکنون مطالعه‌ای که به صورت هم‌زمان سه مؤلفه کلیدی شامل چارچوب تولید ناب، مدل‌سازی داده‌محور مبتنی بر شبکه عصبی مصنوعی و مفهوم نرخ پذیرش محصول را در صنعت مواد غذایی تلفیق کند، گزارش نشده است. به‌ویژه، مفهوم نرخ پذیرش محصول که بیانگر میزان تطابق محصول با انتظارات کیفی، فرایندی و بازار است، تاکنون بیشتر به صورت ضمنی یا توصیفی مورد اشاره قرار گرفته و مدل پیش‌بینی کمی و داده‌محور برای آن ارائه نشده است. این امر نشان‌دهنده وجود خلأیی ساختاری در سطح تصمیم‌گیری بازاری-فرایندی در ادبیات پژوهش است؛ خلأیی که ضرورت انجام پژوهشی یکپارچه و میان‌رشته‌ای را آشکار می‌سازد و پژوهش حاضر درصدد پر کردن آن است.

### ۳- روش پژوهش

روش‌شناسی این پژوهش بر پایه رویکردی نظام‌مند و ترکیبی طراحی شده است تا با بهره‌گیری هم‌زمان از داده‌های کیفی و کمی، مدل مناسبی برای پیش‌بینی نرخ پذیرش محصول در محیط‌های تولید ناب ارائه دهد. هدف اصلی، نزدیک‌ساختن مدل پژوهش به شرایط واقعی تولید و افزایش قابلیت کاربرد آن در صنایع غذایی است. از این‌رو، ساختار روش‌شناسی بر سه محور اصلی شامل هدف پژوهش، نوع داده‌های مورد نیاز و شیوه اجرای مراحل تحقیق استوار است. پژوهش حاضر با هدف طراحی و ارزیابی یک مدل داده‌محور برای پیش‌بینی نرخ پذیرش محصول در محیط تولید ناب انجام شده است. از نظر هدف، پژوهش کاربردی و از نظر رویکرد، کمی-تحلیلی با پشتیبانی خبرگی است. در گام نخست، متغیرهای بالقوه مؤثر بر نرخ پذیرش محصول با اتکا به پیشینه پژوهش تولید ناب، کنترل کیفیت و نیز دیدگاه‌های خبرگان صنعتی شناسایی شدند. بدین منظور، نظرات ۱۵ نفر از خبرگان حوزه تولید ناب و مدیریت کیفیت در صنایع

<sup>5</sup> Multilayer Perceptron

<sup>6</sup> Epochs

به‌منظور شناسایی و غربال شاخص‌های مؤثر بر نرخ پذیرش محصول و دستیابی به اجماع خبرگان، روش دلفی فازی در دو راند متوالی اجرا شد. جدول ۲ نتایج حاصل از راند اول و دوم دلفی فازی را نشان می‌دهد و مبنای انتخاب شاخص‌های ورودی برای مراحل بعدی تحلیل و مدل‌سازی را فراهم می‌کند.

متغیرهایی که امتیاز آن‌ها کمتر از آستانه توافق خبرگان (۰/۷۰) بود حذف گردیدند. درنهایت، ۶ شاخص که بالاترین امتیاز دفازی شده و بیشترین اجماع خبرگان را داشتند، به‌عنوان متغیرهای ورودی نهایی انتخاب شدند. به‌منظور افزایش اعتبار انتخاب متغیرهای ورودی و ایجاد پیوند روش‌شناختی میان روش دلفی فازی و الگوریتم‌های یادگیری ماشین، از یک رویکرد ترکیبی شامل آزمون‌های آماری کلاسیک و روش‌های داده‌محور اعتبارسنجی ویژگی‌ها استفاده شد. به‌منظور بررسی معناداری تفاوت شاخص‌های ورودی در سطوح مختلف نرخ پذیرش محصول و اطمینان از قدرت تمایز آن‌ها، از آزمون ناپارامتریک کروسکال-والیس استفاده شد.

جدول ۳ نتایج این آزمون را برای هر یک از شاخص‌های ورودی ارائه می‌کند و نقش آن‌ها را در تفکیک طبقات نرخ پذیرش مشخص می‌سازد. نتایج جدول ۳ نشان می‌دهد که تمامی شاخص‌های منتخب، تفاوت آماری معناداری میان طبقات نرخ پذیرش محصول ایجاد می‌کنند ( $p < 0.01$ ). مقادیر اندازه اثر نیز بیانگر آن است که این متغیرها علاوه بر معناداری آماری، از نظر عملیاتی نقش قابل توجهی در تفکیک سطوح مختلف پذیرش محصول دارند. به‌منظور بررسی همپوشانی اطلاعاتی میان شاخص‌های ورودی و ارزیابی اهمیت داده‌محور آن‌ها پیش از مدل‌سازی، جدول ۴ ارائه شده است. همچنین نتایج اطلاعات متقابل و اهمیت جابجایی حاکی از آن است که شاخص‌های منتخب، حتی مستقل از ساختار درخت تصمیم، سهم معناداری در پیش‌بینی نرخ پذیرش محصول دارند و اهمیت آن‌ها صرفاً وابسته به یک مدل خاص نیست.

ترکیب آزمون کروسکال-والیس به‌عنوان ابزار اعتبارسنجی آماری و تحلیل‌های تشخیصی انتخاب ویژگی به‌عنوان روش‌های داده‌محور، نشان می‌دهد که شاخص‌های منتخب نه تنها از اجماع خبرگان در روش دلفی فازی

آموزش بر اساس همگرایی خطای مجموعه اعتبارسنجی تعریف شد تا از بیش‌برازش جلوگیری شود. پیاده‌سازی مدل با استفاده از زبان برنامه‌نویسی پایتون و کتابخانه کراس<sup>۷</sup> انجام شد که امکان کنترل دقیق ساختار شبکه، تنظیم ابرپارامترها و ارزیابی عملکرد مدل را فراهم می‌کند. به‌منظور ارزیابی عملکرد مدل پایه و افزایش اعتبار نتایج، عملکرد شبکه عصبی مصنوعی با چند الگوریتم رگرسیونی مرجع و متداول شامل رگرسیون خطی<sup>۸</sup>، درخت تصمیم رگرسیونی<sup>۹</sup>، جنگل تصادفی<sup>۱۰</sup> و ماشین بردار پشتیبان رگرسیونی<sup>۱۱</sup> مقایسه شد.

به‌منظور بررسی پایایی داده‌ها، داده‌های جمع‌آوری شده از خطوط تولید صنایع غذایی مورد پیش‌پردازش قرار گرفتند که شامل حذف داده‌های پرت، نرمال‌سازی و بررسی سازگاری مقادیر بود. پایایی مدل پیشنهادی نیز از طریق ارزیابی عملکرد شبکه عصبی مصنوعی در داده‌های آموزش و آزمون موردسنجش قرار گرفت. برای این منظور، از شاخص‌هایی نظیر ضریب تعیین، میانگین مربعات خطا و ریشه میانگین مربعات خطا استفاده شد.

#### ۴- تجزیه و تحلیل داده‌ها

##### ۴-۱- پایش متغیرهای تصمیم‌گیری با رویکرد دلفی فازی

در گام نخست، با اتکا به مرور نظام‌مند منابع علمی، مقالات معتبر منتشرشده مرتبط، مجموعاً ۲۵ متغیر اولیه شناسایی و تدوین گردید. سپس نظرات ۱۵ خبره با استفاده از مقیاس زبانی پنج‌سطحی فازی مثلثی متناظر تبدیل گردید. تجمیع نظرات خبرگان با استفاده از میانگین فازی انجام شد و برای تبدیل مقادیر فازی به مقادیر قطعی، روش مرکز ثقل<sup>۱۲</sup> به کار گرفته شد. فرآیند دلفی فازی در دو راند متوالی اجرا گردید و معیار توقف زمانی برقرار تلقی شد که تغییر امتیاز دفازی شده شاخص‌ها بین دو راند کمتر از ۰/۱۰ باشد که نشان‌دهنده همگرایی نظرات خبرگان است (Abedi et al., 2025).

<sup>7</sup> Keras

<sup>8</sup> Linear Regression (LR)

<sup>9</sup> Decision Tree Regression (DTR)

<sup>10</sup> Random Forest (RF)

<sup>11</sup> Support Vector Regression (SVR)

<sup>12</sup> Centroid

از این شاخص‌ها در مرحله مدل‌سازی یادگیری ماشین و استخراج قوانین تصمیم‌گیری فراهم می‌سازد.

برخوردارند، بلکه از منظر داده‌های واقعی تولید نیز دارای توان تمایز، استقلال و اهمیت پیش‌بینی‌کننده هستند. این اعتبارسنجی دوگانه، مبنای مستحکمی برای استفاده

جدول ۲. خروجی راند اول و دوم دلفی فازی

Table 2. Output of the first and second rounds of the Fuzzy Delphi method

ردیف	نام متغیر	مقدار فازی مثلثی راند دوم		دامنه اختلاف
		مقدار دی‌فازی شده	مقدار دی‌فازی شده	
		راند اول	راند دوم	
۱	درصد خطای انسانی در عملیات	(۴/۵، ۵/۲، ۶/۱)	۵/۲۷	۰/۰۴
۲	نرخ ضایعات مواد اولیه	(۵/۵، ۶/۰، ۶/۶)	۶/۰۳	۰/۰۳
۳	نرخ خرابی تجهیزات	(۵/۱، ۵/۸، ۶/۴)	۵/۷۷	۰/۰۴
۴	درصد آموزش‌پذیری نیروی انسانی	(۵/۲، ۶/۰، ۶/۸)	۶/۰۰	۰/۱
۵	شیفت تولید	(۷/۰، ۷/۶، ۸/۱)	۷/۵۷	۰/۰۶
۶	نرخ رضایت مشتری	(۵/۵، ۶/۰، ۶/۶)	۶/۰۳	۰
۷	نرخ بازگشت محصول از مشتری	(۷/۱، ۷/۷، ۸/۴)	۷/۷۳	۰/۱
۸	درصد بهره‌وری نیروی انسانی	(۴/۸، ۵/۳، ۶/۰)	۵/۳۷	۰/۰۶
۹	تطابق محصول با نیاز بازار	(۵/۹، ۶/۵، ۷/۱)	۶/۵۰	۰/۰۳
۱۰	درصد استفاده از داده‌های کنترلی	(۶/۰، ۶/۶، ۷/۲)	۶/۶۰	۰/۰۳
۱۱	میانگین زمان انتظار در خط تولید	(۵/۳، ۶/۱، ۶/۸)	۶/۰۷	۰/۱
۱۲	درصد انطباق با استاندارد مواد اولیه	(۷/۳، ۷/۹، ۸/۵)	۷/۹۰	۰/۱
۱۳	تعداد توقفات خط تولید	(۵/۴، ۶/۰، ۶/۷)	۶/۰۳	۰
۱۴	زمان چرخه تولید	(۵/۷، ۶/۲، ۶/۹)	۶/۲۷	۰/۰۴
۱۵	میانگین زمان انبارش مواد اولیه	(۷/۱، ۷/۶، ۸/۰)	۷/۵۷	۰/۰۳
۱۶	نرخ اعمال نمره کیفی ارفاقی	(۷/۲، ۷/۸، ۸/۴)	۷/۸۰	۰/۱۰
۱۷	تعداد خطاهای گزارش شده	(۵/۰، ۵/۶، ۶/۳)	۵/۶۳	۰
۱۸	سطح شفافیت در گزارش‌های تولید	(۶/۰، ۶/۵، ۷/۰)	۶/۵۰	۰
۱۹	هزینه‌های ناشی از کیفیت پایین	(۶/۱، ۶/۷، ۷/۳)	۶/۷۰	۰/۱۰
۲۰	درصد ضایعات تولید روزانه	(۷/۲، ۷/۸، ۸/۴)	۷/۸۰	۰/۰۷
۲۱	قابلیت ردیابی مواد اولیه	(۵/۹، ۶/۴، ۷/۰)	۶/۴۳	۰/۱
۲۲	میزان انحراف از برنامه تولید	(۵/۵، ۶/۱، ۶/۸)	۶/۱۳	۰/۱
۲۳	نرخ مرجوعی محصول به دلیل خرابی	(۶/۰، ۶/۵، ۷/۱)	۶/۵۳	۰/۰۷
۲۴	درصد تعمیرات اضطراری	(۵/۸، ۶/۳، ۶/۹)	۶/۳۳	۰/۱
۲۵	درصد تطابق عملکرد با شاخص‌ها	(۶/۰، ۶/۴، ۷/۰)	۶/۴۷	۰/۰۳

جدول ۳. آزمون تمایز آماری (کروسکال-والیس) شاخص‌های ورودی نسبت به طبقات نرخ پذیرش

Table 3. Kruskal-Wallis statistical discrimination test of input variables across product acceptance rate categories

شاخص ورودی	مقدار آماره	مقدار p	اندازه اثر ( $E^2$ )	نتیجه
زمان تولید (شیفت کاری)	۱۸/۴۲	۰/۰۰۱	۰/۲۱	معنادار
درصد تطابق مواد اولیه با استانداردهای کیفی	۳۶/۷۵	<۰/۰۰۱	۰/۳۸	معنادار
نرخ تأیید استثنایی محصول	۲۲/۱۰	<۰/۰۰۱	۰/۲۶	معنادار
درصد ضایعات تولید روزانه	۴۱/۶۳	<۰/۰۰۱	۰/۴۴	معنادار
میانگین زمان انبارش مواد اولیه	۲۹/۵۸	<۰/۰۰۱	۰/۳۱	معنادار
درصد بازگشت محصول از مشتری	۲۵/۹۰	<۰/۰۰۱	۰/۲۸	معنادار

## جدول ۴. تحلیل‌های تشخیصی همپوشانی و اهمیت داده‌محور شاخص‌های ورودی

Table 4. Diagnostic analyses of multicollinearity and data-driven importance of input variables

شاخص ورودی	عامل تورم واریانس	اطلاعات متقابل	اهمیت جابجایی
زمان تولید (شیفت کاری)	۱/۴۲	۰/۱۸	۰/۰۴۱
درصد تطابق مواد اولیه با استانداردهای کیفی	۱/۸۵	۰/۴۶	۰/۱۱۲
نرخ تأیید استثنایی محصول	۱/۶۷	۰/۲۹	۰/۰۶۴
درصد ضایعات تولید روزانه	۱/۹۱	۰/۵۲	۰/۱۳۸
میانگین زمان انبارش مواد اولیه	۱/۵۸	۰/۳۳	۰/۰۷۱
درصد بازگشت محصول از مشتری	۱/۴۹	۰/۲۷	۰/۰۵۹

## جدول ۵. متغیرهای ورودی و خروجی مدل پیش‌بینی نرخ پذیرش محصول

Table 5. Input and output variables of the product acceptance prediction model

ردیف	عنوان متغیر	علامت اختصاری	نوع متغیر	توضیحات
۱	زمان تولید (شیفت کاری)	TShift	ورودی	مشخص‌کننده نوبت کاری تولید محصول (شیفت ۱، ۲ یا ۳)
۲	درصد تطابق مواد اولیه با استانداردهای کیفی	RMIQ	ورودی	درصد مواد اولیه‌ای که قبل از ورود به تولید، الزامات کیفی را پاس کرده‌اند
۳	نرخ تأیید استثنایی محصول نهایی (نمرات ارفاقی)	EQA	ورودی	درصد محصولاتی که با وجود عدم انطباق کامل، به‌صورت مشروط تأیید شده‌اند
۴	درصد ضایعات تولید روزانه	Wrate	ورودی	نسبت وزن یا تعداد ضایعات به کل تولید در یک روز
۵	میانگین زمان انبارش مواد اولیه پیش از مصرف	RMStorageTime	ورودی	مدت‌زمان ماندگاری مواد اولیه در انبار پیش از ورود به فرایند تولید بر (بر حسب روز)
۶	درصد بازگشت محصول از مشتری	PRRate	ورودی	نسبت محصولات بازگشتی به کل محصولات تحویل‌داده‌شده
۷	نرخ پذیرش محصول توسط بازار (متغیر هدف)	AcceptanceRate	خروجی	درصدی از محصولات تولیدشده که توسط مشتریان خریداری و پذیرفته شده‌اند (به‌صورت عددی بین ۰ تا ۱۰۰ درصد)

## ۴-۲- مدل‌سازی شبکه عصبی

در این پژوهش، هدف از به‌کارگیری شبکه عصبی مصنوعی، پیش‌بینی نرخ پذیرش محصول بر اساس داده‌های ثبت‌شده در واحدهای تولید، کنترل کیفیت و فروش در صنعت غذایی است. مدل پیشنهادی به‌عنوان یک مسئله رگرسیون در نظر گرفته می‌شود، زیرا متغیر خروجی، نرخ پذیرش عددی بین ۰ تا ۱۰۰ درصد است.

## • تعیین متغیرهای ورودی و خروجی مدل

انتخاب متغیرهای ورودی بر اساس فرایند روش دلفی فازی از خبرگان صورت گرفت. ابتدا فهرستی از ۲۵ متغیر کلیدی مرتبط با اصول تولید ناب و مدیریت کیفیت جامع در صنعت غذایی تدوین شد. این متغیرها حاصل بررسی منابع علمی و تجارب میدانی در حوزه تولید و کیفیت

بودند. با استفاده از پرسشنامه فازی و جمع‌آوری داده‌ها از ۱۵ خبره متخصص در حوزه‌های کنترل کیفیت، مهندسی تولید و فروش، ارزیابی در ۲ راند انجام پذیرفت. نهایتاً ۶ متغیر ورودی و یک متغیر خروجی انتخاب گردید. این متغیرها به‌صورت عددی و قابل اندازه‌گیری بوده و مبتنی بر سه فرآیند اصلی زنجیره تأمین (تأمین، تولید، فروش) و اصول تولید ناب می‌باشند. به‌منظور شفاف‌سازی ساختار مدل پیش‌بینی و تبیین نقش هر یک از متغیرها در فرآیند مدل‌سازی، جدول ۵ متغیرهای ورودی و خروجی مورد استفاده در پژوهش را ارائه می‌دهد. این جدول مبنای درک ارتباط بین شاخص‌های کیفی و فرایندی با نرخ پذیرش محصول و چارچوب کلی مدل پیش‌بینی را فراهم می‌سازد. نرخ‌ها بر اساس داده‌های فروش واقعی همان محصول در روزهای بعد از تولید و تجزیه و تحلیل آن

نرخ پذیرش محصول، عملکرد مدل با استفاده از داده‌های آموزش، اعتبارسنجی و آزمون ارزیابی شد. در این راستا، جدول ۷ نتایج ارزیابی عملکرد مدل را بر اساس شاخص‌های آماری گزارش می‌کند و مبنایی برای قضاوت درباره توان پیش‌بینی مدل و عدم نیاز به بازطراحی یا تنظیم مجدد آن فراهم می‌سازد. میانگین خطای مطلق (MAE) در همه مجموعه‌ها بین ۴/۱ تا ۴/۵ باقی‌مانده که نشان می‌دهد مدل به‌طور میانگین حداکثر حدود  $\pm 5$  واحد درصد اختلاف با مقدار واقعی دارد. میانگین مربع خطا (MSE) نیز پایین و نزدیک به هم است که نشانگر عدم وجود نوسانات شدید در خطاهای مدل است. شاخص ضریب تعیین ( $R^2$ ) بالاتر از ۰/۸۸ برای همه مجموعه‌هاست که نشان می‌دهد بیش از ۸۸ درصد از تغییرات نرخ پذیرش محصول توسط متغیرهای ورودی قابل توضیح هستند. لذا مدل طراحی‌شده از دقت و پایداری قابل قبولی برخوردار است.

#### • مقایسه عملکرد مدل پیشنهادی با مدل‌های رگرسیونی مرجع

به‌منظور ارزیابی اثربخشی مدل شبکه عصبی مصنوعی پیشنهادی، عملکرد آن با چند مدل رگرسیونی متداول و ساده‌تر که به‌طور گسترده به‌عنوان مدل‌های مرجع در مسائل پیش‌بینی پیوسته مورد استفاده قرار می‌گیرند، مقایسه شد. هدف از این مقایسه، بررسی این موضوع است که آیا پیچیدگی مدل ANN منجر به بهبود معنادار دقت پیش‌بینی نسبت به روش‌های کلاسیک می‌شود یا خیر. از آنجاکه مسئله پژوهش از نوع رگرسیون پیوسته است، به‌منظور ارزیابی اثربخشی مدل پیشنهادی و سنجش برتری آن نسبت به روش‌های متداول، عملکرد شبکه عصبی مصنوعی با چند مدل رگرسیونی مرجع بر روی داده‌های آزمون مقایسه شده است. جدول ۸ نتایج مقایسه عملکرد مدل پیشنهادی با مدل‌های رگرسیونی مرجع را ارائه می‌کند و مبنایی برای تحلیل مزیت نسبی مدل پیشنهادی فراهم می‌سازد.

نتایج جدول ۸ نشان می‌دهد که مدل شبکه عصبی مصنوعی پیشنهادی در مقایسه با مدل‌های رگرسیونی مرجع، بهترین عملکرد را بر روی داده‌های آزمون ارائه داده است. مقدار میانگین خطای مطلق (MAE) کمتر در مدل شبکه عصبی مصنوعی بیانگر کاهش خطای مطلق

نسبت به واحدهای ارسال‌شده به بازار محاسبه شد. متغیر خروجی نشان‌دهنده میزان موفقیت محصول تولیدشده در پذیرش نهایی توسط مشتری یا خریدار نهایی است.

#### • جمع‌آوری و آماده‌سازی داده‌ها

داده‌ها از واحدهای تولید، کنترل کیفیت و فروش در یک بازه زمانی ۲ ساله استخراج گردید که شامل ۴۸۰۰ رکورد روزانه برای چهار محصول مختلف بود. این داده‌ها شامل اطلاعات کیفی، تولیدی و فروش هر محصول در روزهای خاص بود که به‌صورت دقیق با یکدیگر هم‌راستا و یکپارچه شدند. در طی مراحل پیش‌پردازش در گام اول، داده‌های اولیه از سه منبع اصلی (تولید، کیفیت، فروش) دریافت شد (۴۸۰۰ رکورد). در گام دوم، با حذف داده‌های ناقص یا دارای مقادیر گم‌شده، حجم داده‌ها به حدود ۴۵۰۰ رکورد کاهش یافت. در گام دوم، با شناسایی و حذف داده‌های پرت با استفاده از روش‌هایی IQR، حجم داده‌ها به حدود ۴۲۰۰ رکورد نهایی رسید. همچنین نرمال‌سازی متغیرهای عددی و کدگذاری متغیرهای کیفی (مانند شیفت کاری) انجام شد تا شبکه عصبی قادر به پردازش یکنواخت داده‌ها باشد. برای آموزش و ارزیابی عملکرد شبکه عصبی، داده‌های نهایی (۴۲۰۰ رکورد) به سه بخش مجزا تقسیم شدند: مجموعه آموزش شامل ۲۹۴۰ رکورد (۷۰٪ از کل داده‌ها)، مجموعه اعتبارسنجی شامل ۶۳۰ رکورد (۱۵٪ از کل داده‌ها) و مجموعه آزمون شامل ۶۳۰ رکورد (۱۵٪ از کل داده‌ها). این تقسیم‌بندی با هدف آموزش مدل، تنظیم پارامترها (مانند نرخ یادگیری و ساختار لایه‌ها) و ارزیابی نهایی دقت مدل انجام شد.

#### • طراحی ساختار شبکه عصبی

به‌منظور تشریح ساختار، پارامترهای آموزشی و تنظیمات فنی مدل شبکه عصبی مصنوعی به‌کاررفته در این پژوهش، جدول ۶ ارائه شده است. این جدول مشخصات معماری شبکه، روش یادگیری و بهینه‌سازی را به‌صورت خلاصه و نظام‌مند گزارش می‌کند و مبنایی برای تفسیر نتایج مدل‌سازی و ارزیابی تکرارپذیری پژوهش فراهم می‌سازد.

#### • ارزیابی عملکرد مدل پایه

به‌منظور سنجش دقت و پایداری مدل شبکه عصبی آموزش‌دیده و اطمینان از کفایت عملکرد آن در پیش‌بینی

اگرچه مدل‌هایی مانند ماشین بردار پشتیبان و درخت تصمیم نسبت به روش‌های کلاسیک بهبود نسبی داشته‌اند، اما همچنان در تمامی شاخص‌ها از مدل شبکه عصبی مصنوعی پیشنهادی عقب‌تر هستند. این نتایج نشان می‌دهد که ماهیت غیرخطی و چندبعدی مسئله پیش‌بینی نرخ پذیرش محصول در تولید ناب به‌طور مؤثرتری توسط شبکه عصبی مصنوعی قابل مدل‌سازی است.

پیش‌بینی نسبت به سایر مدل‌هاست، درحالی‌که MSE پایین‌تر نشان‌دهنده پایداری بیشتر مدل در برابر خطاهای بزرگ می‌باشد. همچنین مقدار ضریب تعیین بالاتر حاکی از توان تبیین بالاتر مدل شبکه عصبی در توضیح تغییرات نرخ پذیرش محصول است. در مقابل، مدل‌های ساده‌تر مانند رگرسیون خطی و درخت تصمیم، به دلیل ناتوانی در مدل‌سازی روابط غیرخطی پیچیده میان متغیرهای تولید ناب، عملکرد ضعیف‌تری از خود نشان داده‌اند.

#### جدول ۶. مشخصات فنی و تحلیلی مدل شبکه عصبی مصنوعی

Table 6. Technical and analytical specifications of the artificial neural network model

ردیف	عنوان	مقدار / توضیح	شرح
۱	نوع شبکه	Feedforward Neural Network	مناسب برای مسائل رگرسیونی غیرخطی
۲	تعداد لایه‌ها	۴ لایه (ورودی، ۲ پنهان، خروجی)	با استفاده از Grid Search و ارزیابی عملکرد اعتبارسنجی
۳	تعداد نورون‌ها	۱۲ (لایه پنهان اول)، ۸ (لایه پنهان دوم)	بر اساس کمیته‌سازی خطای اعتبارسنجی و کنترل بیش‌برازش
۴	تابع فعال‌سازی لایه‌های پنهان	ReLU	مناسب برای روابط غیرخطی
۵	تابع فعال‌سازی لایه خروجی	Linear	متناسب با خروجی پیوسته
۶	الگوریتم یادگیری	Backpropagation	یادگیری مبتنی بر گرادینت
۷	روش بهینه‌سازی	Adam Optimizer	همگرایی سریع و پایدار
۸	نرخ یادگیری	۰/۰۱	قابل تنظیم در طول آموزش
۹	تعداد دوره‌های آموزش	100 epochs	آموزش اولیه مدل
۱۰	تقسیم داده‌ها	۷۰٪ آموزش، ۱۵٪ اعتبارسنجی، ۱۵٪ آزمون	ارزیابی تعمیم‌پذیری
۱۱	معیار توقف آموزش	همگرایی خطای اعتبارسنجی	جلوگیری از بیش‌برازش

#### جدول ۷. ارزیابی عملکرد مدل با شاخص‌های MAE، MSE و R<sup>2</sup>

Table 7. Model Performance Evaluation Using MAE, MSE, and R<sup>2</sup> Metrics

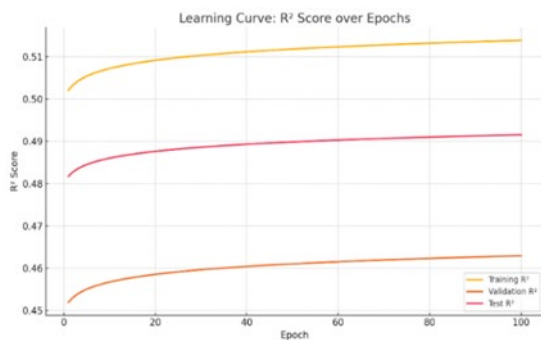
معیار آماری	آموزش (Training)	اعتبارسنجی (Validation)	آزمون (Validation)
میانگین خطای مطلق (MAE)	۴/۱۲	۴/۳۵	۴/۴۸
میانگین مربع خطا (MSE)	۲۵/۸	۲۷/۴	۲۸/۹
ضریب تعیین (R <sup>2</sup> )	۰/۹۱۲	۰/۸۹۷	۰/۸۸۵

#### جدول ۸. مقایسه عملکرد مدل پیشنهادی با مدل‌های رگرسیونی مرجع (داده‌های آزمون)

Table 8. Performance comparison of ANN with baseline regression models on test data

مدل	MAE	MSE	R <sup>2</sup>
رگرسیون خطی (Linear Regression)	۶/۸۵	۵۲/۴	۰/۷۴۲
درخت تصمیم (Decision Tree)	۶/۱۰	۴۷/۸	۰/۷۶۸
ماشین بردار پشتیبان (SVR)	۵/۳۲	۳۹/۶	۰/۸۱۲
جنگل تصادفی (Random Forest)	۴/۹۵	۳۴/۱	۰/۸۴۶
شبکه عصبی مصنوعی (ANN)	۴/۴۸	۲۸/۹	۰/۸۸۵

در مجموع، این نمودار نشان می‌دهد که مدل دارای عملکرد نسبتاً پایدار و قابل‌اعتماد در پیش‌بینی نرخ پذیرش محصول است.



شکل ۲. نمودار تغییرات دقت مدل.

Figure 2. Model accuracy variation plot.

### • ارزیابی عملکرد مدل با شاخص تحلیل حساسیت متغیرها

به‌منظور نمایش تعامل هم‌زمان دو متغیر ورودی و بررسی اثر ترکیبی آن‌ها بر نرخ پذیرش محصول، شکل ۳ ارائه شده است. در این شکل، چهار نمودار سه‌بعدی مختلف نشان داده شده است سطح پاسخ مبتنی بر ANN برای نمایش اثر تعاملی دو متغیر ورودی بر نرخ پذیرش محصول (با فرض اینکه سایر متغیرها در مقدار میانگین ثابت شده‌اند) می‌باشد.

**نمودار بالا-چپ:** اثر متقابل کیفیت مواد اولیه (IMQ) و ضایعات تولید (DW) بر نرخ پذیرش را نشان می‌دهد.

**نمودار بالا-راست:** اثر زمان انبارش مواد اولیه (RMStorageTime) و کیفیت مواد اولیه (IMQ).

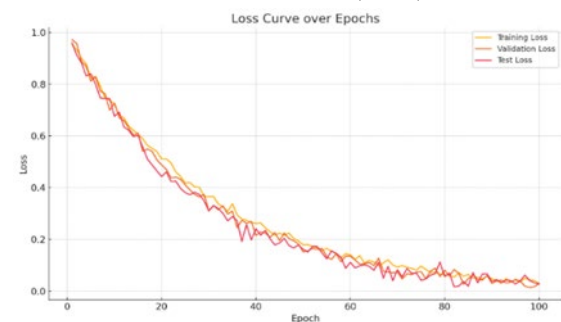
**نمودار پایین-چپ:** اثر عامل استثنای تأیید (AEF) و ضایعات تولید (DW).

**نمودار پایین-راست:** اثر شیفیت تولید (PT) و زمان انبارش مواد اولیه (RMStorageTime)

به‌منظور تولید این نمودارها، از رویکرد تحلیل حساسیت مبتنی بر مدل و ترسیم سطح پاسخ استفاده شد. پس از آموزش شبکه عصبی مصنوعی، برای هر نمودار سه‌بعدی، دو متغیر ورودی به‌صورت هم‌زمان در بازه مشاهده‌شده در داده‌های واقعی تغییر داده شدند (بر اساس حداقل و حداکثر هر متغیر)، درحالی‌که سایر متغیرهای ورودی در مقدار میانگین خود ثابت نگه داشته شدند. سپس برای هر جفت مقدار ورودی  $(X_i, X_j)$ ، خروجی شبکه عصبی

### • ارزیابی عملکرد مدل با شاخص بررسی روند خطای یادگیری

به‌منظور بررسی روند همگرایی و مقایسه خطای مدل در داده‌های آموزش، اعتبارسنجی و آزمون، شکل ۱ ارائه شده است. این نمودار روند کاهش خطای آموزش، اعتبارسنجی و آزمون را در طول ۱۰۰ دوره یادگیری نشان می‌دهد. همان‌طور که مشاهده می‌شود: خطای آموزش به‌طور یکنواخت کاهش یافته و به سطح پایین و پایداری رسیده است. خطای اعتبارسنجی نیز روندی مشابه دارد و نشانه‌ای از بیش‌برازش مشاهده نمی‌شود. خطای تست در محدوده قابل‌قبول باقی مانده است که نشان می‌دهد مدل تعمیم‌پذیری خوبی دارد. این نمودار تأیید می‌کند که فرآیند آموزش مدل موفق بوده و نیازی به تنظیم مجدد پارامترها در گام ششم وجود ندارد.



شکل ۱. نمودار خطای داده‌های آموزش، اعتبارسنجی و تست.

Figure 1. Error plot of training, validation, and test data.

### • ارزیابی عملکرد مدل با شاخص تغییرات دقت مدل

شکل ۲ تغییرات دقت مدل یا همان ضریب تعیین را در طول ۱۰۰ دوره آموزش برای سه مجموعه داده آموزش، اعتبارسنجی و آزمون نشان می‌دهد. این نمودار بیانگر چند نکته کلیدی است: هر سه مجموعه روند افزایشی ملایمی دارند که نشان می‌دهد مدل به‌تدریج یادگیری مؤثری دارد. اختلاف بین  $R^2$  مجموعه‌های اعتبارسنجی و آموزش خیلی زیاد نیست، بنابراین احتمال بیش‌برازش پایین است. هر سه منحنی پس از حدود ۷۰ تا ۸۰ دوره به یک نقطه تقریباً پایدار رسیده‌اند. در مجموع، این نمودار نشان می‌دهد که مدل دارای عملکرد نسبتاً پایدار و قابل‌اعتماد در پیش‌بینی نرخ پذیرش محصول است.

۳) پایین چپ: مجموعه آزمون

۴) پایین راست: ترکیب کل داده‌ها

خط قرمز نقطه‌چین، خط پیش‌بینی کامل را نشان می‌دهد که هر نقطه روی آن نشان‌دهنده پیش‌بینی دقیق مدل است. نقاط نزدیک به خط قرمز نشان‌دهنده دقت بالا در پیش‌بینی هستند. پراکندگی نقاط در اطراف این خط نشان می‌دهد که مدل تا حد زیادی توانسته روابط میان متغیرهای ورودی و خروجی را به‌درستی مدل‌سازی کند. توزیع نسبتاً متقارن و چگال نشان‌دهنده عدم وجود سوگیری جدی یا انحراف سیستماتیک در مدل است. این شاخص‌ها نشان می‌دهند که مدل در تمام مراحل از جمله آموزش، اعتبارسنجی و آزمون، عملکرد خوبی در پیش‌بینی نرخ پذیرش محصول داشته است.

• اهمیت نسبی متغیرهای ورودی بر اساس

وزن‌های شبکه عصبی

در شکل ۵ اهمیت نسبی متغیرهای ورودی بر اساس بر اساس میزان تأثیر در پیش‌بینی نرخ پذیرش محصول نشان داده شده است.

به صورت  $y^{\wedge}=f(x)=y^{\wedge}$  محاسبه و به‌عنوان نرخ پذیرش پیش‌بینی شده ثبت گردید. نقاط نمایش داده‌شده در شکل ۳ در واقع مجموعه‌ای از  $(x_i, x_j, y^{\wedge})$  هستند که از اجرای مدل روی یک شبکه منظم از مقادیر (grid) یا نمونه‌گیری یکنواخت از بازه واقعی داده‌ها به‌دست آمده‌اند. بدین ترتیب، شکل ۳ اثر غیرخطی و تعاملی دو متغیر را بر نرخ پذیرش پیش‌بینی شده نشان می‌دهد و مبنای تفسیر نقش اثرات هم‌زمان متغیرها در چارچوب مدل ANN فراهم می‌سازد.

• ارزیابی عملکرد مدل با شاخص خط

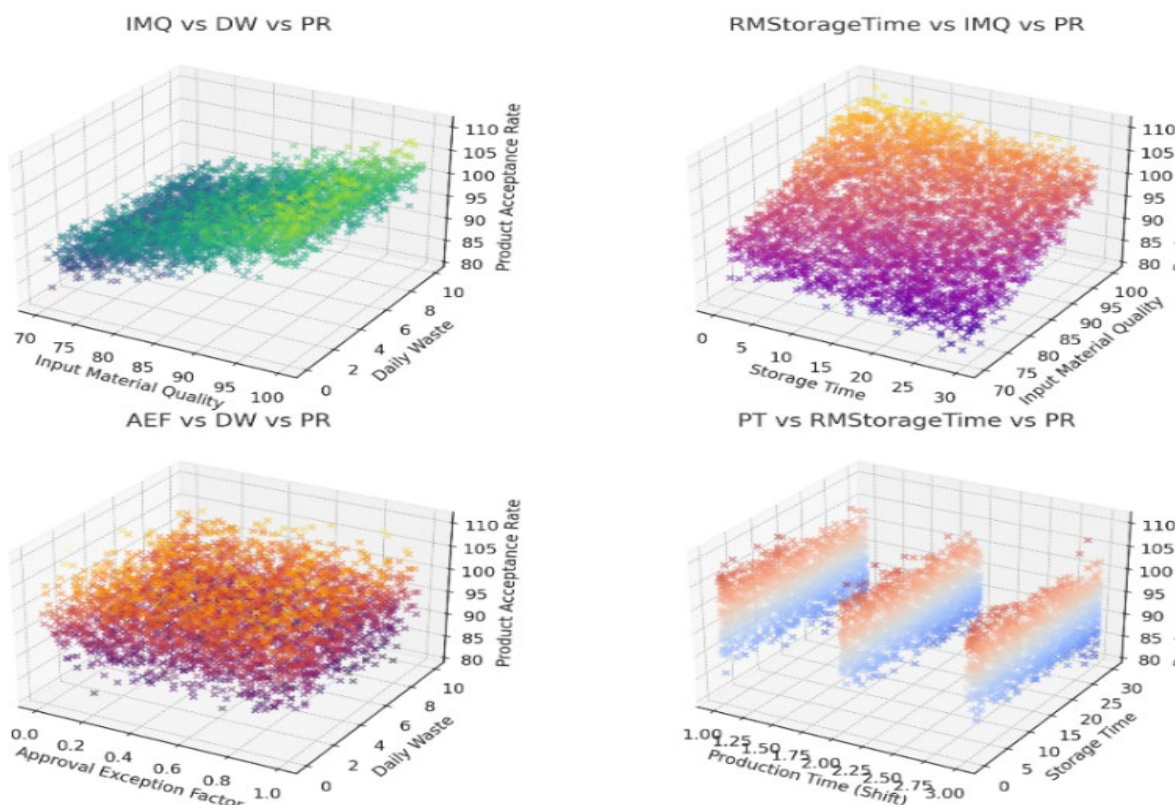
رگرسیون و شاخص  $R^2$

به‌منظور ارزیابی دقت پیش‌بینی مدل و بررسی میزان تطابق مقادیر پیش‌بینی‌شده با مقادیر واقعی در داده‌های آموزش، اعتبارسنجی و آزمون، شکل ۴ ارائه شده است.

در شکل ۴، چهار نمودار رگرسیون برای بررسی تطابق مقادیر پیش‌بینی‌شده با مقادیر واقعی نمایش داده شده‌اند:

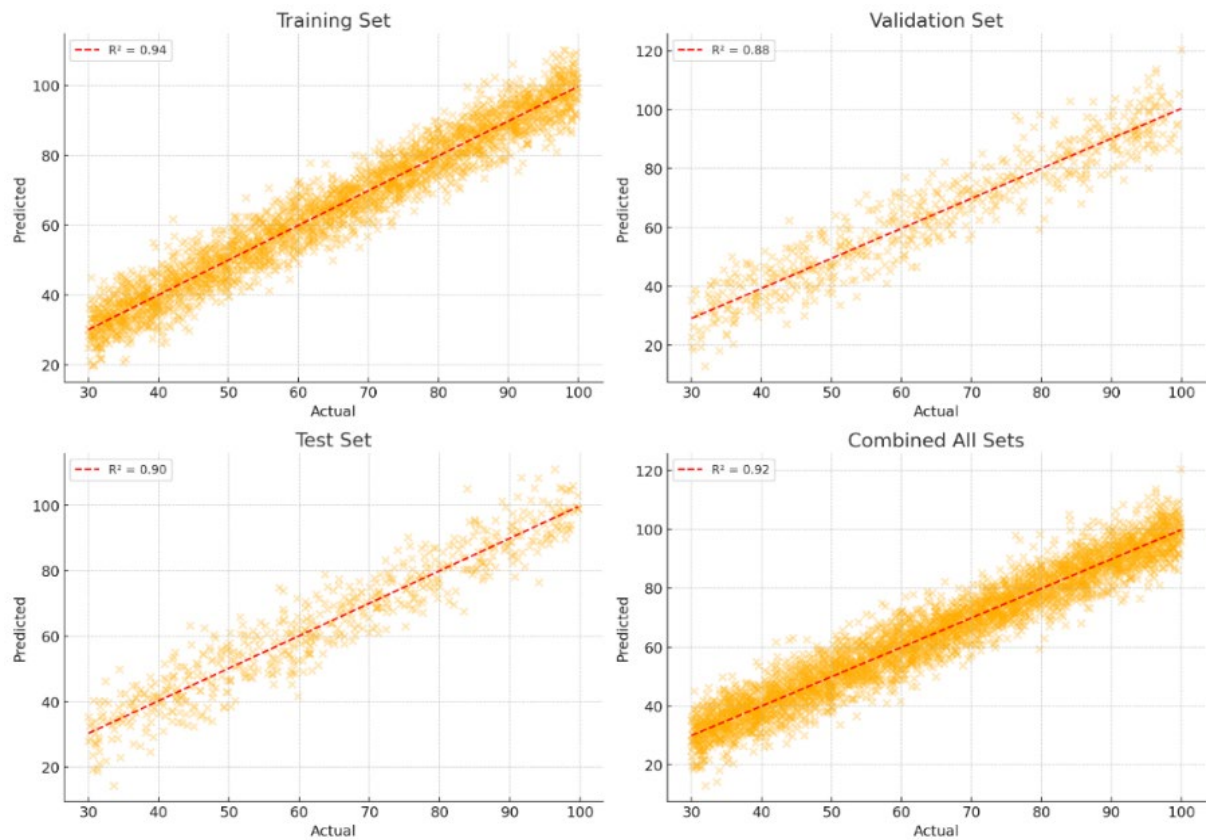
۱) بالا چپ: مجموعه آموزش

۲) بالا راست: مجموعه اعتبارسنجی




شکل ۳. تعامل بین دو متغیر ورودی و تأثیر آن‌ها بر نرخ پذیرش محصول.

Figure 3. Interaction between two input variables and their effect on product acceptance rate.



شکل ۴. بررسی دقت پیش‌بینی مدل با مقادیر واقعی.

Figure 4. Evaluation of model prediction accuracy against actual values.



شکل ۵. اهمیت نسبی متغیرهای ورودی بر اساس وزن‌های شبکه عصبی.

Figure 5. Relative importance of input variables based on neural network weights.

شاخص‌های کلیدی مؤثر بر پذیرش محصول با مشارکت خبرگان صنعت شناسایی و اعتبارسنجی شدند و سپس در بخش کمی، داده‌های واقعی خطوط تولید گردآوری و برای ساخت مدل شبکه عصبی مورد استفاده قرار گرفتند. این ساختار دومرحله‌ای امکان ایجاد مدلی را فراهم کرد که هم بر پایه دیدگاه‌های تخصصی صنعت استوار است و هم از پشتوانه داده‌های تجربی بهره‌مند است. بر اساس نتایج کمی استخراج‌شده از تحلیل اهمیت متغیرها و همان‌گونه که در شکل ۵ نشان داده شده است، کیفیت مواد اولیه با مقدار اهمیت نسبی ۰/۲۸ بیشترین نقش را در پیش‌بینی نرخ پذیرش محصول ایفا می‌کند. این یافته به‌روشنی بیانگر آن است که کنترل و بهبود کیفیت ورودی‌ها، اصلی‌ترین عامل اثرگذار بر پذیرش محصول نهایی در محیط تولید ناب محسوب می‌شود. پس‌از آن، متغیر ضایعات تولید روزانه با مقدار اهمیت ۰/۲۰ در رتبه دوم قرار دارد که نشان‌دهنده ارتباط مستقیم بهره‌وری فرایند تولید با پذیرش بازار است.

سایر متغیرها از جمله زمان شیفت تولید (۰/۱۵) و مدت‌زمان انبارش مواد اولیه (۰/۱۳) دارای اثرگذاری متوسط بوده و نقش آن‌ها عمدتاً از طریق تأثیر غیرمستقیم بر کیفیت نهایی محصول قابل تبیین است. در مقابل، نرخ تأیید استثنایی محصول (۰/۱۲) و نرخ بازگشت محصول از مشتری (۰/۱۲) اگرچه در پیش‌بینی مدل معنادار هستند، اما در مقایسه با عوامل پیشین سهم کمتری دارند. همچنین یافته‌های این پژوهش از منظر نظری نشان می‌دهد که نرخ پذیرش محصول در محیط تولید ناب صرفاً تابع کیفیت نهایی محصول نیست، بلکه نتیجه برهم‌کنش پیچیده‌ای از عوامل فرایندی، تصمیمات مدیریتی و شرایط عملیاتی است. این موضوع اهمیت نگاه سیستمی به تولید ناب را برجسته می‌کند و نشان می‌دهد که ارزیابی موفقیت تولید نباید به شاخص‌های ایستا محدود شود، بلکه باید متغیرهای پویای مؤثر بر پذیرش بازار نیز در نظر گرفته شوند. بدین ترتیب، پژوهش حاضر به توسعه ادبیات تولید ناب کمک می‌کند و مفهوم پذیرش محصول را به‌عنوان یک خروجی عملکردی مکمل در کنار کیفیت و بهره‌وری معرفی می‌نماید.

این یافته نشان می‌دهد که فرآیند تولید ناب تنها با حذف اتلاف‌ها محقق نمی‌شود، بلکه نیازمند کنترل دقیق متغیرهای ورودی، کاهش نوسانات و ثبات‌بخشی به

به‌منظور محاسبه اهمیت نسبی متغیرهای ورودی، از روش Method Connection Weights استفاده شد. در این روش، پس از آموزش کامل شبکه عصبی مصنوعی، وزن‌های ارتباطی بین لایه ورودی و لایه پنهان و همچنین وزن‌های بین لایه پنهان و لایه خروجی استخراج گردید. سپس اهمیت هر متغیر ورودی از طریق محاسبه مجموع قدرمطلق حاصل ضرب وزن‌های مسیرهای ورودی-پنهان-خروجی تعیین شد، به‌گونه‌ای که متغیرهایی با وزن‌های بزرگ‌تر، تأثیر بیشتری بر خروجی مدل دارند. درنهایت، مقادیر به‌دست‌آمده نرمال‌سازی شدند تا اهمیت نسبی متغیرها به‌صورت قابل‌مقایسه ارائه گردد. مقادیر نمایش داده‌شده در شکل ۵ بر اساس این فرآیند محاسبه شده‌اند. این رویکرد امکان رتبه‌بندی متغیرها بر اساس میزان تأثیر آن‌ها بر نرخ پذیرش محصول را فراهم کرده و به افزایش شفافیت و تفسیرپذیری مدل شبکه عصبی کمک می‌کند. تحلیل نتایج نشان می‌دهد: کیفیت مواد اولیه (IMQ) بیشترین اهمیت را در پیش‌بینی نرخ پذیرش دارد (۰/۲۸) که نشان می‌دهد کیفیت ورودی نقش کلیدی در پذیرش محصول نهایی دارد. ضایعات تولید روزانه (DW) نیز با اهمیت ۰/۲۰ تأثیر قابل‌توجهی دارد و بیانگر ارتباط مستقیم بین بهره‌وری تولید و پذیرش بازار است. زمان شیفت تولید (PST) و مدت‌زمان انبارش مواد اولیه (RMST) هر دو تأثیر متوسطی دارند که می‌تواند به دلیل تأثیر این عوامل بر کیفیت نهایی محصول باشد. نرخ اعطای تأیید استثنایی (EAR) و نرخ بازگشت محصول از مشتری (PRR) در رتبه‌های بعدی قرار دارند و اگرچه تأثیر مستقیمی دارند، اما نسبت به عوامل بالا، وزن کمتری دارند. این تحلیل به تصمیم‌گیران کمک می‌کند که بر عوامل کلیدی اثرگذار بر پذیرش محصول تمرکز کنند و راهبردهای بهبود را هدفمندتر طراحی نمایند.

## ۵- بحث و نتیجه‌گیری

پژوهش حاضر با هدف طراحی یک مدل پیش‌بینی‌کننده برای نرخ پذیرش محصول در محیط تولید ناب انجام شد تا بتواند با بهره‌گیری از داده‌های واقعی و روش‌های یادگیری ماشین، رابطه میان شاخص‌های فرایندی و کیفی را به شکل دقیق‌تری تبیین کند. روش پژوهش به‌صورت ترکیبی طراحی شد؛ به این معنا که ابتدا در بخش کیفی،

همگرایی تولید ناب و هوش مصنوعی در سیستم‌های تولیدی مدرن به شمار می‌آید.

## ۶- پیامدهای مدیریتی و کاربردی

(۱) یافته‌های این پژوهش نشان می‌دهد که کیفیت مواد اولیه، به‌عنوان اثرگذارترین متغیر ورودی مدل، نقش تعیین‌کننده‌ای در نرخ پذیرش محصول دارد. بر این اساس، مدیران تولید و کنترل کیفیت می‌توانند از خروجی مدل شبکه عصبی به‌عنوان یک ابزار پیش‌بینی‌محور برای تصمیم‌گیری درباره پذیرش یا رد مواد اولیه پیش از ورود به خط تولید استفاده کنند. راهکار اجرایی در این زمینه، استقرار یک سیستم ارزیابی کیفی ورودی مبتنی بر داده است که در آن شاخص‌های کیفی مواد اولیه به‌صورت مستمر پایش شده و مقدار پیش‌بینی‌شده نرخ پذیرش محصول به‌عنوان معیار تصمیم‌گیری مورد استفاده قرار گیرد. این ابزار می‌تواند به‌صورت یک داشبورد ساده در کنار سیستم‌های موجود کنترل کیفیت پیاده‌سازی شود و از تولید محصول نامنطبق در مراحل بعدی جلوگیری کند.

(۲) نتایج مدل همچنین نشان می‌دهد که ضایعات تولید و زمان انبارش مواد اولیه اثر غیرخطی و قابل‌توجهی بر کاهش نرخ پذیرش محصول دارند. از منظر مدیریتی، این یافته به‌معنای ضرورت بازنگری در رویه‌های نگهداری مواد اولیه و کنترل فرایندهای تولید است. راهکار پیشنهادی، استفاده از خروجی مدل برای تعریف آستانه‌های هشدار در متغیرهای ضایعات و زمان انبارش است، به‌گونه‌ای که در صورت نزدیک‌شدن این شاخص‌ها به سطوح بحرانی، اقدامات اصلاحی مانند تنظیم پارامترهای فرایندی، بازتخصیص مواد یا مداخله تیم‌های بهبود فعال شود. ابزار مناسب برای این منظور، یک سیستم هشدار زودهنگام مبتنی بر داده است که با اصول تولید ناب و پیشگیری از اتلاف هم‌راستا باشد.

فرآیندهای تولید است. یکی از یافته‌های مهم آن است که شبکه عصبی توانست الگوهای پنهان در داده‌ها را که روش‌های کلاسیک قادر به شناسایی آن‌ها نیستند استخراج کند و پیش‌بینی نسبتاً دقیقی از نرخ پذیرش محصول ارائه دهد. این نتیجه با ماهیت غیرخطی و پیچیده فرآیندهای تولید همخوان است و توضیح می‌دهد که چرا استفاده از مدل‌های داده‌محور در تحلیل کیفیت تولید کارآمدتر از روش‌های سنتی است. اهمیت نتایج این مطالعه در آن است که نشان می‌دهد روابط میان متغیرهای کلیدی تولید ناب و نرخ پذیرش محصول ماهیتی غیرخطی و وابسته به تعامل چندمتغیره دارند. این یافته به‌طور ضمنی محدودیت روش‌های سنتی خطی را در تحلیل سیستم‌های تولیدی پیچیده آشکار می‌سازد. یافته‌های این پژوهش به‌طور خاص برای صنعت مواد غذایی اهمیت ویژه‌ای دارد؛ صنعتی که در آن حساسیت نسبت به کیفیت، زمان، ضایعات و نوسانات تقاضا بسیار بالاست. نتایج نشان می‌دهد که بهبود تک‌بعدی یک عامل، تضمین‌کننده افزایش پذیرش محصول نیست و تنها از طریق مدیریت هم‌زمان چند متغیر کلیدی می‌توان به نتایج پایدار دست یافت. این بینش می‌تواند به‌عنوان مبنایی برای بازطراحی سیاست‌های کنترل کیفیت و تولید ناب در صنایع غذایی مورد استفاده قرار گیرد. اهمیت عملی نتایج پژوهش در توانایی مدل پیشنهادی برای پشتیبانی از تصمیم‌گیری پیش‌نگرانه مدیران تولید و کنترل کیفیت نهفته است.

به‌جای واکنش پس از بروز عدم پذیرش محصول در بازار، مدیران می‌توانند پیش از عرضه، سطح پذیرش احتمالی محصول را برآورد کرده و اقدامات اصلاحی لازم را در مراحل اولیه تولید اعمال کنند. این رویکرد موجب کاهش ضایعات، بهبود تخصیص منابع و افزایش هم‌راستایی بین اهداف تولید ناب و انتظارات بازار می‌شود و نقش مدل را از یک ابزار تحلیلی صرف به یک ابزار مدیریتی ارتقا می‌دهد. در مجموع، اهمیت اصلی این پژوهش در ارائه یک چارچوب پیش‌بینانه است که شکاف بین داده‌های عملیاتی تولید و رفتار بازار را پر می‌کند. این چارچوب نشان می‌دهد که تولید ناب زمانی به موفقیت واقعی منجر می‌شود که با ابزارهای هوشمند پیش‌بینی و تحلیل داده‌محور همراه شود. از این منظر، پژوهش حاضر نه تنها به بهبود عملکرد تولید کمک می‌کند، بلکه گامی در جهت

توان مدل را در واکنش سریع به تغییرات ناگهانی فرایند تولید، نوسانات تقاضا و شرایط محیطی افزایش داده و دقت پیش‌بینی نرخ پذیرش محصول را در محیط‌های پویای تولید ناب بهبود بخشد. با توجه به وابستگی مدل ارائه‌شده به داده‌های صنایع غذایی و این نکته که مقدار خطای پیش‌بینی در برخی محصولات بحرانی می‌تواند پیامدهای عملیاتی مهمی داشته باشد، پیشنهاد می‌شود پژوهش‌های آتی مدل را در صنایع دیگر یا برای محصولات با استانداردهای کیفی سخت‌گیرانه‌تر ارزیابی کنند. انجام مطالعات مقایسه‌ای بین صنایع می‌تواند به شناسایی متغیرهای عمومی و صنعت‌محور مؤثر بر پذیرش محصول کمک کرده و زمینه‌ساز توسعه مدل‌های دقیق‌تر و قابل‌تعمیم‌تر در چارچوب تولید ناب داده‌محور شود. بررسی نقش متغیرهای تکمیلی مانند عوامل رفتاری اپراتورها، شرایط محیطی تولید و سیاست‌های کنترلی سازمان در کنار متغیرهای فنی می‌تواند به توسعه مدل‌های جامع‌تر منجر شود. چنین پژوهش‌هایی می‌توانند به درک عمیق‌تر از تعامل عوامل انسانی و فنی در پذیرش محصول کمک کرده و چارچوب‌های تصمیم‌گیری هوشمندتری برای پیاده‌سازی تولید ناب ارائه دهند.

## ۸- محدودیت‌های پژوهش

باوجود دستاوردهای قابل‌توجه پژوهش حاضر در طراحی یک مدل داده‌محور برای پیش‌بینی نرخ پذیرش محصول در محیط تولید ناب، نتایج آن با برخی محدودیت‌ها همراه است که باید در تفسیر یافته‌ها موردتوجه قرار گیرند. نخست، مدل پیشنهادی بر اساس داده‌های تاریخی استخراج‌شده از خطوط تولید صنایع غذایی توسعه یافته است؛ از این‌رو، عملکرد و دقت پیش‌بینی آن تا حدی به ویژگی‌های ساختاری، فرایندی و کیفی این صنعت خاص وابسته است. در نتیجه، تعمیم مستقیم نتایج به سایر صنایع تولیدی با ماهیت متفاوت باید با احتیاط صورت گیرد. دوم، اگرچه مدل شبکه عصبی مصنوعی توانسته است روابط غیرخطی میان متغیرهای ورودی و نرخ پذیرش محصول را با دقت مناسبی شناسایی کند، اما تغییرات فصلی، نوسانات تقاضا و شوک‌های محیطی یا عملیاتی به‌صورت صریح در ساختار مدل لحاظ نشده‌اند.

۳) عامل استثنای تأیید محصول و شیفت کاری نیز به‌عنوان متغیرهای مؤثر در مدل شناسایی شدند که بیانگر نقش شرایط عملیاتی و تصمیمات مدیریتی در پذیرش نهایی محصول هستند. از این منظر، مدیران می‌توانند از مدل پیش‌بینی ارائه‌شده برای ارزیابی اثر تغییرات شیفت کاری یا سیاست‌های تأیید استثنایی بر نرخ پذیرش محصول استفاده کنند. راهکار اجرایی در این زمینه، شبیه‌سازی سناریوهای مختلف تولید پیش از اجرای واقعی آن‌هاست، به‌طوری‌که اثر هر تصمیم مدیریتی بر پذیرش محصول به‌صورت کمی پیش‌بینی شود. این رویکرد می‌تواند از طریق یک ابزار تصمیم‌یار ساده مبتنی بر خروجی شبکه عصبی در جلسات برنامه‌ریزی تولید مورد استفاده قرار گیرد.

۴) در نهایت، ترکیب تمامی متغیرهای ورودی در قالب یک مدل پیش‌بینی‌کننده واحد نشان می‌دهد که بهبود نرخ پذیرش محصول صرفاً از طریق تمرکز بر یک عامل امکان‌پذیر نیست و نیازمند نگاه سیستمی به فرایند تولید ناب است. پیامد مدیریتی این یافته آن است که مدیران باید به‌جای تصمیم‌گیری‌های جزیره‌ای، از ابزارهای تحلیلی داده‌محور برای ارزیابی هم‌زمان اثر متغیرهای کیفی و فرایندی استفاده کنند. راهکار پیشنهادی، استقرار یک سامانه پشتیبان تصمیم مبتنی بر شبکه عصبی است که خروجی آن به‌عنوان مبنای برنامه‌ریزی تولید، تخصیص منابع و کنترل کیفیت به کار گرفته شود و زمینه حرکت به‌سوی تولید ناب هوشمند و مبتنی بر داده را فراهم آورد.

## ۷- پیشنهادات برای پژوهش‌های آینده

با توجه به محدودیت مدل حاضر در استفاده از داده‌های تاریخی و عدم پوشش صریح تغییرات فصلی و نوسانات زمانی، پیشنهاد می‌شود در پژوهش‌های آینده از داده‌های بلادرنگ و مدل‌های یادگیری ماشین مبتنی بر زمان، نظیر شبکه‌های بازگشتی یا مدل‌های ترکیبی سری زمانی-یادگیری عمیق استفاده شود. این رویکرد می‌تواند

- and its Impact on Customer Attraction (a Case Study in Tehran Railway Company). *Systems Engineering and Productivity*, 3(1), 41–65 (In Persian).  
<https://doi.org/10.22034/sep.2023.706142>
- Alsaedi, A. W. M., Al-Hilphy, A. R., Al-Mousawi, A. J., & Gavahian, M. (2024). Artificial neural network modeling to predict electrical conductivity and moisture content of milk during non-thermal pasteurization: New application of artificial intelligence (AI) in food processing. *Processes*, 12(11), 2507.  
<https://doi.org/10.3390/pr12112507>
- Al-Shboul, M. D. A. (2025). Assessing sustainability of green supply chain performance: The roles of agile innovative products, business intelligence readiness, innovative supply chain process integration, and lean supply chain capability as a mediating factor. *Journal of Open Innovation: Technology, Market, and Complexity*, 11(1), 100476.  
<https://doi.org/10.1016/j.joitmc.2025.100476>
- Amani, N., Taghizadeh, H., & Iranzadeh, S. (2020). Discriminant Analysis of Supply Chain Sustainability Clusters Based on Leans Tools. *Journal of Executive Management (JEM) University of Mazandaran*, 12(23), 67–94 (In Persian).  
<https://doi.org/10.22080/jem.2020.17905.3085>
- Bahramparvar, M., Salehi, F., & Razavi, S. M. (2014). Predicting total acceptance of ice cream using artificial neural network. *Journal of Food Processing and Preservation*, 38(3), 1080–1088 (In Persian). <https://doi.org/10.1111/jfpp.12066>
- Banaei, Gh., & Maleki, M. R. (2021). Investigating the relationship between top managers' leadership, employee empowerment, job satisfaction, and customer satisfaction in organizations implementing total quality management. *Systems Engineering and Productivity*, 11(1), 99–120 (In Persian).  
<https://doi.org/10.22034/sep.2022.243399>
- Bashar, A., Hasin, A. A., & Adnan, Z. H. (2021). Impact of lean manufacturing: Evidence from apparel industry in Bangladesh. *International Journal of Lean Six Sigma*, 12(5), 923–943.  
<https://doi.org/10.1108/IJLSS-01-2020-0005>
- Batista, L. F., Marques, C. S., Pires, A. C. S., Minim, L. A., Soares, N. F. F., & Vidigal, M. C. T. R. (2021). Artificial neural networks modeling of non-fat yogurt texture properties: Effect of process conditions and food composition. *Food and Bioprocess Technology*, 126, 164–174.  
<https://doi.org/10.1016/j.fbp.2021.01.002>
- Batwara, A., Kediya, S., & Kayande, R. A. (2025). An analytical framework for optimizing supply chain operations with lean practices. *Supply*
- عدم پوشش این عوامل می‌تواند در شرایطی که الگوهای تولید و کیفیت به‌طور ناگهانی تغییر می‌کنند، بر دقت پیش‌بینی مدل تأثیرگذار باشد. سوم، مقدار میانگین خطای مطلق ( $MAE \approx 4.5$ ) هرچند از نظر آماری قابل‌قبول است، اما در مورد برخی محصولات با حساسیت کیفی بالا یا استانداردهای سخت‌گیرانه پذیرش، می‌تواند به‌عنوان یک محدودیت عملیاتی تلقی شود. در چنین مواردی، حتی انحراف‌های کوچک در پیش‌بینی نرخ پذیرش ممکن است پیامدهای اقتصادی یا کیفی قابل‌توجهی به همراه داشته باشد.

## مشارکت‌های نویسندگان

همه نویسندگان در مقاله نقش و سهم یکسان داشته‌اند.

## تضاد منافع

نویسندگان اعلام می‌کنند که هیچ‌گونه تضاد منافع مرتبط با تحقیق حاضر ندارند و نتایج به‌صورت بی‌طرفانه و بدون دخالت منافع شخصی یا حرفه‌ای به‌دست‌آمده است.

## قدردانی

نویسندگان از عوامل اجرایی نشریه مهندسی سیستم و بهره‌وری و همچنین داوران محترم که کیفیت این مقاله را افزایش دادند، قدردانی می‌نمایند.

## مراجع

- Abedi, S., Karimi, M. R., & Alinezhad, A. (2025). Predicting and Analyzing Pathways toward Sustainable Development of the Mining Sector under the NZE Scenario: An Integrated Approach Using Fuzzy MCDM and ANFIS. *Journal of Mining and Environment* (In Persian).  
<https://doi.org/10.22044/jme.2025.16846.3304>
- Alfiani, R. N., Ushada, M., Ainuri, M., & Fajar Falah, M. A. (2024). Modeling consumer overall acceptance for traditional spice-based ready-to-drink using artificial neural network and Kansei engineering. *International Journal on Advanced Science, Engineering and Information Technology*, 14(4), 1528–1536.  
<https://doi.org/10.18517/ijaseit.14.4.19314>
- Alivardilou, M., & Ahmadvand, A. M. (2023). Investigating the Factors Affecting the Implementation of Total Quality Management

- strategies: A literature review. *Materials Today: Proceedings*, 62(3), 1489–1495. <https://doi.org/10.1016/j.matpr.2022.02.155>
- Dieste, M., Panizzolo, R., & Garza-Reyes, J. A. (2021). A systematic literature review regarding the influence of lean manufacturing on firms' financial performance. *Journal of Manufacturing Technology Management*, 32(9), 101–121. <https://doi.org/10.1108/JMTM-08-2020-0304>
- Elnadi, M., Gheith, M. H., Troise, C., Bresciani, S., & Abdallah, Y. O. (2025). Examining the interplay of Industry 4.0, lean, agile, and circular manufacturing practices on sustainability performance. *Technovation*, 146, 103290. <https://doi.org/10.1016/j.technovation.2025.103290>
- Emamzadeh, M., & Tabatabaei, S. M. (2020). Effective prioritization in the implementation of destroyed production in the rotating company of Tabriz using the network process analysis method. *Applied Research in Management and Accounting*, 5(19), 1–23 (In Persian).
- Esmaili, Kh. A., Taghaddos, H., & Karimi, M. S. (2021). enhancing construction process employing lean principles and discrete event simulation. *Sharif journal of civil engineering*, 37-2(2/1), 39–49 (In Persian).
- Farahkord Mahalleh, A., & Hosseini, S. A. R. (2022). Investigating the relationship between total quality management and competitive advantage in healthcare centers. *Systems Engineering and Productivity*, 2(4), 45–63 (In Persian). <https://doi.org/10.22034/sep.2023.704331>
- Ferrazzi, M., Costa, F., Frecassetti, S., & Portioli-Staudacher, A. (2025). Unlocking synergies in lean manufacturing for enhanced environmental performance: A cross-sector investigation through fuzzy DEMATEL. *Cleaner Logistics and Supply Chain*, 15, 100219. <https://doi.org/10.1016/j.clscn.2025.100219>
- Gatell, I. S., & Avella, L. (2024). Impact of Industry 4.0 and circular economy on lean culture and leadership: Assessing digital green lean as a new concept. *European Research on Management and Business Economics*, 30(1), 100232. <https://doi.org/10.1016/j.iemeen.2023.100232>
- Gorbachev, V., Nikitina, M., Velina, D., Mutallibzoda, S., Nosov, V., Korneva, G., Terekhova, A., Artemova, E., Khashir, B., Sokolov, I., Dimitrieva, S., & Nikitin, I. (2022). Artificial neural networks for predicting food antiradical potential. *Applied Sciences*, 12(12), 6290. <https://doi.org/10.3390/app12126290>
- Habib, M. A., Rizvan, R., & Ahmed, S. (2023). Implementing lean manufacturing for improvement of operational performance in a labeling and packaging plant: A case study in *Chain Analytics*, 11, 100145. <https://doi.org/10.1016/j.sca.2025.100145>
- Boumsisse, I., Benhadou, M., & Haddout, A. (2025). Optimizing Green Lean Six Sigma using Industry 5.0 technologies. *Cleaner Waste Systems*, 10, 100234. <https://doi.org/10.1016/j.clwas.2025.100234>
- Bubber, D., Babber, G., Shashi, & Jain, R. K. (2023). Toward increased business productivity: Interlinks between lean thinking, process quality, inventory management, and productivity. *Global Knowledge, Memory and Communication*, 74(56), 1511–1531. <https://doi.org/10.1108/GKMC-03-2023-0079>
- Bueno, A., Caiado, R. G. G., Oliveira, T. L. G. de., Scavarda, L. F., Godinho Filho, M., & Tortorella, G. L. (2023). Lean 4.0 implementation framework: Proposition using a multi-method research approach. *International Journal of Production Economics*, 264, 108988. <https://doi.org/10.1016/j.ijpe.2023.108988>
- Costa, F., Alemsan, N., Bilancia, A., Tortorella, G. L., & Portioli Staudacher, A. (2024). Integrating industry 4.0 and lean manufacturing for a sustainable green transition: A comprehensive model. *Journal of Cleaner Production*, 465, 142728. <https://doi.org/10.1016/j.jclepro.2024.142728>
- Cui, F., Zheng, S., Wang, D., Tan, X., Li, Q., Li, J., & Li, T. (2023). Recent advances in shelf life prediction models for monitoring food quality. *Comprehensive Reviews in Food Science and Food Safety*, 22(2), 1257–1284. <https://doi.org/10.1111/1541-4337.13110>
- Dębska, B., & Guzowska-Swider, B. (2011). Application of artificial neural network in food classification. *Analytica Chimica Acta*, 705(1–2), 283–291. <https://doi.org/10.1016/j.aca.2011.06.033>
- Dehghani Filabadi, A., Titekkanlou, H. N., & Jamali, S. (2025). Identification and ranking of key factors in adopting total quality management using a hybrid Delphi–Fuzzy SWARA approach (Case study: Shiraz Petrochemical Company). *Systems Engineering and Productivity*, (In Persian). <https://doi.org/10.22034/sep.2025.2071569.1394>
- Deng, F., Lu, H., Yuan, Y., Chen, H., Li, Q., Wang, L., Tao, Y., Zhou, W., Cheng, H., Chen, Y., Lei, X., Li, G., Li, M., & Ren, W. (2023). Accurate prediction of the eating and cooking quality of rice using artificial neural networks and the texture properties of cooked rice. *Food Chemistry*, 407, 135176. <https://doi.org/10.1016/j.foodchem.2022.135176>
- Deshmukh, M., Gangele, A., Gope, D. K., & Dewangan, S. (2022). Study and implementation of lean manufacturing

- manufacturing: Testing moderation effects. *International Journal of Production Economics*, 203, 301-310. <https://doi.org/10.1016/j.ijpe.2018.07.009>
- Ojha, R., & Venkatesh, U. (2022). Manufacturing excellence using lean systems—a case of an automotive aggregate manufacturing plant in India. *Journal of Advances in Management Research*, 19(1), 1-11. <https://doi.org/10.1108/JAMR-10-2020-0284>
- Ranjbar Zarenagh, M., Nabatcheian, M. R., Arshadi, M. J., & Roshan Zamir, S. (2024). Identifying and Prioritizing Obstacles to Implementing Lean Manufacturing in Iran's Printing Industry. *Systems Engineering and Productivity*, 4(3), 83–102(In Persian). <https://doi.org/10.22034/sep.2024.717031>
- Reza, J. R. D., Alcaraz, J. L. G., Ramírez, C. S., López, J. A. G., Vargas, A. R., & Álvarez, J. L. R. (2025). Achieving strategic goals by continuous improvement and lean manufacturing implementation: A structural equation model-system dynamics approach. *Sustainable Futures*, 9, 100551. <https://doi.org/10.1016/j.sftr.2025.100551>
- Sahoo, S. (2020). Assessing lean implementation and benefits within Indian automotive component manufacturing SMEs. *Benchmarking: An International Journal*, 27(3), 1042-1084. <https://doi.org/10.1108/BIJ-07-2019-0299>
- Shi, C., Zhao, Z., Jia, Z., Hou, M., Yang, X., Ying, X., & Ji, Z. (2024). Artificial neural network-based shelf life prediction approach in the food storage process: A review. *Critical Reviews in Food Science and Nutrition*, 64(32), 12009–12024. <https://doi.org/10.1080/10408398.2023.2245899>
- Sundararajan, N., & Terkar, R. (2022). Improving productivity in fastener manufacturing through the application of Lean-Kaizen principles. *Materials Today: Proceedings*, 62, 1169-1178. <https://doi.org/10.1016/j.matpr.2022.04.350>
- Sunmola, F., Mbafotu, O. R., Salihu-Yusuf, M. L., & Sunmola, H. O. (2024). Lean green practices in automotive components manufacturing. *Procedia Computer Science*, 232, 2001-2008. <https://doi.org/10.1016/j.procs.2024.02.022>
- Synnes, E. L., & Welo, T. (2022). Using lean to transform the product development process in a marine company: A case study. *Procedia CIRP*, 109, 623-628. <https://doi.org/10.1016/j.procir.2022.05.304>
- Tavana, M., Di Caprio, D., & Rostamkhani, R. (2025). A total quality management action plan assessment model in supply chain management using the lean and agile scores. *Journal of Innovation & Knowledge*, 10(1), Bangladesh. *Results in Engineering*, 17, 100818. <https://doi.org/10.1016/j.rineng.2022.100818>
- Hariyani, D., & Mishra, S. (2022). Drivers for the adoption of integrated sustainable green lean six sigma agile manufacturing system (ISGLSAMS) and research directions. *Cleaner Engineering and Technology*, 7, 100449. <https://doi.org/10.1016/j.clet.2022.100449>
- Hariyani, D., Mishra, S., Sharma, M. K., & Hariyani, P. (2023). A study of the barriers to the adoption of integrated sustainable-green-lean-six sigma-agile manufacturing system (ISGLSAMS) in Indian manufacturing organizations. *Cleaner Waste Systems*, 5, 100098. <https://doi.org/10.1016/j.clwas.2023.100098>
- Hossain, M. M., & Purdy, G. (2023). Integration of Industry 4.0 into lean production systems: a systematic literature review. *Manufacturing Letters*, 35, 1347-1357. <https://doi.org/10.1016/j.mfglet.2023.08.098>
- Huang, X., You, Y., Zeng, X., Liu, Q., Dong, H., Qian, M., Xiao, S., Yu, L., & Hu, X. (2024). Back propagation artificial neural network (BP-ANN) for prediction of the quality of gamma-irradiated smoked bacon. *Food Chemistry*, 437(Part 1), 137806. <https://doi.org/10.1016/j.foodchem.2023.137806>
- Jing, S., Feng, Y., & Yan, J. (2021). Path selection of lean digitalization for traditional manufacturing industry under heterogeneous competitive position. *Computers & Industrial Engineering*, 161, 107631. <https://doi.org/10.1016/j.cie.2021.107631>
- Kosasih, W., Pujawan, I. N., Karningsih, P. D., & Shee, H. (2023). Integrated lean-green practices and supply chain sustainability framework. *Cleaner and Responsible Consumption*, 11, 100143. <https://doi.org/10.1016/j.clrc.2023.100143>
- Lakshmanan, R., Nyamekye, P., Virolainen, V. M., & Piili, H. (2023). The convergence of lean management and additive manufacturing: Case of manufacturing industries. *Cleaner Engineering and Technology*, 13, 100620. <https://doi.org/10.1016/j.clet.2023.100620>
- Liakos, K. G., Athanasiadis, V., Bozinou, E., & Lalas, S. I. (2025). Machine learning for quality control in the food industry: A review. *Foods*, 14(19), 3424. <https://doi.org/10.3390/foods14193424>
- Limon-Romero, J., García-Alcaraz, J. L., Gastelum-Acosta, C., Antony, J., Baez-Lopez, Y., & Tortorella, G. (2025). Toward the successful adoption of Lean Six Sigma in manufacturing organizations: proposing a causal model. *International Journal of Productivity and Performance Management*, 74(6), 1897-1918. <https://doi.org/10.1108/IJPPM-07-2024-0436>
- Marodin, G., Frank, A. G., Tortorella, G. L., & Netland, T. (2018). Lean product development and lean

100633.

<https://doi.org/10.1016/j.jik.2024.100633>

Utama, D. M., & Abirfatin, M. (2023). Sustainable Lean Six-sigma: A new framework for improve sustainable manufacturing performance. *Cleaner engineering and technology*, 17, 100700.

<https://doi.org/10.1016/j.clet.2023.100700>

Waheed, W., Khodeir, L., & Fathy, F. (2025). Investigation of sustainability and lean approaches for efficient architecture design management. *Results in Engineering*, 27, 105847.

<https://doi.org/10.1016/j.rineng.2025.105847>

Yang, X., Zhu, L., Jiang, W., Yang, Y., Niu, L., Zhao, Y., Wang, Y., Chen, L., Gan, M., Zhu, L., & Shen, L. (2025). Artificial intelligence-driven food quality prediction: Applying machine learning ensemble models for dynamic forecasting of pork pH and meat color changes. *Food Chemistry*, 492(Part 2), 145383.

<https://doi.org/10.1016/j.foodchem.2025.145383>

Yu, P., Low, M. Y., & Zhou, W. (2018). Development of a partial least squares-artificial neural network (PLS-ANN) hybrid model for the prediction of consumer liking scores of ready-to-drink green tea beverages. *Food Research International*, 103, 68-75.

<https://doi.org/10.1016/j.foodres.2017.10.015>

Zhu, N., Wang, K., Zhang, S.-L., Zhao, B., Yang, J.-N., & Wang, S.-W. (2021). Application of artificial neural networks to predict multiple quality of dry-cured ham based on protein degradation. *Food Chemistry*, 344, 128586.

<https://doi.org/10.1016/j.foodchem.2020.128586>

[6](#)