

PREDIÇÃO DA DENSIDADE RELATIVA NO AÇO INOXIDÁVEL AISI 316L FABRICADO POR FUSÃO EM LEITO DE PÓ COM APRENDIZADO DE MÁQUINA SUPERVISIONADO

Rodrigo Andrade Paes¹; Raphael Araújo²; Paulo Paiva Oliveira Leite Dyer³; Getúlio de Vasconcelos⁴; Vera Lúcia Othéro de Brito⁵

¹ Instituto de Estudos Avançados. (ranpaes@yahoo.com.br).

² Instituto de Estudos Avançados. (araujoraf@fab.mil.br).

³ Instituto de Estudos Avançados. (paulo_dyer@yahoo.com).

⁴ Instituto de Estudos Avançados. (getuliovas@gmail.com).

⁵ Instituto de Estudos Avançados. (veravlob@fab.mil.br).

Resumo: A manufatura aditiva metálica por Fusão em Leito de Pó (L-PBF) tem se consolidado como uma tecnologia estratégica para a produção de componentes no setor aeroespacial. Entretanto, a obtenção de peças com densidade relativa superior a 99% ainda representa um desafio significativo. Pequenas variações nos parâmetros de processo, como potência do *laser*, velocidade de varredura, espaçamento entre trilhas e espessura de camada, alteram o regime de fusão, favorecendo a formação de defeitos como porosidade. A definição de janelas ótimas de processamento depende de campanhas experimentais extensivas, com elevado custo e tempo. Nesse contexto, modelos preditivos baseados em aprendizado de máquina supervisionado surgem como uma alternativa promissora para estimar a densificação de peças e reduzir a dependência experimental. Este trabalho teve como objetivo desenvolver e avaliar modelos de aprendizado de máquina supervisionado, incluindo algoritmos nativos e *ensembles*, para a predição da densidade relativa de peças em aço inoxidável AISI 316L produzidas por L-PBF, considerando sua robustez estatística, interpretabilidade e aplicabilidade. Para isso, foi utilizado um conjunto de dados com 387 registros experimentais provenientes de diferentes condições operacionais. Foram consideradas seis variáveis de entrada: potência do *laser*, velocidade de varredura, espaçamento entre trilhas, espessura de camada, diâmetro do *spot* e diâmetro médio das partículas (D_{50}), sendo a densidade relativa (%) a variável-alvo. Os dados foram normalizados por padronização *z-score* e divididos em treino e teste (80/20). Foram avaliados modelos de regressão (Random Forest, XGBoost, CatBoost, HistGradientBoost, SVR e NuSVR), além de *ensembles* do tipo *stacking*. O desempenho foi avaliado por métricas estatísticas (R^2 , MAE, MSE e RMSE), complementadas por intervalos de confiança de 95% via *bootstrapping* e análise de importância das variáveis por permutação. Para validação experimental, amostras em AISI 316L foram fabricadas sob diferentes condições experimentais, com densidade medida pelo método de Arquimedes. Os resultados evidenciaram o elevado desempenho preditivo dos modelos. O Random Forest se destacou pela melhor capacidade de generalização ($R^2 = 0,8534$; MAE = 1,5040; RMSE = 2,2537), enquanto o CatBoost apresentou desempenho competitivo ($R^2 = 0,8322$; MAE = 1,5616; RMSE = 2,4114), porém com indícios de leve sobreajuste. Os modelos *ensemble* apresentaram desempenho intermediário, sem ganhos relevantes. A análise de importância indicou a velocidade de varredura e o diâmetro do *spot* como variáveis mais influentes, seguidas pela potência do

laser, refletindo o controle do aporte térmico. A validação experimental corroborou esses resultados, com boa concordância em regimes de maior densificação ($>93\%$), apresentando desvios inferiores a $\pm 1\%$. Em regimes de menor densificação ($\sim 85\text{--}90\%$), observou-se superestimação, com desvios de até $\sim 7\text{--}8\%$, associada a transições entre os regimes de fusão. Os resultados demonstraram que os modelos de aprendizado de máquina supervisionado, particularmente Random Forest e CatBoost, possuem elevada capacidade preditiva para estimar a densidade relativa de peças produzidas por L-PBF em aço AISI 316L. A abordagem tem potencial para reduzir a dependência de campanhas experimentais, fornecendo suporte quantitativo à definição de janelas de processamento e apresentando potencial de escalabilidade para outras propriedades e materiais, contribuindo para a integração de gêmeos digitais na manufatura aditiva.

Palavras-chave: Manufatura aditiva metálica; Fusão em Leito de Pó (L-PBF); AISI 316L; Aprendizado de máquina; Modelos preditivos; Gêmeos digitais.