

O USO DE MACHINE LEARNING NA CLASSIFICAÇÃO DA ORIENTAÇÃO DE IMPRESSÃO DE POLIAMIDA 12 MANUFATURADA POR SLS

Congresso Brasileiro De Manufatura Aditiva, 1ª edição, de 30/11/2020 a 01/12/2020
ISBN dos Anais: 978-65-86861-62-4

BARBOSA; Lucas Costa¹, **SILVA; Cristiane E. R. da**², **FARIAS; Cláudio Miceli**³, **O'CONNOR; Joan**⁴, **SANTOS; Cláudio T. dos**⁵

RESUMO

1 INTRODUÇÃO Manufatura Aditiva (MA) é um “processo de deposição de materiais, camada a camada, para produzir peças a partir de dados de um modelo digital 3D, um processo de fabricação que é o oposto da fabricação tradicional, chamada de subtrativa e formativa”. O desenvolvimento de novos processos e materiais fornece uma variedade maior de áreas para aplicações de MA. Atualmente, a manufatura aditiva é usada não apenas nas indústrias aeroespacial, médica e automotiva, mas também na indústria de alimentos, produção e arquitetura de jóias, etc (MANI et al., 2015). Com mais uso, mais necessidades e requisitos são definidos para produtos fabricados pela manufatura aditiva. Uma das questões mais difíceis que devem ser abordadas é como melhorar e controlar a qualidade da peça construída e definir o que influencia significativamente nessa qualidade. Todo o processo de fabricação aditiva possui seus próprios parâmetros que, combinados às propriedades do material e às condições ambientais, influenciam a qualidade das peças fabricadas. Experimentalmente, através da observação, é muito difícil definir esses parâmetros e suas combinações, e quais têm maior impacto nas propriedades mecânicas, físicas e materiais do produto (HOFLAND; BARAN; WISMEIJER, 2017). Além disso, pelo fato de os experimentos práticos serem caros (especialmente para o pó de metal) (MANI et al., 2015), a detecção de parâmetros que influenciam a qualidade da peça construída torna-se uma tarefa mais desafiadora. Machine Learning (ML) se refere a extração de conhecimento de um conjunto de dados. Trata-se de um campo de pesquisa que se situa na intersecção entre a estatística, a Inteligência Artificial (IA) e a ciência da computação. O método de ML também é conhecido como Análise Preditiva ou Aprendizado Estatístico. Existem quatro tipos de algoritmos de ML, os supervisionados, não supervisionados, semi-supervisionados e por reforço. (Figura 1). Neste trabalho utilizaremos somente o aprendizado supervisionado.

¹ Instituto Nacional de Tecnologia, lucas.barbosa.0899@poli.ufrj.br

² INT, crisevelise@gmail.com

³ Laboratório de Caracterização de Propriedades Mecânicas e Microestruturais, cmicelifarias@gmail.com

⁴ Av. Venezuela, joconnorb@gmail.com

⁵ 82 Praça Mauá. Rio de Janeiro, claudio.santos@int.gov.br

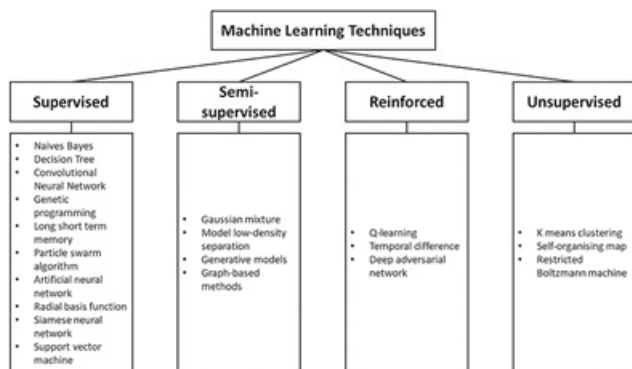


Figura 1: Os 4 tipos de

técnicas de ML. *Fonte: (GOH; SING; YEONG, 2020)* Os algoritmos supervisionados são aqueles que automatizam um processo de decisão pela generalização de exemplos conhecidos. Neste caso, o usuário alimenta o algoritmo com um conjunto de dados de entrada X e saída Y conhecidos. O algoritmo, então, através de uma função própria $f(x/\theta)$, onde θ são os parâmetros dessa função, e f retorna os valores calculados pelo algoritmo para Y . O algoritmo, então, descobre quais os parâmetros que minimizam a função de erro $E(f(x/\theta), Y)$ que retorna o erro entre os valores reais Y e os calculados $f(x/\theta)$. Com isso, o algoritmo consegue reproduzir a saída desejada para uma entrada nunca vista antes. Os modelos de ML têm sido aplicados em diversos problemas científicos, tais como entendimento do comportamento de estrelas, descoberta de planetas distantes, descoberta de novas partículas, análise da sequência de DNA, no tratamento personalizado do câncer, etc. (ALPAYDIN, 2009; CAPUANO; RIMOLI, 2019; LANGLEY, 1996) Porém, um ponto negativo dessas técnicas é que exigem grandes quantidades de dados para melhor generalização e precisão. Portanto, neste trabalho serão apresentados os resultados de análise estatística experimental e técnicas de aprendizado de máquina para ajudar na classificação das propriedades mecânicas nas diferentes orientações da plataforma de impressão estudadas até aqui. 2 METODOLOGIA

2.1 Materiais

O material usado foi a poliamida 12, da Duraform. Os CPs de tração foram modelados usando CAD para obtenção do modelo digital STL (segundo a norma ASTM-D638, Tipo V). Como mostrados nas Figuras 2.a e




Figura 2.a: CP

tipo V segundo a norma ASTM D638-02a. Figura 2.b: Dimensões do CP
Fonte: ASTM D-638 (2014)

2.2 Impressão

Os CPs foram impressos na impressora SLS ProX 500 da 3D systems, da Associação Mineira de Reabilitação - AMR, utilizando-se os parâmetros: Temperatura de *warm-up*: 130 °C, 150 °C e 167,3 °C em 03 períodos de aquecimento. Temperatura de construção: 167,3 °C. Potência do laser: 59 W. Altura da camada: 0,1 mm. velocidade de varredura: 12.700 mm/s. Os

¹ Instituto Nacional de Tecnologia, lucas.barbosa.0899@poli.ufrj.br

² INT, crisevelise@gmail.com

³ Laboratório de Caracterização de Propriedades Mecânicas e Microestruturais, cmicelifarias@gmail.com

⁴ Av. Venezuela, joconnorb@gmail.com

⁵ 82 Praça Mauá. Rio de Janeiro, claudio.santos@int.gov.br

CPs foram impressos em 7 direções segundo a norma ASTM 52921-13 - *Standard Terminology for Additive Manufacturing-Coordinate Systems and Test Methodology* que estabelece requisitos para validação do processo de impressão. Para cada direção (XYZ, XYZ (rotacionado 45° em torno do eixo Z), XZY, YXZ, YZX, ZXY e ZYX), foram impressos 5 cps conforme indicado nas Figuras 3.a e 3.b




Figura 3. a):

Diferentes direções de impressão. Fonte: ASTM 52921, (2013). Figura 3.b. Orientação de fabricação dos CPs na plataforma de construção da impressora SLS. Fonte: elaboração própria.

2.3 Ensaio de Tração

Os CPs foram ensaiados a taxa de 0,5 mm/min na direção longitudinal somente, utilizando uma máquina de ensaio universal INSTRON 3382, com capacidade de 100 kN. Serão avaliados através da curva tensão vs deformação o módulo de elasticidade e resistência à fratura do material no Laboratório de Caracterização de Propriedades Mecânicas e Microestruturais (LACPM) do Instituto Nacional de Tecnologia (INT).

2.4 Machine Learning

Foi utilizada a linguagem de programação *open source Python* (BROWNLEE, 2017) com o módulo de análise de dados *pandas*, e o módulo de ML *scikit-learn* (GARRETA; MONCECCHI, 2013), que atualmente é o mais proeminente do *Python* por conter muitos algoritmos de ML no estado-da-arte e uma vasta documentação. O código implementado pode ser visualizado em (LUCASCARBOSA, [s.d.]), na pasta *Manufatura Aditiva/Classificação de Direção*. Para cada estudo, foram utilizados diferentes algoritmos baseados no tipo de dados e no tipo de problema. Em todos os algoritmos foram utilizados o *random state* de 42, para assegurar reprodutibilidade dos modelos. (GARRETA; MONCECCHI, 2013)

2.4.1 Dados Para dados estruturados por parâmetros, utilizou-se algoritmos de machine learning, por serem mais simples e de fácil implementação. 2.4.2 Classificação de direção de impressão Para a classificação dos dados obtidos pelo ensaio mecânico nas orientações de impressão, primeiramente, foi extraído do ensaio realizado 10 parâmetros, os quais são: área inicial, módulo de elasticidade, força no escoamento, tensão no escoamento, deformação no escoamento, força máxima, tensão na força máxima, deformação na força máxima, força de ruptura e deformação na ruptura. Desta forma, foi decidido agrupar as direções/orientações em 4 grupos/planos: “deitado” (XYZ e YXZ), “de lado” (XZY e YZX), “em pé” (ZXY e ZYX), e “45°” para o XYZ rotacionado. Além disso, a cada plano foi dado um ID para auxiliar no treinamento do modelo (Tabela 1). **Tabela 1:** ID de cada plano

Nome do plano	Plano	ID
deitado	1	0
em pé	2	1
45°	3	2
deitado	4	3

Para aumentar a diferenciabilidade

¹ Instituto Nacional de Tecnologia, lucas.barbosa.0899@poli.ufrj.br

² INT, crisevelise@gmail.com

³ Laboratório de Caracterização de Propriedades Mecânicas e Microestruturais, cmicelifarias@gmail.com

⁴ Av. Venezuela, joconnorb@gmail.com

⁵ 82 Praça Mauá. Rio de Janeiro, claudio.santos@int.gov.br

entre cada amostra, normalizou-se os dados no método mínimo-máximo, onde cada valor é calculado através da equação 1:

$$x' = \frac{x-m}{m-M} \quad 1$$

onde x' é o novo valor, x é o valor antigo, m e M correspondem aos valores mínimo e máximo encontrados, respectivamente, para cada parâmetro. Além disso, como são poucas amostras, foi utilizada a técnica de *k-fold cross-validation*, que consiste em separar os dados em k subgrupos, treinar o modelo utilizando cada subgrupo como dado de teste, e extrair a métrica desse modelo. Posteriormente é calculada a média das métricas. Na figura 4 é mostrado um exemplo para $k = 5$.

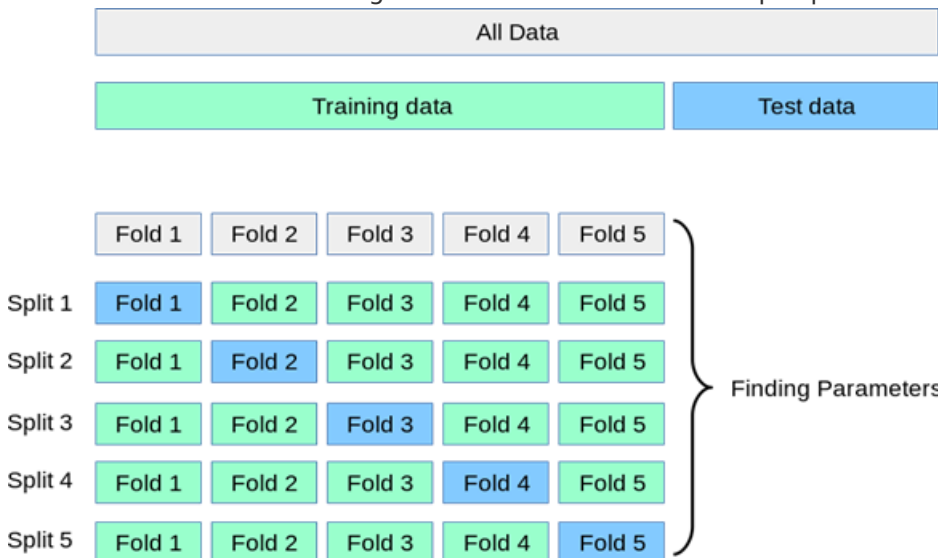


Figura 4: Ilustração do algoritmo de *k-fold cross-validation* para $k = 5$.

Fonte: (GARRETA; MONCECCHI, 2013)

2.4.3 Problema Existem dois tipos de problemas: regressão e classificação. Problemas de regressão tem por objetivo, dado os valores de entrada X prever valores de saída Y . Nos de classificação, a saída Y é uma classe, que pode ser representada por valores numéricos, palavras, tensores (como no caso do *one-hot-encoding*), etc. Para regressão, utilizou-se os algoritmos de regressão linear para casos lineares e *Support Vector Machine* (SVM) (GOBERT et al., 2018) para casos não-lineares. Para classificação, utilizou-se os algoritmos *K-Nearest-Neighbours* (KNN) (WU; SONG; MOON, 2019), SVM para classificação, árvore de decisão (GOBERT et al., 2018), e Descida de Gradiente Estocástica (SGD) (WU et al., 2016). Para todos os algoritmos, foram realizadas 10 configurações de dados de treino e teste, sendo o conjunto de dados de teste correspondendo a 35% do total de dados.

2.4.4 Análise de dados Analisou-se primeiramente a correlação entre os parâmetros extraídos do ensaio de tração, para visualizar se há redundância, isto é, se há dois ou mais parâmetros com uma correlação tão alta, que consiga representar todo o comportamento do outro, sem a necessidade de usar todos os parâmetros, podendo escolher entre eles para representar o todo (e.g. não há a necessidade de utilizar os parâmetros comprimento, largura e área, já que é largura e altura estão implícitas no cálculo da área). A correlação geral pode ser vista na Figura 6. É possível notar que alguns pares possuem grande correlação positiva (e.g. os parâmetros “Tensão na força máxima” e “Módulo elástico”) e negativa (e.g. “Deformação na força máxima” e “Módulo elástico”). Ambas as relações são corroboradas pelo modelo físico, visto na equação 2

¹ Instituto Nacional de Tecnologia, lucas.barbosa.0899@poli.ufrj.br

² INT, crisevelise@gmail.com

³ Laboratório de Caracterização de Propriedades Mecânicas e Microestruturais, cmicelifarias@gmail.com

⁴ Av. Venezuela, joconnorb@gmail.com

⁵ 82 Praça Mauá. Rio de Janeiro, claudio.santos@int.gov.br

$E = \frac{\sigma}{\epsilon}$ sendo E o módulo elástico, σ a tensão, e ϵ a deformação.




Figura 5: Mapa de

calor representando a correlação entre pares de parâmetros. *Fonte: Elaboração própria.* Além disso é possível notar, na Figura 6.a., que para o gráfico “tensão na ruptura” vs “deformação na força máxima”, os pontos já estão *clusterizados* em seus grupos. Graças a isso, foram usados somente esses dois parâmetros. Para se treinar o modelo de ML, foi necessário que os dados estivessem balanceados, isto é, cada classe possuísse a mesma quantidade de pontos. Como a classe “45” só possuía 5 pontos (já que não foi agrupada com outra classe), foi necessário criar mais 5 pontos para esta classe (o desbalanceamento dos dados pode levar a um viés maior, já que o modelo aprenderá menos sobre a classe “45” (MARUOTTI; ROCCI, 2012)) Para isso, utilizou-se a técnica de *Synthetic Minority Over-sampling Technique* (SMOTE) (FERNANDEZ et al., 2018; HU; LI, 2013) para criar estes pontos, como pode ser visto na Figura 6.b.

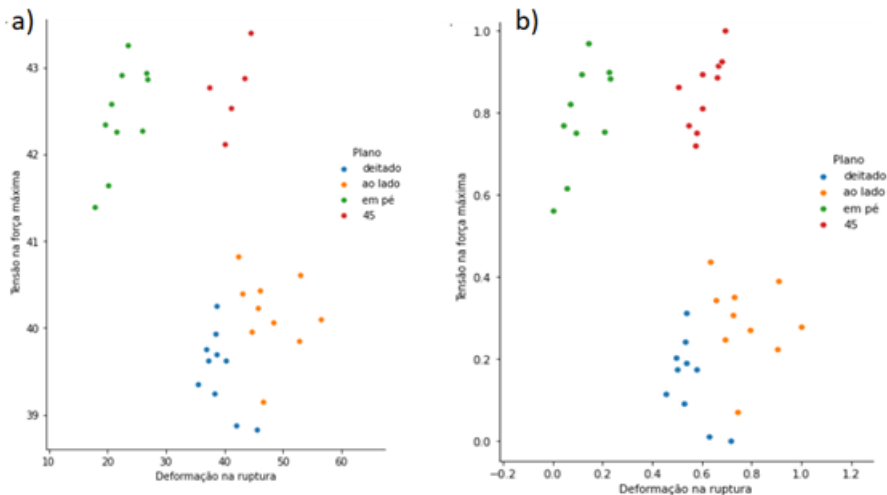


Figura 6.a: Dispersão dos pontos, separados por grupos, considerando somente os parâmetros “Tensão na força máxima” e “Deformação na ruptura”. *Fonte: Elaboração própria.* Figura 6.b: Gráfico de dispersão do mesmo par de parâmetros “Tensão na força máxima” e “Deformação na ruptura” após o uso de SMOTE para a criação de 5 pontos para o plano “45”. *Fonte: Elaboração própria.* Esta técnica consiste em escolher randomicamente 2 pontos da classe da qual se deseja criar mais pontos, e um limiar / aleatório entre 0 e 1. Assim, pegou-se um ponto na reta entre esses 2 pontos que estavam a uma distância percentual (em relação a distância dos 2 pontos) a um dos pontos igual ao limiar escolhido e ao

¹ Instituto Nacional de Tecnologia, lucas.barbosa.0899@poli.ufrj.br

² INT, crisevelise@gmail.com

³ Laboratório de Caracterização de Propriedades Mecânicas e Microestruturais, cmicelifarias@gmail.com

⁴ Av. Venezuela, joconnorb@gmail.com

⁵ 82 Praça Mauá. Rio de Janeiro, claudio.santos@int.gov.br

outro ponto igual a $I-I$, como pode ser visto na Figura 7. Como a classe x (círculo preto) é minoritária em relação a classe y (quadrado hachurado), é preciso aumentar o número de pontos dessa classe. Assim, para o limiar fixo de 0,5, foram escolhidos diversos pares de pontos da classe x e criados sinteticamente novos pontos (vermelho) da classe preto.




Figura 7: Representação do

algoritmo de SMOTE. *Fonte: (HU; LI, 2013)* 3 RESULTADOS E DISCUSSÃO Nesta seção serão apresentados os resultados obtidos até o momento do envio deste trabalho. Primeiramente, serão apresentados os resultados do ensaio mecânico de tração, tais como módulo de elasticidade, tensão na força máxima e tensão de escoamento do PA 12 manufaturado em SLS, e os resultados de ML para classificar as propriedades mecânicas nas orientações impressas na plataforma de construção obtidas até aqui.

3.1 Ensaio de Tração

Na Tabela 2, são mostrados os resultados do ensaio de tração do PA fabricado em SLS, em diferentes orientações. Os valores de tensão máxima variaram de 39,36 MPa a 42,49 MPa. A incerteza da medição variou de 0,79 MPa a 1,1 MPa, indicando uma baixa dispersão dos valores. O valor da tensão máxima encontrado na literatura para PA (nylon 12, Duraform) impresso por SLS foi de 40 MPa (Starr et al, 2011) (não foi informada a direção estudada) similar aos valores encontrados neste estudo **Tabela 2**: Resultados do ensaio de tração do PA fabricado em SLS, em diferentes orientações. Código Tensão na Força Máxima e Incerteza Expandida [MPa] Tensão de Escoamento e Incerteza Expandida. [MPa] Módulo de Elasticidade e Incerteza Expandida [MPa] SLS_XY 39,36 ± 0,79 18,33 ± 0,44 1377 ± 23 SLS_XZ 40,23 ± 0,67 18,86 ± 0,44 1397 ± 46 SLS_YX 39,7 ± 1,10 18,76 ± 0,54 1391 ± 39 SLS_YZ 40,1 ± 1,10 18,55 ± 0,57 1384 ± 39 **SLS_ZX 42,4 ± 0,66 20,12 ± 0,66 1557 ± 21** **SLS_ZY 42,49 ± 0,9 20,48 ± 0,46 1537 ± 22** **SLS_45 42,74 ± 0,68 21,7 ± 1,10 1533 ± 27**

3.2 Machine Learning

Primeiramente, é necessário achar os valores ótimos dos parâmetros de cada modelo. Para o KNN, ajustou-se K . Para o SGD e SVM, foi utilizado o algoritmo de busca em grade para ajustar $L1$ e $alfa$ (taxa de aprendizado), no caso do SGD, e C e $gama$ (que parametrizam a sigmóide utilizada como $kernel$), no caso do SVM. Para a Árvore de Decisão, ajustou-se o número máximo de bifurcações (ou comparações) da árvore. Os testes podem ser vistos nas figuras 8.a, 8.b, 8.c, 8.d. A Figura 8.a, que representa $F1-score$ vs K , mostra uma evidente queda de $F1-score$, conforme K aumenta, o que é corroborado por (HERLOCKER et al., 1999). Na figura 8.b, um mapa de calor cujo gradiente representa o valor de $F1-$

¹ Instituto Nacional de Tecnologia, lucas.barbosa.0899@poli.ufrj.br

² INT, crisevelise@gmail.com

³ Laboratório de Caracterização de Propriedades Mecânicas e Microestruturais, cmicelifarias@gmail.com

⁴ Av. Venezuela, joconnorb@gmail.com

⁵ 82 Praça Mauá. Rio de Janeiro, claudio.santos@int.gov.br

score em função dos dois parâmetros *alfa* e *L1*, é possível observar que os menores valores de *alfa* levaram aos maiores valores de *F1-score*, o que talvez se dê pelo fato de que os dados já estão bem agrupados, ou seja, os valores iniciais dos parâmetros já são próximos dos valores ótimos. Porém, não foi possível identificar um intervalo de valores de *L1* que levasse a valores de *F1-score* altos, por isso foi utilizado o valor padrão da biblioteca para a penalidade *L2*. Para o SVM (Figura 8.c), não observados intervalos característicos para os valores de (*C*, *gama*) que levassem a valores de *F1-score* (representado também pelo gradiente) altos. Por isso, foi utilizado os valores padrão da biblioteca. Na figura 8.d, que ilustra a curva *F1-score* vs *profundidade máxima* do algoritmo de Árvore de decisão, nota-se um pico de *F1-score* em profundidade 2, e que a partir de uma profundidade 3, *F1-score* não muda, o que também pode ser explicado pelo fato de que uma maior complexidade de árvores não é necessária para o dado problema.

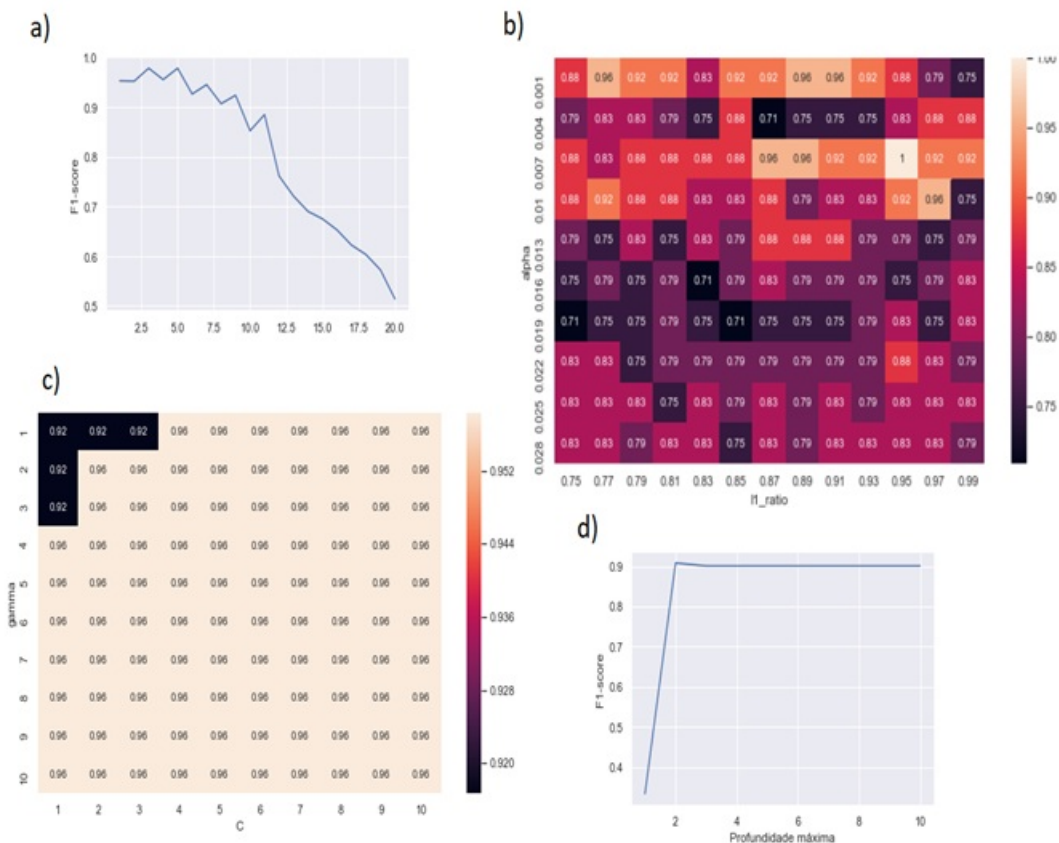


Figura 8.a: *F1-score* do algoritmo KNN vs *K*. Figura 8.b: Mapa de calor representando *F1-score* do algoritmo SGD em função dos parâmetros *alfa* e *L1*. Figura 8.c: Mapa de calor representando *F1-score* do algoritmo SVM em função de *C* e de *gama*. Figura 8.d: *F1-score* do algoritmo de Árvore de Decisão vs Profundidade máxima da árvore. Os resultados dos hiperparâmetros pode ser visto na Tabela 3. Para o KNN, o pico de *F1-score* deu-se para $K=5$. Para o SGD, foi escolhido o valor de $\alpha = 0,04$ e $L1 = 0$, que é o valor padrão da biblioteca no caso da penalidade “L2”. Para o SVM, como não houve um valor único ou um intervalo de *C* e *gama* que levasse aos maiores valores de *F1-score*, decidiu-se usar o valor padrão fornecido pela biblioteca, de $C=1$ e $\gamma = 1/n$, sendo *n* o número de entradas, no caso 2 (“Deformação na ruptura” e “Tensão na força máxima”), logo $\gamma = 0,5$. Para a Árvore de Decisão, foi utilizada profundidade máxima de 2. **Tabela 3:** Valores ótimos dos hiperparâmetros de cada algoritmo: Algoritmo Parâmetro Valor KNN

¹ Instituto Nacional de Tecnologia, lucas.barbosa.0899@poli.ufrj.br

² INT, crisevelise@gmail.com

³ Laboratório de Caracterização de Propriedades Mecânicas e Microestruturais, cmicelifarias@gmail.com

⁴ Av. Venezuela, joconnorb@gmail.com

⁵ 82 Praça Mauá. Rio de Janeiro, claudio.santos@int.gov.br

K 5 SGD α (taxa de aprendizado) 0,04 $L1$ 0,00 SVM C 1,00 γ 0,50 Árvore de Decisão Profundidade máxima 2 O resultado por algoritmo e precisão de classificação nas orientações impressas usando 4 diferentes algoritmos, com 40% dos dados de teste, estão apresentados na Tabela 4. Este valor alto para a porção de dados de teste se dá pelo fato de que os dados estão bem agrupados, logo é importante evitar *overfitting* (utilizar muitos dados de treino, de forma que o modelo simplesmente memorize esses dados). Caso houvesse dados mais abundantes e mais diversos, seria possível aumentar os dados de treino de forma a tornar nosso modelo mais holístico. Como observado, as precisões de todos os algoritmos em classificar as propriedades mecânicas encontradas nas orientações agrupadas foi extremamente alta, variando de 90,92% (para a árvore de decisões) a 97,88% (para o KNN). Nossa hipótese é de que a causa primária foi a excelente qualidade dos ensaios realizados no Laboratório do INT, com excelentes dados de origem. Além disso, supomos que o KNN se saiu melhor que os demais por possuir menos hiperparâmetros e maior simplicidade, o que faz com que ele alcance métricas maiores em problemas de baixa complexidade como este. **Tabela 4:** Precisão de cada algoritmo utilizado Algoritmo $F1$ -score (%) KNN 97,88 SGD 96,80 SVM 96,83 Árvore de Decisão 90,92 Utilizou-se $F1$ -score por ser uma métrica que consegue abarcar tanto a precisão quanto a acurácia do modelo. As equações 3, 4 e 5 ilustram como é feito o cálculo de tal métrica:

$$F = 2 \frac{\text{recall} * \text{precision}}{\text{recall} + \text{precision}} \quad 3$$

$$\text{recall} = \frac{TP}{TP + FP} \quad 4 \quad \text{onde } TP, TN \text{ e}$$

$$\text{precision} = \frac{TP}{TP + FN} \quad 5$$

TF equivalem aos verdadeiros positivos, verdadeiros negativos, e falsos positivos, respectivamente. Os resultados de classificação de cada algoritmo podem ser visualizados nas figuras 9.a, 9.b, 9.c e 9.d.

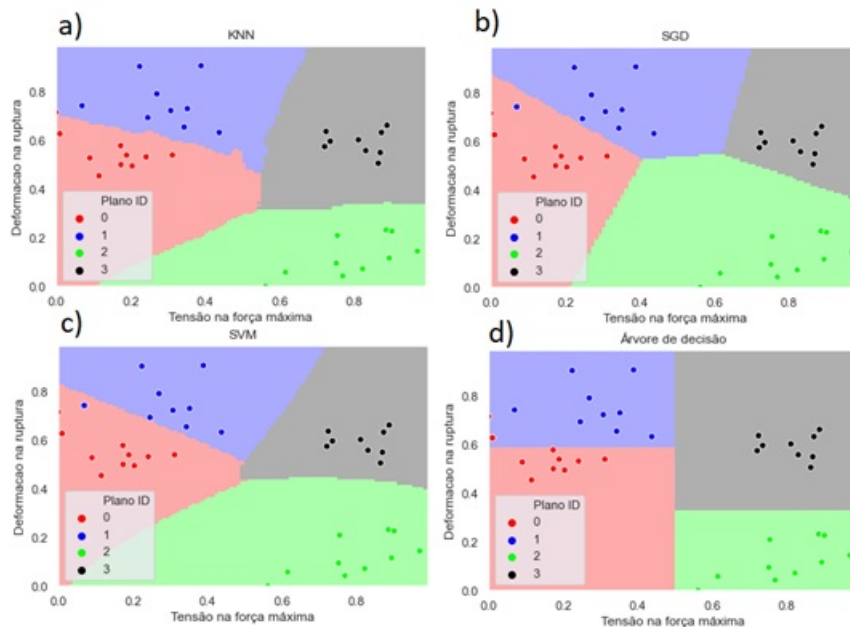


Figura 9.a: Visualização do resultado do KNN para $K = 5$. Figura 9.b: Visualização do resultado do SVM. Figura 9.c: Visualização do resultado do SGD. Figura 9.d: Visualização do resultado da Árvore de Decisão. *Fonte:*

¹ Instituto Nacional de Tecnologia, lucas.barbosa.0899@poli.ufrj.br

² INT, crisevelise@gmail.com

³ Laboratório de Caracterização de Propriedades Mecânicas e Microestruturais, cmicelifarias@gmail.com

⁴ Av. Venezuela, joconnorb@gmail.com

⁵ 82 Praça Mauá, Rio de Janeiro, claudio.santos@int.gov.br

3.3 Discussões e próximas etapas

Como observado nos ensaios mecânicos as direções Z e 45° possuíram valores maiores para os 3 parâmetros estudados. Este comportamento é uma indicação clara de anisotropia. Como observado por (HOFLAND; BARAN; WISMEIJER, 2017) que investigaram a correlação de parâmetros de processo com propriedades mecânicas de peças PA12 sinterizadas a laser, a diferença no módulo de elasticidade e alongamento na ruptura está provavelmente relacionado à diferença de resfriamento nesta técnica de fabricação. Vários estudos confirmaram que a taxa de resfriamento influenciou o alongamento na ruptura das peças sinterizadas: de acordo com (GOODRIDGE; TUCK; HAGUE, 2012), produtos resfriados rapidamente têm um alongamento maior na ruptura do que produtos refrigerados lentamente. Além de um alongamento diferente na ruptura, é importante saber que o resfriamento lento (maior cristalinidade) resulta em mais encolhimento. Eles também observaram que para uma densidade de energia de 0,53 [J/mm³] as propriedades de força máxima foram maiores em Z que em X, como também observado neste trabalho. No entanto, ainda não foi calculada a densidade de energia de impressão, mas foi observado que os parâmetros utilizados neste trabalho foram muito superiores aos do datasheet do polímero utilizado. Com ML foi possível treinar os diversos algoritmos e classificar com um valor alto de *F1-score* usando SVM, as direções impressas estudadas. Como dito anteriormente, o algoritmo KNN obteve o maior *F1-score* provavelmente pelo fato de ser o mais simples, além do fato dos dados já estarem suficientemente agrupados. O algoritmo de Árvore de Decisão, mesmo sendo simples, se saiu bem separando os grupos em regiões retangulares. Com esta resposta outras propriedades poderão ser variadas na simulação e utilizar as curvas geradas para testar o modelo e vice versa. Todos os algoritmos obtiveram métricas altas, porém estas poderiam ser ainda maiores caso tivéssemos dados mais diversos e numerosos. As etapas futuras deste trabalho serão aplicar algoritmos derivados dos utilizados neste trabalho, como *NRS-Boundary SMOTE* (HU; LI, 2013) ou algoritmos genéticos para ajuste de hiperparâmetros (FROHLICH; CHAPELLE; SCHOLKOPF, [s.d.]). Além disso, iremos utilizar Redes Neurais (RN) para classificar e prever as propriedades mecânicas usando os dados de origem da curva tensão e deformação e os parâmetros de processamento para entender como o processo poderá ser otimizado se os parâmetros de processamento forem alterados, e se estes dados poderão ser usados para melhor estimativa de parâmetros para a simulação computacional e futuramente avançar para modelos de geometria mais complexos. Além disso poderão ser utilizadas Redes Generativas Adversariais (RGA) para gerar novas amostras, suprindo assim a falta de dados experimentais por causa da pandemia da COVID-19.

3 CONCLUSÕES Os resultados de ensaio mecânico mostraram a anisotropia inerente a esse processo, que depende dos parâmetros de energia e da orientação da impressão e como a taxa de resfriamento influencia no comportamento da curva tensão deformação, principalmente na direção Z. ML conseguiu classificar as propriedades do PA quanto à orientação impressa com um *F1-score* acima de 90,92%, principalmente quando o algoritmo utilizado foi o KNN (que atingiu 97,88%) Apesar do trabalho ter sido iniciado no início deste ano e termos sofrido o impacto da pandemia, os resultados até o momento são promissores para otimizar e prever propriedades mecânicas de PA impresso por manufatura aditiva. Acreditamos que, também, poderá ser

¹ Instituto Nacional de Tecnologia, lucas.barbosa.0899@poli.ufrj.br

² INT, crisevelise@gmail.com

³ Laboratório de Caracterização de Propriedades Mecânicas e Microestruturais, cmicelifarias@gmail.com

⁴ Av. Venezuela, joconnorb@gmail.com

⁵ 82 Praça Mauá. Rio de Janeiro, claudio.santos@int.gov.br

estendido a manufatura de outros materiais. REFERÊNCIAS ALPAYDIN, E. **Introduction to Machine Learning**. [S.l.]: MIT Press, 2009. BROWNLEE, J. **Machine Learning Algorithms from Scratch: With Python**. [S.l.: s.n.], 2017. CAPUANO, G.; RIMOLI, J. J. **Smart finite elements: A novel machine learning application**. **Computer Methods in Applied Mechanics and Engineering**. [S.l.: s.n.]. Disponível em: <<http://dx.doi.org/10.1016/j.cma.2018.10.046>>. , 2019 FERNANDEZ, A. et al. **SMOTE for Learning from Imbalanced Data: Progress and Challenges, Marking the 15-year Anniversary**. **Journal of Artificial Intelligence Research**. [S.l.: s.n.]. Disponível em: <<http://dx.doi.org/10.1613/jair.1.11192>>. , 2018 FROHLICH, H.; CHAPELLE, O.; SCHOLKOPF, B. **Feature selection for support vector machines by means of genetic algorithm**. **Proceedings. 15th IEEE International Conference on Tools with Artificial Intelligence**. [S.l.: s.n.]. Disponível em: <<http://dx.doi.org/10.1109/tai.2003.1250182>>. , [s.d.] GARRETA, R.; MONCECCHI, G. **Learning Scikit-Learn: Machine Learning in Python**. [S.l.]: Packt Publishing Ltd, 2013. 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**. [S.l.: s.n.]. Disponível em: <<http://dx.doi.org/10.1016/j.addma.2018.04.005>>. , 2018 GOH, G. D.; SING, S. L.; YEONG, W. Y. **A review on machine learning in 3D printing: applications, potential, and challenges**. **Artificial Intelligence Review**. [S.l.: s.n.]. Disponível em: <<http://dx.doi.org/10.1007/s10462-020-09876-9>>. , 2020 GOODRIDGE, R. D.; TUCK, C. J.; HAGUE, R. J. M. **Laser sintering of polyamides and other polymers**. **Progress in Materials Science**. [S.l.: s.n.]. Disponível em: <<http://dx.doi.org/10.1016/j.pmatsci.2011.04.001>>. , 2012 HERLOCKER, J. L. et al. **An algorithmic framework for performing collaborative filtering**. **Proceedings of the 22nd annual international ACM SIGIR conference on Research and development in information retrieval - SIGIR '99**. [S.l.: s.n.]. Disponível em: <<http://dx.doi.org/10.1145/312624.312682>>. , 1999 HOFLAND, E. C.; BARAN, I.; WISMEIJER, D. A. Correlation of Process Parameters with Mechanical Properties of Laser Sintered PA12 Parts. **Advances in Materials Science and Engineering**, v. 2017, 28 fev. 2017. Disponível em: <<https://www.hindawi.com/journals/amse/2017/4953173/>>. Acesso em: 30 out. 2020. HU, F.; LI, H. A Novel Boundary Oversampling Algorithm Based on Neighborhood Rough Set Model: NRSBoundary-SMOTE. **Mathematical Problems in Engineering**, v. 2013, 11 nov. 2013. Disponível em: <<https://www.hindawi.com/journals/mpe/2013/694809/>>. Acesso em: 31 out. 2020. LANGLEY, P. **Elements of Machine Learning**. [S.l.]: Morgan Kaufmann, 1996. LUCASBARBOSA. [lucasbarbosa/INT](https://github.com/lucasbarbosa/INT). Disponível em: <<https://github.com/lucasbarbosa/INT>>. Acesso em: 31 out. 2020. MANI, M. et al. **Measurement Science Needs for Real-time Control of Additive Manufacturing Powder Bed Fusion Processes**. [S.l.: s.n.]. Disponível em: <<http://dx.doi.org/10.6028/nist.ir.8036>>. , 2015 MARUOTTI, A.; ROCCI, R. A Mixed Non-Homogeneous Hidden Markov Model for Categorical Data, with Application to Alcohol Consumption. **Statistics in Medicine**, v. 31, n. 9, p. 871-886, 30 abr. 2012. WU, M. et al. **Detecting Malicious Defects in 3D Printing Process Using Machine Learning and Image Classification**. **Volume 14: Emerging Technologies; Materials: Genetics to Structures; Safety Engineering and Risk Analysis**. [S.l.: s.n.]. Disponível em: <<http://dx.doi.org/10.1115/imece2016-67641>>. , 2016 WU, M.; SONG, Z.;

¹ Instituto Nacional de Tecnologia, lucas.barbosa.0899@poli.ufrj.br

² INT, crisevelise@gmail.com

³ Laboratório de Caracterização de Propriedades Mecânicas e Microestruturais, cmicelifarias@gmail.com

⁴ Av. Venezuela, joconnorb@gmail.com

⁵ 82 Praça Mauá. Rio de Janeiro, claudio.santos@int.gov.br

MOON, Y. B. **Detecting cyber-physical attacks in CyberManufacturing systems with machine learning methods.** *Journal of Intelligent Manufacturing*. [S.l: s.n.]. Disponível em: <<http://dx.doi.org/10.1007/s10845-017-1315-5>>. , 2019

PALAVRAS-CHAVE: Inteligência Artificial, Machine Learning, Manufatura Aditiva, Propriedades Mecânicas, SLS

¹ Instituto Nacional de Tecnologia, lucas.barbosa.0899@poli.ufrj.br

² INT, crisevelise@gmail.com

³ Laboratório de Caracterização de Propriedades Mecânicas e Microestruturais, cmicelifarias@gmail.com

⁴ Av. Venezuela, joconnorb@gmail.com

⁵ 82 Praça Mauá, Rio de Janeiro, claudio.santos@int.gov.br