



Energias Limpas nas Engenharias

Otimização de trajetória na manufatura aditiva usando inteligência artificial: uma revisão sistemática da literatura

Bárbara D. Ross-Veitía

Doutorando em Engenharia de Produção, Programa de Pós-Graduação Universidade Tecnológica Federal do Paraná (UTFPR) - Campus Ponta Grossa. PR, Brasil

Tathiana Mikamura-Barchi

Doutorando em Engenharia de Produção, Programa de Pós-Graduação Universidade Tecnológica Federal do Paraná (UTFPR) - Campus Ponta Grossa. PR, Brasil

Regina Negri-Pagani

Programa de Pós-Graduação Engenharia de Produção, Universidade Tecnológica Federal do Paraná (UTFPR) - Campus Ponta Grossa. PR, Brasil

Hipólito D. Carvajal-Fals

Pesquisador Visitante. Departamento de Engenharia de Manufatura e Materiais. Universidade Estadual de Campinas. SP, Brasil

Hugo Valadares-Siqueira

Programa de Pós-Graduação Engenharia de Produção, Universidade Tecnológica Federal do Paraná (UTFPR) - Campus Ponta Grossa. PR, Brasil

Resumo: A transformação para fábricas inteligentes impulsionou a integração de tecnologias avançadas, como inteligência artificial (IA) e aprendizado de máquina (ML), nos processos de manufatura aditiva. Este estudo se concentra na aplicação da IA para otimizar as trajetórias de deposição de material na manufatura aditiva, um aspecto fundamental para melhorar as propriedades geométricas e mecânicas das peças fabricadas. A revisão sistemática da literatura explora as abordagens atuais que utilizam algoritmos de AM para modelar processos térmicos, processos microestruturais e propriedades de materiais, destacando seu impacto na qualidade do produto final. Técnicas avançadas, como redes neurais artificiais (ANNs) e métodos de otimização bayesiana, são abordadas para prever e reduzir defeitos, como porosidade e

deformações térmicas, que afetam a precisão e o desempenho do produto. Este artigo sintetiza as principais descobertas na otimização de trajetórias, identificando oportunidades para melhorar a eficiência e a sustentabilidade na produção por meio da IA. Por fim, ele destaca as oportunidades de pesquisas futuras para superar os desafios técnicos e consolidar a integração da IA na manufatura aditiva industrial.

Palavras-chave: Manufatura Inteligente, Manufatura aditiva, Inteligência Artificial, Otimização de trajetórias.

Path optimization in additive manufacturing using artificial intelligence: a systematic literature review.

Abstract: The transformation towards smart factories has driven the integration of advanced technologies, such as artificial intelligence (AI) and machine learning (ML), into additive manufacturing processes. This study focuses on the application of AI to optimise material deposition paths in additive manufacturing, a critical aspect for improving the geometric and mechanical properties of manufactured parts. The systematic literature review explores current approaches using ML algorithms to model thermal processes, microstructural processes and material properties, highlighting their impact on final product quality. Advanced techniques, such as artificial neural networks (ANNs) and Bayesian optimization methods, are addressed to predict and reduce defects, such as porosity and thermal deformations, that affect product accuracy and performance. This article synthesizes key findings in trajectory optimization, identifying opportunities to improve efficiency and sustainability in production through AI. Finally, it highlights future research opportunities to overcome technical challenges and consolidate AI integration in industrial additive manufacturing.

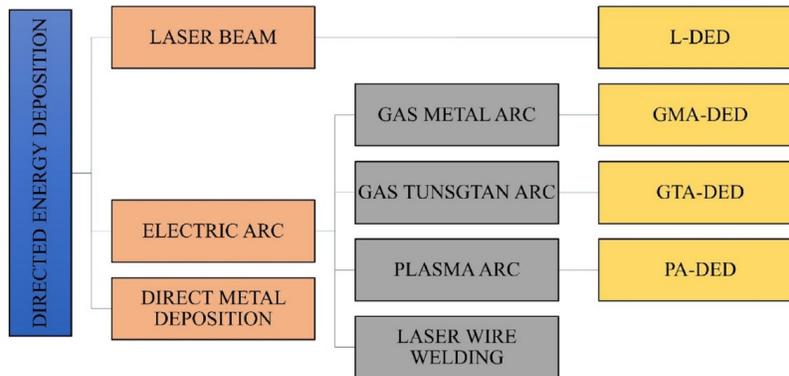
Keywords: Smart Manufacturing, Additive Manufacturing, Artificial Intelligent, Path optimization.

1. Introdução

A manufatura aditiva abrange um conjunto de tecnologias que permitem a criação de objetos tridimensionais a partir de modelos digitais, camada por camada, utilizando diversos materiais (KARKARIA *et al.*, 2024a; LEE *et al.*, 2021; WONG *et al.*, 2012). Os processos de deposição por dispersão de energia (DED) variam de acordo com o material, a potência do laser, o pó e o fornecimento de gás inerte, bem como a trajetória (DEZAKI *et al.*, 2022), resultando em diferentes tipos de DED com características específicas (Figura 1).

Consequentemente, a indústria de manufatura tem demonstrado um crescente interesse por essa abordagem, por ser um dos avanços tecnológicos que mais se destacam, y especialmente quando combinada com a IA. A manufatura aditiva permite uma produção mais precisa e personalizada, minimizando o desperdício de materiais e garantindo um controle de qualidade aprimorado em cada etapa do processo, ao contrário dos métodos tradicionais.

Figura 1. Classificação do processo DED na impressão 3D de metal.



Fonte: (DEZAKI *et al.*, 2022)

A manufatura aditiva permite a criação de geometrias complexas que são difíceis de alcançar com métodos tradicionais (ABDULHAMEED *et al.*, 2019). No entanto, a qualidade das peças produzidas depende em grande medida da precisão na definição das trajetórias de deposição do material. A otimização dessas trajetórias pode melhorar significativamente as propriedades mecânicas e estéticas das peças, reduzir defeitos e desperdícios, e aumentar a eficiência do processo (PEREZ *et al.*, 2022; SUZUKI *et al.*, 2020).

A IA desempenha um papel cada vez mais crucial na manufatura aditiva, ao aprimorar a precisão e a eficiência dos processos de fabricação. Através de algoritmos avançados de aprendizado de máquina, a IA permite a otimização das trajetórias de deposição de material, garantindo uma melhor qualidade das peças produzidas e reduzindo defeitos (PERANI *et al.*, 2023). Nesse sentido, o objetivo desta pesquisa é realizar uma revisão sistemática da literatura sobre a aplicação da inteligência artificial e os algoritmos de aprendizado de máquina na avaliação das trajetórias de deposição do material na manufatura aditiva. Através dessa revisão, pretende-se identificar e analisar os métodos e abordagens existentes que utilizam essas tecnologias para otimizar as trajetórias durante a fabricação das peças.

Este trabalho busca consolidar o conhecimento atual sobre como as novas tecnologias podem contribuir para melhorar a qualidade e eficiência geral das peças produzidas. Para isso, o artigo é estruturado de maneira a apresentar as considerações iniciais na seção 1. Já a seção 2 apresenta o embasamento teórico e a seção 3 a metodologia adotada. Por fim, na seção 4 serão apresentadas as conclusões deste estudo.

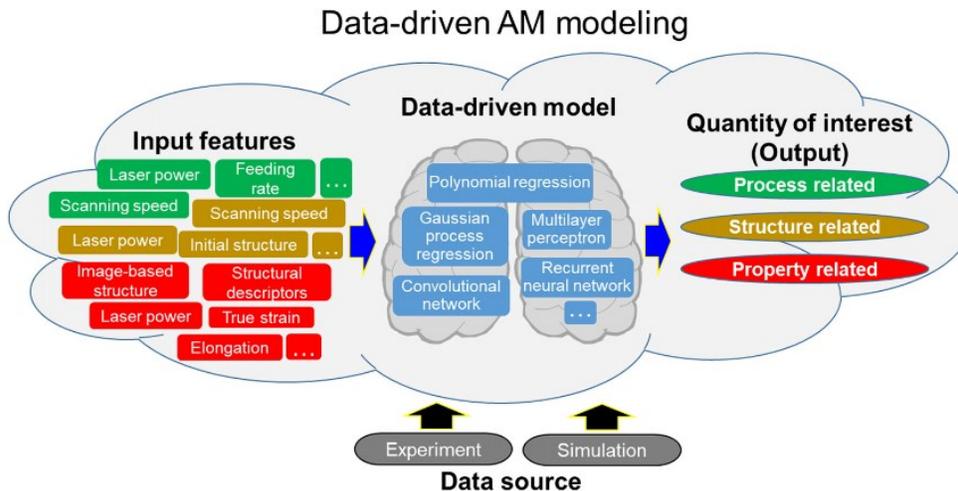
2 Referencial Teórico

A manufatura aditiva está avançando significativamente, expandindo a variedade de materiais e melhorando a precisão, permitindo sua aplicação na produção em massa e na personalização de produtos. Essa evolução contínua afetou diversos setores, como o automotivo, aeroespacial, médico e de bens de consumo, concentrando-se em áreas importantes, como materiais e processos inovadores, integração com inteligência artificial e outras tecnologias emergentes.

2.1 Classificação da modelagem orientada por dados para manufatura aditiva

Diferentes tipos de modelagem de AM orientada por dados têm sido usados na manufatura aditiva (Figura 2). A revisão de (WANG *et al.*, 2022) classifica a modelagem orientada por dados para AM em três categorias principais: modelagem de processos, modelagem de estruturas e modelagem de propriedades.

Figura 2. Ilustração esquemática da modelagem de AM orientada por dados.



Fonte: (WANG *et al.*, 2022).

Os autores subdividem as categorias de acordo com o nível de detalhe ou resultado da modelagem. A modelagem de processos abrange as interações térmicas e físicas durante a fabricação, como a evolução da temperatura e a formação de poças de fusão. A modelagem da estrutura abrange desde microestruturas até geometrias de grande escala, enquanto a modelagem da propriedade se concentra nas propriedades mecânicas das peças fabricadas (WANG *et al.*, 2022).

2.2 Planejamento de trajetórias na manufatura aditiva usando IA e seu impacto na qualidade da manufatura

A modelagem de processos mediante IA está sendo usada no estudo das trajetórias de disposição de material. As trajetórias afetam diretamente o desempenho térmico e a qualidade da peça fabricada (JAFARI *et al.*, 2021). As condições extremas do processo de fabricação de peças ou componentes por manufatura aditiva, que incluem altas temperaturas e interações complexas, induzem defeitos no material, sendo a porosidade um dos defeitos mais prevalentes (LEE *et al.*, 2021; LOREAU *et al.*, 2022). Alguns autores investigaram essa área usando IA para modelar e prever defeitos.

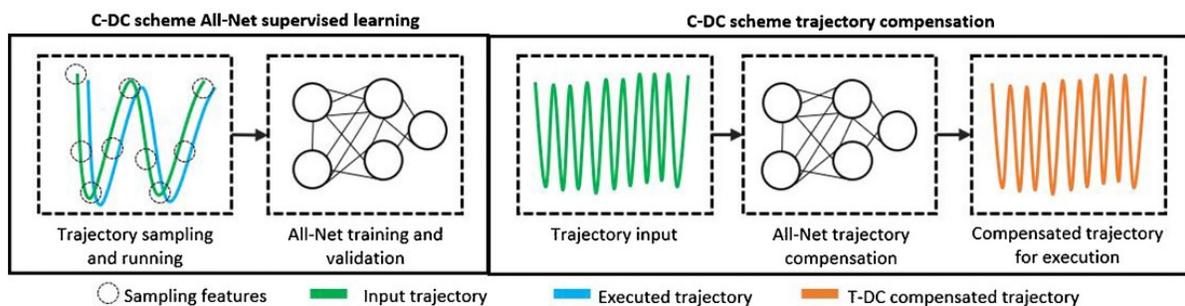
A pesquisa de (LOREAU *et al.*, 2022) se concentra na análise paramétrica e na modelagem baseada em aprendizado de máquina da porosidade induzida pela deposição de metal a laser com fio (wLMD). O estudo aborda os defeitos do processo,

especialmente a porosidade, que podem surgir durante a manufatura aditiva. Vários parâmetros que podem afetar a porosidade observada são discutidos, incluindo a taxa de deposição nas direções x e y, a potência do laser, a espessura da camada e a densidade de spins na trajetória de deposição.

No campo da manufatura aditiva, uma das áreas de pesquisa mais desafiadoras é a produção de estruturas complexas sem a necessidade de suportes adicionais. Nesse contexto, (BHATT *et al.*, 2020) apresentam uma abordagem inovadora na manufatura aditiva para a criação de peças usando um método baseado em extrusão sem estruturas de suporte. As principais contribuições incluem planejamento da trajetória baseado em rede neural para peças assimétricas, um algoritmo de corte otimizado para fabricação sem suporte e um esquema de compensação de trajetória que melhora a precisão da deposição de material.

A Figura 3 ilustra o esquema de compensação dependente do contexto (C-DC) desenvolvido pelos autores, que é dividido em dois estágios: aprendizado supervisionado e compensação de trajetória. No primeiro estágio, as trajetórias são amostradas para treinar uma rede neural artificial (ANN) "All-Net" usando dados de trajetórias executadas e seus erros. Enquanto, no segundo estágio, a rede treinada é usada para gerar trajetórias compensadas que melhoram a precisão e reduzem o erro de tempo durante a execução em manipuladores industriais.

Figura 3. Esquema de compensação dependente do contexto que contém o aprendizado supervisionado e a compensação de trajetória usando All-Net.



Fonte (BHATT *et al.*, 2020)

A implementação dessa abordagem de aprendizado de máquina permite uma redução significativa nos erros da trajetória e orientação, resultando em melhor qualidade das peças impressas no processo de fabricação. A eliminação de suportes não apenas reduz o desperdício de material, mas também simplifica o processo de pós-impresão, melhorando a eficiência e a precisão da fabricação.

2.3 A trajetória e as diferenças de temperatura na integridade da peça

Durante o processo de manufatura aditiva, as diferenças de temperatura podem gerar tensões internas nas peças, o que pode levar a deformações indesejadas. Investigar

como atenuar essas tensões é fundamental para garantir a precisão dimensional e a integridade da peça.

O estudo por (STATHATOS *et al.*, 2019) aborda a previsão em tempo real da evolução da temperatura e densidade em trajetórias longas e arbitrárias na manufatura aditiva a laser, utilizando ANN. Os autores desenvolveram um método de decomposição de trajetórias para transformar trajetórias de laser aleatórios em entradas para a ANN, otimizando o cálculo e a carga das descrições locais de cada ponto da trajetória. O sistema utiliza uma ANN "Master" para calcular a temperatura atual e uma ANN "Rider" para prever a evolução da densidade, demonstrando ser capaz de operar em escala completa com tempos de simulação inferiores a 50% do tempo do processo real.

Outros estudos têm explorado o uso de machine learning para aprimorar o controle e a eficiência na manufatura aditiva, como exemplificado na pesquisa abordada por (KARKARIA *et al.*, 2024b). A pesquisa se concentra no desenvolvimento de uma estrutura de gêmeos digitais no processo de DED. Os autores desenvolvem um modelo de ML baseado em memória de longo prazo (LSTM) e otimização bayesiana para prever e otimizar temperaturas em diferentes locais de componentes durante a fabricação das peças. Os autores destacam o uso de técnicas de ML, em particular redes neurais bayesianas, para prever temperaturas durante o processo DED e otimizar a entrada de energia do laser.

A manufatura aditiva por arco de arame (WAAM) é uma técnica avançada para a produção de componentes de médio a grande porte (12). O planejamento da trajetória e as estratégias de construção desempenham um papel crucial na otimização geométrica e no gerenciamento térmico durante a manufatura aditiva usando WAAM, além de contribuir significativamente para a mitigação da tensão residual e a redução da distorção nas estruturas fabricadas.

Nesse sentido, os autores (KAZMI *et al.*, 2024) realizaram um estudo usando esse tipo de técnica e propuseram uma estratégia inovadora de planejamento da trajetória. A estratégia foi denominada *switchback*. Eles realizaram a análise térmica por termografia infravermelha para monitorar as temperaturas durante a deposição, o que ajudou a correlacionar as temperaturas atingidas com as propriedades mecânicas e microestruturais obtidas. Os autores demonstram que esse tipo de estratégia, em comparação com as estratégias convencionais, melhora as propriedades mecânicas dos componentes da liga de alumínio ER-4043, atenuando o crescimento de grãos unidirecionais e transformando as tensões residuais de tração em compressão.

2.4 Manufatura híbrida

Um dos principais desafios no campo da manufatura aditiva híbrida é conseguir uma integração eficiente entre os processos aditivos e subtrativos. Os desafios e o pós-processamento exigido destacam a necessidade de pesquisas futuras no campo da manufatura. Da mesma forma, (DÁVILA *et al.*, 2020) identificaram as oportunidades e os desafios presentes na fabricação híbrida. Os autores argumentam que é importante

implementar a supervisão contínua em tempo real, incluindo o monitoramento do processo e o planejamento preciso do processo. Eles argumentam que se deve considerar as propriedades do material em cada trajetória e uma análise completa de como o processo de deposição influencia as características do material final.

Um exemplo disso é a pesquisa de (ZHANG *et al.*, 2020), que apresentou uma estratégia inovadora para otimizar a quantidade de material de aço inoxidável 316L depositado, usando simulações e experimentos para melhorar a eficiência do processo de fabricação híbrido e a precisão dimensional. Por meio de simulações do MATLAB, a altura e o passo da plaina foram previstos, o que mostrou que o aumento da taxa de alimentação, da potência do laser e da taxa de fluxo de pó no processo DED reduziu o tempo de deposição.

2.5 O uso de Deep Learning na manufatura aditiva

As interações entre as propriedades das peças fabricadas por manufatura aditiva, o processo de deposição e os parâmetros envolvidos são altamente complexos. Para reduzir a carga computacional exigida pelos modelos multifísicos, tem havido um uso crescente de redes neurais (ANN) e métodos de aprendizado de máquina (ML) na manufatura aditiva (PERANI *et al.*, 2023). As redes neurais convolucionais (CNNs) são a opção mais adequada para tarefas de visão computacional, alcançando desempenho de última geração.

Nesse sentido, (PERANI *et al.*, 2023) em sua pesquisa, implementaram uma abordagem de fusão de dados para otimizar a qualidade do processo de manufatura aditiva por deposição de metal a laser por meio da aprendizagem profunda. Eles coletaram dados de três fontes principais: a máquina, um sistema de visão e um scanner 3D, que foram então integrados em um conjunto de dados unificado. Os resultados mostram que o modelo CNN supera o modelo linear de base por uma ampla margem, com a vantagem adicional de que as CNN aprendem automaticamente os filtros de imagem, ao contrário dos métodos tradicionais.

A metodologia proposta pelos autores (FULLINGTON *et al.*, 2023), denominada ADDAM (Adaptive Design De-identification for Additive Manufacturing). Os autores integram técnicas de inteligência artificial com modelos de aprendizado de máquina para otimizar a detecção de anomalias, permitindo assim um equilíbrio entre a preservação da utilidade dos dados e a proteção de informações confidenciais.

O estudo de (PETRICH *et al.*, 2021) propõe um esquema de validação para detectar defeitos entre camadas na manufatura aditiva por fusão em leito de pó (PBFAM) usando monitoramento *in situ* e técnicas de aprendizado supervisionado. Foi obtida uma correlação significativa entre as informações sensoriais capturadas durante a construção e a identificação de defeitos por meio de tomografia computadorizada (CT), alcançando 98,5% de precisão na classificação de defeitos.

Diante dos avanços recentes discutidos, fica evidente que a manufatura aditiva tem se beneficiado significativamente da integração com técnicas de aprendizado de máquina, permitindo não só a otimização de processos, mas também a previsão e mitigação de defeitos em tempo real. Esses estudos ressaltam a importância de um planejamento de trajetória preciso e do monitoramento contínuo para a melhoria da qualidade das peças e da eficiência dos processos. Com base nesses fundamentos, a próxima seção deste artigo detalhará a metodologia adotada, que integra uma análise crítica das abordagens discutidas, com o intuito de avaliar as contribuições mais relevantes para a área de otimização de trajetórias na manufatura aditiva.

3 METODOLOGIA

A revisão sistemática da literatura foi conduzida de acordo com o PRISMA 2020 (PAGE *et al.*, 2021), seguindo quatro etapas fundamentais. Essas etapas compreendem: (1) a seleção das bases de dados e a definição da estratégia de busca, (2) a triagem dos documentos e a aplicação dos critérios de inclusão, (3) a revisão minuciosa do conjunto final de documentos e (4) a síntese e apresentação dos dados.

3.1 Seleção de banco de dados e estratégia de pesquisa

Os principais bancos de dados usados para pesquisar estudos foram o Scopus e o Web of Science. Ambos fornecem acesso a uma ampla variedade de artigos revisados por pares nas áreas de inteligência artificial e manufatura aditiva. A Tabela 1 apresenta o protocolo de pesquisa, detalhando a string de busca utilizada, o intervalo temporal coberto, a data da pesquisa, bem como os filtros e critérios de inclusão aplicados.

3.2 Triagem de documentos e critérios de inclusão

O gerenciamento dos documentos coletados durante a pesquisa foi otimizado com o auxílio do software Endnote X9. A ferramenta permitiu a revisão eficiente dos documentos em duas etapas complementares. Primeiro, as duplicatas foram removidas automaticamente pelo software, e em seguida, foi realizada uma triagem meticulosa dos documentos, com leitura atenta dos títulos, resumos e palavras-chave em artigos ou revisões de periódicos revisados por pares em inglês e artigos de conferências.

Essa análise criteriosa teve como objetivo identificar e excluir artigos que não se alinhavam com o objetivo deste estudo. Foram selecionados estudos seguindo os seguintes critérios de inclusão: (1) documentos focados em “Machine learning” e (2) documentos que aplicaram a “Additive Manufacturing”. A pesquisa foi realizada usando as seguintes palavras-chave: “Machine learning” OR “artificial intelligence” AND “Smart Manufacturing” AND “Additive Manufacturing” AND “Path Optimization”. A pesquisa abrangeu artigos publicados até 2024.

3.3 Revisão sistemática do portfólio final

A revisão sistemática foi conduzida a partir da leitura integral dos artigos incluídos no portfólio final. Cada artigo passou por uma análise detalhada, permitindo a identificação dos seguintes metadados: autores, ano de publicação, título, periódico, país do estudo de caso, tipo de resíduo analisado, metodologia empregada para a solução, principais achados, limitações reportadas e sugestões de direções para pesquisas futuras.

3.4 Lista de dados

Foram coletados dados relacionados ao uso de aprendizado de máquina e otimização de trajetórias na manufatura aditiva, bem como resultados quantitativos e qualitativos sobre o desempenho e os resultados de cada metodologia.

4 RESULTADOS E DISCUSSÃO

Foram inicialmente identificados 115 artigos nos bancos de dados Scopus e Web of Science, 20 artigos duplicados foram removidos, deixando um total de 95 artigos para análise. Os títulos e resumos foram então avaliados, e 36 artigos foram eliminados por não atenderem aos critérios de elegibilidade. Uma revisão detalhada do texto completo foi realizada em 59 artigos, dos quais 41 foram excluídos por não atenderem aos critérios específicos do estudo. No final, 18 estudos atenderam a todos os critérios de inclusão e foram usados para a análise final. Esse diagrama reflete quantitativamente o rigoroso processo de seleção e filtragem de estudos relevantes para a revisão sistemática.

Como resultado da revisão da literatura, foram identificadas várias abordagens inovadoras que usam IA e ML para otimizar os processos de manufatura aditiva, especialmente para melhorar a precisão das trajetórias de deposição e reduzir os defeitos nas peças fabricadas. A seguir, apresentamos um resumo dos estudos mais relevantes, destacando as metodologias empregadas, as aplicações específicas e as principais conclusões de cada pesquisa (Tabela 2).

Tabela 2. Resumo dos aplicativos de IA/ML na manufatura aditiva.

Autores/Ano	Abordagem AI/ML	Aplicação	Principais descobertas
(LOREAU <i>et al.</i> , 2022)	Modelagem baseada em ML para análise de porosidade.	Deposição de metal a laser (wLMD).	Previsão de defeitos de porosidade por meio de análise paramétrica de vários parâmetros de processo (taxa de deposição nas direções x e y, a potência do laser, a espessura da camada e a densidade de spins)

(BHATT <i>et al.</i> , 2020)	Redes neurais para planejamento de trajetória.	Extrusão sem suporte para peças assimétricas.	Redução de erros de trajetória, melhor qualidade da peça e eliminação de estruturas de suporte.
(STATHATOS <i>et al.</i> , 2019)	Redes neurais artificiais (ANN) para simulação de temperatura.	Trajетórias longas na manufatura aditiva a laser.	Otimização em tempo real da evolução térmica e da densidade.
(KARKARIA <i>et al.</i> , 2024b)	ML baseado em redes LSTM e otimização bayesiana.	Otimização de temperatura em DED.	Melhoria das propriedades microestruturais por meio do controle preciso da temperatura em diferentes áreas do componente durante o processo de deposição.
(KAZMI <i>et al.</i> , 2024)	Método <i>switchback</i>	Monitoramento das temperaturas durante a deposição na manufatura aditiva por arco de arame (WAAM)	Melhoria das propriedades mecânicas dos componentes da liga de alumínio ER-4043.
(DÁVILA <i>et al.</i> , 2020)	Monitoramento em tempo real com sensores (visão computacional).	Fabricação híbrida.	Identificação dos desafios do pós-processamento e da necessidade de monitoramento contínuo para garantir a geometria e as propriedades ideais das peças fabricadas.
(ZHANG <i>et al.</i> , 2020)	Simulação e otimização baseadas em MATLAB.	Otimização da deposição de aço inoxidável na fabricação híbrida.	Aumento da eficiência do processo e da precisão dimensional por meio de simulações para ajustar a taxa de alimentação, a potência do laser e o fluxo de pó.
(PERANI <i>et al.</i> , 2023)	Visão computacional e redes profundas (CNN).	Previsão de geometria na deposição de metal a laser.	Melhoria significativa na precisão geométrica das peças ao correlacionar pontos de trajetória com a forma final usando dados de máquina, visão e scanner 3D.
(FULLINGTON <i>et al.</i> , 2023)	ADDAM (Adaptive Design De-identification for Additive Manufacturing) (DL).	Otimização da detecção de anomalias na DED.	Desenvolvimento de uma estrutura para proteger a privacidade dos dados sem comprometer sua utilidade na detecção de anomalias, equilibrando segurança e colaboração.

(PETRICH <i>et al.</i> , 2021)	Monitoramento in-situ com aprendizado supervisionado. (ANN)	Detecção de falhas na fusão de leito de pó.	Classificação de falhas com 98,5% de precisão por meio da integração de dados de sensores e análise de tomografia computadorizada.
--------------------------------	---	---	--

As limitações identificadas nesta revisão destacam a necessidade crítica de investigar como a variação nas trajetórias de deposição influencia a qualidade do produto final na manufatura aditiva. Em alguns estudos, o tamanho das amostras e o número de experimentos realizados foram limitados, levando à incerteza quanto à generalização dos resultados. Além disso, as palavras chaves definidas validam que a IA é uma ferramenta promissora para otimizar trajetórias de deposição na AM, possibilitando melhorias contínuas na precisão e eficiência das peças produzidas.

5 CONCLUSÕES

Nesta revisão, as abordagens variaram consideravelmente entre os estudos, resultando em uma heterogeneidade notável em termos de métodos de otimização, algoritmos de ML usados e métricas para avaliar os resultados. A falta de padronização e a escassez de detalhes sobre a precisão dos modelos de ML usados dificultam a comparação entre os estudos. Os resultados da pesquisa evidenciaram um crescimento no uso de IA aplicada aos processos de AM. Por fim, como sugestão para futuros trabalhos, recomenda-se avaliar as trajetórias de deposição e sua influencia na qualidade do produto final.

AGRADECIMENTOS

Os autores gostariam de agradecer ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) pelo apoio recebido.

REFERÊNCIAS

ABDULHAMEED, O.; AL-AHMARI, A.; AMEEN, W.; MIAN, S. H. Additive manufacturing: Challenges, trends, and applications. **Advances in Mechanical Engineering**, 11, n. 2, p. 1687814018822880, 2019.

BHATT, P. M.; MALHAN, R. K.; RAJENDRAN, P.; GUPTA, S. K. Building free-form thin shell parts using supportless extrusion-based additive manufacturing. **Additive Manufacturing**, 32, p. 101003, 2020.

DÁVILA, J. L.; NETO, P. I.; NORITOMI, P. Y.; COELHO, R. T. *et al.* Hybrid manufacturing: a review of the synergy between directed energy deposition and subtractive processes. **The International Journal of Advanced Manufacturing Technology**, 110, p. 3377-3390, 2020.

DEZAKI, M. L.; SERJOU EI, A.; ZOLFAGHARIAN, A.; FOTOUHI, M. *et al.* A review on additive/subtractive hybrid manufacturing of directed energy deposition (DED) process. 1, n. 4, p. 100054, 2022.

FULLINGTON, D.; BIAN, L.; TIAN, W. Design de-identification of thermal history for collaborative process-defect modeling of directed energy deposition processes. **Journal of Manufacturing Science Engineering**, 145, n. 5, p. 051004, 2023.

JAFARI, D.; VANEKER, T. H.; GIBSON, I. J. M.; DESIGN. Wire and arc additive manufacturing: Opportunities and challenges to control the quality and accuracy of manufactured parts. 202, p. 109471, 2021.

KARKARIA, V.; GOECKNER, A.; ZHA, R.; CHEN, J. *et al.* Towards a digital twin framework in additive manufacturing: Machine learning and bayesian optimization for time series process optimization. **Advanced Powder Materials**, 4, p. 100054, 2024.

KAZMI, K. H.; SHARMA, S. K.; MANDAL, A.; DAS, A. K. Investigating the effect of path planning strategies on 3D metallic structure deposited using robotic WAAM. **Materials Chemistry and Physics**, p. 129909, 2024.

LEE, J.; PARK, H. J.; CHAI, S.; KIM, G. R. *et al.* Review on quality control methods in metal additive manufacturing. 11, n. 4, p. 1966, 2021.

LOREAU, T.; CHAMPANEY, V.; HASCOET, N.; LAMBARRI, J. *et al.* Parametric analysis and machine learning-based parametric modeling of wire laser metal deposition induced porosity. **International Journal of Material Forming**, 15, n. 3, p. 33, 2022.

PAGE, M. J.; MCKENZIE, J. E.; BOSSUYT, P. M.; BOUTRON, I. *et al.* Declaración PRISMA 2020: una guía actualizada para la publicación de revisiones sistemáticas. **Revista española de cardiología**, 74, n. 9, p. 790-799, 2021.

PERANI, M.; BARALDO, S.; DECKER, M.; VANDONE, A. *et al.* Track geometry prediction for Laser Metal Deposition based on on-line artificial vision and deep neural networks. **Robotics Computer-Integrated Manufacturing**, 79, p. 102445, 2023.

PEREZ, E.; LANDERS, R.; BRISTOW, D. Optimal trajectory smoothing for direct energy deposition additive manufacturing processes. **Mechatronics**, 88, p. 102910, 2022.

PETRICH, J.; SNOW, Z.; CORBIN, D.; REUTZEL, E. W. Multi-modal sensor fusion with machine learning for data-driven process monitoring for additive manufacturing. **Additive Manufacturing**, 48, p. 102364, 2021.

STATHATOS, E.; VOSNIAKOS, G.-C. Real-time simulation for long paths in laser-based additive manufacturing: a machine learning approach. **The International Journal of Advanced Manufacturing Technology**, 104, p. 1967-1984, 2019.

SUZUKI, T.; FUKUSHIGE, S.; TSUNORI, M. Load path visualization and fiber trajectory optimization for additive manufacturing of composites. **Additive Manufacturing**, 31, p. 100942, 2020.

WANG, Z.; YANG, W.; LIU, Q.; ZHAO, Y. *et al.* Data-driven modeling of process, structure and property in additive manufacturing: A review and future directions. 77, p. 13-31, 2022.

WONG, K. V.; HERNANDEZ, A. A review of additive manufacturing. **International scholarly research notices**, 2012, n. 1, p. 208760, 2012.

ZHANG, W.; SOSHI, M.; YAMAZAKI, K. Development of an additive and subtractive hybrid manufacturing process planning strategy of planar surface for productivity and geometric accuracy. **The International Journal of Advanced Manufacturing Technology**, 109, p. 1479-1491, 2020.