

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”**APLICAÇÕES DE MACHINE LEARNING NA MANUFATURA ADITIVA: UMA REVISÃO**

Ariane Aquino de Araujo (IC), Matheus Brendon Francisco (PG)

¹Universidade Federal de Itajubá**Palavras-chave:** Indústria 4.0. Inteligência Artificial. Machine learning. Manufatura aditiva.**Introdução**

A manufatura aditiva, também conhecida como impressão 3D, tem ganhado destaque nos últimos anos devido à sua capacidade de criar peças complexas com grande precisão, flexibilidade de design e a redução de desperdícios. Inicialmente associada a protótipos rápidos, essa tecnologia tem evoluído rapidamente e encontrado aplicações em setores como automotivo, aeroespacial, médico, e até mesmo na produção de alimentos e construção civil. A utilização de materiais avançados e o controle refinado das variáveis de fabricação tornam a manufatura aditiva uma solução promissora para a personalização em massa e a produção de peças sob demanda (Francisco et al., 2023).

Nesse contexto, a união de ferramentas da Indústria 4.0, especificamente a Inteligência Artificial (IA) e o *Machine Learning* (ML), surge como uma resposta direta a essa demanda. Os algoritmos de ML são capazes de processar os grandes volumes de dados gerados durante a fabricação para identificar padrões e otimizar resultados de forma preditiva (SOUZA et al., 2024). A aplicação de técnicas de ML na manufatura aditiva oferece oportunidades significativas para aprimorar o controle e a predição de resultados, como a qualidade da superfície das peças, a resistência mecânica e a otimização do uso de material. Sendo assim é possível prever falhas no processo, otimizar parâmetros de impressão como temperatura e velocidade de deposição, e até mesmo identificar e corrigir defeitos em tempo real, muitos dos quais seriam invisíveis a uma inspeção humana (DAVTALAB et al., 2023). Este trabalho tem como objetivo principal revisar e discutir as principais aplicações de ML na manufatura aditiva, explorando como essa união está moldando o futuro da produção de peças complexas e personalizadas.

Metodologia

Este estudo foi conduzido como uma revisão da literatura, com o objetivo de mapear as áreas de aplicação do *Machine Learning* na manufatura aditiva.

A estratégia de busca utilizou os termos "*Machine Learning*" e "*additive manufacturing*" nas bases de dados *Scopus* e *Google Scholar*, gerando inicialmente 1167 documentos. Após restringir a busca para incluir apenas artigos científicos reduziu este número para 735 publicações. A seleção final dos trabalhos seguiu um rigoroso critério qualitativo, priorizando publicações de alto impacto com resultados inovadores e contribuições significativas. A análise considerou a relevância dos temas, a aplicabilidade dos métodos e a representatividade das soluções para os desafios práticos da manufatura aditiva, com o objetivo de identificar padrões, lacunas e oportunidades para futuras pesquisas.

Resultados e discussão

A análise dos trabalhos publicados entre 2018 e 2024 nos revela um campo de pesquisa dinâmico e com rápido crescimento. O uso de ML na manufatura aditiva concentra-se em resolver desafios práticos que limitam a confiabilidade e a escalabilidade da tecnologia.

Um dos principais focos da pesquisa é a mitigação da variação geométrica. As flutuações de temperatura inerentes ao processo FDM com frequência causam desvios dimensionais em relação ao modelo CAD original. Trabalhos como os de Zhu et al. (2018) e Khanzadeh et al. (2018) foram pioneiros ao utilizar ML para prever e quantificar essas variações, permitindo a compensação dos desvios ainda na fase de projeto.

A detecção de defeitos em tempo real é outra área que traz grande impacto. Gobert et al. (2018) aplicaram com sucesso Máquinas de Vetores de Suporte (SVM) para identificar anomalias, enquanto Scime e Beuth (2018) utilizaram visão computacional combinada com algoritmos de clusterização para o mesmo fim. O uso de

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

Redes Neurais Convolucionais (CNNs) tornou a abordagem padrão para a análise de imagens, com diversos estudos demonstrando sua eficácia na identificação de defeitos superficiais e estruturais em tempo real (KHAN et al., 2021; WESTPHAL; SEITZ, 2021). Além da visão computacional, dados de sensores de temperatura, vibração e emissão acústica também são utilizados para treinar algoritmos preditivos capazes de prever a rugosidade superficial e diagnosticar falhas mecânicas durante a impressão (LI et al., 2019; WU et al., 2019).

Na Tabela 1 pode-se ver o resumo de alguns dos estudos mais relevantes encontrados na literatura, destacando os diferentes algoritmos de ML aplicados para resolver problemas específicos na manufatura aditiva. Tabela 1 – Estudos sobre a aplicação de *Machine Learning* na Manufatura Aditiva (2018-2024)

Tabela 1. Estudos publicados entre 2018 e 2024 que versam sobre *machine learning* e manufatura aditiva

Autor	Projeto	Algoritmo Utilizado
Shevchik et al. (2018)	Monitoramento de qualidade in situ com emissão acústica.	Convolutional Neural Network
Scime e Beuth (2018)	Deteção autônoma de anomalias em fusão a leito de pó a laser.	Convolutional Neural Network
Delli e Chang (2018)	Monitoramento automatizado de processos em impressão 3D.	Support Vector Machine
Caggiano et al. (2019)	Reconhecimento de defeitos online com processamento de imagem.	Convolutional Neural Network
Kadam et al. (2021)	Deteção de falhas superficiais em produtos impressos em 3D.	K-NN, SVM, Naive Bayes, Decision Tree, Random Forest

Nguyen et al. (2022)	Otimização de processo de impressão 3D com abordagem baseada em dados.	Multilayer Perceptron e CNN
Charalampous et al. (2022)	Otimização do comportamento mecânico de peças FFF.	KNN, SVR, Random Forest
Sharma et al. (2022)	Previsão da variação dimensional em geometrias FDM.	Decision Tree
Li et al. (2023)	Avaliação da qualidade na MA baseada em extrusão com escaneamento 3D.	Residual Attention Network
Zubayer et al. (2024)	Inspeção e otimização inteligente para compósitos de fibra de carbono.	YOLOv8

A diversidade de algoritmos demonstra a flexibilidade do ML. Enquanto modelos robustos como CNNs são ideais para tarefas complexas de visão computacional, algoritmos mais simples como Bagging e Random Forest também apresentaram excelente desempenho na detecção de anomalias geométricas, oferecendo maior interpretabilidade (LI et al., 2021). A tendência mais recente aponta para o uso de arquiteturas de ponta, como o YOLOv8, para detecção de objetos, o que permite não apenas identificar um defeito, mas também localizá-lo com precisão na peça, um passo fundamental para sistemas de correção automatizada (ZUBAYER et al., 2024).

Conclusões

A integração do aprendizado de máquina (*Machine Learning*, ML) à manufatura aditiva apresenta um impacto significativo no aprimoramento dos processos produtivos, tornando-os mais precisos, eficientes e sustentáveis. Esta revisão sistemática da literatura demonstrou que o ML está sendo aplicado com sucesso em diversas frentes, incluindo a mitigação de variações

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

geométricas, a detecção de defeitos em tempo real através de múltiplos sensores e a otimização de propriedades mecânicas e a qualidade superficial das peças.

Observou-se uma clara evolução das técnicas, partindo de algoritmos clássicos para redes neurais profundas e arquiteturas de ponta, refletindo a complexidade dos problemas abordados. A capacidade de analisar dados de imagem, vibração e emissão acústica em tempo real está transformando a manufatura aditiva de um processo de malha aberta para um sistema de malha fechada, mais inteligente e autônomo. O resultado é uma produção com maior precisão, eficiência e sustentabilidade, alinhada com as demandas da Indústria 4.0. É possível concluir que o ML não é apenas uma ferramenta de aprimoramento, mas um catalisador que está acelerando a evolução da manufatura aditiva como uma tecnologia de produção em larga escala.

Agradecimentos

Os autores agradecem à Universidade Federal de Itajubá (UNIFEI) e ao Programa Institucional de Bolsas de Iniciação Científica (PIBIC). Agradecem também ao laboratório NOMATI-UNIFEI pelo acesso a seus materiais e expertise.

Referências

AKBARI, P.; ZAMANI, M.; MOSTAFAEI, A. Machine learning prediction of mechanical properties in metal additive manufacturing. **Additive Manufacturing**, v. 91, p. 104320, 2024.

BANERJEE, S. et al. A Machine Learning-Based Model for Multiple Material Density Prediction Developed by Powder Bed Fusion Additive Manufacturing. **Journal of Materials Engineering and Performance**, p. 1-5, 2024.

BATURYNSKA, I. Application of machine learning techniques to predict the mechanical properties of polyamide 2200 (PA12) in additive manufacturing. **Applied Sciences**, v. 9, n. 6, p. 1060, 2019.

BAUMGARTL, H. et al. A deep learning-based model for defect detection in laser-powder bed fusion using in-situ thermographic monitoring. **Progress in Additive Manufacturing**, v. 5, n. 3, p. 277-285, 2020.

CAGGIANO, A. et al. Machine learning-based image processing for on-line defect recognition in additive manufacturing. **CIRP annals**, v. 68, n. 1, p. 451-454, 2019.

CHAN, S. L.; LU, Y.; WANG, Y. Data-driven cost estimation for additive manufacturing in cybermanufacturing. **Journal of manufacturing systems**, v. 46, p. 115-126, 2018.

CHARALAMPOUS, P. et al. Machine learning-based mechanical behavior optimization of 3D print constructs manufactured via the FFF process. **Journal of Materials Engineering and Performance**, v. 31, n. 6, p. 4697-4706, 2022.

CHEEPU, M. Machine learning approach for the prediction of defect characteristics in wire arc additive manufacturing. **Transactions of the Indian Institute of Metals**, v. 76, n. 2, p. 447-455, 2023.

DAVTALAB, O. et al. Automated inspection in robotic additive manufacturing using deep learning for layer deformation detection. **Journal of Intelligent Manufacturing**, v. 33, n. 3, p. 771-784, 2022.

DE SOUZA, L. G. P. et al. Roughness prediction using machine learning models in hard turning: an approach to avoid rework and scrap. **The International Journal of Advanced Manufacturing Technology**, p. 1-17, 2024.

DELLI, U.; CHANG, S. Automated process monitoring in 3D printing using supervised machine learning. **Procedia Manufacturing**, v. 26, p. 865-870, 2018.

DUTTA, C. et al. Outlier detection in additive manufacturing using novel machine learning algorithm. **The International Journal of Advanced Manufacturing Technology**, p. 1-11, 2023.

FRANCISCO, M. et al. Multiobjective design optimization of reentrant auxetic model using Lichtenberg algorithm based on metamodel. **Engineering Computations**, v. 40, n. 9/10, p. 3009-3035, 2023.

GARLAND, A. P. et al. Deep convolutional neural networks as a rapid screening tool for complex additively manufactured structures. **Additive Manufacturing**, v. 35, p. 101217, 2020.

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

- GOBERT, C. et al. Application of supervised machine learning for defect detection during metallic powder bed fusion additive manufacturing using high resolution imaging. **Additive Manufacturing**, v. 21, p. 517-528, 2018.
- KADAM, V. et al. Enhancing surface fault detection using machine learning for 3D printed products. **Applied System Innovation**, v. 4, n. 2, p. 34, 2021.
- KAMATH, C.; FAN, Y. J. Regression with small data sets: a case study using code surrogates in additive manufacturing. **Knowledge and Information Systems**, v. 57, p. 475-493, 2018.
- KHAN, M. F. et al. Real-time defect detection in 3D printing using machine learning. **Materials Today: Proceedings**, v. 42, p. 521-528, 2021.
- KHANZADEH, M. et al. Quantifying geometric accuracy with unsupervised machine learning: Using self-organizing map on fused filament fabrication additive manufacturing parts. **Journal of Manufacturing Science and Engineering**, v. 140, n. 3, p. 031011, 2018.
- LI, Z. et al. Prediction of surface roughness in extrusion-based additive manufacturing with machine learning. **Robotics and Computer-Integrated Manufacturing**, v. 57, p. 488-495, 2019.
- LI, R.; JIN, M.; PAQUIT, V. C. Geometrical defect detection for additive manufacturing with machine learning models. **Materials & Design**, v. 206, p. 109726, 2021.
- LI, X. et al. Qualify assessment for extrusion-based additive manufacturing with 3D scan and machine learning. **Journal of Manufacturing Processes**, v. 90, p. 274-285, 2023.
- NAIR, A.; RAJ, K. Machine Learning Model Selection for Performance Prediction in 3D Printing. **Journal of The Institution of Engineers (India): Series C**, v. 103, n. 4, p. 847-855, 2022.
- SCIME, L.; BEUTH, J. A multi-scale convolutional neural network for autonomous anomaly detection and classification in a laser powder bed fusion additive manufacturing process. **Additive Manufacturing**, v. 24, p. 273-286, 2018.
- SHARMA, P. et al. Predicting the dimensional variation of geometries produced through FDM 3D printing employing supervised machine learning. **Sensors International**, v. 3, p. 100194, 2022.
- SNOW, Z. et al. Toward in-situ flaw detection in laser powder bed fusion additive manufacturing through layerwise imagery and machine learning. **Journal of Manufacturing Systems**, v. 59, p. 12-26, 2021.
- SYAM, W. P. et al. In-process measurement of the surface quality for a novel finishing process for polymer additive manufacturing. **Procedia CIRP**, v. 75, p. 108-113, 2018.
- TIAN, W. et al. Additive manufacturing error quantification on stability of composite sandwich plates with lattice-cores through machine learning technique. **Composite Structures**, v. 327, p. 117645, 2024.
- WESTPHAL, E.; SEITZ, H. A machine learning method for defect detection and visualization in selective laser sintering based on convolutional neural networks. **Additive Manufacturing**, v. 41, p. 101965, 2021.
- WU, H.; YU, Z.; WANG, Y. Experimental study of the process failure diagnosis in additive manufacturing based on acoustic emission. **Measurement**, v. 136, p. 445-453, 2019.
- ZHU, Z. et al. Machine learning in tolerancing for additive manufacturing. **CIRP annals**, v. 67, n. 1, p. 157-160, 2018.
- ZUBAYER, M. H. et al. Enhancing additive manufacturing precision: Intelligent inspection and optimization for defect-free continuous carbon fiber-reinforced polymer. **Composites Part C: Open Access**, v. 14, p. 100451, 2024.