



Ferdowsi University
of Mashhad

Journal of Metallurgical and Materials Engineering

<https://jmme.um.ac.ir>



Iron&Steel
Society of Iran

Machine Learning-Based Modeling of Metal Additive Manufacturing Processes Using Data Augmentation and Ensemble Learning

Research Article

Nima Ayobi¹, Reza Mahboobi Esfanjani² , Ahmad Akbari³, Habib Badri Ghavifekr⁴

DOI: [10.22067/jmme.2025.91745.1177](https://doi.org/10.22067/jmme.2025.91745.1177)

1- Introduction

In recent years, the demand for manufacturing high-quality components with complex geometries has increased significantly. Conventional manufacturing methods, including casting, forming, and subtractive processes, face limitations in producing intricate geometries. These methods generate substantial waste, require high energy consumption, and are not well-suited for customized or personalized parts. To address these issues, additive manufacturing (AM), commonly known as three-dimensional (3D) printing, has been developed. Among various AM techniques, metal additive manufacturing (MAM) has enabled the production of complex metallic components with high density and strength while minimizing waste. Despite its many advantages, MAM faces commercial challenges such as ensuring quality and process repeatability. To overcome these challenges, accurate mathematical models of MAM processes must be developed. However, due to rapid dynamics, multiple physical phenomena, and parametric uncertainties, process modeling remains a complex task, and traditional models often fail to uncover hidden patterns within the process. To address these issues, data-driven methods—particularly artificial intelligence (AI) and machine learning (ML)—have gained significant attention. ML allows nonlinear modeling and the analysis of multidimensional, complex data, enabling the development of accurate models from process data without explicit programming. This approach not only facilitates fast model development but also provides improved prediction for unseen data, higher accuracy through data augmentation, and lower experimental costs and time. Therefore, ML offers a promising tool for modeling MAM processes. Nonetheless, limitations such as the need for large volumes of high-quality data, model selection, parameter tuning, computational constraints, and issues like overfitting still cause challenges in applying ML to MAM process modeling. To address these issues, this paper proposes a

hybrid framework combining data augmentation and ensemble learning as an improved approach for modeling MAM processes. The framework is implemented and evaluated on two key processes: selective laser melting (SLM) and laser direct metal deposition (LDMD).

2- Proposed Framework

In this study, a hybrid framework combining CTGAN-based data augmentation and ensemble learning is employed for modeling MAM processes. The proposed framework consists of two main components: first, process data is collected and pre-processed, after which data augmentation is performed using CTGAN within the Python environment. In the subsequent stage, the augmented data are fed into ML models, thereby enhancing their accuracy and predictive performance. Compared to conventional physics-based and traditional approaches, the proposed framework demonstrates superior capability in modeling the nonlinear and complex nature of AM processes, while also offering significantly higher efficiency and speed than computationally expensive and time-consuming methods such as the finite element method (FEM) or computational fluid dynamics (CFD). These advantages make the framework suitable for industrial applications and real-time applications, including intelligent dimensional control systems. The overall structure of the proposed framework is illustrated in Figure 1.

* Manuscript received January 20, 2025, Revised July 27, 2025, Accepted October 06, 2025.

¹ Ph.D. Candidate, Department of Electrical and Computer Engineering – Control, Sahand University of Technology, Tabriz, Iran.

² Corresponding Author: Professor, Department of Electrical and Computer Engineering – Control, Sahand University of Technology, Tabriz, Iran. **Email:** mahboobi@sut.ac.ir.

³ Associate Professor, Department of and Computer Electrical Engineering – Control, Sahand University of Technology, Tabriz, Iran.

⁴ Professor, Department of Electrical and Computer Engineering – Electronics, Sahand University of Technology, Tabriz, Iran.




Figure 1. The proposed framework for modeling MAM processes integrates data augmentation and ML.

3- Problem Formulation

In this paper, various ML models were implemented and evaluated for modeling MAM processes. The models include Support Vector Machine (SVM), AdaBoost, Extreme Gradient Boosting (EGB), Decision Tree (DT), Random Forest (RF), Linear and Polynomial, LASSO, and Ridge Regression. Additionally, CTGAN-based data augmentation was employed to expand the dataset and improve model accuracy. Cross-validation was applied to assess prediction accuracy, evaluate performance, and ensure the generalizability of the developed models.

4- Simulation Results

In this section, ML models were implemented and evaluated on two well-known MAM processes to assess their predictive performance for process outputs. In the first case study, corresponding to SLM, models including EGB, RF, RBF, Polynomial Regression, Ensemble learning, and AdaBoost were employed to predict the outputs of density, tensile strength, and hardness of the fabricated parts. The simulation results indicate that applying CTGAN-based data augmentation reduced CV-RMSE by 58% for density, 42% for tensile strength, and 59% for hardness, demonstrating a significant improvement in model prediction accuracy. In the second case study, related to LDMD, models such as EGB, RF, RBF, Polynomial Regression, Ensemble learning, and Ridge Regression were utilized to predict the width, depth, and height of the deposited tracks. The application of CTGAN resulted in reductions in the mean prediction error of 44% for width, 51% for depth, and 49% for height. These findings confirm that the integration of ensemble learning with data augmentation substantially enhances the accuracy and reliability of the models, enabling fast and precise process output predictions in industrial environments. Compared to conventional simulation approaches such as FEM or CFD, the proposed framework achieves significantly higher execution speed and responsiveness without the need for high computational resources or extended run times. Consequently, this

approach is more suitable for real-time applications, process control, and industrial production optimization, while also contributing to reduced costs and experimental time. Beyond speed, the proposed framework demonstrates reliable performance under parametric uncertainties and measurement noise, and it can be integrated into real-time intelligent dimensional control systems. Furthermore, it allows the prediction of dimensional deviations during production and provides automated alerts or corrective actions in the event of defects, thereby improving process efficiency. Overall, the combination of ensemble learning and data augmentation enables accurate and cost-effective modeling of complex MAM processes compared to traditional methods.

5- Conclusion

In this paper, several ML methods, including DT, EGB, RBF, AdaBoost, ensemble learning, Polynomial Regression, and RF, were implemented to model two MAM processes: SLM and LDMD. Due to the limited amount of available data, a hybrid approach combining CTGAN-based data augmentation with ensemble learning was adopted, and the models were evaluated using R^2 and CV-RMSE metrics. The simulation results demonstrate that data augmentation improved the predictive performance of the models by an average of 53% for the SLM process and 48% for the LDMD process. The proposed framework enables real-time prediction of process outputs in industrial environments. Compared to finite element simulations, the proposed method is significantly more efficient in terms of both computation time and resource requirements, while also serving as a complementary tool for enhancing existing models. For future work, potential directions include integrating the proposed framework with neural networks, extending it to other metallurgical outputs, developing intelligent dimensional control systems, and applying nature-inspired optimization algorithms such as particle swarm optimization (PSO) to identify optimal operating conditions and minimize energy consumption.



مدل سازی مبتنی بر یادگیری ماشین فرایندهای ساخت افزایشی فلزی با استفاده از روش های داده افزایی و یادگیری گروهی*

مقاله پژوهشی

نیمایوبی^(۱) رضا محبوبی اسفنجانی^(۲) احمد اکبری^(۳) حبیب بدری قویفکر^(۴)

DOI: 10.22067/jmme.2025.91745.1177

چکیده با وجود قابلیت های فراوان ساخت افزایشی فلزی، این روش با محدودیت هایی از جمله قابلیت تکرارپذیری و تضمین کیفیت قطعات مواجه است. به منظور رفع این محدودیت ها به مدل سازی دقیق فرایند نیاز است. از طرفی، کارایی روش های مدل سازی سنتی برای این امر پایین است. یکی از روش های جدید مدل سازی مبتنی بر داده که امکان کشف الگوهای پنهان در فرایندهای غیر خطی را فراهم می کند، یادگیری ماشین است. با وجود مزایای فراوان، به دلیل تعداد محدود داده در فرایند ساخت افزایشی، پیاده سازی یادگیری ماشین با مشکلاتی مواجه است. در این مقاله برای رفع این موارد از ترکیب داده افزایی و یادگیری ماشین برای مدل سازی دو روش شناخته شده ساخت افزایشی فلزی استفاده شده است. نتایج شبیه سازی نشان دهنده کارایی روش پیشنهادی در مدل سازی مناسب فرایند ساخت افزایشی فلزی است.

واژه های کلیدی ساخت افزایشی فلزی، یادگیری ماشین، داده افزایی، یادگیری گروهی، مدل سازی.

Machine Learning-Based Modeling of Metal Additive Manufacturing Processes Using Data Augmentation and Ensemble Learning

Nima Ayobi

Reza Mahboobi Esfajani

Ahmad Akbari

Habib Badri Ghavifekr

Abstract Although metal additive manufacturing offers many advantages, it is restricted by the repeatability and quality assurance of the produced parts. Accurate mathematical modeling of the process is essential to tackle these limitations. Traditional mathematical modeling approaches are inefficient in describing this complicated system. Machine learning is a novel data-driven modeling approach to discover hidden patterns in nonlinear systems. However, applying this scheme in the metal additive manufacturing process is challenging due to the limited data samples. This paper uses machine learning and data augmentation to tackle the mentioned issues and model two well-known metal additive manufacturing processes. Simulation results demonstrate the effectiveness of the proposed method in modeling the metal additive manufacturing processes.

Keywords Metal additive manufacturing, Machine learning, Data augmentation, Ensemble learning, Modeling.

* تاریخ دریافت مقاله ۱۴۰۳/۱۱/۱ و تاریخ پذیرش آن ۱۴۰۴/۷/۱۴ می باشد.

(۱) دانشجوی مقطع دکتری، دانشکده مهندسی برق و کامپیوتر - کنترل، دانشگاه صنعتی سهند تبریز، تبریز.

(۲) نویسنده مسئول؛ استاد، دانشکده مهندسی برق و کامپیوتر - کنترل، دانشگاه صنعتی سهند تبریز، تبریز

(۳) دانشیار، دانشکده مهندسی برق و کامپیوتر - کنترل، دانشگاه صنعتی سهند تبریز، تبریز.

(۴) استاد، دانشکده مهندسی برق و کامپیوتر - الکترونیک، دانشگاه صنعتی سهند تبریز، تبریز.

Email: mahboobi@sut.ac.ir

مقدمه

در سال‌های اخیر نیاز به ساخت قطعات با کیفیت و دارای ساختارهای پیچیده بیش از پیش احساس می‌شود. روش‌های تولید سنتی از جمله ریخته‌گری، شکل‌دهی و فرایندهای ساخت کاهشی با محدودیت‌هایی در ساخت شکل‌های پیچیده مواجه هستند. این روش‌ها پسماند فراوانی تولید می‌کنند و مصرف انرژی بالایی دارند. از طرفی روش‌های یاد شده برای ساخت قطعات سفارشی و شخصی‌سازی شده مناسب نیستند و از نظر اقتصادی برای نمونه‌سازی کارایی ندارند. برای رفع این مشکلات روش‌های ساخت افزایشی توسعه داده شده‌اند. ساخت افزایشی عبارت رسمی و تخصصی برای فرایند نمونه‌سازی سریع است و در عموم از آن به عنوان فناوری چاپ سه‌بعدی یاد می‌شود [1]. از بین روش‌های نمونه‌سازی سریع، ساخت افزایشی فلزی که با استفاده از آن می‌توان قطعات با ساختار پیچیده را از آلیاژهای فلزی مختلف تولید کرد، مورد توجه واقع شده است. در صورت نیاز می‌توان با استفاده از ساخت افزایشی فلزی قطعات فرسوده و معیوب را که در طول زمان دچار خرابی شده‌اند نیز تعمیر کرد. امکان ساخت قطعات با چگالی و استحکام بالا با کمترین میزان تولید پسماند به وسیله این فرایندها ممکن شده است [2].

با وجود مزایای فراوانی که ساخت افزایشی فلزی دارد، روش مذکور در سطح تجاری مشکلاتی از جمله تضمین کیفیت بالا و تکرارپذیری دارد. مدل‌سازی این فرایندها برای بررسی اثر پارامترهای مختلف روی خروجی و حفظ برخی ویژگی‌های قطعه ساخته شده، چالشی است. پارامترهایی مانند تخلخل، چگالی و کیفیت سطح برای ساخت قطعات با کیفیت باید در یک بازه مشخص حفظ شوند. پارامترهای متعددی مانند ویژگی‌های ماده، تنظیمات دستگاه و پایداری فرایند روی کیفیت قطعه اثرگذار هستند؛ بنابراین مدل‌سازی ریاضی این فرایندها چالشی است. مدل‌های فیزیکی و سنتی ارائه داده شده برای این فرایندها اغلب بسیار پیچیده هستند و به منابع محاسباتی قدرتمندی برای حل آن‌ها احتیاج است. این نوع مدل‌سازی اغلب توانایی آشکارسازی الگوهای پنهان در فرایند به دلیل وقوع دینامیک‌های سریع و وجود پدیده‌های مختلف فیزیکی را ندارد. همچنین مدل‌سازی فیزیکی با ساده‌سازی در روابط همراه است که روی دقت پیش‌بینی خروجی اثر نامطلوبی دارد. از طرفی در حضور نامعینی کارکرد مدل‌سازی فیزیکی دچار مشکل می‌شود [3]. امروزه برای غلبه بر مشکلات مدل‌سازی در فرایندهای پیچیده و

غیر خطی مانند ساخت افزایشی فلزی از روش‌های مبتنی بر داده یا ترکیبی از این روش‌ها با مدل‌سازی فیزیکی استفاده می‌شود. از میان این روش‌ها هوش مصنوعی و زیرشاخه شناخته شده آن یعنی یادگیری ماشین کارایی بالایی در زمینه مدل‌سازی غیر خطی دارند. در این میان ساخت افزایشی نیز به عنوان یک روش ساخت و تولید مدرن مطرح شده و ترکیب آن با هوش مصنوعی به عضو جدانشدنی زنجیره‌های تأمین و تولید کارخانه‌ها مبدل شده است [4]. یادگیری ماشین، توانایی یادگیری از داده‌های ورودی را بدون برنامه‌ریزی آشکار و صریح برای کامپیوتر فراهم می‌کند. استفاده از این روش نسبت به روش‌های مدل‌سازی سنتی ساده‌تر است و به سرعت می‌توان مدل‌های مختلفی برای داده‌های ورودی توسعه داد [5]. داده‌های حاصل از خروجی فرایندهای ساخت افزایشی چندبعدی، پیچیده و غیر خطی هستند. بر خلاف روش‌های داده‌کاوی و یادگیری ماشین، رگرسیون‌های ساده و سنتی توانایی کشف الگوهای پنهان میان متغیرهای فرایند را ندارند. این مورد در حضور نامعینی پارامتری، نویز اندازه‌گیری و عدم تعادل داده‌های به دست آمده که در ساخت افزایشی رایج است، بیشتر نمایان می‌شود. سرعت توسعه مدل‌های یادگیری ماشین بسیار بالاتر هستند و به راحتی می‌توان از میان مدل‌های توسعه یافته بهترین مدل را انتخاب کرد؛ به خصوص در مورد داده‌هایی که تا کنون مدل ندیده‌اند امکان ارائه پیش‌بینی‌های دقیق‌تری وجود دارد. همچنین ابزارهای موجود در این حوزه از جمله داده‌افزایی، توانایی بالایی در افزایش دقت مدل‌ها و صرفه‌جویی در هزینه و زمان دارند و امکان مدل‌سازی تطبیقی را فراهم می‌کنند. استفاده همزمان از داده‌افزایی و یادگیری ماشین سبب افزایش چشمگیر دقت مدل‌های ارائه داده شده می‌شود، امری که با رگرسیون‌های ساده امکان‌پذیر نیست. امروزه از هوش مصنوعی و یادگیری ماشین در زمینه‌های مختلف مهندسی استفاده می‌شود [6-9]. در ساخت افزایشی نیز از یادگیری ماشین برای پیش‌بینی کیفیت و ابعاد قطعات ساخته شده [10]، تعیین پارامترهای بهینه برای تضمین کیفیت قطعه در فرایند بستر پودر لیزری [11]، پیش‌بینی دمای حوضچه مذاب در فرایند DED [12] و کنترل زمان حقیقی فرایند ساخت فیلامان ذوبی [13] استفاده شده است. به طور کلی کاربردهای یادگیری ماشین در ساخت افزایشی شامل بهینه‌سازی پارامترهای فرایند، پیش‌بینی ویژگی‌ها و کیفیت قطعه، تشخیص خرابی، کنترل حلقه بسته فرایندها، برآورد هزینه تولید قطعات و بهینه‌سازی ساختار می‌باشند [14]. با وجود مزایای فراوان ذکر شده برای یادگیری ماشین روش‌های

مذکور با چند محدودیت مواجه هستند. این روش‌ها برای اجرای مناسب و داشتن دقت بالا در پیش‌بینی مقادیر جدید نیاز به تعداد زیادی داده دارند. به عبارتی ماشین برای یادگیری رفتار فرایند نیاز به داده‌های با کیفیت و بدون نویز با تعداد بالا دارد. همچنین انتخاب مدل مناسب و تنظیم پارامترهای مدل انتخابی نیز امری چالش‌انگیز است. از طرفی ادوات محاسباتی و پردازنده‌های موجود توان محاسباتی و پردازشی محدودی دارند. بنابراین استفاده از مدل‌های پیچیده می‌تواند سبب افزایش بی‌رویه بار محاسباتی شود و مشکلاتی از جمله بیش‌برازش را در این مدل‌ها ایجاد کند [15]. در برخی از کاربردهای یادگیری ماشین مانند پردازش تصویر و پردازش سیگنال‌های صوتی تعداد زیادی داده برای آموزش الگوریتم در دسترس هستند. با این وجود در تعدادی از کاربردهای علم مواد از جمله ساخت افزایشی امکان گرفتن هزاران نمونه داده از فرایند وجود ندارد. انجام این کار مستلزم صرف هزینه و زمان بسیار زیاد است و از لحاظ اقتصادی مقرون به صرفه نیست. همچنین هر چه مدل‌های ارائه داده شده برای مدل‌سازی این فرایندها دقیق‌تر باشد، نیاز به انجام آزمایش‌های پرهزینه برای گرفتن نتایج خروجی مرتفع می‌گردد [16].


به منظور استفاده از روش‌های یادگیری ماشین برای مدل‌سازی این فرایندها باید درجه و پارامترهای مدل را به صورت مناسب انتخاب کرد. از طرفی با استفاده از تکنیک‌های موجود مانند یادگیری انتقالی یا داده‌افزایی می‌توان مشکل کمبود داده‌ها را به صورت نرم‌افزاری مرتفع کرد. برای رفع مشکلات یاد شده در این مقاله از ترکیب داده‌افزایی و یادگیری گروهی به منظور ارائه یک مدل بهبود یافته برای مدل‌سازی فرایندهای ساخت افزایشی فلزی استفاده شده است. به منظور ارزیابی دقیق کارایی چهارچوب پیشنهادی، چندین مدل یادگیری ماشین برای دو نوع فرایند ساخت افزایشی فلزی از جمله ذوب لیزری انتخابی (SLM) و رسوب‌گذاری مستقیم فلز لیزری (LDMD) استفاده شده است. مدل‌های ارائه داده شده قبل و بعد از اعمال داده‌افزایی به وسیله معیارهای آماری ارزیابی شده‌اند. با مقایسه مدل‌های موجود می‌توان بهترین رهیافت را برای مدل‌سازی هر فرایند انتخاب کرد. روش موجود امکان ترکیب با سایر روش‌های مبتنی بر داده را نیز دارد و می‌تواند در جهت افزایش کارایی و بهبود عملکرد این روش‌ها از جمله شبکه عصبی استفاده شود.

مقاله به این شرح ساختار بندی شده است: در بخش دوم،

چهارچوب پیشنهادی

در این مقاله از ترکیب داده‌افزایی به روش CTGAN و یادگیری گروهی برای مدل‌سازی فرایندهای ساخت افزایشی فلزی استفاده شده است. مطابق با شکل (۱) چهارچوب پیشنهادی شامل دو قسمت اصلی است. در قسمت اول داده‌های حاصل از فرایند ساخت افزایشی فلزی جمع‌آوری می‌شود و پس از آماده‌سازی‌های اولیه داده‌افزایی روی آن‌ها اجرا می‌شود. در این قسمت الگوریتم CTGAN که در محیط پایتون پیاده‌سازی شده است، توزیع داده‌های اصلی را یاد می‌گیرد. در گام بعدی این الگوریتم بر اساس توزیع داده‌های اصلی شروع به اجرای فرایند داده‌افزایی می‌کند. پس از اجرای این مرحله داده‌های جدید که تعدادشان از نمونه‌های اولیه بیشتر است برای آموزش مدل پیش‌بینی بهبود یافته مورد استفاده قرار داده می‌شوند. در صورت استفاده از مدل‌هایی با درجه مناسب و یادگیری گروهی می‌توان کارایی مدل را تا حد زیادی بهبود بخشید.

در این مقاله، بر اساس داده‌های ورودی و خروجی، نگاشتی بین پارامترهای ورودی (ویژگی‌ها) و خروجی مطلوب فرایند (Target) به فرم یک مسئله رگرسیون برقرار می‌شود. بنابراین مدل ایجاد شده جزو زیرشاخه یادگیری نظارت شده از روش‌های یادگیری ماشین دسته‌بندی می‌شود. در بخش دوم نیز مدل‌های ارائه داده شده مورد ارزیابی قرار داده شده و با استفاده از معیارهای آماری، کارایی آن‌ها مورد بررسی قرار داده می‌شود. بعد از انتخاب بهترین مدل ممکن می‌توان از آن برای پیش‌بینی دقیق مقادیر خروجی فرایند در مواجهه با داده‌های ورودی جدید استفاده کرد.



شکل ۱ چهارچوب پیشنهادی برای مدل سازی فرایند ساخت افزایشی فلزی با تلفیق داده افزایی و یادگیری ماشین

تشخیص عیوب در حین تولید می توان در مواد و هزینه ها صرفه جویی کرد.

فرمول بندی مسئله

بر اساس مسئله و اهداف تعیین شده برای آن باید الگوریتم های یادگیری ماشین مناسب را انتخاب کرد. با توجه به اینکه مسائل مورد بررسی در این مقاله دارای تعداد داده های محدود در مقیاس یادگیری ماشین هستند، انتخاب مدل مناسب سراسر نیست. مدل های انتخابی باید حداکثر کارایی را با حداقل درجه مدل داشته باشند تا بتوانند در پیش بینی داده های جدید عملکرد مناسبی داشته باشند. در این بخش مدل های یادگیری ماشینی که در این مقاله مورد استفاده قرار داده شده اند به وسیله معادلات ریاضی حاکم بر الگوریتم ها توضیح داده خواهند شد.

ماشین بردار پشتیبان

در یک فضای با ابعاد بزرگ این روش یک ابر صفحه یا گروهی از آن ها را ایجاد می کند. ابر صفحه ساخته شده با بیشترین فاصله از داده های آموزش در هر کلاس، یک جداساز قوی می شود. هر چه حاشیه ایجاد شده بزرگ تر باشد خطای تعمیم الگوریتم به داده های جدید کمتر می شود. روش یاد شده در فضاهای با ابعاد بالا کارایی مناسبی دارد و بنا به نوع توابع ریاضی استفاده شده که از آن ها تحت عنوان هسته یاد می شود، می تواند رفتار متفاوتی

چهارچوب پیشنهادی نسبت به روش های مدل سازی فیزیکی و سنتی توانایی بیشتری در مدل سازی فرایند غیرخطی و پیچیده ساخت افزایشی فلزی دارد. از طرفی مدل به دست آمده از سرعت اجرا و پاسخ دهی بسیار بیشتری نسبت به شبیه سازی های صورت گرفته با روش المان محدود یا دینامیک سیالاتی محاسباتی برخوردار است. روش های مذکور نیازمند توان محاسباتی بالا و صرف زمان زیاد و چندین ساعته برای حل مدل هستند، در صورتی که در محیط های صنعتی رسیدن به یک تخمین دقیق از خروجی فرایند در مدت زمان محدود مورد نیاز است. با تنظیم درست پارامترهای مدل یادگیری ماشین می توان در زمان بسیار کوتاه تری نسبت به روش های فیزیکی و المان محدود به تخمین خروجی دست یافت. در نتیجه رهیافت ارائه شده برای کاربردهای زمان - حقیقی و کنترل این فرایندها در محیط های صنعتی انتخاب بهتری است. روش پیشنهادی با توجه به کارایی بالا در برابر نامعینی های پارامتری و نویز اندازه گیری توانایی تلفیق با فرایند را برای ایجاد یک سامانه هوشمند کنترل ابعادی زمان - واقعی دارد. چهارچوب پیشنهادی می تواند به صورت یک سامانه نرم افزاری انحرافات ابعادی قطعه نهایی را پیش بینی کند. این سامانه توانایی تخمین دقیق وضعیت ابعادی قطعه حین تولید را دارد و در صورت وقوع نقص در قطعه یا وقوع عیب در سنسورها هشدار صادر می کند یا اصلاح خودکار انجام می دهد. در نتیجه عملکرد دستگاه بهبود می یابد و با

کتابخانه Scikit Learn قابل دسترسی است.

مدل سازی مبتنی بر درخت تصمیم

درخت تصمیم روشی شناخته شده و از دسته یادگیری نظارت شده بدون متغیر است که در مسائل رگرسیون و دسته بندی کاربرد دارد. نمونه های ورودی به وسیله ساختاری درخت مانند شامل ریشه و برگ دسته بندی می شوند. نمونه ها با بررسی ویژگی های تعریف شده توسط گره های درخت دسته بندی می شوند. در نهایت نمونه ها به گره برگ می رسند و در آن ارزش کلاس داده ها بر اساس مقدار میانگین نمونه های خروجی که دسته بندی شده اند محاسبه می شود. برای تقسیم داده ها متداول ترین روش استفاده از شاخص Gini، ناخالصی Gini و شاخص بی نظمی (Entropy) برای به دست آوردن اطلاعات است. معادلات ریاضی این روش به فرم معادلات (۴) و (۵) قابل بیان هستند.

$$\text{Entropy: } H(x) = - \sum_{i=1}^n p(x_i) \log_2 p(x_i) \quad (4)$$

$$\text{Gini}(\varepsilon) = 1 - \sum_{i=1}^c p_i^2 \quad (5)$$

که در معادلات بالا از Entropy به عنوان شاخصی برای اندازه گیری شاخص بی نظمی یا عدم قطعیت در مجموعه داده ها یا سیستم استفاده می شود. به عبارتی از این شاخص برای ارزیابی کیفیت مدل و توانایی آن برای تولید پیش بینی های دقیق استفاده می شود. عدم قطعیت یا ناخالصی به عنوان حاصل جمع لگاریتم احتمال با مبنای ۲ برای یک دسته از داده ها یعنی p_i ضربدر احتمال آن ها تعریف می شود. شاخص i بیانگر تعداد دسته های امکان پذیر در میان داده هاست. از شاخص Gini نیز برای ارزیابی میزان ناخالصی یا مخلوط شدگی مجموعه داده ها استفاده می شود. در معادله (۵) عبارت p_i احتمال وقوع یک گروه مشخص از داده ها است و این حاصل جمع برای تمامی گروه های موجود در داده ها پیاده سازی می شود. جنگل تصادفی یکی دیگر از روش های متداول یادگیری ماشین مبتنی بر درخت می باشد که درواقع، تعمیم یافته حالت یادگیری گروهی درخت تصمیم می باشد. این روش از گروهی موازی از تقسیم کننده های درخت تصمیم در ترکیب با زیرنمونه ها استفاده می کند. سپس از رأی گیری تجمعی یا میانگین گیری برای محاسبه نتیجه نهایی

داشته باشد [17]. روش یاد شده توابع رگرسیون تقریب زده شده را با استفاده از معادلات خطی با ابعاد بالا مقداردهی اولیه می کند. این معادلات را می توان به شکل معادله (۱) ارائه کرد:

$$y = w\phi(x) + b \quad (1)$$

که در آن $w, y, x, \phi(x), b$ به ترتیب ضریب اصلی، ویژگی فضای ابعادی، ورودی، خروجی و بایاس هستند. متغیرهای یاد شده را می توان بعد از ساده سازی معادله (۲) که از آن به عنوان معادله ریسک تنظیم شده یاد می شود تقریب زد [18].

$$R = \frac{\|w\|^2}{2} + C \sum_{i=1}^n L_{\varepsilon}(x_i, y_i, f_1) \quad (2)$$

که در آن

$$L_{\varepsilon}(x_i, y_i, f_1) = \begin{cases} |y_i - f(x_i)| - \varepsilon, & |y_i - f(x_i)| \geq \varepsilon \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

در اینجا $\frac{\|w\|^2}{2}$ عبارت تنظیم است و از آن به عنوان معیاری برای سنجش سادگی مدل استفاده می شود. C پارامتر تنظیم گری است که بین سادگی مدل و خطای آموزش مصالحه ایجاد می کند. ε اندازه مسیر و عبارت $L_{\varepsilon}(x_i, y_i, f_1)$ تابع زیان غیر حساس به ε است و خطاهای بزرگتر از ε را جریمه می کند [19].

یادگیری گروهی

یادگیری گروهی رهیافتی است که اغلب از آن برای تلفیق دو یا چند الگوریتم یادگیری ماشین با هم استفاده می شود. با این روش می توان بازدهی و کارایی بیشتری نسبت به همان الگوریتم های یادگیری ماشین به صورت تکی حاصل کرد. یادگیری گروهی ابزاری مناسب برای پیاده سازی بهینه یادگیری ماشین برای مسائل با داده های محدود است. امروزه محققان، اغلب از یادگیری گروهی و یادگیری عمیق برای ایجاد مدل های بهینه با قابلیت تعمیم به داده های جدید استفاده می کنند. مدل های به دست آمده با این روش قوام و عملکرد بهتری دارند. یادگیری گروهی اغلب به سه دسته تقویت کردن، بسته بندی و انباشته کردن تقسیم می شوند. روش های EGB و AdaBoost از نوع روش های تقویت کردن هستند. الگوریتم شناخته شده جنگل تصادفی نیز از نوع روش های بسته بندی است [20]. در این بررسی از الگوریتم AdaBoost و EGB برای بهبود کارایی پیش بینی مقادیر جدید استفاده شده است. جزئیات مربوط به این دو روش در مراجع

روش Ridge زمانی کاربردی است که داده های ورودی هم خطی چندگانه با سایر پیش بین های موجود داشته باشند [17].

داده افزایی به روش CTGAN

در برخی از فرایندهای دنیای واقعی که بیشتر حاصل از فرایندهای فیزیکی و شیمیایی هستند تعداد داده های در دسترس محدود هستند. این امر سبب ایجاد محدودیت در به کارگیری روش های هوش مصنوعی برای این دسته از فرایندها می شود [21]. تعداد داده کم با کیفیت پایین می تواند ضعف بزرگی برای یادگیری ماشین باشد و سبب کاهش دقت و بازدهی شود. یکی از روش های شناخته شده برای بهبود دقت روش های مبتنی بر داده به خصوص در داده های با تعداد نمونه محدود داده افزایی می باشد. استفاده از این روش باعث می شود که از تعداد داده محدود در دسترس داده های بیشتری با همان توزیع تولید شود و در نتیجه مشکل بیش برآزش تا حد زیادی مرتفع گردد [22].

عمده کاربرد داده افزایی برای افزایش تعداد داده در روش های قابل پیاده سازی در هوش مصنوعی از جمله یادگیری ماشین و شبکه عصبی است. علاوه بر افزایش تعداد داده محدود می توان از داده افزایی برای تبدیل تعداد نمونه زیاد به نمونه های حجیم برای استفاده در یادگیری عمیق و مدل های با درجات بالاتر استفاده کرد [23-27]. از روش های متداول داده افزایی می توان به دو روش GAN و VAE اشاره کرد که روش های مذکور برای مسائل رگرسیون و دسته بندی پیاده سازی شده اند. پس از یادگیری توزیع نمونه ها توسط الگوریتم داده افزایی، داده های با تعداد و کیفیت بالا بر اساس توزیع اولیه توسط الگوریتم تولید می شوند.

در این مقاله از روش CTGAN که در [28] توسط Xu و همکاران ارائه داده شده است برای پیاده سازی روش داده افزایی استفاده شده است. روش استفاده شده نسبت به سایر روش های مورد استفاده در این حوزه مانند MedGAN [29]، VeeGAN [30] و TableGAN [31] کارایی بهتری دارد. الگوریتم پیشنهادی از روش های مبتنی بر GAN است و از آن برای مدل سازی و داده افزایی داده هایی که به فرم جدول هستند، استفاده می شود. این روش بر اساس یک مولد شرطی شکل داده می شود و سپس توسط یک روش نمونه برداری آموزش داده می شود. نمای کلی

استفاده می شود. به این ترتیب این روش می تواند کارایی مدل را بهبود دهد و از بیش برآزش الگوریتم جلوگیری کند [17].

رگرسیون خطی و چند جمله ای

در رگرسیون خطی متغیر وابسته پیوسته است و متغیر مستقل می تواند پیوسته یا گسسته باشد. این روش یک رابطه ریاضی بین متغیر وابسته y و یک یا چند متغیر مستقل x به وسیله بهترین برازش با یک خط مستقیم برقرار می کند. این روند را می توان به صورت معادلات زیر بیان کرد:

$$y = a + bx + e \quad (6)$$

$$y = a + b_1x_1 + b_2x_2 + \dots + b_nx_n + e \quad (7)$$

که در معادلات بالا a عرض از مبدأ، b شیب خط و e مقدار خطا است. رگرسیون چند جمله ای در مسائلی استفاده می شود که رابطه بین x و y به شکل معادلات چند جمله ای مبتنی بر x با درجه n می باشد. رابطه مربوط را می توان از معادله رگرسیون خطی با تعریف درجه متغیر مستقل برابر با ۱ به دست آورد. معادلات رگرسیون چند جمله ای به شکل زیر قابل تعریف هستند.

$$y = b_0 + b_1x + b_2x^2 + b_3x^3 + \dots + b_nx^n + e \quad (8)$$

که در معادله (۸)، $y, b_0, b_1, \dots, b_n, x$ به ترتیب متغیرهای وابسته، ضرایب رگرسیون و متغیر مستقل هستند [17].

رگرسیون LASSO و Ridge

این روش ها توانایی بالایی برای جلوگیری از بیش برآزش دارند؛ پیچیدگی مدل را کاهش می دهند و توانایی تعمیم به داده های جدید مدل را بهبود می دهند. روش LASSO از تنظیم گری L_1 در تلفیق با جمع شدگی برای جریمه کردن مقادیر مطلق ضرایب استفاده می کند. بنابراین با این روش می توان تعداد ویژگی های مدل را کاهش داد و زیرمدل پیش بینی با کمترین مقدار خطای پیش بینی را به دست آورد. از طرفی رگرسیون Ridge از تنظیم گری L_2 که به عنوان مربع اندازه ضرایب تعریف می شود استفاده می کند. این کار سبب می شود که ضرایب و وزن های به دست آمده کوچک شوند ولی صفر نشوند. در حالت کلی روش LASSO توانایی بسیار بالایی در به دست آوردن زیرگروهی از پیش بینی ها با حذف ویژگی های غیر ضروری دارد. در طرف دیگر

مربوط را می‌توان به صورت بردارهای پوششی به فرم معادله (۱۱) ارائه داد:

$$m_i^{(k)} = \begin{cases} 1, & \text{if } i = i^* \text{ and } k = k^* \\ 0, & \text{otherwise.} \end{cases} \quad (11)$$

سپس بردار $cond$ را می‌توان به فرم زیر نشان داد:

$$cond = m_1 \oplus \dots \oplus m_{N_d} \quad (12)$$

پس از ارائه بردار شرطی نوبت به بررسی مولد کاهش می‌رسد. مولد شرطی توانایی ساختن هر گروهی از بردارهای وان - هات را به فرم $\hat{d}_1, \dots, \hat{d}_{N_d}$ دارد. به ویژه با شرط $(D_i^* = k^*)$ که برای بردار $cond$ در نظر گرفته شده است هیچ عاملی توانایی جلوگیری از تولید $\hat{d}_i^{(k^*)}$ یا $\hat{d}_i^{(k)}$ برای مقادیر $k \neq K^*$ در مسیر مستقیم را ندارد. این روال به این دلیل طراحی شده است که مولد شرطی را مجبور کند که $\hat{d}_i^* = m_i^*$ را برای جریمه کردن کاهش به وسیله اضافه کردن آنتروپی متقاطع به تمامی نمونه‌های بین m_i^* و d_i^* بسازد. بنابراین در حالی که روند آموزش ادامه می‌یابد مولد یاد می‌گیرد که یک نسخه مشابه و دقیق از m_i^* متناظر را برای d_i^* ایجاد کند.


روش CTGAN در شکل (۲) نمایش داده شده است. قسمت مولد شرطی باید توزیع داده شرطی داده‌های واقعی را یاد بگیرد که به صورت رابطه (۹) قابل بیان است:

$$P_G(row|D_{i^*} = k^*) = P(row|D_{i^*} = k^*) \quad (9)$$

که در آن row ردیفی از توزیع داده‌های نمونه‌برداری شده می‌باشد. در گام بعدی توزیع اصلی داده‌ها را می‌توان به صورت زیر بازتولید کرد:

$$P(row) = \sum_{k \in D_{i^*}} P_G(row|D_{i^*} = k^*) P(D_{i^*} = k) \quad (10)$$

راه حل این مسئله شامل سه مرحله اصلی بردار شرطی، کاهش مولد و بخش آموزش با نمونه‌برداری است. در بخش بردار شرطی، بردار $cond$ به عنوان روالی برای طراحی شرط $(D_i^* = k^*)$ بیان می‌شود. توجه داشته باشید که تمامی ستون‌های گسسته $D_1, \dots, D_{N_d}$ در نهایت تبدیل به بردارهای وان - هات $d_1, \dots, d_{N_d}$ می‌شوند به نحوی که بردار وان - هات $\hat{d}_i$ برای تمامی مقادیر $k = 1, \dots, |D_i|$ برابر است با $d_i = [d_i^{(k)}]$. فرض کنید $m_i = [m_i^{(k)}]$ برای مقادیر $k = 1, \dots, |D_i|$ امین بردار پوششی متناظر با بردار وان‌هات $\hat{d}_i$ باشد. بنابراین شرط



شکل ۲ ساختار کلی روش CTGAN [28]

الگوریتم ۱ فرایند آموزش و نمونه برداری پیاده سازی شده در [28] CTGAN

Input: The distribution of real data

Output: $\hat{t} = P_G(row|D_{i^*})$; The conditional generator

```

while 1 do
  Step 1
  for  $i = 1:1:N_d$  do
    Generate mask vectors  $m_i = [m_i^{(k)}]_{k=1,...,|D_i|}$  with zero elements
  end

  Step 2
  Choose a discrete column  $D_i$  randomly from entire  $N_d$  discrete columns with uniform distribution

  Step 3
  Generate PMF across a range of values of the column picked in Step 2

  Step 4
   $k^*$  picked up uniformly following PMF of Step 3

  Step 5
  Set the  $k^*$ th component of the  $i^*$  mask to 1,  $(m_{i^*}^{(k^*)} \leftarrow 1)$ 

  Step 6
   $cond = m_1 \oplus ... m_{i^*} \oplus m_{N_d}$ 
end

```

کارایی مدل در تعمیم به ورودی های جدید می شود و از مشکل بیش برآزش جلوگیری می کند. بیش برآزش سبب می شود که مدل به خوبی به داده های در دسترس و اندازه گیری شده از فرایند، برآزش شود ولی در مقابله با داده های جدید دقت مدل نامطلوب خواهد بود. با این روش می توان داده های ورودی را به صورت تصادفی به چندین زیرگروه تقسیم کرد و به صورت تکراری مدل را ارزیابی کرد. خطای نهایی از میانگین تمامی خطاهای محاسبه شده به دست می آید. اگر تعداد داده ها کم باشد می توان هر داده را به عنوان یک زیرگروه انتخاب کرد و بنابراین به تعداد داده ها زیرگروه خواهیم داشت. بیان ریاضی این معیار آماری را می توان به صورت زیر نشان داد:

$$CV - RMSE_{(n)} = \frac{1}{n} \sum_{i=1}^n RMSE_i \quad (13)$$

که در آن $RMSE_i$ برای زیرگروه اعتبارسنجی محاسبه می شود [17]. در کنار مفهوم بیش برآزش، مفهوم دیگری تحت عنوان بیش آموزش وجود دارد که به نوعی این دو مفهوم مترادف هم هستند. دو مفهوم یاد شده به معنی ایجاد حافظه ماشینی به جای درک روند می باشند. در صورت استفاده از یادگیری

در گام بعدی آموزش به وسیله نمونه برداری پیاده سازی می گردد. خروجی تولید شده به وسیله مولد شرطی باید به وسیله قسمت critic که فاصله بین توزیع شرطی یاد گرفته شده $P_g(row|cond)$ و توزیع شرطی روی داده های واقعی یعنی $P(row|cond)$ را تخمین می زند مورد ارزیابی قرار داده شود. داده های آموزش واقعی و تولید بردار $cond$ باید به بخش critic برای تخمین فاصله کمک کنند. با نمونه برداری درست و اصولی از بردار $cond$ و داده های ورودی مدل تولید شده می تواند تمامی مقادیر ممکن را در ستون های گسسته بررسی کند. روند کلی و مراحل پیاده سازی رهیافت پیاده سازی شده در این مقاله در الگوریتم (۱) ارائه داده شده است. قابل ذکر است الگوریتم CTGAN نیازی به نرمال سازی داده ها به صورت معمول و دستی ندارد. الگوریتم یاد شده به وسیله نرمال سازی ویژگی های پیوسته، تبدیل داده ها به فضای توزیع نرمال شده و one-hot encoding این کار را به صورت خودکار انجام می دهد.

معیارهای آماری ارزیابی

یکی از روش های متداول در یادگیری ماشین برای ارزیابی دقت مدل روش اعتبارسنجی متقابل است. این روش اغلب سبب بهبود

چهارچوب پیشنهادی از خروجی‌های متفاوت برای هر مورد مطالعاتی استفاده شده است.

مورد مطالعاتی اول: مدل‌سازی فرایند ذوب لیزری

انتخابی

در این مورد مطالعاتی قطعات با استفاده از یک دستگاه SLM^{HL} 280 (SLM solutions GmbH) ساخته شده‌اند. پودر افشانش گازی شده AlSi10Mg با ابعاد ذره‌ای در بازه ۵۰ - ۲۰ میکرومتر به صورت انحصاری تهیه شده است. ترکیب‌بندی شیمیایی پودر استفاده شده به صورت جدول (۱) ارائه داده شده است. قبل از ساخت نمونه‌ها پودر ذکر شده در یک اجاق با دمای ۱۰۰ درجه سانتی‌گراد خشک شده است.

در این مورد مطالعاتی از ترکیب‌های متفاوت پارامترها برای بررسی فرایند SLM استفاده شده است. ضخامت لایه‌ها در طی انجام آزمایش‌ها به صورت ثابت و برابر با ۳۰ میکرومتر در نظر گرفته شده است. پارامترهای فرایند از جمله توان لیزر، سرعت اسکن و نرخ همپوشانی به صورت متغیر برای روش فاکتوریل کامل در نظر گرفته شده‌اند. در گام نخست آزمایش‌هایی برای بررسی عرض تک‌مسیرهای ذوب شده انجام داده شده است. برای هر گروه یکتا از پارامترهای فرایند، ۳ بار آزمایش مربوط تکرار شده است. در گام بعدی از آزمایش‌های دو مسیر برای بررسی اثر نرخ همپوشانی استفاده شده است. بعد از انجام آزمایش‌های تک مسیر و دو مسیر نتایج مربوط به اسکن‌های چند مسیر برای بررسی تخلخل، سختی و استحکام کششی قطعات ساخته شده انجام داده شده‌اند. برای هر ترکیب یکتا از پارامترهای انتخاب شده سه مکعب حجیم با ابعاد ۸×۶×۱۰ میلی‌متر و یک مکعب مستطیل با ابعاد ۱۰×۵×۱۴ میلی‌متر ساخته شده‌اند.

در کل ۸۱ نمونه برای بررسی خروجی‌های مورد نظر تولید شده‌اند. قطعات تولید شده با استفاده از روش ماشین‌کاری تخلیه الکتریکی از بستر ساخت جدا شده‌اند. برای اندازه‌گیری مشخصات قطعه در ابتدا هر نمونه ساخته شده به سه قسمت برش داده شده و مشخصات قطعه اندازه‌گیری شده‌اند. اندازه‌گیری‌های انجام داده شده برای سنجش چگالی، استحکام کششی و سختی برای هر قطعه سه بار انجام داده شده و نتایج میانگین گزارش شده‌اند. نتایج حاصل از اندازه‌گیری‌های انجام داده شده برای هر گروه از پارامترها مطابق با جدول (۲) ارائه داده شده‌اند [33].

گروهی، خطاهای خاص هر مدل توسط مدل‌های دیگر خنثی می‌شود و مدل‌های بیش‌برازش شده وزن کمتری در خروجی نهایی خواهند داشت. استفاده از روش اعتبارسنجی متقابل در ترکیب با یادگیری گروهی و داده‌افزایی به دلیل تغییر داده‌های تست به صورت متناوب و افزایش تنوع داده‌ها، سبب کاهش مشکل بیش‌برازش و بیش‌آموزش می‌شود. همچنین تا حد امکان باید با استفاده از امکانات موجود در محیط برنامه‌نویسی روش‌هایی مانند توقف زودهنگام را پیاده‌سازی کرد تا از بیش‌آموزش جلوگیری شود [32]. در مدل‌های مورد استفاده در این مقاله، روش توقف زودهنگام و معادل‌های آن برای هر مدل پیاده می‌شود تا مشکلات یاد شده رفع شوند.

نتایج شبیه‌سازی

ابتدا الگوریتم‌های یادگیری ماشین ذکر شده در قسمت فرمول‌بندی ریاضی مسئله به همراه یادگیری گروهی در محیط پایتون پیاده‌سازی شده‌اند. شبیه‌سازی و پیاده‌سازی این الگوریتم‌ها با استفاده از کتابخانه Scikit Learn انجام داده شده است. این کتابخانه شامل مدل‌های یادگیری ماشین از جمله مدل‌های رگرسیون است که به سادگی می‌توان آن‌ها را به کار گرفت. در تمامی مدل‌های به کارگرفته شده میانگین مربع خطا به عنوان تابع هزینه و کاهش خطا در نظر گرفته شده است. از آنجایی که تعداد محدودی نمونه از فرایند در دسترس است از روش Cross Validation برای ارزیابی مدل‌ها استفاده شده است. در این بررسی علاوه بر یادگیری گروهی اثر داده‌افزایی پیاده‌سازی شده با روش CTGAN نیز مطالعه شده است. این الگوریتم برای ۵۰۰۰ تکرار روی داده‌های اصلی اجرا می‌شود و الگوریتم بعد از پایان اجرا توزیع داده‌های اصلی را یاد می‌گیرد. بعد از فرایند آموزش الگوریتم داده‌افزایی تولید داده‌های افزوده شده به منظور بهبود مدل انجام داده شده است. قابل ذکر است که حد خاصی برای تولید داده‌های افزوده وجود دارد. مجموعه داده‌های تولید شده در این بررسی شامل ۲۰ درصد داده واقعی و ۸۰ درصد داده افزوده شده هستند. تولید داده‌های بیشتر به صورت مستقیم توزیع داده‌ها را تحت تأثیر قرار می‌دهد و ممکن است سبب کاهش کارایی مدل شود. در ادامه مدل‌های یادگیری ماشین بررسی می‌شود و روش CTGAN روی دو فرایند شناخته شده ذوب لیزری انتخابی و رسوب‌گذاری مستقیم فلز لیزری پیاده‌سازی می‌شود و نتایج آن‌ها بررسی می‌گردد. به منظور ارزیابی بهتر

جدول ۱ ترکیب بندی شیمیایی پودر AlSi10Mg در ساخت قطعات [33]


Elements	Al	Si	Mg	Fe	Cu	Mn	Zn	Ti	Ni	Pb	Sn
W.t%	Balance	9.5	0.38	0.18	<0.01	<0.01	<0.01	<0.01	<0.01	<0.01	<0.01

جدول ۲ مقادیر پارامترهای ورودی و نتایج اندازه گیری های انجام شده در ۲۷ آزمایش مربوط به مورد مطالعاتی اول [33]

No	Process Parameters				Measured Parameters		
	Laser Power [W]	Scan Speed [mm/s]	Hatch Distance [um]	Overlap Rate	Density [g/cm ³]	Tensile Strength [MPa]	Hardness [HV]
1	320	600	102.4	0.25	2.6102	455.00	119.0
2	320	600	95.5	0.3	2.6266	450.00	123.2
3	320	600	88.7	0.35	2.6270	443.33	130.8
4	320	750	93.1	0.25	2.6196	448.33	124.4
5	320	750	86.9	0.3	2.6094	443.33	123.2
6	320	750	80.7	0.35	2.6204	445.00	127.8
7	320	900	81.8	0.25	2.6310	443.33	127.6
8	320	900	76.3	0.3	2.6221	446.67	127.8
9	320	900	70.9	0.35	2.6298	450.00	122.6
10	360	600	111.0	0.25	2.5965	431.67	127.2
11	360	600	103.6	0.3	2.6237	436.67	135.2
12	360	600	96.2	0.35	2.6063	441.67	116.4
13	360	750	98.0	0.25	2.6083	430.00	129.8
14	360	750	91.4	0.3	2.6308	441.67	123.2
15	360	750	84.9	0.35	2.6087	445.00	128.8
16	360	900	88.9	0.25	2.6092	420.00	119.0
17	360	900	83.0	0.3	2.6260	431.67	127.2
18	360	900	77.1	0.35	2.6252	446.67	122
19	400	600	116.4	0.25	2.5618	420.00	118.6
20	400	600	108.6	0.3	2.6241	445.00	131.0
21	400	600	100.9	0.35	2.6296	438.33	139.2
22	400	750	104.7	0.25	2.6056	430.00	124.8
23	400	750	97.7	0.3	2.6164	431.67	127.4
24	400	750	90.7	0.35	2.5981	446.67	120.8
25	400	900	94.1	0.25	2.6250	416.67	125.4
26	400	900	87.8	0.3	2.5864	443.33	113.2
27	400	900	81.5	0.35	2.6152	438.33	118.4

داده سبب می شود که کارایی هر الگوریتم برای پیش بینی هر خروجی بررسی شود و بهترین مدل ممکن برای فرایند انتخاب شود. به عبارتی مدل سازی با استفاده از یادگیری ماشین ساده است و باید به سرعت مدل های یادگیری ماشین را توسعه داد و

بعد از وارد کردن مقادیر اندازه گیری شده به عنوان ورودی به مدل، الگوریتم های یادگیری ماشین مختلف برای مدل سازی این فرایند و ایجاد نگاشت بهینه بین ورودی و خروجی روی داده ها پیاده سازی شده اند. پیاده سازی الگوریتم های مختلف روی




شکل ۳ نمودار مقادیر R^2 و CV-RMSE برای سه خروجی چگالی، استحکام کششی و سختی در فرایند ذوب لیزری انتخابی


از مقایسه نمودارهای ارائه شده در شکل‌ها می‌توان به این نتیجه رسید که اجرای فرایند داده‌افزایی به طور میانگین برای خروجی‌های چگالی، استحکام کششی و سختی به ترتیب سبب کاهش ۵۸، ۴۲ و ۵۹ درصدی مقدار CV-RMSE شده است. مقادیر بهبود الگوریتم‌ها بسته به نوع الگوریتم و ساختار مدل با هم تفاوت دارند. با این وجود بهبود کلی در تمامی مدل‌های ارائه داده شده قابل مشاهده است. در تخمین مقدار چگالی دو مدل EGB و AdaBoost بهترین عملکرد را دارند در حالی که برای تخمین مقدار سختی و استحکام کششی مدل‌های Poly و Ensemble کارایی بیشتری بعد از اجرای داده‌افزایی از خود نشان داده‌اند. برای هر خروجی می‌توان از بهترین مدل ممکن برای پیش‌بینی استفاده کرد. همچنین قابل ذکر است که زمان اجرای این الگوریتم‌ها در محیط Google Colab به ترتیب برابر با ۲ دقیقه و ۱۰ ثانیه و ۴ دقیقه و ۱۴ ثانیه بوده است. طولانی‌تر شدن زمان شبیه‌سازی در حالتی که داده‌افزایی اجرا می‌شود به دلیل آموزش الگوریتم CTGAN برای ۵۰۰۰ تکرار است. از لحاظ بار محاسباتی اجرای این الگوریتم‌ها در بستر اینترنت است و از لحاظ زمان اجرا نسبت به سایر روش‌های مدل‌سازی مانند المان محدود کارایی بسیار بیشتری دارد. بنابراین از این الگوریتم‌ها می‌توان به صورت آنلاین و در محیط‌های صنعتی برای تخمین سریع خروجی فرایند و تنظیم آن استفاده کرد.

از بین آن‌ها بهترین را انتخاب کرد. در مورد مطالعاتی اول از ۶ مدل رگرسیون EGB، RF، RBF، Poly، Ensemble و AdaBoost استفاده شده است. مدل استفاده شده برای یادگیری گروهی (Ensemble) شامل مدل‌های DT، EGB و RBF می‌باشد. کارایی هر یک از این مدل‌ها برای پیش‌بینی مقادیر چگالی، استحکام کششی و سختی با استفاده از معیارهای R^2 و CV-RMSE بررسی شده و نتایج آن‌ها در شکل (۳) ارائه داده شده است. بر اساس شبیه‌سازی‌های انجام شده می‌توان گفت که دو مدل EGB و Ensemble نسبت به سایر مدل‌ها دقت و کارایی بیشتری برای مدل‌سازی فرایند دارند و از قابلیت اطمینان بالایی برخوردارند. در واقع کمترین مقدار خطا همراه با بیشترین دقت در پیش‌بینی خروجی‌ها توسط این دو مدل حاصل شده است. با این وجود در صورت پیاده‌سازی روش CTGAN می‌توان خطای پیش‌بینی را کاهش داد و دقت مدل را بهبود بخشید.


در گام بعدی از روش CTGAN برای اجرای داده‌افزایی و افزایش تعداد نمونه‌های در دسترس برای آموزش مدل‌ها استفاده شده است. هدف از این کار کاهش خطای پیش‌بینی الگوریتم در مواجهه با داده‌های ورودی جدید است. به عبارتی، در این روش با یک راه حل نرم‌افزاری و بدون اجرای آزمایش‌های بیشتر می‌توان تعداد بیشتری نمونه برای آموزش مدل فراهم کرد. به این صورت می‌توان دقت مدل‌ها را افزایش داد و با تنظیم پارامترها با سعی و خطا به دقت بهینه برای هر مدل دست پیدا کرد. در این قسمت مقادیر CV-RMSE برای مدل‌های پیاده‌سازی شده روی فرایند قبل و بعد از اجرای فرایند داده‌افزایی محاسبه شده و مطابق با شکل (۴) ارائه داده شده‌اند. برای هر سه پارامتر خروجی چگالی، استحکام کششی و سختی این فرایند تکرار شده و برای مقایسه گزارش شده‌اند.




شکل ۴ چگالی



(الف) چگالی



(ب) استحکام کششی




(ج) سختی


شکل ۵ مقایسه مقادیر اندازه‌گیری شده و پیش‌بینی شده توسط بهترین مدل یادگیری ماشین برای سه خروجی چگالی، استحکام کششی و سختی در فرایند ذوب لیزری انتخابی

مورد مطالعاتی دوم: مدل‌سازی فرایند رسوب‌گذاری مستقیم فلز لیزری


در مورد مطالعاتی دوم از یک لیزر برای لایه نشانی خطی آلیاژ Al 2024 استفاده شده است. از لیزر Yb:YAG فیبری با توان ۴ کیلو وات در حالت تابش پیوسته استفاده شده است. سیستم موقعیت‌دهی نازل با استفاده از یک ربات شش‌محوره صنعتی پیاده‌سازی شده است که امکان کنترل دقیق موقعیت را فراهم می‌کند. برای تزریق پودر به سر نازل از یک سیستم نازل سه‌راهی



(الف) چگالی



(ب) استحکام کششی



(ج) سختی

شکل ۴ مقایسه مقادیر CV-RMSE برای سه خروجی چگالی، استحکام کششی و سختی قبل و بعد از اجرای داده‌افزایی در فرایند ذوب لیزری انتخابی

برای ارزیابی بهتر عملکرد چهارچوب پیشنهادی در پیش‌بینی مقادیر خروجی آزمایش‌ها، برای هر آزمایش انجام داده شده مقادیر خروجی و مقادیر پیش‌بینی شده الگوریتم رسم شده‌اند. شکل (۵) نشان دهنده مقایسه مقادیر خروجی حاصل از آزمایش‌ها برای سه خروجی چگالی، استحکام کششی و سختی و مقادیر خروجی پیش‌بینی شده حاصل از چهارچوب پیشنهادی است. برای رسم هر خروجی از بهترین مدل ممکن با کمترین میزان خطا استفاده شده است. مقادیر حاصل از خروجی آزمایش‌ها با O و مقادیر حاصل از مدل‌های یادگیری ماشین با * رسم شده‌اند. همان گونه که در شکل‌ها قابل مشاهده است مدل‌های یادگیری ماشین توانسته‌اند با دقت بسیار بالایی خروجی‌های آزمایش‌ها را پیش‌بینی کنند.

معیارهای R^2 و CV-RMSE برای مقایسه عملکرد این الگوریتم‌ها مورد استفاده قرار داده شده و مقادیر محاسبه شده برای این دو معیار در شکل (۶) نشان داده شده‌اند. در پیش‌بینی مقادیر عرض و عمق و ارتفاع مسیرهای لایه‌نشانی شده مدل EGB دارای بهترین عملکرد در بین سایر مدل‌هاست.

پس از بررسی کارایی مدل‌ها بر داده‌های واقعی، اثر داده‌افزایی نیز مورد بررسی قرار داده می‌شود. برای خروجی‌های عرض، ارتفاع و عمق مسیرهای لایه‌نشانی شده داده‌افزایی با روش CTGAN پیاده‌سازی شده است. سپس از معیار آماری CV-RMSE برای مقایسه عملکرد الگوریتم‌ها با حالت بدون داده‌افزایی استفاده شده است. با مقایسه نمودارهای ارائه داده شده برای مدل‌های پیاده‌سازی شده در شکل (۷) می‌توان به این نتیجه رسید که داده‌افزایی سبب کاهش خطای پیش‌بینی در تمامی مدل‌های موجود شده است. به طور میانگین داده‌افزایی برای خروجی‌های عرض، عمق و ارتفاع مسیرهای لایه‌نشانی شده به ترتیب سبب کاهش ۴۴، ۵۱ و ۴۹ درصدی خطا در مدل‌های پیشنهادی شده است. مدت زمان اجرای مدل‌های ذکر شده در مورد مطالعاتی دوم بدون داده‌افزایی و با لحاظ اثر داده‌افزایی به ترتیب ۱ دقیقه و ۲۶ ثانیه و ۳ دقیقه و ۳۱ ثانیه هستند.


مشابه با مورد مطالعاتی اول، در این مورد مطالعاتی نیز از مقایسه مقادیر خروجی آزمایش‌ها و خروجی مدل‌های یادگیری ماشین برای ارزیابی عملکرد استفاده شده است. در شکل (۸) برای سه پارامتر عرض، عمق و ارتفاع مقادیر خروجی آزمایش با O و مقادیر پیش‌بینی شده توسط الگوریتم با * رسم شده‌اند. همان گونه که قابل مشاهده است عملکرد مدل‌ها قابل قبول است و با دقت بالایی مقادیر آزمایش‌ها پیش‌بینی شده و بر هم منطبق شده‌اند که نشان از کارایی چهارچوب پیشنهادی دارد.

که پودر را از یک حمل کننده نوسانی دریافت می‌کند استفاده شده است. گاز آرگون به عنوان حمل کننده پودر و محافظت کننده حوضچه مذاب از عوامل محیطی به کار گرفته می‌شود. به منظور محافظت از سیستم ایتیکی و جلوگیری از ورود مقابل مواد زائد برگشتی، نازل با یک زاویه ۴ درجه‌ای شروع به فرایند ساخت خواهد کرد. ذره‌های پودر مطابق با ادعای سازنده دارای ابعاد ۲۰ تا ۶۰ میکرومتری است و قبل از استفاده در دمای ۱۸۰ درجه سانتی گراد به مدت ۲ ساعت خشک شده‌اند. بستر استفاده شده برای لایه نشانی مسیرها از جنس AI 2024 با ضخامت ۵ میلی‌متر است. مسیرهای ساخته شده دارای طول ۱۰۰ میلی‌متری است و برای هر گروه یکتا از پارامترها شامل توان لیزر، سرعت حرکت نازل و نرخ تزریق پودر سه مسیر لایه‌نشانی شده است. هدف از تکرار مسیرها جلوگیری و کاهش خطاهای سیستماتیک در اندازه‌گیری مشخصات و پارامترهای مسیرهای ساخته شده است. برای اندازه‌گیری عرض، عمق و ارتفاع مسیرهای لایه‌نشانی شده ابتدا قطعات به صورت مقطعی برش داده شده و سپس قطعات پولیش شده‌اند تا برای اندازه‌گیری آماده شوند. از مقادیر میانگین برای آموزش مدل استفاده می‌شود. تعداد ۳۰ آزمایش انجام داده شده و پارامترهای مربوط به هر آزمایش در جدول (۳) گزارش داده شده‌اند [34]. قابل ذکر است پیش‌بینی و کنترل ابعادی جزو مهم‌ترین چالش‌ها در تولید دقیق و تکرارپذیری قطعات فلزی در کاربردهای صنعتی هستند. در طی سالیان اخیر مطالعات فراوانی در این مورد برای انواع مختلف فرایندهای ساخت افزایشی انجام داده شده است [35-37]. همچنین کنترل ابعادی در صنایع حساس و ساخت سفارشی مانند ایمپلنت‌های پزشکی اهمیت بسیار بالایی دارد زیرا به طور مستقیم روی راحتی بیمار و کارایی ایمپلنت اثرگذار است [38].

مشابه با مورد اول در این مورد مطالعاتی نیز مدل‌های یادگیری ماشین مختلف برای مدل‌سازی این فرایند به کار گرفته شده‌اند. در این قسمت از مدل‌های EGB, RF, RBF, Poly, Ensemble و Ridge برای ایجاد نگاشت بین ورودی‌ها و عرض، عمق و ارتفاع مسیرهای لایه‌نشانی شده استفاده شده است. در این مورد مطالعاتی از مدل Ensemble استفاده شده است که شامل الگوریتم‌های EGB, Poly, LASSO, Ridge, RF و DT می‌باشد.


جدول ۳ مقادیر پارامترهای ورودی و نتایج اندازه گیری های انجام داده شده در ۳۰ آزمایش مربوط به مورد مطالعاتی دوم [34]

No.	Process Conditions			Measured Geometrical Parameters		
	P(W)	v(mm/min)	$\dot{m}$ (g/min)	Width(mm)	Depth(mm)	Height(mm)
1	1200	400	4	3.09	0.25	0.98
2	1500	400	4	3.71	0.46	1.08
3	1500	400	6	3.61	0.37	1.46
4	1500	400	8	3.49	0.11	1.98
5	1500	400	10	4.3	0.21	2.14
6	2000	200	3	5.24	0.70	0.85
7	2000	200	10	5.28	0.74	2.11
8	2000	300	3	5.32	1.81	1.38
9	2000	400	8	4.07	0.59	1.75
10	2000	500	8	3.94	0.65	1.49
11	2000	500	3	4.31	1.22	1.11
12	2500	100	5	10.7	2.83	0.82
13	2500	150	5	8.5	1.51	1.04
14	2500	150	7	8.9	1.52	2.06
15	2500	200	5	8.05	1.5	1.05
16	2500	200	7	8.66	1.62	1.89
17	2500	250	5	8.32	1.69	0.78
18	2500	400	3	5.3	2.13	1.1
19	3000	150	5	8.6	2.42	1.16
20	3000	150	7	9.4	2.6	1.53
21	3000	200	5	8.05	2.43	0.99
22	3000	200	7	8.8	2.41	1.34
23	3000	200	4	8.08	2.39	0.79
24	3000	200	6	9.22	1.83	1.2
25	3000	200	3	7.5	2.27	0.67
26	3000	200	10	9.3	2.33	1.86
27	3000	300	3	7.04	3.23	1.07
28	3000	500	3	5.38	2.25	0.96
29	3000	600	3	4.67	0.92	0.29
30	3000	600	10	5.5	1.04	1.28




(ج) ارتفاع


شکل ۷ مقایسه مقادیر CV-RMSE برای سه خروجی عرض، عمق و ارتفاع مسیرهای لایه‌نشانی شده قبل و بعد از اجرای داده‌افزایی در فرایند رسوب‌گذاری مستقیم فلز لیزری



(الف) عرض




(ب) عمق




(ج) ارتفاع


شکل ۸ مقایسه مقادیر اندازه‌گیری شده و پیش‌بینی شده توسط بهترین مدل یادگیری ماشین برای سه خروجی عرض، عمق و ارتفاع مسیرهای لایه‌نشانی شده در فرایند رسوب‌گذاری مستقیم فلز لیزری



(الف) عرض مسیر




(ب) عمق مسیر




(ج) ارتفاع مسیر

شکل ۹ نمودار مقادیر R^2 و CV-RMSE برای سه خروجی عرض، عمق و ارتفاع مسیرهای لایه‌نشانی شده در فرایند رسوب‌گذاری مستقیم فلز لیزری



(الف) عرض



(ب) عمق

نتیجه‌گیری

در این مقاله چندین رهیافت یادگیری ماشین از جمله EGB, DT, RBF, Adaboost, یادگیری گروهی، رگرسیون چندجمله‌ای و RF برای مدل‌سازی دو فرایند ساخت افزایشی فلزی پیاده‌سازی شده‌اند. از دو فرایند متفاوت با پارامترها و داده‌های مستقل برای ارزیابی روش پیشنهادی استفاده شده است. این دو فرایند شامل روش‌های SLM و DLMD هستند و هر کدام به ترتیب شامل ۲۷ و ۳۰ نمونه هستند. تعداد نمونه‌های یاد شده برای این دو فرایند در مقیاس یادگیری ماشین محدود هستند. برای رفع این مشکل و جلوگیری از بیش‌برازش از ترکیب روش‌های یادگیری گروهی و داده‌افزایی استفاده شده است. درجه مدل‌های استفاده شده در حد امکان، پایین انتخاب شده‌اند. داده‌افزایی با روش شناخته شده CTGAN انجام داده شده است. داده‌های حاصل از فرایند داده‌افزایی برای آموزش روش‌های یادگیری ماشین استفاده شده و نتایج با داده‌های اصلی مقایسه شده‌اند. تمامی شبیه‌سازی‌ها و ارزیابی مدل‌ها در کتابخانه Scikit Learn پایتون و در محیط Google Colab اجرا شده‌اند. برای هر مدل از معیارهای آماری R^2 و CV-RMSE برای ارزیابی عملکرد استفاده شده است. نتایج شبیه‌سازی نشان دهنده بهبود عملکرد مدل‌های مربوط به فرایندهای SLM و DLMD به ترتیب به اندازه ۵۳ و ۴۸ درصدی نسبت به حالت بدون داده‌افزایی می‌باشد. با توجه به مدت زمان کوتاه اجرای مدل‌ها می‌توان از چهارچوب پیشنهادی برای تخمین دقیق مقادیر خروجی به صورت زمان - حقیقی در صنعت استفاده کرد. روش مذکور نسبت به روش المان محدود زمان اجرای بسیار کمتری دارد و از نظر حجم محاسباتی هم کارایی بسیار بیشتری دارد. همچنین می‌توان از این چهارچوب برای بهبود عملکرد روش‌های المان محدود استفاده کرد. ترکیب CTGAN با شبکه عصبی نیز می‌تواند برای بهبود کارایی سایر مدل‌های ارائه شده در علم مواد استفاده شود. مواردی از جمله استفاده از مدل‌های ارائه شده برای کنترل مبتنی بر داده فرایندهای ساخت افزایشی فلزی مانند سامانه هوشمند کنترل ابعادی، تعمیم چهارچوب پیشنهادی به سایر خروجی‌های متالورژیکی، مقایسه روش‌های یادگیری ماشین مورد استفاده با شبکه عصبی و

بهینه‌سازی فرایند مبتنی بر روش‌های الهام گرفته شده از طبیعت مانند الگوریتم بهینه‌سازی ازدحام ذرات برای یافتن نقاط کاری و مصرف انرژی بهینه بر اساس مدل ارائه داده شده موضوعات پیشنهادی برای کارهای آینده هستند.

واژه‌نامه

روش تقویت تطبیقی	Adaptive Boost (AdaBoost)
دینامیک سیالات محاسباتی	Computational Fluid Dynamics (CFD)
شبکه‌های مولد تخصصی جدولی شرطی	Conditional Tabular Generative Adversarial Networks (CTGAN)
اعتبارسنجی متقابل	Cross Validation
درخت تصمیم	Decision Tree
رسوب‌گذاری انرژی هدایت شده	Directed Energy Deposition (DED)
تقویت گرادینان تجمیعی	Ensemble Gradient Boosting (EGB)
یادگیری گروهی	Ensemble Learning
روش المان محدود	Finite Element Method (FEM)
شبکه مولد تخصصی	Generative Adversarial Network (GAN)
هسته	Kernel
رسوب‌گذاری مستقیم فلز لیزری	Laser Direct Metal Deposition (LDMD)
عملگر انقباض مطلق کمینه و انتخاب	Least Absolute Shrinkage and Selection Operator (LASSO)
بیش آموزش	Over Training
تابع پایه شعاعی	Radial Basis Function (RBF)
جنگل تصادفی	Random Forest
ذوب لیزری انتخابی	Selective Laser Melting (SLM)
خود رمزگذار متغیر	Variational Auto Encoder (VAE)

مراجع

- [1] I. Gibson, D. Rosen, B. Stucker, and M. Khorasani, "Introduction and basic principles," in *Additive Manufacturing Technologies*, Cham: Springer International Publishing, pp. 1–21, 2020. https://doi.org/10.1007/978-3-030-56127-7_1
- [2] S. Dharmadhikari, N. Menon, and A. Basak, "A reinforcement learning approach for process parameter optimization in additive manufacturing," *Additive Manufacturing*, vol. 71, p. 103556, 2023. <https://doi.org/10.1016/j.addma.2023.103556>
- [3] J. Qin *et al.*, "Research and application of machine learning for additive manufacturing," *Additive Manufacturing*, vol. 52, p. 102691, 2022. <https://doi.org/10.1016/j.addma.2022.102691>
- [4] S. Kumar *et al.*, "Machine learning techniques in additive manufacturing: a state of the art review on design, processes and production control," *Journal of Intelligent Manufacturing*, vol. 34, no. 1, pp. 21-55, 2023. <https://doi.org/10.1007/s10845-022-02029-5>
- [5] A. M. Schweidtmann *et al.*, "Machine Learning in Chemical Engineering: A Perspective," *Chemie Ingenieur Technik*, vol. 93, no. 12, pp. 2029-2039, 2021. <https://doi.org/10.1002/cite.202100083>
- [6] F. Rahimi, S. Ziaei, and R. M. Esfanjani, "A Reinforcement Learning-Based Control Approach for Tracking Problem of a Class of Nonlinear Systems: Applied to a Single-Link Manipulator," in 2023 31st International Conference on Electrical Engineering (ICEE), 2023, pp. 58-63. <https://doi.org/10.1109/ICEE59167.2023.10334874>
- [7] M. H. Sulaiman, M. S. Jadin, Z. Mustaffa, M. N. M. Azlan, and H. Daniyal, "Short-Term Forecasting of Floating Photovoltaic Power Generation Using Machine Learning Models," *Cleaner Energy Systems*, p. 100137, 2024. <https://doi.org/10.1016/j.cles.2024.100137>
- [8] H. Mahanna, N. El-Rashidy, M. R. Kaloop, S. El-Sapakh, A. Alluqmani, and R. Hassan, "Prediction of wastewater treatment plant performance through machine learning techniques," *Desalination and Water Treatment*, vol. 319, p. 100524, 2024. <https://doi.org/10.1016/j.dwt.2024.100524>
- [9] S. Hamal, B. K. Mishra, R. Baldock, W. Sayers, T. N. Adhikari, and R. M. Gibson, "A comparative analysis of machine learning algorithms for detecting COVID-19 using lung X-ray images," *Decision Analytics Journal*, vol. 11, p. 100460, 2024. <https://doi.org/10.1016/j.dajour.2024.100460>
- [10] D. J. McGregor, M. V. Bimrose, C. Shao, S. Tawfick, and W. P. King, "Using machine learning to predict dimensions and qualify diverse part designs across multiple additive machines and materials," *Additive Manufacturing*, vol. 55, p. 102848, 2022. <https://doi.org/10.1016/j.addma.2022.102848>
- [11] Z. Gu *et al.*, "A universal predictor-based machine learning model for optimal process maps in laser powder bed fusion process," *Journal of Intelligent Manufacturing*, vol. 34, no. 8, pp. 3341-3363, 2023. <https://doi.org/10.1007/s10845-022-02004-0>
- [12] Z. Zhang, Z. Liu, and D. Wu, "Prediction of melt pool temperature in directed energy deposition using machine learning," *Additive Manufacturing*, vol. 37, p. 101692, 2022. <https://doi.org/10.1016/j.addma.2020.101692>

- [13] J. Akhavan, J. Lyu, and S. Manoochehri, "A deep learning solution for real-time quality assessment and control in additive manufacturing using point cloud data," *Journal of Intelligent Manufacturing*, vol. 35, no. 3, pp. 1389-1406, 2024. <https://doi.org/10.1007/s10845-023-02121-4>
- [14] L. Meng *et al.*, "Machine Learning in Additive Manufacturing: A Review," *JOM*, vol. 72, no. 6, pp. 2363-2377, 2020. <https://doi.org/10.1007/s11837-020-04155-y>
- [15] K. Azizi, H. Taheri, and S. Khooyooz, "Using Structured Pruning to Find Winning Lottery Tickets," in 2023 28th International Computer Conference, Computer Society of Iran, 2023, pp. 1-5. <https://doi.org/10.1109/CSICC58665.2023.10105376>
- [16] J. F. Rodrigues, L. Florea, M. C. F. de Oliveira, D. Diamond, and O. N. Oliveira, "Big data and machine learning for materials science," *Discover Materials*, vol. 1, no. 1, p. 12, 2021. <https://doi.org/10.1007/s43939-021-00012-0>
- [17] I. H. Sarker, "Machine Learning: Algorithms, Real-World Applications and Research Directions," *SN Computer Science*, vol. 2, no. 3, p. 160, 2021. <https://doi.org/10.1007/s42979-021-00592-x>
- [18] A. Yafouz *et al.*, "Comprehensive comparison of various machine learning algorithms for short-term ozone concentration prediction," *Alexandria Engineering Journal*, vol. 61, no. 6, pp. 4607-4622, 2022. <https://doi.org/10.1016/j.aej.2021.10.021>
- [19] X. Su, J. An, Y. Zhang, P. Zhu, and B. Zhu, "Prediction of ozone hourly concentrations by support vector machine and kernel extreme learning machine using wavelet transformation and partial least squares methods," *Atmospheric Pollution Research*, vol. 11, no. 6, pp. 51-60, 2020. <https://doi.org/10.1016/j.apr.2020.02.024>
- [20] I. D. Mienye and Y. Sun, "A Survey of Ensemble Learning: Concepts, Algorithms, Applications, and Prospects," *IEEE Access*, vol. 10, pp. 99129-99149, 2022. <https://doi.org/10.1109/ACCESS.2022.3207287>
- [21] P. Kokol, M. Kokol, and S. Zagoranski, "Machine learning on small size samples: A synthetic knowledge synthesis," *Science Progress*, vol. 105, no. 1, 2022. <https://doi.org/10.1177/00368504211029777>
- [22] K. Maharana, S. Mondal, and B. Nemade, "A review: Data pre-processing and data augmentation techniques," *Global Transitions Proceedings*, vol. 3, no. 1, pp. 91-99, 2022. <https://doi.org/10.1016/j.gltp.2022.04.020>
- [23] H. Ohno, "Auto-encoder-based generative models for data augmentation on regression problems," *Soft Computing*, vol. 24, no. 11, pp. 7999-8009, 2020. <https://doi.org/10.1007/s00500-019-04094-0>
- [24] L.-M. Liu, X.-Y. Ren, F. Zhang, L. Gao, and B. Hao, "Dual-dimension Time-GGAN data augmentation method for improving the performance of deep learning models for PV power forecasting," *Energy Reports*, vol. 9, pp. 6419-6433, 2023. <https://doi.org/10.1016/j.egyr.2023.05.226>
- [25] K. Nawa, K. Hagiwara, and K. Nakamura, "Prediction-accuracy improvement of neural network to ferromagnetic multilayers by Gaussian data augmentation and ensemble learning," *Computational Materials Science*, vol. 219, p. 112032, 2023. <https://doi.org/10.1016/j.commatsci.2023.112032>
- [26] E. Pérez and S. Ventura, "Progressive growing of Generative Adversarial Networks for improving data augmentation and skin cancer diagnosis," *Artificial Intelligence in Medicine*, vol. 141, p. 102556, 2023. <https://doi.org/10.1016/j.artmed.2023.102556>

- [27] G. Celik, "CovidCoughNet: A new method based on convolutional neural networks and deep feature extraction using pitch-shifting data augmentation for covid-19 detection from cough, breath, and voice signals," *Computers in Biology and Medicine*, vol. 163, p. 107153, 2023. <https://doi.org/10.1016/j.compbimed.2023.107153>
- [28] L. Xu, M. Skoularidou, A. Cuesta-Infante, and K. Veeramachaneni, "Modeling Tabular data using Conditional GAN," 2019. [Online].
- [29] E. Choi, S. Biswal, B. Malin, J. Duke, W. F. Stewart, and J. Sun, "Generating multi-label discrete patient records using generative adversarial networks," in *Machine learning for healthcare conference*, 2017: PMLR, pp. 286-305.
- [30] A. Srivastava, L. Valkov, C. Russell, M. U. Gutmann, and C. Sutton, "Veegan: Reducing mode collapse in gans using implicit variational learning," *Advances in neural information processing systems*, vol. 30, 2017.
- [31] N. Park, M. Mohammadi, K. Gorde, S. Jajodia, H. Park, and Y. Kim, "Data synthesis based on generative adversarial networks," *arXiv preprint arXiv:1806.03384*, 2018.
- [32] G. a. W. James, Daniela and Hastie, Trevor and Tibshirani, Robert, *An Introduction to Statistical Learning: With Applications in R*, 2nd ed. Springer, 2021.
- [33] T. Peng, J. Lv, A. Majeed, and X. Liang, "An experimental investigation on energy-effective additive manufacturing of aluminum parts via process parameter selection," *Journal of Cleaner Production*, vol. 279, p. 123609, 2021. <https://doi.org/10.1016/j.jclepro.2020.123609>
- [34] F. Caiazzo and A. Caggiano, "Laser Direct Metal Deposition of 2024 Al Alloy: Trace Geometry Prediction via Machine Learning," *Materials*, vol. 11, no. 3, p. 444, 2018. <https://doi.org/10.3390/ma11030444>
- [35] G. Tapia, S. Khairallah, M. Matthews, W. E. King, and A. Elwany, "Gaussian process-based surrogate modeling framework for process planning in laser powder-bed fusion additive manufacturing of 316L stainless steel," *The International Journal of Advanced Manufacturing Technology*, vol. 94, no. 9, pp. 3591-3603, 2018. <https://doi.org/10.1007/s00170-017-1045-z>
- [36] Y. Li, Y. Sun, Q. Han, G. Zhang, and I. Horváth, "Enhanced beads overlapping model for wire and arc additive manufacturing of multi-layer multi-bead metallic parts," *Journal of Materials Processing Technology*, vol. 252, pp. 838-848, 2018. <https://doi.org/10.1016/j.jmatprotec.2017.10.017>
- [37] A. Kalilayeva, D. Zhumashev, D. Wei, A. Perveen, and D. Talamona, "Investigation of Stereolithography Additively Manufactured Components for Deviations in Dimensional and Geometrical Features," *Polymers*, vol. 16, no. 23, 2024. <https://doi.org/10.3390/polym16233311>
- [38] A. Karadag and O. Ulkir, "Prediction of Dimensional Accuracy and Surface Quality in Additively Manufactured Biomedical Implants Using ANN," *International Journal of Precision Engineering and Manufacturing*, vol. 26, no. 5, pp. 1187-1213, 2025. <https://doi.org/10.1007/s12541-025-01229-2>

