



Designing a Digital Twin System for Plastic Injection Molding Machine to Improve Production Cycle Time (Case Study: Entekhab Industrial Group)

Mohammad Javad Aghalar¹, Kamran Kianfar² , Alireza Goli³ and Mohammad Abdeyazdan^{4,5}

1. MSc. of Industrial Engineering, Faculty of Engineering, University of Isfahan, Isfahan, Iran. Email: mohamadj81@gmail.com
2. Assistant Professor of Industrial Engineering, Faculty of Engineering, University of Isfahan, Isfahan, Iran. Email: k.kianfar@eng.ui.ac.ir
3. Assistant Professor of Industrial Engineering, Faculty of Engineering, University of Isfahan, Isfahan, Iran. Email: goli.a@eng.ui.ac.ir
4. PhD Candidate in Industrial Engineering, Department of Industrial & Systems Engineering, Isfahan University of Technology, Isfahan, Iran. Email: m.abdeyazdan@in.iut.ac.ir

Article Info	ABSTRACT
Article type: Research Article	Technological advancements in Industry 4.0 have brought about fundamental changes in manufacturing processes through the use of advanced digital technologies such as Digital Twin, Internet of Things (IoT), and Artificial Intelligence (AI). This study examines the Digital Twin as one of the key technologies of this industrial revolution. After analyzing the injection molding process, the implementation of a Digital Twin system is proposed for the plastic injection molding machine at Plastic factory, a subsidiary of Entekhab Industrial Group. The proposed system consists of real-time data collection and three subsystems: simulation, artificial intelligence, and a graphical user interface. The simulation is designed using MoldFlow software, and the AI model is implemented with a neural network in Python, utilizing real-world data. The Digital Twin simulator can adjust parameters such as injection pressure and speed, mold temperature, and cooling water temperature in real time, leading to reduced production cycle time while maintaining the physical quality of the product. The results indicate that the implementation of this system led to a 13.3% reduction in production cycle time and an increase in production rate.
Article history: Received 10 December 2024 Received in revised form 30 May 2025 Accepted 21 October 2025 Published online 1 December 2025	
Keywords: Digital Twin Plastic Injection Simulation Neural Network Production Cycle Time Entekhab Industrial Group.	

Cite this article: Aghalar, M. & et al, (2025), Designing a Digital Twin System for Plastic Injection Molding Machine to Improve Production Cycle Time (Case Study: Entekhab Industrial Group). *Engineering Management and Soft Computing*, 11 (2). 21-55.
DOI: <https://doi.org/10.22091/jemsc.2025.11872.1232>



© Aghalar et. al (2025)

Publisher: University of Qom

DOI: <https://doi.org/10.22091/jemsc.2025.11872.1232>

1) INTRODUCTION

Injection molding is one of the most widely used processes for manufacturing plastic parts, carried out using an injection molding machine, mold, and temperature control systems. It is a process in which molten plastic is injected into a mold under pressure. The process consists of heating, injection, cooling, and ejection stages, all of which influence the production cycle time. One of the main challenges of this process is the precise adjustment of the cycle time to increase productivity while maintaining the quality of the final product. Therefore, optimizing the time and precisely controlling process parameters play a crucial role in improving performance and reducing production costs. To achieve this goal, integrating existing Industry 4.0 technologies, such as the Digital Twin, can help enhance the process and improve production performance. The Digital Twin, through real-time simulation and the use of real data, enables the optimization of the molding process and reduction of the production cycle time.

The plastic injection unit of Entekhab Industrial Group faces various challenges in optimizing the production process due to the diversity of parts and molding machines used. The injection molding machines, manufactured by Borche, operate in parallel with different tonnages and are used to produce various plastic components for products such as refrigerators, washing machines, and vacuum cleaners. The production cycle time of each machine, particularly during the product cooling phase after injection, is a critical factor that directly impacts the quality and speed of production. Due to the manual adjustment of the parameters influencing the cycle time, this duration may either be too high, resulting in insufficient production output, or too low, leading to substandard quality of the produced parts. Therefore, there is a strong need for a system capable of optimizing the production cycle time using real-time and actual data. The proposed Digital Twin system leverages real-time simulation and optimization, utilizing real-time sensor data and historical information to enhance production process optimization and quality control.

In the study by Hürkamp [1] a Digital Twin and surrogate models were employed to support decision-making in thermoplastic composite injection molding processes. These models focus on predicting quality and real-time process control, utilizing methods such as decision trees for evaluation. Wang [2] implemented an intelligent manufacturing system for injection molding using a Digital Twin. The aim of this system was to enhance production efficiency, monitor the process, and reduce costs. The technologies used included smart control and cloud platforms, enabling quality monitoring and defect detection. Lacueva-Pérez [3] introduced the SHION system, a cloud-based Digital Twin supported by artificial intelligence for failure prediction in injection molding. This system analyses Internet of Things (IoT) data to identify errors and defective products in real time, improving production quality. Modoni [4] implemented a Digital Twin for monitoring and optimizing the micro injection molding (μ IM) process. The model examines parameters such as pressure and temperature to ensure product quality using data collected from sensors. The results showed reduced waste and improved production cycle time. In the research by Rehmer et al. [5], predictive quality models for plastic injection molding were explored. Dynamic models, such as feedforward neural networks, were utilized for quality prediction and process control, leading to improved prediction accuracy and optimized quality of the produced parts.

The main innovation of this research lies in the implementation of a Digital Twin to improve the cycle time of the injection molding process. Unlike previous studies, which primarily focused on product quality enhancement and process monitoring, this study specifically addresses cycle time optimization using a Digital Twin and real-time data analysis. By integrating machine learning technologies and the Internet of Things (IoT), the Digital Twin can predict and adjust key process parameters, such as cooling time and injection pressure, resulting in a significant reduction in production cycle time. This innovation can enhance productivity in the injection molding industry and effectively reduce production costs, while also enabling large-scale optimization of the manufacturing process.

2) Solution Method

The Digital Twin system for the injection molding machine and production cycle time calculation consists of two main components. The first component of the Digital Twin system is dedicated to

collecting and transmitting production process data from the plastic injection machine. This data includes parameters such as mold temperature, injection pressure, various process times (injection, cooling, ejection), and other specifications related to machine performance. The process information is collected using sensors such as inductive sensors, thermocouples (temperature sensors), pressure transmitters, linear position sensors, optocouplers, and microswitches. Each of these sensors continuously records various real-time data related to the machine's conditions and materials.

The second component of the system comprises the Digital Twin framework, which consists of artificial intelligence algorithms and simulation software. This component is designed for intelligent decision-making and real-time analysis of data collected from the physical machine. By creating virtual models of the process, it enables the simulation of various scenarios and the evaluation of potential changes to improve system performance. Initially, process data, machine information, and part details are input into the two subsystems: simulation and artificial intelligence algorithms. Training and initial modelling of the AI system and simulation are conducted using this data. Subsequently, the final AI model and the optimized parameters derived from the simulation are displayed in the graphical user interface (GUI). Additionally, the simulation results for various scenarios can be utilized within the GUI-embedded AI model to predict the production cycle time. If the AI's predictions demonstrate high accuracy, these inputs can be used as new training samples for the AI model to further enhance its precision.

The graphical user interface of the Digital Twin system, developed using Python, plays a crucial role in real-time monitoring of the injection molding process. This interface displays real-time data from various stages of the process, the production cycle time, and the operational status of the machine (active or inactive). It also provides access to information about the produced part and the simulation results. Through the GUI, users can perform production cycle time predictions using artificial intelligence and directly run the MoldFlow simulation software.

The artificial neural network (ANN) subsystem, inspired by the structure of the human brain, is designed to predict the production cycle time. This neural network will be implemented in Python and consists of input, hidden, and output layers. The network includes two hidden layers with 64 and 32 neurons, respectively, configured to extract complex patterns. The *ReLU* activation function and the Mean Squared Error (MSE) loss function are employed to optimize the model's accuracy. The network is trained using the Adam optimization algorithm for 100 epochs. If the accuracy is insufficient, a grid search algorithm will be applied to fine-tune the hyperparameters, ensuring optimal performance.

3) Experimental Tests

To implement this system in a real production environment and evaluate its reliability and accuracy, a case study was conducted on one of the plastic parts produced by *Entekhab Industrial Group*. The part under study is a plastic component of a dishwasher, weighing 73 grams and made of polyamide reinforced with 30% glass fiber. It is produced using a single-cavity mold with a cold runner system. This plastic part is manufactured on Borsche brand injection molding machines, which feature specifications such as an injection shot volume of 1346 cm³, a clamping force of 3200 kN, and a maximum injection pressure of 166 MPa.

In the initial simulation, conducted using real process data, the process parameters were extracted from the injection molding machine and the KEBA controller and configured in the simulation software. These parameters included melt temperature (290°C), mold surface temperature (80°C), and the times for injection, holding, and cooling, which totalled 43.5 seconds per cycle.

After running the simulation, the filling phase resulted in an injection time of 4.19 seconds. As illustrated in Figure 1, it was observed that the edges of the part were filled later. During the holding phase, the pressure reached 89.16 MPa and then stabilized.




Figure 1: Visualization of Injection Process and Timing in the Software

In the second simulation, the MoldFlow software automatically executed all simulations, optimally calculating the process parameters for injection, holding, and cooling. The melt temperature remained at 290°C, and the mold opening and closing time stayed fixed at 20 seconds. The results of the automated simulation showed that the injection time was reduced to 0.808 seconds, with an injection pressure of 46.32 MPa. The holding phase lasted 4.68 seconds with a pressure of 50.84 MPa. The gross weight of the part and runner was calculated to be 83.56 grams. In the cooling phase, the total production cycle time was calculated to be 38.59 seconds, encompassing all stages. The coolant water temperature was 15°C, and the average temperature of the part after cooling was recorded as 51.13°C. (see Figure 2)

Summary of Cavity Temperature Results		Packing phase results summary :	
=====		Peak pressure	
Part surface temperature - maximum	= 78.3140 C	- minimum among cavity nodes	(at 0.000 s) = 0.0000 MPa
Part surface temperature - minimum	= 29.5314 C	Clamp force - maximum	(at 1.218 s) = 55.9463 tonne
Part surface temperature - average	= 51.1367 C	Total weight - maximum	(at 5.468 s) = 83.5644 g
Cavity surface temperature - maximum	= 72.3600 C	Pack/hold pressure profile (abs):	
Cavity surface temperature - minimum	= 23.8549 C	duration	pressure
Cavity surface temperature - average	= 44.6580 C	0.0000 s	46.3220 MPa
Average mold exterior temperature	= 19.8049 C	0.2000 s	50.8403 MPa
Heat removal through the outer boundaries	= -0.1719 kW	4.4698 s	50.8403 MPa
Cycle time calculated from percentage frozen on average part thickness	= 38.5934 s	End of packing phase results summary :	
Cycle time	= 290.0000 C	Time at the end of packing	= 18.5936 s
Maximum temperature	= 15.0000 C	Total weight (part + runners)	= 83.5632 g
Minimum temperature			

Figure 2: Results of the Holding and Cooling Phases in the Automated Mode

4) conclusion

This study examines the plastic injection molding process using Industry 4.0 technologies and the development of a Digital Twin system for monitoring and optimizing production cycle time. This system was implemented at Entekhab Industrial Group and consists of subsystems for simulation, artificial intelligence, and a user interface. The simulation results were consistent with the real-world process, and this system achieved a 13.3% reduction in production cycle time.

5) REFERENCES

1. Hürkamp A., Gellrich S., Ossowski T., Beuscher J., Thiede S., Herrmann C., Dröder K., Combining simulation and machine learning as digital twin for the manufacturing of overmolded thermoplastic composites. *Journal of Manufacturing and Materials Processing* 4(3): 1-20 (2020), <https://doi.org/10.3390/jmmp4030092>
2. Wang Z., Feng W., Ye J., Yang J., Liu C., A study on intelligent manufacturing industrial internet for injection molding industry based on digital twin. *Complexity* 2021(5): 1-16 (2021), <https://doi.org/10.1155/2021/8838914>
3. Lacueva-Pérez F.J., Hermawati S., Amoraga P., Salillas-Martínez R., Hoyo-Alonso R.d., Lawson G., SHION (Smart tHermoplastic InjectiON): An interactive digital twin supporting real-time shopfloor operations. *IEEE Internet Computing* 26(3): 23-32 (2022), <https://doi.org/10.1109/MIC.2020.3047349>
4. Modoni G.E., Stampone B., Trotta G., Application of the digital twin for in-process monitoring of the micro injection moulding process quality. *Computers in Industry* 135: 103568 (2022), <https://doi.org/10.1016/j.compind.2021.103568>
5. Rehmer A., Klute M., Heim H.-P., Kroll A., A digital twin for part quality prediction and control in plastic injection molding. In: Mercorelli P., Zhang W., Nemati H., Zhang Y. (Eds.), *Modeling, Identification, and Control for Cyber-Physical Systems Towards Industry 4.0*, Academic Press, pp. 79-109 (2024), <https://doi.org/10.1016/B978-0-32-395207-1.00014-7>

طراحی سیستم دوقلوی دیجیتال ماشین تزریق پلاستیک برای بهبود زمان چرخه تولید (مورد مطالعه: گروه صنعتی انتخاب)

محمدجواد آقارو^۱، کامران کیانفر^۲ , علیرضا گلی^۳  و محمد عبدیزدان^۴ 

۱. کارشناس ارشد مهندسی صنایع، دانشکده فنی و مهندسی، دانشگاه اصفهان، اصفهان، ایران. رایانامه: mohamadj81@gmail.com

۲. دانشیار گروه مهندسی صنایع و آینده پژوهی، دانشکده فنی و مهندسی، دانشگاه اصفهان، اصفهان، ایران. رایانامه: k.kianfar@eng.ui.ac.ir

۳. استادیار گروه مهندسی صنایع و آینده پژوهی، دانشکده فنی و مهندسی، دانشگاه اصفهان، اصفهان، ایران. رایانامه: goli.a@eng.ui.ac.ir

۴. دانشجوی دکتری مهندسی صنایع، دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه صنعتی اصفهان، اصفهان، ایران. رایانامه: m.abdevazdan@in.iut.ac.ir

چکیده	اطلاعات مقاله
تحولات فناوری در صنعت ۴۰ به‌ویژه با بکارگیری فناوری‌هایی مانند دوقلوی دیجیتال، اینترنت اشیا و هوش مصنوعی، باعث تغییرات چشمگیری در فرآیندهای تولید شده‌است. این پژوهش به بررسی دوقلوی دیجیتال به‌عنوان یکی از فناوری‌های کلیدی این انقلاب صنعتی در کارخانه‌ای وابسته به گروه صنعتی انتخاب می‌پردازد. این سیستم شامل سه زیرسیستم اصلی جمع‌آوری داده‌های لحظه‌ای، شبیه‌سازی با استفاده از نرم‌افزار MoldFlow و هوش مصنوعی مبتنی بر شبکه عصبی در محیط پایتون است. همچنین یک رابط کاربری برای تعامل با سیستم طراحی شده‌است. شبیه‌ساز دوقلوی دیجیتال می‌تواند با تنظیم بلادرنگ پارامترهایی مانند فشار، سرعت تزریق، دمای قالب و آب خنک‌کننده، زمان چرخه تولید را کاهش داده و درعین حال کیفیت محصول را حفظ کند. نتایج نشان داد که اجرای این سیستم به کاهش ۱۳.۳ درصدی در زمان چرخه تولید و افزایش نرخ تولید منجر شده‌است.	نوع مقاله: مقاله پژوهشی تاریخ دریافت: ۱۴۰۳/۰۵/۲۹ تاریخ بازنگری: ۱۴۰۳/۱۲/۱۶ تاریخ پذیرش: ۱۴۰۴/۰۵/۱۳ تاریخ انتشار: ۱۴۰۴/۰۹/۱۰ کلیدواژه‌ها: دوقلوی دیجیتال، زمان چرخه تولید، شبکه عصبی، شبیه‌سازی تزریق پلاستیک، گروه صنعتی انتخاب.

استناد: یوسفی‌نژاد عطاری، مهدی و همکاران. (۱۴۰۴). «طراحی سیستم دوقلوی دیجیتال ماشین تزریق پلاستیک برای بهبود زمان چرخه تولید (مورد مطالعه: گروه صنعتی انتخاب)». مدیریت مهندسی و رایانش نرم، دوره ۱۱ (۲). صص: ۵۵-۲.
 Error! Bookmark not defined.

<https://doi.org/10.22091/jemsc.2025.11872.1232>



© آقارو و همکاران (۱۴۰۴).

ناشر: دانشگاه قم

(۱) مقدمه

قالب گیری تزریقی^۱، یکی از پرکاربردترین فرآیندهای تولید قطعات پلاستیکی است که با استفاده از ماشین تزریق، قالب و سیستم های کنترل دما انجام می شود. این صنعت بطور سنتی با مشکلاتی نظیر پایین بودن سطح اطلاعات و هوشمندی مواجه است که منجر به کاهش بهره وری و افزایش هزینه ها می شود. قالب گیری تزریقی، فرآیندی است که در آن پلاستیک ذوب شده، تحت فشار به داخل قالب تزریق می شود. این فرآیند شامل مراحل گرمایش، تزریق، سردسازی و خارج کردن قطعه از قالب است که همه آنها بر زمان چرخه تولید تاثیر می گذارند. یکی از چالش های اصلی این فرآیند، تنظیم دقیق زمان چرخه برای افزایش بهره وری و حفظ کیفیت محصول نهایی است. بنابراین بهینه سازی این زمان و کنترل دقیق پارامترهای فرآیند، نقشی کلیدی در بهبود عملکرد و کاهش هزینه های تولید دارد. برای رسیدن به این هدف، ادغام فناوری های موجود در صنعت ۴.۰^۲ مانند دوقلوی دیجیتال^۳ (DT)، می تواند به بهبود این فرآیند و ارتقای عملکرد تولید کمک کند. DT با شبیه سازی بلادرنگ و استفاده از داده های واقعی، امکان بهینه سازی فرآیند قالب گیری و کاهش زمان چرخه تولید را فراهم می سازد.

صنعت ۴.۰ نمادی از نوآوری های تکنولوژیکی در حوزه تولید است که با ترکیب فناوری های اینترنت اشیا^۴، رایانش ابری^۵، هوش مصنوعی^۶ و غیره، ارتباط بین دنیای فیزیکی و دیجیتال را تقویت می کند (Koch et al., 2014). این تحول در مقایسه با انقلاب های صنعتی گذشته، نشان دهنده مرحله پیشرفته تری است که به وسیله فناوری های هوش مصنوعی، اتوماسیون و تحلیل داده ها، فرآیندهای تولید و توزیع را بهبود می بخشد (Liao et al., 2017). یکی از مفاهیم کلیدی در صنعت ۴.۰، DT است که نمایشی دیجیتالی از یک سیستم یا شیء فیزیکی است و با استفاده از داده های بی درنگ^۷ و تجزیه و تحلیل پیشرفته، عملکرد و تحلیل پیش بینی کننده را بهبود می بخشد (Lee & Lee, 2021). این فناوری ابتدا توسط ناسا برای شبیه سازی فضاپیماها استفاده شد (Bhandal et al., 2022) و امروزه در صنایع مختلف کاربردهای گسترده ای پیدا کرده است. در حوزه مهندسی و ساخت، این فناوری به ایجاد نسخه های مجازی از محصولات فیزیکی و سیستم های تولید کمک می کند تا طراحی ها بهینه سازی شوند و فرآیندها بهبود یابند (Kritzinger et al., 2018). در صنعت انرژی و تاسیسات، DT برای بهینه سازی عملکرد و نگهداری زیرساخت های پیچیده ای همچون نیروگاه ها و شبکه های برق بکار می رود (Sleiti et al., 2022). همچنین در مراقبت های بهداشتی، از مدل های مجازی بیماران برای شبیه سازی پاسخ های فیزیولوژیکی و برنامه ریزی های دقیق درمان استفاده می شود (Erol et al., 2020). در توسعه شهرهای هوشمند، دوقلوهای دیجیتال با شبیه سازی محیط های شهری به بهینه سازی مصرف انرژی، حمل و نقل و تخصیص منابع کمک می کنند (White et al., 2021). علاوه بر این، در حوزه حمل و نقل و تدارکات، این فناوری برای بهبود مدیریت ناوگان و بهینه سازی زنجیره تامین استفاده می شود و از نظارت بلادرنگ بر دارایی ها و کاهش هزینه ها اطمینان می دهد (Wang et al., 2022).

1 Injection molding

2 Industry 4.0

3 Digital twin

4 Internet of things

5 Cloud computing

6 Artificial intelligence

7 Real-time Data

دستیابی به تولید مورد نیاز، یکی از مهمترین هدف‌های هر شرکت تولیدی است. یکی از رایج‌ترین فرآیندهای تولیدی که برای ساخت قطعات پلاستیکی استفاده می‌شود، قالب‌گیری تزریقی است. صنعت پلاستیک کشور یکی از بخش‌های تولیدی مهم کشور و پیش‌نیاز تولید محصولات متنوع دیگر است. به گفته کارشناسان، سالانه حدود ۴ میلیون تن، انواع محصولات پلاستیکی و پلیمری در ایران تولید می‌شود. شرکت مورد مطالعه به عنوان یکی از ارکان اصلی تولید گروه صنعتی انتخاب با حجم تولید بسیار بالا، در واقع پیش‌نیاز تولید سایر واحدها می‌باشد. به نحوی که تاخیر در تولید در این واحد و یا عدم دستیابی به برنامه تولید، منجر به ایجاد گلوگاه در سایر واحدها می‌شود. همچنین در صورتیکه واحد مذکور به میزان تولید مورد نیاز خود نرسد، منجر به محصول از دست رفته می‌شود و یا مجبور به برون‌سپاری برای تولید محصولات مورد نیاز خود خواهد شد که در نهایت افزایش هزینه‌ها را به همراه خواهد داشت. بررسی‌ها نشان می‌دهد این واحد صنعتی روزانه در حدود ۵۰ تن مواد پلاستیکی مصرف می‌کند.

بهینه‌سازی این فرآیند به دلیل ماهیت پیچیده و چند مرحله‌ای و حساس به تنظیمات، همواره چالش برانگیز بوده است. پارامترهایی مانند فشار تزریق، دمای قالب، سرعت و زمان خنک‌کاری، تاثیر مستقیم بر کیفیت محصول نهایی، میزان ضایعات و زمان چرخه دارند. کنترل دستی یا سنتی این پارامترها نه تنها مستعد خطا است بلکه توان پاسخگویی سریع به تغییرات ناگهانی در شرایط تولید را ندارد. در این میان، DT به عنوان یک ابزار هوشمند و بلادرنگ، می‌تواند با شبیه‌سازی دقیق فرآیند و بهره‌گیری از داده‌های لحظه‌ای، دید جامعی از وضعیت جاری سیستم ارائه دهد و با اعمال تنظیمات بهینه، عملکرد تولید را ارتقا دهد. بکارگیری DT در قالب‌گیری تزریقی نه تنها موجب کاهش زمان و هزینه‌های تولید می‌شود، بلکه امکان پیش‌بینی خطاها، افزایش بهره‌وری و بهبود کیفیت محصول را نیز فراهم می‌آورد. از این رو، استفاده از این فناوری برای ارتقای رقابت‌پذیری و انعطاف‌پذیری در محیط‌های صنعتی، امری ضروری به نظر می‌رسد.

علاوه بر مزایای فنی، پیاده‌سازی DT دارای مزایای اقتصادی قابل توجهی نیز هست. کاهش زمان چرخه تولید مستقیماً منجر به افزایش نرخ تولید و کاهش هزینه‌های انرژی می‌شود. همچنین کاهش ضایعات و بهینه‌سازی مصرف مواد اولیه، هزینه تمام‌شده هر قطعه را کاهش می‌دهد. این عوامل در مجموع منجر به بازگشت سرمایه سریع‌تر، افزایش بهره‌وری و بهبود رقابت‌پذیری اقتصادی در بازارهای صنعتی می‌شوند.


مراحل تولید این قطعات پلاستیکی به این صورت است که پس از قرارداد مواد در قیف دستگاه، پلاستیک شدن مواد از طریق گرما و با اصطکاک مواد با پیچ چرخان، سیلندر و درون خود مواد حاصل می‌شود. چرخش پیچ متوقف می‌شود تا زمانی که حجم مذاب کافی در فضای بین نوک پیچ و نازل قرار گیرد. متعاقباً قالب بسته می‌شود و تزریق مذاب با حرکت انتقالی پیچ تحت فشار بالا انجام می‌شود. سپس توسط آب سرد، عملیات خنک‌شدن قالب انجام شده و پس از سرد شدن و جامد شدن مذاب، قالب باز می‌شود و قسمت قالب‌گیری تزریقی تمام‌شده را خارج می‌کند. مجموع زمان فعالیت‌های فوق، زمان چرخه تولید دستگاه را نشان می‌دهد.

واحد تزریق پلاستیک گروه صنعتی انتخاب، به دلیل تنوع قطعات و دستگاه‌های قالب‌گیری مورد استفاده، با چالش‌های مختلفی در بهینه‌سازی فرآیند تولید روبه‌رو است. دستگاه‌های قالب‌گیری تزریقی که از برند Borch هستند، به صورت موازی و در تناژ مختلف فعالیت می‌کنند و برای تولید قطعات مختلف پلاستیکی محصولاتی مانند یخچال،

لباسشویی و جاروبرقی استفاده می‌شوند. زمان چرخه تولید هر دستگاه به‌ویژه در مرحله خنک‌سازی محصول پس از تزریق، عاملی حیاتی است که تاثیر مستقیمی بر کیفیت و سرعت تولید دارد. به دلیل تنظیم دستی پارامترهای دخیل در زمان چرخه، ممکن است این زمان یا بسیار بالا باشد که منجر به عدم تحقق تولید کافی می‌شود یا بسیار پایین باشد که در این صورت قطعات تولید شده، استانداردهای کیفی لازم را نخواهند داشت. بنابراین نیاز به سیستمی که بتواند زمان چرخه تولید را بهینه کند و از داده‌های لحظه‌ای و واقعی استفاده کند، به شدت احساس می‌شود. DT پیشنهادی، سیستمی است که از شبیه‌سازی و بهینه‌سازی بلادرنگ بهره می‌گیرد و با استفاده از اطلاعات واقعی از سنسورها و داده‌های تاریخی، به بهینه‌سازی فرآیند تولید و کنترل کیفیت کمک می‌کند.

در هنگام تولید محصول روی دستگاه، به صورت همزمان سیستم DT فعال است و زمان چرخه تولید را به عنوان خروجی مشخص می‌کند. نحوه محاسبه زمان چرخه براساس الگوریتم‌های هوش مصنوعی است که رابطه‌ای بین ورودی و خروجی سیستم مشخص می‌کنند.

DT ماشین تزریق متشکل از ماشین‌های تزریق با تمام جزئیات آنها نظیر نوع قالب، واحد کنترل دمای آنها و غیره تحت عنوان موجودیت فیزیکی^۱ و یک موجودیت شبیه‌سازی شده مطابق با موجودیت فیزیکی با عنوان موجودیت مجازی^۲ است. ورودی‌های سیستم از موجودیت‌های فیزیکی به صورت لحظه‌ای و زمان واقعی^۳ جمع‌آوری می‌شود و براساس آنها همزمان با قالب‌گیری یک قطعه در دنیای واقعی، سیستم شبیه‌ساز نیز زمان سیکل تولید قطعه را محاسبه می‌کند.



شکل ۱. ساختار DT پیشنهادی

در ادامه این پژوهش به بررسی ادبیات موضوع در این زمینه پرداخته می‌شود. شکاف‌های تحقیقاتی استخراج شده و نوآوری‌های پژوهش حاضر بیان خواهد شد. سپس به تعریف کامل مسئله و ارائه یک سیستم پیشنهادی و ابزارهای مورد استفاده برای پیاده‌سازی آن پرداخته می‌شود و سیستم پیشنهادی در محیط واقعی تولید یک قطعه، پیاده‌سازی خواهد شد. در پایان قابلیت اطمینان و اعتبار این سیستم با تحلیل نتایج آن مورد بررسی قرار خواهد گرفت.

۲) پیشینه تحقیق

پیشینه پژوهش، در سه بخش کلی مطالعات مربوط به کاربرد فناوری‌ها و DT در صنعت، بهینه‌سازی فرآیند و زمان چرخه تولید قالب‌گیری تزریقی و استفاده از DT در صنعت تزریق ارائه شده‌است. در ادامه به شرح هر بخش پرداخته و مقالات مربوط به آنها ارائه شده‌است.

۲-۱) پیشینه پژوهش کاربرد فناوری‌ها و دوقلوی دیجیتال در صنعت

در سال‌های اخیر، پژوهشگران بسیاری به بررسی و توسعه مفهوم DT در صنایع مختلف پرداخته‌اند که نقطه اشتراک اغلب آنها تمرکز بر افزایش انعطاف‌پذیری، بهبود تصمیم‌گیری و ارتقای کارایی در شرایط پیچیده و پویا است. کاوالکانتی و همکاران (Cavalcante et al., 2019) با تمرکز بر زنجیره تامین، از ترکیب شبیه‌سازی و یادگیری ماشین برای مدیریت اختلالات و عدم قطعیت تقاضا بهره می‌برند و مدلی ارائه می‌دهند که به تصمیم‌گیری در انتخاب تامین‌کننده و طراحی استراتژی‌های کاهش ریسک کمک می‌کند. ماندولا و همکاران (Mandolla et al., 2019) با تمرکز تولید افزودنی^۱ در صنعت هواپیمایی، DT را با فناوری بلاکچین ترکیب می‌کنند تا رهگیری و صحت اطلاعات در زنجیره تامین را تضمین کرده و بدین ترتیب کارایی و شفافیت فرآیند را افزایش دهند.

در ادامه این جریان، ایوانف و همکاران (Ivanov et al., 2019) از DT به عنوان ابزاری برای تحلیل ریسک و ارتقای انعطاف‌پذیری زنجیره‌های تامین دیجیتال بهره می‌برند. آنها با ادغام شبیه‌سازی، بهینه‌سازی و تحلیل داده‌ها، نشان می‌دهند که چگونه DT می‌تواند اختلالات را کاهش داده و پاسخگویی زنجیره تامین را بهبود بخشد. لی و همکاران (Li et al., 2020) دیدگاه کلان‌تری اتخاذ می‌کنند و مدل کسب و کار پنج‌بعدی برای DT در محیط‌های سازمانی پیشنهاد می‌کنند که به تبیین ارزش‌های اقتصادی، اجتماعی و زیست‌محیطی آن می‌پردازد و نقش آن را در نوآوری و پایداری مدل‌های کسب و کار برجسته می‌سازد. مازی و همکاران (Mazzei et al., 2020) با ترکیب فناوری بلاکچین^۲ و اینترنت اشیا صنعتی، سیستمی مبتنی بر DT معرفی می‌کنند که قادر است داده‌ها را از ماشین‌های قدیمی و جدید دریافت و تحلیل کند و با ارائه اطلاعات لحظه‌ای، به بهبود امنیت و پایداری زنجیره تامین صنعتی کمک نماید. این روند، با ورود به حوزه‌های تولیدی پیشرفته‌تر، در مقاله لین و همکاران (Lin et al., 2025) ادامه می‌یابد. آنها چارچوبی پنج‌لایه برای DT در ماشین کاری CNC ارائه می‌دهند که در آن یادگیری تقویتی و مدل‌های زبان بزرگ به صورت همزمان برای تصمیم‌گیری هوشمند و بهینه‌سازی مسیر ابزار ادغام شده‌اند.

1 Additive manufacturing

2 The industrial blockchain Tokenizer

هوانگ (Huang et al., 2024) نیز در جهت افزایش سازگاری و مقیاس پذیری دوقلوهای دیجیتال، مدلی شی گرا و مبتنی بر استانداردهای ISO ارائه می دهد که به قابلیت استفاده مجدد، مدولاسازی و همگرایی با سایر استانداردها توجه دارد. این رویکرد با تمرکز بر قابلیت های نرم افزاری، پایه ای نظری برای توسعه دوقلوهای دیجیتال تعمیم یافته در محیط های تولیدی ارائه می دهد. در همین راستا، سان و همکاران (Sun et al., 2024) با هدف پر کردن شکاف بین شبیه سازی مجازی و شرایط واقعی، یک متدولوژی راه اندازی با وفاداری بالا، برای ماشین های CNC مبتنی بر DT توسعه داده اند که با استفاده از زبان Modelica و به روزرسانی متناوب مدل، عملکرد و دقت فرآیند راه اندازی را بطور چشمگیری افزایش می دهد.

در نهایت ژانگ و همکاران (Zhang et al., 2024)، مروری جامع بر کاربرد DT در پزشکی شخصی سازی شده ارائه می دهند و از طریق ادغام داده های چندوجهی و بهره گیری از هوش مصنوعی و متاورس، چشم اندازی از آینده پزشکی ارائه می کنند که در آن تشخیص، درمان و پایش سلامت به صورت کاملاً هوشمند، بلادرنگ و شخصی سازی شده انجام می شود. علیرغم پیشرفت های قابل توجه، آنها بر چالش هایی همچون حریم خصوصی، قدرت محاسباتی و اخلاق هوش مصنوعی تاکید کرده و راهکارهایی نظیر بلاکچین را برای رفع این موانع پیشنهاد می کنند.

درمجموع آنچه در این بدنه از پژوهش ها مشترک است، بهره گیری از DT به عنوان یک ابزار چندوجهی و منعطف برای مدل سازی، تحلیل، تصمیم گیری و بهینه سازی در محیط های پیچیده است که با تکیه بر تلفیق فناوری های نوین، از زنجیره تامین و تولید صنعتی گرفته تا پزشکی پیشرفته، قابلیت تحول آفرینی بالایی دارد.

۲-۲) پیشینه پژوهش صنعت قالب گیری تزریقی

در راستای بهینه سازی فرآیند قالب گیری تزریقی، مارتوویوو و همکاران (Martowibowo & Kaswadi, 2017) از ترکیب الگوریتم ژنتیک و شبیه سازی نرم افزار MoldFlow برای کاهش زمان چرخه تولید قطعات کاسه ای شکل از ماده PP AZ564 بهره گرفته اند. نتایج این مطالعه نشان داد که زمان چرخه تولید با بهینه سازی پارامترها به ۱۴.۱۱ ثانیه کاهش یافته و کارایی ترکیب الگوریتم های هوشمند با ابزارهای شبیه سازی را تایید می کند. در ادامه، میانرو و همکاران (Mianehrow & Abbasian, 2017) با تمرکز بر تحلیل مصرف انرژی در ماشین های قالب گیری تزریقی هیدرولیک، نشان دادند که پارامترهایی نظیر زمان چرخه و توان عملیاتی تاثیر قابل توجهی بر مصرف انرژی دارند و نقش سیستم کنترل و سن ماشین نیز در این زمینه بارز است. از سوی دیگر، سینگ و همکاران (Singh et al., 2018) رویکرد ترکیبی تاگوشی و تابع مطلوبیت را برای بهینه سازی فرآیند قالب گیری بکار بردند تا زمان چرخه و تاب خوردگی در محصولات با دیواره نازک را کاهش دهند. نتایج حاصل، بهبود عملکرد فرآیند و کاهش هزینه های تولید را نشان داده و کاربرد این روش را در پیش بینی کیفیت محصول برجسته ساخته است. در همین زمینه، کیتایاما و همکاران (Kitayama et al., 2019) به ارائه رویکردی چندهدفه برای کاهش خطوط جوش و کاهش زمان چرخه در قالب گیری چرخه حرارتی سریع ($RHCM^1$) پرداخته اند. آنها با استفاده از کانال های خنک کننده منسجم و تحلیل مرز پارتو، به بهینه سازی توامان کیفیت و بهره وری دست یافتند.

در بررسی اثرات طراحی کانال‌های خنک‌کننده، کو و همکاران (Kuo & Xu, 2018) دریافتند که کانال‌های خنک‌کننده منسجم سری موجب کاهش قابل توجهی در زمان خنک‌سازی (تا ۸۹.۲ درصد) می‌شوند و ترکیب طراحی‌های موازی و سری را برای بهینه‌سازی سرمایش توصیه کردند. افزون بر این، برون‌تالر و همکاران (Brunthaler et al., 2022) با استفاده از داده‌های شتاب‌سنج و یادگیری ماشین، سیستمی برای پایش هوشمند فرآیند قالب‌گیری و تشخیص خودکار وضعیت ماشین ارائه دادند که دقتی تا ۹۴ درصد در تشخیص حالات مختلف فرآیند نشان داده‌است. در نهایت ساپوناس و همکاران (Sapounas et al., 2020) با تفکیک مراحل مختلف فرآیند قالب‌گیری (پرکردن، خنک‌سازی، بسته‌بندی) و مدل‌سازی اثر پارامترها، روشی شبیه‌سازی‌شده برای تنظیمات دقیق ماشین پیشنهاد دادند که به کاهش عیوبی مانند تاب‌خوردگی کمک می‌کند و در بهینه‌سازی عملیاتی موثر واقع می‌شود.

۲-۳) پیشینه پژوهش دوقلوی دیجیتال در صنعت قالب‌گیری تزریقی

در زمینه بهره‌گیری از DT در صنعت قالب‌گیری تزریقی، لیاو و همکاران (Liau et al., 2018) با تکیه بر مدل‌های مجازی و تحلیل داده‌ها، راهکاری برای نظارت و بهینه‌سازی عملکرد فرآیند ارائه کرده‌اند که نیازمند ادغام اینترنت اشیا و سیستم‌های فیزیکی-سایبری است و چالش‌هایی مانند جمع‌آوری داده‌های دستی و استفاده از حسگرها را به‌همراه دارد. در ادامه، مطالعه بیو و همکاران (Bibow et al., 2020) رویکردی مدل‌محور برای توسعه DT در سیستم‌های تولید سایبر-فیزیکی (CPPS1) پیشنهاد داده‌اند که امکان بهینه‌سازی پارامترهایی نظیر جریان تزریق و دمای نازل و نیز تجزیه و تحلیل داده‌های بلادرنگ را فراهم می‌سازد. هورکمپ و همکاران (Hürkamp et al., 2020) نیز از DT و مدل‌های جایگزین برای پشتیبانی تصمیم‌گیری در قالب‌گیری تزریقی کامپوزیت‌های گرمانرم بهره برده‌اند. این مدل‌ها با تمرکز بر پیش‌بینی کیفیت و کنترل فرآیند در زمان واقعی، از روش‌هایی مانند درخت تصمیم^۲ برای تحلیل داده‌ها استفاده کرده‌اند. به‌همین ترتیب، وانگ و همکاران (Wang et al., 2021) با طراحی یک سیستم تولید هوشمند مبتنی بر DT، بهبود کارایی، نظارت و کاهش هزینه‌ها را هدف قرار داده و از فناوری‌هایی همچون کنترل هوشمند و پلتفرم‌های ابری برای پایش کیفیت و تشخیص عیوب بهره گرفته‌اند. در همین راستا، پرز و همکاران (Lacueva-Pérez et al., 2022) با معرفی سیستم SHION، یک DT مبتنی بر ابر با پشتیبانی هوش مصنوعی، امکان شناسایی خرابی‌ها و محصولات معیوب را از طریق تحلیل داده‌های IoT در زمان واقعی فراهم کرده‌اند که منجر به ارتقای کیفیت تولید شده‌است. همچنین مدونی و همکاران (Modoni et al., 2022) بکاربرد DT در فرآیند قالب‌گیری تزریقی میکرو (μIM)^۳ پرداخته و با نظارت بر پارامترهایی مانند فشار و دما از طریق حسگرها، کاهش ضایعات و بهبود زمان چرخه را به‌دست آورده‌اند. در نهایت در پژوهش رحمر و همکاران (Rehmer et al., 2024) مدل‌های پیش‌بینی کیفیت برای قالب‌گیری تزریقی پلاستیک مورد بررسی قرار گرفته‌است. از مدل‌های پویا نظیر شبکه عصبی پیش‌خور^۴ برای پیش‌بینی کیفیت و کنترل فرآیند استفاده شده‌است که منجر به بهبود دقت پیش‌بینی و بهینه‌سازی کیفیت قطعات تولیدی می‌شود.

1 Cyber physical System

2 Decision tree

3 Micro injection molding

4 Feedforward neural networks

با بررسی پژوهش‌های پیشین در زمینه پیاده‌سازی DT در صنعت قالب‌گیری تزریقی، مشخص شد که بیشتر تحقیقات به بهبود کیفیت محصول، پیش‌بینی خرابی‌ها و بهینه‌سازی پارامترهای تولید پرداخته‌اند. استفاده از DT بطور موفقیت‌آمیزی در بهبود کیفیت محصول و نظارت در زمان واقعی در فرآیندهای قالب‌گیری تزریقی بکار گرفته شده‌است. با این حال، شکاف عمده‌ای در تحقیقات مربوط به بهینه‌سازی زمان چرخه فرآیند قالب‌گیری تزریقی وجود دارد. علیرغم برخی تلاش‌ها برای کاهش زمان خنک‌سازی و بهینه‌سازی مراحل مختلف فرآیند، هنوز نیاز به تحقیقات بیشتری برای بررسی پیاده‌سازی جامع DT در بهینه‌سازی کل چرخه فرآیند قالب‌گیری تزریقی به‌ویژه در کاهش زمان چرخه با استفاده از ابزارهای پیشرفته تحلیل داده‌ها و یادگیری ماشین، احساس می‌شود. این شکاف می‌تواند با توسعه مدل‌های پیش‌بینی زمان چرخه و بهینه‌سازی بلادرنگ فرآیند از طریق DT پر شود.

نوآوری اصلی پژوهش حاضر در پیاده‌سازی DT برای بهبود زمان چرخه فرآیند قالب‌گیری تزریقی نهفته است. برخلاف پژوهش‌های قبلی که بیشتر بر بهبود کیفیت محصول و نظارت بر فرآیند متمرکز بوده‌اند، این تحقیق بطور خاص به بهینه‌سازی زمان چرخه با استفاده از DT و تحلیل داده‌های بلادرنگ می‌پردازد. با ترکیب فناوری‌های یادگیری ماشین و اینترنت اشیا، این DT قادر به پیش‌بینی و تنظیم پارامترهای کلیدی فرآیند مانند زمان خنک‌سازی و فشار تزریق خواهد بود که منجر به کاهش قابل توجهی در زمان چرخه تولید می‌شود. این نوآوری می‌تواند بهره‌وری را در صنعت قالب‌گیری تزریقی افزایش دهد و هزینه‌های تولید را بطور موثری کاهش دهد درحالی‌که بهینه‌سازی فرآیند تولید در مقیاس وسیع‌تری نیز ممکن می‌شود. براساس توضیحات ارائه‌شده، ویژگی‌های مرتبط با این پژوهش در جدول ۱ آورده شده‌است.

جدول ۱. پژوهش حاضر

مطالعه موردی	ابزار و تکنولوژی	هدف	روش حل		نوع پژوهش		محیط مطالعه
			بهینه‌سازی	شبیه‌سازی	کاربری	توسعاتی	
گروه صنعتی انتخاب	نرم‌افزار MoldFlow، هوش مصنوعی، رابط گرافیکی پایتون	بهبود زمان چرخه تولید	✓	✓	✓		تولید

(۳) روش تحقیق

سیستم DT برای ماشین قالب‌گیری تزریقی و محاسبه زمان چرخه تولید از دو بخش اصلی تشکیل شده‌است. بخش اول سیستم DT به جمع‌آوری و انتقال داده‌های فرآیند تولید از دستگاه تزریق پلاستیک اختصاص دارد. این داده‌ها شامل پارامترهایی مانند دمای قالب، فشار تزریق، زمان‌های مختلف فرآیند (تزریق، خنک‌سازی، خارج کردن قطعه) و سایر مشخصات مرتبط با عملکرد ماشین است که در جدول ۲ آورده شده‌است.

جدول ۲. نماد و شرح پارامترهای مربوط به فرآیند تزریق و ماده اولیه

نماد (مربوط به فرآیند)	شرح نماد	نماد (مربوط به ماده)	شرح نماد
T_m	دمای قالب	T_M	دمای ذوب
P_{inj}	فشار تزریق	MFI	شاخص جریان پذیری مذاب
h	ضخامت قطعه	Shrinkage %	درصد شrinkage
$Machine_t$	تُناژ ماشین	Density	چگالی ماده
T_w	دمای آب خنک کننده	C_p	گرمای ویژه ماده
$t_f + t_{hold}$	زمان پرشدن و نگهداری		
$t_{ejection}$	زمان خارج شدن		
$t_{cooling}$	زمان خنک سازی		
t_f	زمان تزریق		

اطلاعات فرآیند توسط سنسورهای نظیر سنسورهای القایی^۱ (برای تشخیص موقعیت باز و بسته شدن قالب)، ترموکوپل ها^۲ (برای اندازه گیری دمای مذاب و قالب)، سنسورهای فشار آنالوگ^۳ (برای ثبت فشار تزریق و فشار نگهداری)، سنسورهای موقعیت خطی^۴ (برای اندازه گیری جابه جایی مارپیچ تزریق یا صفحات قالب)، اپتوکوپلرها^۵ (برای نظارت بر وضعیت سیگنال های کنترلی) و میکروسوییچ ها^۶ (برای تشخیص وضعیت نهایی حرکت اجزا) جمع آوری می شوند. هر کدام از این سنسورها بطور لحظه ای داده های مختلفی از شرایط ماشین و مواد را ثبت می کنند. به عنوان مثال: سنسورهای دما و فشار برای کنترل دقیق دمای مواد و فشار تزریق بکار می روند درحالی که سنسورهای القایی و موقعیت، بر جابه جایی و وضعیت قطعات ماشین نظارت دارند. پس از جمع آوری، این داده ها توسط کنترلرهای ماشین خوانده شده و در قالب فایل های اکسل به صورت لحظه ای به روزرسانی می شوند. این فایل ها شامل اطلاعات جامع هر مرحله از فرآیند مانند زمان خنک سازی، تزریق و فشار تزریق هستند و به سیستم DT ارسال می شوند.

بخش دوم سیستم شامل چهارچوب DT است که از الگوریتم های هوش مصنوعی و نرم افزار شبیه سازی تشکیل شده است. این بخش به منظور تصمیم گیری هوشمند و تحلیل بلادرنگ داده های جمع آوری شده از ماشین فیزیکی طراحی

1 Inductive sensor

2 Thermocouple

3 Pressure transmitter

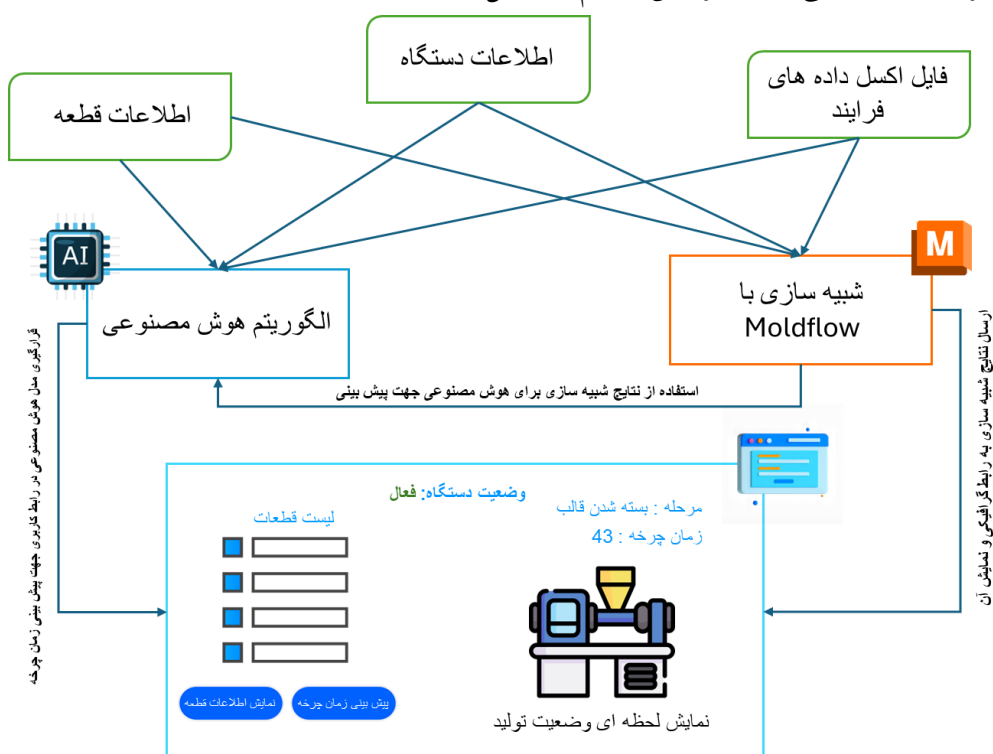
4 Linear position transducer

5 Optocoupler

6 Microswitch

شده و با ایجاد مدل‌های مجازی از فرآیند، امکان شبیه‌سازی سناریوهای مختلف و ارزیابی تغییرات احتمالی را برای بهبود عملکرد سیستم فراهم می‌کند. سیستم DT پیشنهادی این قابلیت را دارد که با بهینه‌سازی پارامترهای کلیدی، زمان چرخه تولید را کاهش داده و کارایی کل فرآیند را افزایش دهد.

براساس اطلاعات و داده‌هایی که می‌توان جمع‌آوری کرد و ابزارهایی که برای نظارت و بهینه‌سازی زمان چرخه تولید این فرآیند در دسترس هستند، می‌توان طراحی کلی این سیستم را به صورت زیر شرح داد. نحوه کارکرد کلی این سیستم به این صورت است که ابتدا اطلاعات مربوط به فرآیند، اطلاعات دستگاه و اطلاعات قطعه به دو زیرسیستم شبیه‌سازی و الگوریتم هوش مصنوعی وارد می‌شوند. تمرین و ساخت مدل هوش مصنوعی و شبیه‌سازی اولیه با این داده‌ها انجام می‌شود. سپس مدل نهایی هوش مصنوعی و پارامترهای بهینه‌ای که از طریق شبیه‌سازی به دست آمده‌اند، در رابط گرافیکی نمایش داده می‌شوند. همچنین می‌توان نتایج شبیه‌سازی برای سناریوهای مختلف را با استفاده از مدل هوش مصنوعی تعبیه شده در رابط گرافیکی جهت پیش‌بینی زمان چرخه تولید بکار برد و در صورتیکه پیش‌بینی ارائه شده از سوی هوش مصنوعی دقت بالایی داشته باشد، از آن ورودی‌ها به عنوان نمونه جدید در مدل هوش مصنوعی جهت بالابردن دقت آن استفاده کرد. شماتیک کلی از کارکرد این سیستم در شکل ۲ آورده شده است.



شکل ۲. شماتیک سیستم پیشنهادی DT فرآیند تزریق پلاستیک


رابط کاربری گرافیکی^۱ (GUI) سیستم DT که با زبان برنامه‌نویسی پایتون توسعه یافته است، نقش کلیدی در نظارت بالادرنگ بر فرآیند قالب‌گیری تزریقی دارد. این رابط داده‌های لحظه‌ای مراحل مختلف فرآیند و زمان چرخه تولید را

نمایش می‌دهد و همچنین وضعیت فعال یا غیرفعال بودن دستگاه را نشان می‌دهد. اطلاعات قطعه تولیدی و نتایج شبیه‌سازی نیز در آن قابل مشاهده است. کاربران از طریق رابط کاربری می‌توانند پیش‌بینی زمان چرخه تولید را با استفاده از هوش مصنوعی انجام دهند و نرم‌افزار شبیه‌سازی MoldFlow را مستقیماً اجرا کنند.

زیرسیستم شبکه عصبی مصنوعی^۱ سیستم، با الهام از ساختار مغز انسان، برای پیش‌بینی زمان چرخه تولید طراحی شده است. شبکه‌های عصبی مصنوعی به دلیل توانایی آنها در یادگیری از داده‌ها، برای اقداماتی که شامل تشخیص الگو، رگرسیون و طبقه‌بندی است، مفید هستند. (Behera & Das, 2017) به همین خاطر در این مسئله به سراغ شبکه‌های عصبی مصنوعی رفته‌ایم. شبکه عصبی مدنظر به زبان پایتون نوشته خواهد شد. ساختار یک ANN را می‌توان به چندین جزء کلیدی تقسیم کرد:

❖ **نورون‌ها و لایه‌ها:** نورون‌ها واحدهای پردازشی اصلی شبکه هستند که ورودی دریافت می‌کنند، آن را پردازش کرده و در نهایت خروجی تولید خواهند کرد. نورون‌ها به صورت لایه‌هایی سازماندهی شده‌اند. بطور معمول سه نوع لایه وجود دارد:

- لایه ورودی^۲: داده‌های اولیه را دریافت می‌کند.
- لایه‌های پنهان^۳: انجام محاسبات میانی و استخراج ویژگی‌ها.
- لایه خروجی^۴: خروجی نهایی شبکه را تولید می‌کند.



شکل ۳. ساختار شبکه عصبی مصنوعی

❖ **وزن‌ها و توابع فعال‌سازی^۵:** وزن‌ها، پارامترهایی هستند که داده‌های ورودی را در نورون‌ها تغییر می‌دهند. هر ارتباط بین نورون‌ها، وزن مرتبطی دارد. داده‌ها از لایه ورودی، از طریق لایه‌های پنهان به لایه خروجی جریان می‌یابد.

1 Artificial neural networks
2 Input layer
3 Hidden layers
4 Output layer
5 Activation function

خروجی هر نورون به عنوان مجموع وزنی ورودی‌های آن محاسبه می‌شود که از طریق یک تابع فعال‌سازی منتقل می‌شود. توابع اعمال‌شده در خروجی هر نورون برای معرفی غیر خطی بودن، شبکه را قادر می‌سازد تا الگوهای پیچیده را یاد بگیرد.

❖ **توابع ضرر^۱:** تابعی که تفاوت بین خروجی پیش‌بینی شده شبکه و مقادیر هدف واقعی را اندازه‌گیری می‌کند. هدف از آموزش، به حداقل رساندن این ضرر است.

❖ **فراپارامترها^۲:** پارامترهایی که ساختار شبکه و فرآیند آموزش را تعریف می‌کنند مانند تعداد لایه‌ها، تعداد نورون‌ها در هر لایه، نرخ یادگیری، بهینه‌ساز، اندازه دسته‌ای و تعداد دوره‌ها.

این شبکه شامل لایه‌های ورودی، پنهان و خروجی است. دو لایه پنهان آن با ۶۴ و ۳۲ نورون، برای استخراج الگوهای پیچیده تنظیم شده‌اند. تابع فعال‌سازی ReLU و تابع ضرر خطای میانگین مربعات MSE^۳ برای بهینه‌سازی دقت مدل استفاده شده‌اند. این تابع میانگین اختلاف مجذور بین مقادیر پیش‌بینی شده و زمان‌های چرخه واقعی را اندازه‌گیری می‌کند و نشانه روشنی از دقت پیش‌بینی مدل ارائه می‌دهد. با جریمه کردن بیشتر خطاهای بزرگتر، MSE به مدل کمک می‌کند تا روی به حداقل رساندن انحرافات قابل توجه تمرکز کند و منجر به پیش‌بینی‌های دقیق‌تر و قابل اعتمادتر شود. این امر MSE را به گزینه‌ای ایده‌آل برای بهینه‌سازی عملکرد شبکه عصبی در پیش‌بینی دقیق زمان‌های چرخه تولید تبدیل می‌کند. همچنین دو لایه پنهان، به مدل عمق کافی برای ثبت روابط غیر خطی در داده‌ها می‌دهد. لایه‌های بیش از حد، ممکن است منجر به برازش بیش از حد^۴ شود درحالی‌که لایه‌های بسیار کم ممکن است، توانایی مدل را برای خروجی مناسب محدود کند. استفاده از نورون‌های ۶۴ و ۳۲ به مدل اجازه می‌دهد تا الگوهای پیچیده را بدون سنگینی محاسباتی مدیریت کند. ۶۴ نورون در لایه اول به مدل اجازه می‌دهد تا طیف گسترده‌ای از ویژگی‌ها و الگوها را از ورودی بگیرد که برای یادگیری پیچیدگی فرآیند قالب‌گیری تزریقی می‌تواند مفید باشد. در ادامه ۳۲ نورون لایه دوم، ابعاد و پیچیدگی را کاهش می‌دهد و به فیلتر و اصلاح الگوهای لایه اول خواهد پرداخت. این یک روش معمول در طراحی شبکه‌های عصبی است که در آن لایه‌ها به تدریج اندازه خود را کاهش می‌دهند تا بر استخراج ویژگی‌های دقیق‌تر تمرکز کنند (Marrone et al., 2021). پارامترها و فراپارامترهای الگوریتم در جدول ۳ بیان شده‌است.

جدول ۳. پارامترهای ورودی شبکه عصبی مصنوعی

نماد	شرح نماد	نام ورودی
vector_size	اندازه بردار ورودی	Material
Activation	تابع فعال‌سازی لایه اول	Injection pressure
Loss	تابع ضرر لایه اول	Density

1 Loss function

2 Hyper parameters

3 Mean squared error

4 Overfitting

Melt Temperature	تابع فعال‌سازی لایه دوم	Activation_2
Part weight	تابع ضرر لایه دوم	Loss_2
Holding Pressure	اندازه بسته ورودی‌ها	Batch_size
Cooling time	تعداد دوره‌های آموزش الگوریتم	Epochs
MFI	بهینه‌ساز الگوریتم	Optimizer

شبکه با الگوریتم Adam و ۱۰۰ دوره آموزشی، آموزش داده می‌شود. در صورت عدم دقت کافی، الگوریتم جستجوی شبکه‌ای^۱ برای تنظیم فرآیندهای بهینه مانند نرخ یادگیری، تعداد نرون‌ها، تعداد لایه‌های مخفی و اندازه دسته‌ها استفاده می‌شود تا بهترین عملکرد حاصل گردد (Passos & Mishra, 2022). این الگوریتم با بررسی ترکیب‌های مختلفی از مقادیر ممکن برای هر فرآیند در یک شبکه منظم، به یافتن ترکیبی از تنظیمات منجر می‌شود که کمترین خطا را در داده‌های اعتبارسنجی دارد. پارامترهای بردار ورودی به هوش مصنوعی براساس اطلاعات دریافتی در دسترس و همچنین اطلاعات قابل استخراج از نتایج شبیه‌سازی تعیین شده‌اند (مطابق جدول ۴). این ویژگی‌ها لزوماً تمام ویژگی‌های قابل استفاده نبوده‌است و صرفاً براساس اطلاعات در دسترس انتخاب شده‌اند.

جدول ۴. پارامترهای ورودی شبکه عصبی مصنوعی

شماره	نام ورودی	توضیحات
۱	Material	نوع ماده
۲	Injection pressure	فشار تزریق
۳	Density	چگالی
۴	Melt Temperature	دمای مذاب
۵	Part weight	وزن قطعه
۶	Holding Pressure	فشار نگهداری
۷	Cooling time	زمان خنک‌سازی

1 Grid search algorithm

شاخص جریان پذیری ماده	MFI	۸
-----------------------	-----	---

برای زیرسیستم شبیه سازی، از نرم افزار MoldFlow استفاده شده است. نرم افزار MoldFlow که توسط Autodesk توسعه یافته، برای شبیه سازی فرآیند قالب گیری تزریقی پلاستیک استفاده می شود و امکان ایجاد مدل های مجازی سیستم فیزیکی را فراهم می کند. این نرم افزار توانایی پیش بینی پرشدن حفره قالب، شناسایی نقص های قطعه و بهینه سازی فرآیند و طراحی قطعات را دارد. پایگاه داده وسیع مواد و قابلیت شبیه سازی فرآیندهای تزریق پیشرفته، کاربران را قادر می سازد تا سناریوهای مختلف را آزمایش کنند. همچنین پشتیبانی از فضای ابری و یکپارچگی با نرم افزار CAD، بهینه سازی گردش کار و اشتراک گذاری نتایج را تسهیل می کند. نرم افزار شبیه سازی، بستری ایجاد و اجرای مدل های مجازی سیستم فیزیکی را در محیط DT فراهم می کند و به مهندسان و محققان اجازه می دهد تا رفتار سیستم واقعی را تحت شرایط مختلف تکرار کنند، سناریوهای مختلف را آزمایش کنند و تاثیر تغییرات یا بهبودهای بالقوه را ارزیابی کنند.

۴) تحلیل یافته ها و آزمون های تجربی

برای پیاده سازی این سیستم در محیط تولید واقعی و بررسی قابلیت اطمینان و دقت آن، مطالعه موردی روی یکی از قطعات پلاستیکی کارخانه تزریق پلاستیک انجام شد. شرکت مذکور، زیرمجموعه ای از گروه صنعتی انتخاب، یکی از تولیدکنندگان پیشرو در صنعت پلاستیک ایران است که از سال ۱۳۸۵ در منطقه صنعتی مورچه خورت اصفهان فعالیت می کند. این شرکت با ماشین آلات مدرن و مصرف روزانه ۵۰ تن مواد پلیمری، تامین کننده قطعات پلاستیکی لوازم خانگی برای برندهای اسنوا، دوو و حایر است. قطعه مورد مطالعه، یک قطعه پلاستیکی با وزن ۷۳ گرم و ساخته شده از پلی آمید ۳۰ درصد الیاف شیشه است که در قالبی با یک حفره و سیستم رانر سرد تولید می شود. این قطعه پلاستیکی با استفاده از دستگاه های تزریق پلاستیک برند Borché تولید می شود که دارای ویژگی هایی مانند حجم شات ورودی ۱۳۴۶ سانتی متر مکعب، نیروی بستن ۳۲۰۰ کیلونیوتن و حداکثر فشار تزریق ۱۶۶ مگاپاسکال است. داده ها در دو حالت دستی و آنلاین جمع آوری شده است. نوع اول داده ها، داده هایی هستند که به صورت دستی جمع آوری می شوند. این داده ها شامل پارامترهای ثابت فرآیند، اطلاعات اولیه قطعه، اطلاعات مواد اولیه و مشخصات دستگاه تزریق پلاستیک است.

نوع دوم داده ها، داده هایی هستند که به صورت لحظه ای و زمان-واقعی از فرآیند و توسط سنسورها جمع آوری می شوند. این داده ها توسط کنترلرهای برند Keba متصل به دستگاه تزریق در یک فایل اکسل به صورت لحظه ای ذخیره می شوند. این فایل و سیستم کنترلر به سیستم DT متصل است و اطلاعات آن به صورت لحظه ای خوانش می شود. اطلاعات دریافتی از ماشین تزریق شامل جدول زیر است.

جدول ۵. پارامترهای دریافتی از ماشین تزریق

شماره	نام ورودی	توضیحات
۱	SystemPressure	فشار تزریق

۲	SystemVelocity	سرعت تزریق
۳	ActualTemperature	دمای واقعی مذاب
۴	OilTemperature	دمای روغن
۵	Heater	نمایش هیتر فعال
۶	LastCycleTime	زمان سیکل قبلی
۷	EventType	مرحله فرآیند
۸	LogDate	تاریخ و ساعت

نحوه جمع‌آوری اطلاعات توسط کنترلر و انتقال آن به سیستم DT به این صورت است که داده‌های سنسورها ابتدا خوانش می‌شوند و پس از پردازش در ستون‌های مرتبط هر پارامتر در یک فایل اکسل به صورت لحظه‌ای به‌روزرسانی می‌شوند. در هر مرحله از فرآیند سطر جدیدی به صورت لحظه‌ای و در زمان واقعی به اطلاعات قبلی این فایل اضافه می‌شود و در همان لحظه نیز توسط سیستم DT سطر جدید خوانده می‌شود. این فایل اکسل حاوی اطلاعات لحظه‌ای هر مرحله از فرآیند شامل فشار، دما، نام مرحله، تاریخ و زمان گذرانده شده آن است. نمونه اطلاعات دریافتی در شکل ۴ نمایش داده شده است.

	SystemPressure	SystemVelocity	ActualTemperature	OilTemperature	Heater1	Heater2	Heater3	Heater4	Heater5	Heater6	LastCycleTime	EventType	LogDate
9	90	23.9	289.8999939	32.70000076	0	0	0	0	0	1	42.3	MoldClose	8:47:00 AM
10	120	99.9	289.8000183	32.60000229	1	0	0	0	0	1	42.3	InjectionActive	8:47:00 AM
11	0	0	289.8000183	32.60000229	1	1	0	0	0	1	42.3	HoldPressur	8:47:00 AM
12	15	15.1	289.8000183	32.60000229	1	1	0	0	0	1	42.3	PlastActive	8:47:00 AM
13	12.8	8.2	289.8000183	32.60000229	1	0	0	1	0	0	42.3	MoldOpen	8:48:00 AM
14	44	12.2	289.8000183	32.60000229	1	0	0	1	0	0	42.3	AllCoreOut	8:48:00 AM
15	0	0	289.8000183	32.60000229	1	0	0	0	0	0	42.3	EjectorActive	8:48:00 AM
16	90	48	289.8000183	32.70000076	0	1	0	0	0	1	45.6	MoldClose	8:48:00 AM
17	120	99.9	289.8000183	32.70000076	0	0	0	0	0	0	45.6	InjectionActive	8:48:00 AM
18	0	0	289.7000122	32.70000076	0	0	0	0	0	0	45.6	HoldPressur	8:48:00 AM
19	15	15.1	289.8000183	32.70000076	0	0	0	0	0	0	45.6	PlastActive	8:48:00 AM
20	20	9.7	289.8000183	32.60000229	0	0	0	0	0	0	45.6	MoldOpen	8:48:00 AM
21	50	15	289.8000183	32.70000076	0	0	0	0	0	0	45.6	AllCoreOut	8:48:00 AM
22	0	0	289.8000183	32.60000229	0	0	0	0	0	1	45.6	EjectorActive	8:48:00 AM


شکل ۴. اطلاعات دریافتی از سنسورها

۴-۱) نتایج شبیه سازی

در مرحله شبیه سازی، شبیه سازی به دو صورت (۱) با داده های فعلی فرآیند و (۲) حالت اتوماتیک نرم افزار انجام خواهد گرفت. ابتدا مدل سه بعدی قطعه به همراه مدل رانر و کانال های خنک کننده آن طراحی شد و در نرم افزار وارد شد. در حالت اول شبیه سازی که با استفاده از داده های واقعی فرآیند انجام شد، پارامترهای فرآیند از دستگاه تزریق و کنترلر KEBA استخراج شده و در تنظیمات نرم افزار تنظیم شدند. از جمله پارامترهای دمای مذاب (۲۹۰ درجه سانتی گراد)، دمای سطح قالب (۸۰ درجه سانتی گراد) و زمان های مربوط به تزریق، نگهداری و خنک سازی قطعه که مجموعاً ۴۳.۵ ثانیه برای هر چرخه تعیین شد. پارامترهای زمانی تعیین شده روی دستگاه برای زمان های کارکرد دستگاه در هر سیکل تولید به شرح زیر است:


- زمان تزریق = ۴ ثانیه
- زمان نگهداری = ۰/۵ ثانیه
- زمان خنک سازی = ۲۰ ثانیه
- زمان باز و بسته شدن قالب و پران قطعه = ۲۰ ثانیه

پس از اجرای شبیه سازی، در مرحله پرشدن، زمان تزریق ۴.۱۹ ثانیه به دست آمد و همانطور که از شکل ۵ مشخص است، مشخص شد که کناره های قطعه دیرتر پر می شوند. در فاز نگهداری، فشار به ۸۹.۱۶ Mpa رسیده و سپس ثابت می ماند.




شکل ۵. نمایش نحوه تزریق و زمان آن در نرم افزار

عیوب پیش‌بینی شده شامل علائم سینک^۱ (فرورفتگی‌های سطحی که معمولاً در نواحی ضخیم‌تر قطعه به دلیل انقباض غیریکنواخت هنگام سرد شدن ایجاد می‌شوند) و حبس هوا^۲ (گیر افتادن هوا در حفره قالب که ممکن است منجر به ایجاد حفره یا سوختگی در قطعه شود) بودند. همچنین خطوط جوش^۳ (نقاطی که جریان‌های مذاب از چند مسیر به هم می‌رسند و ممکن است استحکام کمتری داشته باشند) و میزان تغییر شکل قطعه به‌ویژه در لبه‌ها (که می‌تواند ناشی از توزیع غیریکسان دما و تنش در هنگام خنک کاری باشد)، بررسی شدند که حداکثر تغییر شکل ۰.۶ میلی‌متر بود.




شکل ۶. نمایش خطوط جوش در نرم‌افزار



شکل ۷. نمایش میزان تغییر فرم قطعه در نرم‌افزار

- 1 Sink mark
- 2 Air trap
- 3 Weld line

همچنین در فاز خنک سازی، دمای آب خنک کننده ۱۶.۸۶ درجه سانتی گراد و دمای بیشینه قطعه ۱۷۰.۵ درجه سانتی گراد تعیین شد.




شکل ۸. نمایش بیشینه دمای قطعه در نرم افزار

از مواردی دیگری که می توان در نتایج شبیه سازی فاز خنک سازی مشاهده کرد، می توان به میانگین دمایی قطعه و رانر، پروفیل دمایی، دمای قطعه و قالب پس از خنک سازی و راندمان حذف حرارت اشاره کرد. بطور کلی مقایسه پارامترهای اصلی فرآیند و پارامترهای به دست آمده از نتایج شبیه سازی در جدول ۶ قابل مشاهده است.

جدول ۶. مقایسه مقدار شبیه سازی شده و مقدار واقعی

پارامتر	مقدار واقعی	مقدار شبیه سازی
زمان چرخه تولید (ثانیه)	۴۳/۵	۴۴/۵
وزن ناخالص (گرم)	۸۳	۸۳/۵۵
وزن رانر (گرم)	۱۰	۱۲/۰۱
وزن خالص قطعه (گرم)	۷۳	۷۱/۵۴
میزان تغییر فرم قطعه (میلی متر)	--	۰/۶
دمای آب ورودی و خروجی (سانتی گراد)	۱۵	۱۵ - ۱۶/۸۶
ماکزیمم دمای قطعه (سانتی گراد)	--	۱۷۵/۵
ماکزیمم دمای رانر (سانتی گراد)	--	۲۱۲

در حالت دوم شبیه سازی، نرم افزار MoldFlow به صورت خودکار تمامی مراحل را اجرا کرد و پارامترهای فرآیند مانند تزریق، نگهداری و خنک سازی بطور بهینه محاسبه شدند. دمای مذاب همچنان ۲۹۰ درجه سانتی گراد و زمان باز و بسته شدن قالب ۲۰ ثانیه باقی ماند. نتایج شبیه سازی خودکار نشان داد که مدت زمان تزریق به ۰.۸۰۸ ثانیه کاهش یافته و فشار تزریق ۴۶.۳۲ مگاپاسکال بود. فاز نگهداری ۴.۶۸ ثانیه با فشار ۵۰.۸۴ مگاپاسکال به طول انجامید. وزن ناخالص قطعه و رانر به ۸۳.۵۶ گرم رسید.



شکل ۹. نمایش زمان تزریق در حالت خودکار

Packing phase results summary :

Peak pressure			
- minimum among cavity nodes	(at 0.000 s) =	0.0000 MPa	
Clamp force - maximum	(at 1.218 s) =	55.9463 tonne	
Total weight - maximum	(at 5.468 s) =	83.5644 g	
Pack/hold pressure profile (abs):			
duration	pressure		
0.0000 s	46.3220 MPa		
0.2000 s	50.8403 MPa		
4.4698 s	50.8403 MPa		

End of packing phase results summary :

Time at the end of packing	=	18.5936 s
Total weight (part + runners)	=	83.5632 g

شکل ۱۰. نتایج فاز نگهداری در حالت خودکار

در فاز خنک سازی، زمان کل چرخه تولید ۳۸.۵۹ ثانیه محاسبه شد که شامل همه مراحل است. دمای آب خنک کننده ۱۵ درجه سانتی گراد و میانگین دمای قطعه پس از خنک سازی ۵۱.۱۳ درجه سانتی گراد بود.

Summary of Cavity Temperature Results

Part surface temperature - maximum	= 78.3140 C
Part surface temperature - minimum	= 29.5314 C
Part surface temperature - average	= 51.1367 C
Cavity surface temperature - maximum	= 72.3600 C
Cavity surface temperature - minimum	= 23.8549 C
Cavity surface temperature - average	= 44.6580 C
Average mold exterior temperature	= 19.8049 C
Heat removal through the outer boundaries	= -0.1719 kW
Cycle time calculated from percentage frozen on average part thickness	= 38.5934 s
Cycle time	= 38.5934 s
Maximum temperature	= 290.0000 C
Minimum temperature	= 15.0000 C

شکل ۱۱. نتایج فاز خنک‌سازی در حالت خودکار

بطور کلی زمان‌های فرآیند در حالت خودکار بهینه‌تر و کوتاه‌تر از حالت واقعی بوده‌است. مقایسه بین حالت واقعی و حالت خودکار در جدول ۷ آورده شده‌است.

جدول ۷. مقایسه نتایج شبیه‌سازی در دو حالت واقعی و خودکار

نوع پارامتر	حالت واقعی	حالت خودکار
زمان تزریق	۴.۱۴ ثانیه	۰.۸۱ ثانیه
فشار نگهداری	۷۴.۸۳ mpa	۵۰.۸۴ mpa
زمان در پایان فاز نگهداری	۲۴.۵ ثانیه	۱۸.۵۰ ثانیه
وزن کل قطعه و رانر	۸۳.۹۱ گرم	۸۳.۵۶ گرم
دمای آب خنک‌کننده	۱۵ سانتی‌گراد	۱۵ سانتی‌گراد
سایکل تایم	۴۴.۵ ثانیه	۳۸.۵۹ ثانیه

در حالت خودکار نتایج منجر به بهبود زمان چرخه تولید شده‌است. همانطور که در جدول ۷ مشخص است، دمای سطح قطعه به هنگام خروج از دستگاه ۵۱ درجه سانتی‌گراد است و همچنین در تحلیل پارامترهای کیفی قطعه مانند تاب برداشت قطعه (در حدود ۰.۶)، علائم سینک و غیره، وضعیت مطلوبی داشته‌اند که مجموع این نتایج نشان‌دهنده زمان چرخه مطلوب ۳۸.۵۹ ثانیه برای فرآیند تولید این قطعه است.

با مقایسه جداول ۶ و ۷ مشخص می‌شود که تفاوت‌هایی میان نتایج واقعی و شبیه‌سازی شده وجود دارد. برای مثال: وزن رانر در حالت شبیه‌سازی اندکی بیشتر از مقدار واقعی (۱۲.۰۱ گرم در برابر ۱۰ گرم) به‌دست آمده‌است. این اختلاف ممکن است ناشی از تفاوت در دقت مدل‌سازی سه‌بعدی رانر یا چگالی ماده پیش‌فرض در نرم‌افزار باشد که به‌صورت دقیق

با شرایط واقعی تنظیم نشده است. همچنین تغییر فرم قطعه در حالت واقعی اندازه گیری نشده در حالیکه در شبیه سازی مقدار آن حدود ۰.۶ میلی متر بوده است. این مقدار برای ارزیابی کیفی قطعه مفید است اما نیاز به تایید تجربی دارد. در بخش زمان تزریق، اختلاف قابل توجهی میان حالت واقعی (۴.۱۴ ثانیه) و حالت خودکار (۰.۸۱ ثانیه) مشاهده می شود. این کاهش ناشی از بهینه سازی ترتیب و سرعت تزریق در نرم افزار MoldFlow است که در حالت واقعی به دلیل محدودیت های فنی دستگاه یا احتیاط اپراتورها، ممکن است با سرعت کمتری انجام شود. به علاوه، فشار نگهداری در حالت خودکار نیز کاهش یافته که می تواند به کاهش تنش های داخلی قطعه کمک کرده و مصرف انرژی را بهینه کند. برای محاسبه درصد کاهش زمان چرخه تولید، اختلاف زمان بین حالت واقعی و حالت خودکار محاسبه شده و بر زمان چرخه حالت واقعی تقسیم شده است. فرمول محاسبه به صورت زیر است:

$$\text{درصد کاهش} = \left(\frac{44.5 - 38.59}{44.5} \right) \times 100 = 13.3\%$$

این کاهش، نشان دهنده بهبود قابل توجه در عملکرد سیستم DT است. علاوه بر این، کیفیت قطعه تولید شده نیز با تحلیل شاخص هایی همچون دمای سطح قطعه، میزان تاب برداشتن (حداکثر ۰.۶ میلی متر) و عدم وجود علائم قابل توجه سینگ و حبس هوا ارزیابی شد و نتایج کیفی مطلوبی به دست آمد که اعتبار بهبود حاصل شده را تایید می کند. با این حال برای ارزیابی دقیق تر معناداری آماری این بهبود، پیشنهاد می شود در پژوهش های آتی چندین سری شبیه سازی و آزمون های آماری مانند آزمون t یا تحلیل واریانس (ANOVA) برای مقایسه دقیق تر نتایج انجام گیرد.

کلیه نتایج شبیه سازی از طریق فایل خروجی که نرم افزار MoldFlow تولید می کند، قابل استخراج است. با چارچوبی که در شکل ۱ بیان شده، این نتایج به صورت بصری در محیط رابط کاربری به نمایش در خواهند آمد. همچنین پارامترهای ورودی هوش مصنوعی از این نتایج استخراج شده و قابلیت ارسال به هوش مصنوعی تعبیه شده در سیستم را دارند. بطور کلی خروجی ها شامل تمام پارامترهای ورودی به هوش مصنوعی، زمان تزریق بهینه، زمان نگهداری بهینه و زمان خنک سازی خواهد بود.

۴-۲) نتایج محاسباتی هوش مصنوعی


در مدل اولیه شبکه عصبی مصنوعی، داده های مورد نیاز برای آموزش شامل ۱۲۰ نمونه از تولید واقعی و اطلاعات مرتبط با ۴ قطعه از کارخانه جمع آوری شد. ویژگی های اصلی این داده ها شامل نوع ماده، چگالی، شاخص جریان پذیری، دمای ذوب، فشار تزریق و نگهداری، وزن قطعه و زمان خنک سازی بودند که به عنوان ورودی های مدل بکار رفتند تا زمان چرخه تولید را پیش بینی کنند. پس از پالایش داده ها، ۱۰۰ نمونه نهایی برای آموزش استفاده شد و ۸۰ درصد از داده ها به صورت تصادفی به مجموعه آموزشی اختصاص یافت.

برنامه نویسی مدل با استفاده از کتابخانه های مختلف پایتون انجام و مدل در ۱۰۰ تکرار و بسته های ۸ تایی آموزش داده شد. مدل شامل سه لایه بود: لایه ورودی با ۶۴ نورون، لایه پنهان با ۳۲ نورون و لایه خروجی با ۱ نورون که مجموعاً ۲۸۱۷ پارامتر را برای آموزش دربر گرفت. اطلاعات مربوط به مدل اولیه در جدول ۸ ارائه شده است که در اینجا تمام پارامترها به صورت آموزش پذیر در شبکه تشخیص داده شدند و هیچ پارامتر آموزش ناپذیری در شبکه عصبی وجود ندارد.

جدول ۸. اطلاعات مدل اولیه شبکه عصبی مصنوعی


لایه (نوع)	شکل خروجی	# پارامتر
لایه ورودی	(None, 64)	۷۰۴
لایه پنهان	(None, 32)	۲۰۸۰
لایه خروجی	(None, 1)	۳۳
تعداد کل پارامترها		۲۸۱۷

در نهایت پس از آموزش شبکه عصبی، مقدار کمینه تابع ضرر ۱۲.۱۰ به دست آمد. نمودار تابع ضرر نشان داد که مدل در تعمیم دهی عملکرد ضعیفی دارد و با نوسانات زیادی مواجه است. همانطور که از شکل ۱۲ پیداست، نمودار ضرر نوسانات قابل توجهی را نشان می دهد که نشان دهنده عملکرد مدل در مجموعه اعتبارسنجی ناسازگار است. این الگو نشان می دهد که مدل در حال تقلا برای تعمیم و کمینه کردن مقدار تابع ضرر است. احتمالاً به دلیل مسائلی مانند نرخ یادگیری بالا، یک مدل بیش از حد پیچیده یا فرایارامترهایی که بهینه نیستند، فقدان روند نزولی مشخص در تابع ضرر مشهود است که نشان می دهد مدل بطور موثر یاد نمی گیرد.



شکل ۱۲. مقادیر تابع ضرر مجموعه اعتبارسنجی در تکرارهای مختلف مدل اولیه

همچنین مقادیر پیش‌بینی شده و مقادیر واقعی پس از آموزش مدل در شکل زیر نمایش داده شده است. مقادیر پیش‌بینی شده (خط نارنجی) عموماً از روند مقادیر واقعی (خط آبی) پیروی می کنند که نشان می دهد مدل در حال گرفتن الگوی کلی داده ها است اما در برخی نقاط انحرافات مشاهده شد که نشان دهنده خطاهای مدل در پیش‌بینی بود.




شکل ۱۳. مقایسه مقادیر واقعی و مقادیر پیش‌بینی شده مدل اولیه

برای بهبود دقت مدل و کاهش تابع هزینه، از الگوریتم جستجوی شبکه‌ای برای بهینه‌سازی فرآپارامترها استفاده شد. در این روش، سه فرآپارامتر اصلی مدل یعنی تعداد نورون‌ها، تابع فعال‌ساز و نوع بهینه‌ساز با سه مقدار متفاوت برای هر کدام مورد بررسی قرار گرفتند. مجموعاً ۲۷ مدل مختلف آموزش داده شدند و بهترین ترکیب پارامترها انتخاب شد. فرآپارامترهای بهینه‌شده:

- تعداد نورون‌ها: ۳۲ نورون در لایه اول و ۶۴ نورون در لایه دوم
- تابع فعال‌ساز: $\tanh$
- بهینه‌ساز: sgd

نتیجه بهینه‌سازی منجر به ساخت مدلی با ۲۵۳۱ پارامتر شد که عملکرد بهتری نسبت به مدل اولیه داشت. تابع ضرر مدل بهبودیافته از ۱۲.۱۰ به ۱۱.۸۰ کاهش یافت. اگرچه پیش‌بینی‌های مدل بهینه همچنان دارای برخی انحرافات بود اما بهبود قابل ملاحظه‌ای نسبت به مدل اولیه مشاهده شد. همچنین برای کاهش خطاهای باقیمانده، نیاز به داده‌های بیشتری است که در ادامه با استفاده از سیستم DT و تعامل با داده‌های جدید از تولید قابل حل است.




شکل ۱۴. مقادیر تابع ضرر مجموعه اعتبارسنجی در تکرارهای مختلف مدل ثانویه

۳-۴ خروجی طراحی رابط کاربری


رابط کاربری طراحی شده مطابق شکل های ۱۵ و ۱۶ برای سیستم DT نقش حیاتی در نظارت و تعامل کاربران با فرآیند قالب گیری تزریقی دارد. این رابط برای یکپارچه سازی زیرسیستم های شبیه سازی و هوش مصنوعی با استفاده از کتابخانه Tkinter در پایتون ساخته شده است. رابط کاربری با نمایش مراحل فرآیند در زمان واقعی، اطلاعات مرتبط با چرخه تولید و فراهم کردن امکاناتی برای تعامل مستقیم با سیستم، تجربه کاربری بصری را ارائه می دهد.

اجزای اصلی رابط کاربری:

- **نمایش مرحله فرآیند:** وضعیت فعلی قالب گیری نمایش داده می شود و در زمان واقعی به روز می شود.
- **نمایش زمان چرخه:** زمان چرخه تولید نشان داده و پس از هر مرحله به روزرسانی می شود.
- **نشانه وضعیت سیستم:** نشان دهنده فعال یا غیرفعال بودن سیستم به صورت رنگی است.
- **نمایش تصویر مرحله:** یک تصویر بصری مرتبط با هر مرحله از فرآیند قالب گیری نمایش داده می شود.
- **دکمه پیش بینی هوش مصنوعی:** کاربران می توانند با وارد کردن پارامترهای مختلف فرآیند، زمان چرخه تولید را پیش بینی کنند.
- **لیست قطعات:** امکان انتخاب قطعات مختلف و نمایش اطلاعات و تصاویر مربوط به آنها وجود دارد.



شکل ۱۵. پنجره اصلی رابط کاربری در حالت غیر فعال



شکل ۱۶. پنجره اصلی رابط کاربری در حالت فعال

ویژگی‌های رابط پیش‌بینی هوش مصنوعی: کاربر با وارد کردن پارامترهای فرآیند می‌تواند از طریق دکمه "AI Predict"، زمان چرخه تولید را با استفاده از مدل هوش مصنوعی پیش‌بینی کند. همچنین امکان استفاده از نتایج شبیه‌سازی برای بهبود پیش‌بینی‌ها فراهم است.

شکل ۱۷. پنجره پیش‌بینی با هوش مصنوعی

ویژگی‌های پنجره اطلاعات قطعه: انتخاب یک قطعه از لیست باکس، نمایش تصویر و اطلاعات آن را فعال می‌کند. همچنین کاربران می‌توانند مستقیماً نتایج شبیه‌سازی MoldFlow را مشاهده کنند. این رابط کاربری با ارائه اطلاعات به‌روز و امکانات پیش‌بینی، به کاربران کمک می‌کند تا فرآیند تولید را بهینه و به‌صورت موثرتری نظارت کنند و تصمیم‌گیری‌های مبتنی بر داده‌ها را انجام دهند.

شکل ۱۸. پنجره اطلاعات قطعه

۵) نتیجه‌گیری و پیشنهادات

این پژوهش فرآیند قالب‌گیری تزریق پلاستیک را با استفاده از فناوری‌های صنعت ۴.۰ و ایجاد سیستم DT برای نظارت و بهینه‌سازی زمان چرخه تولید بررسی کرده‌است. سیستم پیشنهادی که شامل زیرسیستم‌های شبیه‌سازی، هوش مصنوعی و

رابط کاربری است، در گروه صنعتی انتخاب و بر روی یکی از ماشین‌های تزریق پلاستیک طراحی پیاده‌سازی شد. داده‌های لحظه‌ای از سنسورهای دستگاه تزریق جمع‌آوری و به DT ارسال می‌شوند تا یک مدل بلادرنگ برای پیش‌بینی زمان چرخه و بهبود عملکرد تولید ایجاد شود.

در این پژوهش، ابتدا مبانی نظری و مفاهیم پایه مانند صنعت ۴.۰، DT و فرآیند تزریق پلاستیک معرفی شدند. سپس با بررسی پیشینه پژوهش، به تحلیل شکاف‌های تحقیقاتی در کاربرد DT و بهینه‌سازی زمان چرخه قالب‌گیری تزریقی پرداخته شد. در ادامه پس از بررسی مسئله، راهکار پیشنهادی برای پیاده‌سازی آن ارائه شد و زیرسیستم‌های آن مورد بررسی قرار گرفتند. پس از آن سیستم پیشنهادی تحت فرآیند واقعی پیاده‌سازی شد و عملکرد آن در شبیه‌سازی فرآیند تولید قطعات پلاستیکی ارزیابی شد. نتایج نشان داد که این سیستم قادر است با استفاده از زیرسیستم شبیه‌سازی، دقت بالایی در بازتاب شرایط واقعی فرآیند ارائه دهد. شبیه‌سازی با استفاده از پارامترهای تولید نشان داد که نتایج شبیه‌سازی با فرآیند دنیای واقعی مطابقت دارد و قابلیت اطمینان و دقت سیستم DT را تایید می‌کند. همچنین این زیرسیستم توانست متوسط زمان چرخه تولید را تا ۱۳.۳ درصد کاهش دهد. از آنجاییکه دمای خروج قطعه و پارامترهای کیفی آن در نتایج شبیه‌سازی دارای مقادیر مطلوب بود و مقادیر به تایید کارشناسان واحد مربوطه رسید، این زمان چرخه به عنوان زمان بهینه تعیین شد. علاوه بر این، بکارگیری شبکه عصبی مصنوعی بهبود قابل توجهی در دقت پیش‌بینی‌های فرآیند بهینه‌سازی فراهم کرد و استفاده از الگوریتم جستجوی شبکه‌ای باعث کاهش تابع ضرر و افزایش کارایی مدل شد. درخصوص تاثیر رابط کاربری بر قابلیت استفاده و کارایی سیستم DT، رابط کاربری جهت کارایی بهتر و تعامل بخش‌های مختلف سیستم با یکدیگر طراحی شد. این رابط کاربری قابلیت پایش فرآیند در زمان واقعی از جمله نمایش مرحله تولید و نمایش زمان چرخه تولید را داشت. همچنین قابلیت نمایش مشخصات قطعه موردنظر، استخراج نتایج شبیه‌سازی و نمایش بصری آن و پیش‌بینی زمان چرخه تولید با هوش مصنوعی نیز به این ابزار اضافه شده‌است. بطور کلی رابط کاربری تاثیر مثبتی بر قابلیت استفاده و کارایی سیستم DT داشت. تعامل آسان با سیستم را تسهیل می‌کند و کاربران را قادر می‌سازد تا پارامترهای ورودی، نظارت بر شبیه‌سازی‌ها و تفسیر نتایج را با حداقل آموزش انجام دهند. طراحی بصری رابط کاربری تضمین می‌کند که کاربران می‌توانند فرآیند تزریق را بدون دانش فنی گسترده نظارت و بهینه کنند.

با این حال، این پژوهش با محدودیت‌هایی نیز مواجه بود که لازم است در تحقیقات آتی مورد توجه قرار گیرند. یکی از مهمترین محدودیت‌ها، وابستگی سیستم به داده‌های ورودی دقیق و کامل بود. داده‌های ناقص یا دارای نویز می‌توانند دقت پیش‌بینی‌های مدل را به شدت کاهش دهند. به منظور رفع این چالش، استفاده از الگوریتم‌های پاک‌سازی و پیش‌پردازش داده و همچنین بهره‌گیری از سنسورهای با کیفیت و کالیبره شده توصیه می‌شود. همچنین نیاز به توان پردازشی بالا برای اجرای همزمان شبیه‌سازی و تحلیل‌های مبتنی بر هوش مصنوعی، یکی دیگر از چالش‌ها بود که در محیط‌های صنعتی با محدودیت منابع می‌تواند مشکل ساز باشد. در این راستا، پیشنهاد می‌شود از راهکارهای محاسباتی ابری یا لبه‌ای استفاده شود تا اجرای مدل‌ها با تاخیر کمتر و هزینه پایین‌تر امکان پذیر شود. محدودیت دیگر، دشواری در تعمیم‌پذیری مدل به سایر ماشین‌آلات یا فرآیندها بود که این موضوع با طراحی ماژولار سیستم و آموزش مدل‌ها براساس داده‌های متنوع

و گسترده قابل بهبود است. در مجموع، سیستم DT توسعه یافته، پتانسیل بالایی برای بهینه سازی و کاهش هزینه های تولید در صنعت قالب گیری تزریقی نشان داد.

پیشنهادهای عملی برای بهبود عملکرد سیستم DT در قالب گیری تزریقی براساس یافته های این تحقیق شامل اعتبارسنجی منظم مدل با داده های واقعی و مقایسه دوره های آنها برای حفظ دقت است. توصیه می شود یک سیستم خودکار برای جمع آوری داده های واقعی به منظور به روزرسانی مداوم DT پیاده سازی شود. همچنین همکاری نزدیک میان متخصصان فناوری اطلاعات و تیم های عملیاتی برای اطمینان از استحکام زیرساخت دیجیتال و دقت در فرآیندهای اجرایی اهمیت دارد. از طرفی، طراحی سیستم باید مقیاس پذیر باشد تا بتواند با افزایش تقاضای تولید و تغییرات فرآیندی همگام شود. در نهایت رابط کاربر پسند و آموزش کارآمد اپراتورها و مهندسان برای بهره برداری موثر از سیستم و تصمیم گیری بر مبنای نتایج شبیه سازی ها ضروری است. علاوه بر این، برای پیاده سازی موفق DT در سایر صنایع، پیشنهاد می شود فرآیندهای تولیدی مشابه با قالب گیری تزریقی مانند ریخته گری، اکستروژن یا شکل دهی فلزات نیز مورد بررسی قرار گیرند. در این صنایع نیز می توان با جمع آوری داده های فرآیندی و استفاده از مدل های شبیه سازی و یادگیری ماشین، سیستم های DT سفارشی سازی شده ایجاد کرد. به عنوان نمونه:

در ریخته گری (مانند ریخته گری تحت فشار یا ماسه ای)، پارامترهایی نظیر دمای مذاب، سرعت پُرشدن قالب، فشار تزریق، زمان انجماد و توزیع دما در قالب، از عوامل کلیدی در کیفیت نهایی قطعه هستند. استفاده از DT در این حوزه می تواند به کاهش عیوبی مانند تخلخل، سردجوش و اعوجاج کمک کرده و بهینه سازی سیکل ریخته گری را ممکن سازد. این فناوری در صنایع خودروسازی، هوافضا و تولید قطعات سنگین صنعتی بسیار کاربردی است.

در فرآیند اکستروژن (برای مواد پلیمری یا فلزی)، پارامترهایی مانند نرخ تغذیه، فشار و دمای نازل، سرعت کشش و نرخ خنک کاری حیاتی هستند. DT در این فرآیند می تواند به پیش بینی دقیق خواص مکانیکی و هندسی محصول، بهبود کنترل کیفیت سطح و کاهش ضایعات کمک کند. این کاربرد در صنایع ساخت پروفیل های ساختمانی، تولید کابل، لوله و ورق بسیار مهم است.

در شکل دهی فلزات (مانند فورجینگ، نورد یا کشش عمیق)، داده هایی نظیر نیرو و سرعت پرس، دمای قالب و قطعه، نرخ تغییر شکل و اصطکاک سطحی، نقش تعیین کننده ای در کیفیت و عمر ابزار دارند. DT می تواند برای پیش بینی سایش قالب، تحلیل تنش و کرنش و جلوگیری از ترک خوردگی قطعه بکار رود. این کاربردها در صنایع هوافضا، نظامی و خودروسازی اهمیت زیادی دارد.

شناسایی پارامترهای بحرانی هر فرآیند، انتخاب ابزارهای مناسب برای مدل سازی و توسعه رابط های کاربری متناسب با نیازهای خاص آن صنعت از جمله اقداماتی هستند که می توانند به انتقال موفق این فناوری به سایر زمینه های تولیدی کمک کنند.

پیشنهادهای آتی این پژوهش شامل بررسی تکنیک های پیشرفته تر یادگیری ماشین مانند یادگیری عمیق تقویتی برای افزایش دقت پیش بینی و بهینه سازی سیستم DT است. بهبود رابط های کاربری بصری و قابل تنظیم برای کاربران با سطوح مختلف تخصص، استفاده و دسترسی سیستم را ارتقا می دهد. ترکیب مدل های شبیه سازی قطعی و تصادفی برای نمایش

بهرتر پیچیدگی‌ها و عدم قطعیت‌های فرآیند قالب‌گیری، بهینه‌سازی چندهدفه برای بهبود معیارهای مختلف عملکردی همچون کیفیت و زمان چرخه و تمرکز بر بهینه‌سازی مصرف انرژی نیز می‌تواند به پیشرفت سیستم کمک کنند. ایجاد استراتژی‌های تعمیر و نگهداری پیش‌بینی‌کننده برای کاهش خرابی و هزینه‌ها و همچنین مطالعه و پیاده‌سازی استراتژی‌های امنیت سایبری برای حفاظت از داده‌ها و فرآیندها از دیگر پیشنهادات آتی هستند.

منابع

- Behera, R., & Das, K. (2017). A Survey on Machine Learning: Concept, Algorithms and Applications. *International Journal of Innovative Research in Computer and Communication Engineering*, 2 .
- Bhandal, R., McRiton, R., Kavanagh, R. E., & Brown, A. (2022). The application of digital twin technology in operations and supply chain management: a bibliometric review. *Supply Chain Management-an International Journal*, 27(2), 182-206. <https://doi.org/10.1108/scm-01-2021-0053>
- Bibow, P., Dalibor, M., Hopmann, C., Mainz, B., Rumpe, B., Schmalzing, D., Schmitz, M., & Wortmann, A. (2020, 2020/). Model-Driven Development of a Digital Twin for Injection Molding. *Advanced Information Systems Engineering*, Cham.
- Brunthaler, J., Grabski, P., Sturm, V., Lubowski, W., & Efrosinin, D. (2022). On the Problem of State Recognition in Injection Molding Based on Accelerometer Data Sets. *SENSORS*, 22(16), Article 6165. <https://doi.org/10.3390/s22166165>
- Cavalcante, I. M., Frazzon, E. M., Forcellini, F. A., & Ivanov, D. (2019). A supervised machine learning approach to data-driven simulation of resilient supplier selection in digital manufacturing. *INTERNATIONAL JOURNAL OF INFORMATION MANAGEMENT*, 49, 86-97. <https://doi.org/10.1016/j.ijinfomgt.2019.03.004>
- Erol, T., Mendi, A. F., & Doğan, D. (2020, 22-24 Oct. 2020). The Digital Twin Revolution in Healthcare. 2020 4th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT) ,
- Huang, H., Ji, T., & Xu, X. (2024). An adaptable Digital Twin model for manufacturing. *Manufacturing Letters*, 41, 1163-1169. <https://doi.org/https://doi.org/10.1016/j.mfglet.2024.09.142>
- Hürkamp, A., Gellrich, S., Ossowski, T., Beuscher, J., Thiede, S., Herrmann, C., & Dröder, K. (2020). Combining Simulation and Machine Learning as Digital Twin for the Manufacturing of Overmolded Thermoplastic Composites. *Journal of Manufacturing and Materials Processing*, 4 .(۳)
- Ivanov, D., Dolgui, A., Das, A., & Sokolov, B. (2019). Digital Supply Chain Twins: Managing the Ripple Effect, Resilience , and Disruption Risks by Data-Driven Optimization, Simulation, and Visibility. In D. Ivanov, A. Dolgui, & B. Sokolov (Eds.), *HANDBOOK OF RIPPLE EFFECTS IN THE SUPPLY CHAIN* (Vol. 276, pp. 309-332). https://doi.org/10.1007/978-3-030-14302-2_15
- Kitayama, S., Ishizuki, R., Takano, M., Kubo, Y., & Aiba, S. (2019). Optimization of mold temperature profile and process parameters for weld line reduction and short cycle time in rapid heat cycle molding. *INTERNATIONAL JOURNAL OF ADVANCED MANUFACTURING TECHNOLOGY*, 103(5-8), 1735-1744. <https://doi.org/10.1007/s00170-019-03685-3>
- Koch, V., Kuge, S., Geissbauer, R., & Schrauf, S. (2014). Industry 4.0: Opportunities and challenges of the industrial internet. *Strategy & PwC*, 5-50 .
- Kritzinger, W ,Karner, M., Traar, G., Henjes, J., & Sihn, W. (2018). Digital Twin in manufacturing: A categorical literature review and classification. *IFAC-PapersOnLine*, 51(11), 1016-1022. <https://doi.org/https://doi.org/10.1016/j.ifacol.2018.08.474>
- Kuo, C. C., & Xu, W. C. (2018). Effects of different cooling channels on the cooling efficiency in the wax injection molding process. *INTERNATIONAL JOURNAL OF ADVANCED MANUFACTURING TECHNOLOGY*, 98(1-4), 887-895. <https://doi.org/10.1007/s00170-018-2345-7>
- Lacueva-Pérez ,F. J., Hermawati, S., Amoraga, P., Salillas-Martínez, R., Hoyo-Alonso, R. d., & Lawson, G. (2022). SHION (Smart tHermoplastic InjectiON): An Interactive Digital Twin Supporting Real-Time Shopfloor Operations. *IEEE Internet Computing*, 26(3), 23-32. <https://doi.org/10.1109/MIC.2020.3047349>
- Lee, D., & Lee, S. (2021). Digital Twin for Supply Chain Coordination in Modular Construction. *APPLIED SCIENCES-BASEL*, 11(13), Article 5909. <https://doi.org/10.3390/app11135909>
- Li, X., Cao, J. R., Liu, Z. G., & Luo, X .G. (2020). Sustainable Business Model Based on Digital Twin Platform Network: The Inspiration from Haier's Case Study in China. *SUSTAINABILITY*, 12(3), Article 936. <https://doi.org/10.3390/su12030936>

- Liao, Y., Deschamps, F., Loures, E. d. F. R., & Ramos, L. F. P. (2017). Past, present and future of Industry 4.0 - a systematic literature review and research agenda proposal. *International Journal of Production Research*, 55(12), 3609-3629. <https://doi.org/10.1080/00207543.2017.1308576>
- Liau, Y. Y., Lee, H & ,Ryu, K. (2018). Digital Twin concept for smart injection molding. *IOP Conference Series: Materials Science and Engineering*, 324, 012077. <https://doi.org/10.1088/1757-899X/324/1/012077>
- Lin, X., Chen, W., Zhou, Z., Li, J., Zhao, Y., & Zhang, X. (2025). A five-dimensional digital twin framework driven by large language models-enhanced RL for CNC systems. *Robotics and Computer-Integrated Manufacturing*, 95, 103009. <https://doi.org/https://doi.org/10.1016/j.rcim.2025.103009>
- Mandolla, C., Petruzzelli, A. M ,Percoco, G., & Urbinati, A. (2019). Building a digital twin for additive manufacturing through the exploitation of blockchain: A case analysis of the aircraft industry. *Computers in Industry*, 109, 134-152. <https://doi.org/10.1016/j.compind.2019.04.011>
- Marrone, S., Papa, C., & Sansone, C. (2021). Effects of hidden layer sizing on CNN fine-tuning. *Future Generation Computer Systems*, 118, 48-55. <https://doi.org/https://doi.org/10.1016/j.future.2020.12.020>
- Martowibowo, S. Y., & Kaswadi, A. (2017). Optimization and Simulation of Plastic Injection Process using Genetic Algorithm and Moldflow. *CHINESE JOURNAL OF MECHANICAL ENGINEERING*, 30(2), 398-406. <https://doi.org/10.1007/s10033-017-0081-9>
- Mazzei, D., Baldi, G., Fantoni, G., Montelisciani, G., Pitasi, A ,Ricci, L., & Rizzello, L. (2020). A Blockchain Tokenizer for Industrial IOT trustless applications. *FUTURE GENERATION COMPUTER SYSTEMS-THE INTERNATIONAL JOURNAL OF ESCIENCE*, 105, 432-445. <https://doi.org/10.1016/j.future.2019.12.020>
- Mianehrow, H., & Abbasian, A. (2017). Energy monitoring of plastic injection molding process running with hydraulic injection molding machines. *JOURNAL OF CLEANER PRODUCTION*, 148, 804-810. <https://doi.org/10.1016/j.jclepro.2017.02.053>
- Modoni, G. E., Stampone, B., & Trotta ,G. (2022). Application of the Digital Twin for in process monitoring of the micro injection moulding process quality. *Computers in Industry*, 135, 103568. <https://doi.org/https://doi.org/10.1016/j.compind.2021.103568>
- Passos, D., & Mishra, P. (2022). A tutorial on automatic hyperparameter tuning of deep spectral modelling for regression and classification tasks. *Chemometrics and Intelligent Laboratory Systems*, 223, 104520. <https://doi.org/https://doi.org/10.1016/j.chemolab.2022.104520>
- Rehmer, A., Klute, M ,Heim, H.-P., & Kroll, A. (2024). Chapter 4 - A Digital Twin for part quality prediction and control in plastic injection molding. In P. Mercorelli, W. Zhang, H. Nemati, & Y. Zhang (Eds.), *Modeling, Identification, and Control for Cyber- Physical Systems Towards Industry 4.0* (pp. 79-109). Academic Press. <https://doi.org/https://doi.org/10.1016/B978-0-32-395207-1.00014-7>
- Sapounas, I., Vosniakos, G. C., & Papazetis, G. (2020). A simulation-based robust methodology for operator guidance on injection moulding machine settings. *INTERNATIONAL JOURNAL OF INTERACTIVE DESIGN AND MANUFACTURING - IJIDEM*, 14(2), 519-533. <https://doi.org/10.1007/s12008-020-00646-z>
- Singh, G., Pradhan, M. K., & Verma, A. (2018). Multi Response optimization of injection moulding Process parameters to reduce cycle time and warpage *MATERIALS TODAY-PROCEEDINGS* ,
- Sleiti, A. K., Kapat, J. S., & Vesely, L. (2022). Digital twin in energy industry: Proposed robust digital twin for power plant and other complex capital-intensive large engineering systems. *Energy Reports*, 8, 3704-3726. <https://doi.org/https://doi.org/10.1016/j.egyr.2022.02.305>
- Sun, X., Zhang, F., Niu, X., & Wang, J. (2024). A digital twin commissioning method for machine tools based on scenario simulation. *Journal of Manufacturing Systems*, 77, 697-707. <https://doi.org/https://doi.org/10.1016/j.jmsy.2024.10.017>
- Wang, L., Deng, T. H., Shen, Z. J. M., Hu, H., & Qi, Y. Z. (2022). Digital twin-driven smart supply chain. *Frontiers of Engineering Management*, 9(1), 56-70. <https://doi.org/10.1007/s42524-021-0186-9>
- Wang, Z., Feng, W., Ye, J., Yang, J., & Liu, C. (2021). A Study on Intelligent Manufacturing Industrial Internet for Injection Molding Industry Based on Digital Twin. *Complexity*, 2021, 8838914. <https://doi.org/10.1155/2021/8838914>
- White, G., Zink, A., Codecá, L., & Clarke, S. (2021). A digital twin smart city for citizen feedback. *Cities*, 110, 103064. <https://doi.org/https://doi.org/10.1016/j.cities.2020.103064>
- Zhang, K., Zhou, H.-Y., Baptista-Hon, D. T., Gao, Y., Liu ,X., Oermann, E., Xu, S., Jin, S., Zhang, J., Sun, Z., Yin, Y., Razmi, R. M., Loupy, A., Beck, S., Qu, J., & Wu, J. (2024). Concepts and applications of digital twins in healthcare and medicine. *Patterns*, 5(8), 101028. <https://doi.org/https://doi.org/10.1016/j.patter.2024.101028>