

CARACTERIZAÇÃO DE METAL PARTICULADO USANDO BAG OF VISUAL WORDS

Juan Pablo do Nascimento Vale^{1,2}, Christian Prado dos Santos Machado³, Alex Oliveira Barradas Filho^{2,4}

¹Instituto Federal do Maranhão, Imperatriz, Brasil (juan.vale@ifma.edu.br)

²Laboratório de Análise de Dados e Inteligência Artificial – DARTi Lab, São Luís, Brasil

³Universidade Federal de Minas Gerais, Belo Horizonte, Brasil

⁴Universidade Federal do Maranhão, São Luís, Brasil

Resumo: Introdução: Os particulados de metal podem ser utilizados em processos de fabricação como conformação, metalurgia do pó e manufatura aditiva. O trabalho com particulados está sujeito à diversas dificuldades relacionadas à qualidade do particulado, e um dos aspectos que tem despertado maior interesse é a morfologia do pó, que visa caracterizar os particulados de acordo com o formato, textura e tamanho médio das partículas. Apesar de métodos mecânicos de categorização de particulados já sejam empregados, particulados com diâmetros muito pequenos podem inviabilizar o uso de peneiras e requisitar processos de identificação visual através de microscopia. **Objetivo:** Este estudo tem como objetivo o desenvolvimento de um software de visão computacional capaz de diferenciar diferentes categorias de particulados metálicos a partir de imagens de microscópio eletrônico de varredura. **Materiais:** A base de dados foi composta por imagens artificiais de particulado metálico que simula fotografias de um microscópio eletrônico de varredura, contendo 2048 imagens, divididas igualmente em 8 categorias de particulado. Para desenvolvimento do software foi utilizada a linguagem Python 3.7, as bibliotecas de visão computacional OpenCV e de aprendizagem de máquina Sci-kit Learn. **Métodos:** O pipeline de análise é composto por um método multi-etapa de extração de características chamado Bag of Visual Words (BoVW) seguido de um método de classificação de aprendizagem de máquina. Durante o treinamento, o BoVW utiliza algoritmo SIFT para extração características das imagens depois utiliza o método de clusterização K-means para gerar um “dicionário” com as principais características extraídas. Na etapa de inferência utiliza-se o codebook para transformar as novas imagens em vetores de características. Para a classificação, foram comparados três algoritmos de aprendizagem de máquina: SVM (Support Vector Machines), kNN (k-Nearest Neighbors) e Random Forest. **Resultados:** A base de dados foi dividida em três grupos: 640 imagens para treino, 384 imagens para validação e 1024 imagens para os testes. O método K-means foi configurado para gerar 100 agrupamentos. Todos os classificadores performaram melhor com uso de imagens em escala de cinza, e somente o modelo Random Forest foi beneficiado pelo uso de Standard Scaler. O melhor resultado foi atingido utilizando o classificador SVM com acurácia de 84% na validação e 82% no teste. Os códigos utilizados neste trabalho estão disponíveis em https://github.com/juanjpnv/ParticleMetal_BoVW.

Palavras-chave: Metais particulados, Bag of Visual Words, Machine Learning, Visão computacional

INTRODUÇÃO

Um pó, ou material particulado, pode ser definido como um sólido em partículas finitamente divididas (GROOVER, 2018). A utilização dos materiais particulados e granulados são um campo de interesse da engenharia, pois processos de fabricação baseados em particulados são comuns entre os metais, cerâmicas e polímeros (CHATHAM; LONG; WILLIAMS, 2019; DIENER; ZOCCA; GÜNSTER,

2021; FRANCIS, 2016). Os particulados são a matéria prima em processos de conformação e metalurgia do pó (MP). Técnicas de manufatura do pó não são novas, mas o avanço da tecnologia trouxe novas maneiras de se trabalhar com pós, como manufatura à laser e a manufatura aditiva (BRITO; MEDEIROS; LOURENÇO, 2007).

Existem diversas dificuldades associadas ao trabalho com particulados, porém, um dos aspectos que tem

despertado interesse é a morfologia do pó, no que diz respeito ao seu formato, tamanho médio das partículas e textura. Com base nesses fatores, é possível ter um maior controle sobre o empacotamento das partículas, decidindo se é vantajoso modificar a densidade do particulado através do preenchimento dos poros e espaços vazios. Partículas esféricas, ou aproximadamente esféricas, possuem uma maior densidade de empacotamento o que está diretamente ligado à interface entre as partículas e consequentemente à sinterização (BRAGA; FERREIRA; CAIRO, 2007).

A classificação dos pós pode ser feita através de processos mecânicos, a forma mais comum é a passagem do particulado por peneiras com malhas sucessivamente menores, separando os particulados por seu tamanho e geometria. Nos casos em que existe a necessidade de avaliar a geometria e morfologia do pó, é possível realizar uma análise visual do particulado com auxílio de técnicas de microscopia (GROOVER, 2018). As dificuldades surgem quando as partículas possuem tamanhos muito pequenos que inviabilizam o uso de peneiras, e quando são muito semelhantes e dificultam a identificação visual. Uma possível solução é o uso de técnicas de visão computacional aplicadas à microscopia (RIBEIRO; SHAH, 2006), para automatizar e otimizar a classificação dos particulados.

Visão computacional é um conjunto de técnicas combinadas de inteligência artificial, processamento de imagem, matemática e computação, com o objetivo de extrair informações do mundo real a partir de imagens. Para analisar automaticamente o conteúdo de uma imagem é possível utilizar técnicas de processamento digital de imagem, que são capazes de converter uma imagem em um vetor matemático, possibilitando o uso de algoritmos de inteligência artificial (SZELISKI, 2022).

Atualmente, a aprendizagem de máquina é uma das principais técnicas de inteligência artificial, pois possibilita a geração de modelos de predição através do treino por exemplos (FACELI *et al.*, 2021). A aprendizagem de máquina já vem sendo aplicada em estudos das propriedades mecânicas, eletrônicas e termodinâmicas de materiais, e também já é utilizadas em muitos campos de aplicação como: materiais para armazenamento de energia, supercondutores, termoeletrônicos, catalisadores, fotovoltaicos, e até em estudos de ligas metálicas (WANG *et al.*, 2020). Na ciência dos materiais, a aprendizagem de máquina já vem sendo utilizada para auxiliar na detecção, análise e desenvolvimento de novos materiais (WEI *et al.*, 2019) e na modelagem de novas ligas metálicas (HART *et al.*, 2021).

Em engenharia de minas, já se utilizou visão computacional para analisar a distribuição de tamanho

de partículas de rocha fragmentada (YANG *et al.*, 2021). Em engenharia de materiais, pesquisadores já analisam materiais através de técnicas de inteligência artificial e processamento digital de imagem para identificar estruturas e avaliar as correlações entre microestruturas e o desempenho do material (GE *et al.*, 2020), também já se usou visão computacional para analisar e caracterizar as microestruturas de materiais (HOLM *et al.*, 2020), e para realizar inspeção visual para detecção de defeitos em painéis de cerâmica (HOCENSKI; MATIĆ; VIDOVIĆ, 2016).

Já existem estudos que se dedicam diretamente ao problema da classificação dos particulados metálicos utilizando visão computacional. Já existe base de dados dedicada ao estudo dos particulados metálicos, contendo imagens com diferentes categorias de particulados (DECOST; HOLM, 2016). Os mesmos autores analisaram a base de dados através do método de processamento de imagens *Bag of Visual Words* (BoVW) para classificar o particulado metálico com acurácia de 89%, contudo, o estudo utiliza apenas um único método de classificação, além de utilizar o software proprietário MATLAB, e fazer uso de uma implementação proprietária do algoritmo de extração de característica (DECOST; HOLM, 2017).

Considerando a possibilidade de utilizar visão computacional para classificação de particulados metálicos, e das limitações do estudo proposto por (DECOST; HOLM, 2017), este estudo pretende utilizar o método de processamento de imagens *Bag of Visual Words* e comparar seu desempenho quando aplicado com os diferentes métodos de aprendizagem de máquina: *Support Vector Machines* (SVM), *Random Forests* (RF) e *k-Nearest Neighbors* (kNN).

Dessa forma, este estudo traz uma nova perspectiva sobre a análise realizada por (DECOST; HOLM, 2017) adicionando uma comparação com outros algoritmos de classificação, trazendo uma implementação *open-source* do algoritmo BoVW, empregando a linguagem livre Python, e utilizando implementações de código-aberto de todos os algoritmos.

MATERIAL E MÉTODOS

A base de dados estudada consiste em imagens artificiais que simulam fotografias de pó metálico em um microscópio eletrônico de varredura, renderizadas no software Blender. No total, a base de dados conta com 2048 imagens sintéticas, com resolução de 512×512 pixels, representando 8 classes diferentes de particulados de metal, igualmente divididas com 256 imagens para cada classe.

As classes de particulado são diferenciadas entre si pela Distribuição de Tamanho das Partículas (PSD, na sigla em inglês), onde o tamanho de cada partícula

individual flutua randomicamente ao redor de um valor predeterminado (DECOST; HOLM, 2016). Na Figura 1 são ilustrados exemplos de cada uma das classes de metal particulado.




Figura 1. Exemplos das 8 classes de metal particulado da base de dados. Adaptado de (DECOST; HOLM, 2016)

O Bag of Visual Words (FEI-FEI; PERONA, 2005) pode ser entendido como um método de extração de características de múltiplas etapas, cujo fluxo de trabalho é ilustrado na Figura 2. Inicialmente utiliza-se um algoritmo mais simples de extração de características para gerar descrições matemáticas das imagens de treino, estes descritores são tratados como “palavras” pelo método. Através de um método de clusterização, as “palavras” são aglomeradas em diferentes grupos, de acordo com seu nível de semelhança, e a palavra central de cada grupo é selecionada para compor o Codebook, um conjunto de palavras que é utilizado para resumir todas as descrições matemáticas.

Na terceira etapa é feita uma nova representação das imagens de treino, utilizando histogramas de frequência conta-se quantas vezes cada palavra do Codebook aparece na descrição matemática de cada imagem. Esta representação final é o resultado do BoVW, que é então passado ao método de aprendizagem de máquina escolhido.

Durante o treino, as imagens passam pelo processo de extração de características e são entregues ao modelo de clusterização, onde é construído o Codebook, que em outras palavras consiste em selecionar o membro central de cada um dos agrupamentos gerados. Em seguida, o Codebook é usado para representar as imagens de treino, e com esta nova representação é treinado o classificador. Ambos, Codebook e

classificador, após treinados, serão usados na etapa de inferência para classificar novas imagens.




Figura 2. Fluxograma de treino e inferência do algoritmo Bag of Visual Words. Adaptado de (FEI-FEI; PERONA, 2005)

A etapa de inferência consiste em extrair a descrição matemática e comparar com o Codebook formado durante o treino, gerando a representação final da imagem. O já treinado modelo de classificação recebe a representação da imagem e diz a qual classe determinada imagem pertence.

Internamente ao BoVW, aplica-se o método SIFT para a extração de características e o método de clusterização K-Means para construção do Codebook. Os modelos de classificação avaliados são o Support Vector Machines (SVM), k-Nearest Neighbors (kNN) e Random Forest (RF) e são otimizados utilizando Grid Search e validação k-Fold. O algoritmo é desenvolvido em Python, utilizando a biblioteca de visão computacional OpenCV e a biblioteca de aprendizagem de máquina Sci-Kit Learn (BRADSKI, 2000; PEDREGOSA et al., 2011). O treinamento, testes e validações dos algoritmos foi realizado em uma instância da plataforma Google Colab.

RESULTADOS E DISCUSSÃO

Seguindo as boas práticas de aprendizagem de máquina, a base de dados é dividida em três grupos: 640 imagens foram destinadas ao treino do BoVW e dos classificadores, 384 imagens foram destinadas aos processos de validação onde os classificadores foram otimizados, e 1024 imagens foram destinadas a etapa de testagem. A quantidade de imagens em cada grupo segue a divisão proposta por (DECOST; HOLM, 2017).

Foram desenvolvidas algumas variações nos experimentos realizados. A primeira bateria de experimentos utilizou imagens coloridas em escala BGR. A segunda bateria também utilizou imagens coloridas e aplica um processo conhecido como Standard Scaler para escalonar as representações matemáticas das imagens. A terceira bateria de experimentos utiliza imagens em escala de cinza. Em cada uma destas baterias os classificadores são submetidos a um processo de otimização de diversos hiper-parâmetros. Em todos os casos o método K-Means foi configurado para gerar 100 agrupamentos. A acurácia final de validação e teste para cada uma das baterias de experimentos podem ser vistas na Tabela 1. **Erro! Fonte de referência não encontrada..** Os detalhes da classificação são ilustrados em forma de matriz de confusão na Figura 3.

Tabela 1. Acurácia dos classificadores otimizados

Modelo	SVM	kNN	RF
Imagens escala de cinza	V: 84% T: 82%	V: 79% T: 79%	V: 82% T: 81%

Imagens coloridas	V: 78% T: 77%	V: 78% T: 77%	V: 78% T: 77%
Utilizando Standard Scaler	V: 78% T: 77%	V: 78% T: 79%	V: 81% T: 81%




Figura 3. Matriz de confusão do teste. Imagens em escala de cinza. Classificadores Otimizados

Nota-se que o melhor desempenho para teste e classificação é para imagens em escala de cinza utilizando classificador SVM, o que é compatível com o trabalho de (DECOST; HOLM, 2017). Isto é esperado, uma vez que não há grande variação entre

as imagens coloridas e em escala de cinza, e por ter menos canais para serem trabalhados o método SIFT pode gerar descritores mais representativos. Percebe-se também que o uso do Standard Scaler degrada significativamente o desempenho dos classificadores SVM e kNN. Contudo o classificador Random Forest consegue uma leve melhoria em seu desempenho na base de testes com uso do Standard Scaler. Na Figura 3 percebe-se que alguns pares de classes apresentam certas semelhanças que dificultam os trabalhos dos classificadores, são eles: c–d, e–g e o f–h.

CONCLUSÃO

Este artigo se propôs a desenvolver uma implementação de código aberto do algoritmo Bag Visual Worlds para ser aplicado juntamente com modelos de aprendizagem de máquina para a classificação de imagens de particulados metálicos. Os resultados desse estudo mostram que os métodos empregados foram capazes de classificar com sucesso as diferentes classes de particulados.

De forma geral, o método SVM mostrou o melhor desempenho, atingindo 82% de acurácia com imagens em escala de cinza, seguido dos métodos RF e kNN.

Entre as diferentes formas de entregar imagens ao método, a melhor entrada de dados são as imagens em escala de cinza, pois reduzem o consumo de memória, exigem menos poder computacional e atinge o melhor desempenho com o modelo SVM.

Entre os modelos desenvolvidos, o que melhor generaliza os dados é o SVM, entretanto, o modelo Random Forest não pode ser ignorado, pois também apresenta boa acurácia. Nota-se que uso do Standard Scaler não é recomendável para o método de BoVW.

Neste trabalho, ofereceu-se uma breve perspectiva sobre o modelo de Bag of Visual Words, mostrando seu desempenho com três classificadores otimizados. Os códigos implementados neste trabalho estão disponíveis online na plataforma GitHub na URL: https://github.com/juanjpnv/ParticleMetal_BoVW.

AGRADECIMENTOS

Agradeço aos companheiros do DARTi Lab (UFMA), pelas periódicas trocas de ideais e experiências que ajudaram no desenvolvimento deste artigo.

REFERÊNCIAS

BRADSKI, G. The OpenCV Library. **Dr. Dobb's Journal of Software Tools**, [s. l.], 2000.

BRAGA, Neila de Almeida; FERREIRA, Neidenê Gomes; CAIRO, Carlos Alberto Alves. Obtenção de titânio metálico com porosidade controlada por metalurgia do pó. **Química Nova**, [s. l.], v. 30, p. 450–457, 2007.

BRITO, Francisco Iranylson Gomes de; MEDEIROS, Katarine F.; LOURENÇO, Jorge Magner. Um estudo teórico sobre a sinterização na metalurgia do pó. **HOLOS**, [s. l.], v. 3, n. 0, p. 204–211, 2007.

CHATHAM, Camden A.; LONG, Timothy E.; WILLIAMS, Christopher B. A review of the process physics and material screening methods for polymer powder bed fusion additive manufacturing. **Progress in Polymer Science**, [s. l.], v. 93, p. 68–95, 2019.

DECOST, Brian L.; HOLM, Elizabeth A. A large dataset of synthetic SEM images of powder materials and their ground truth 3D structures. **Data in Brief**, [s. l.], v. 9, p. 727–731, 2016.

DECOST, Brian L.; HOLM, Elizabeth A. Characterizing powder materials using keypoint-based computer vision methods. **Computational Materials Science**, [s. l.], v. 126, p. 438–445, 2017.

DIENER, Sarah; ZOCCA, Andrea; GÜNSTER, Jens. Literature review: Methods for achieving high powder bed densities in ceramic powder bed based additive manufacturing. **Open Ceramics**, [s. l.], v. 8, p. 100191, 2021.

FACELI, Katti *et al.* **Inteligência artificial: uma abordagem de aprendizado de máquina**. 2. ed. Rio de Janeiro: Grupo Gen - LTC, 2021.

FEI-FEI, L.; PERONA, P. A Bayesian hierarchical model for learning natural scene categories. *Em: 2005 IEEE COMPUTER SOCIETY CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR'05)*, 2005, San Diego, California. **2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)**. San Diego, California: IEEE, 2005. p. 524–531 v. 2.

FRANCIS, Lorraine F. Powder Processes. *Em: FRANCIS, Lorraine F. (org.). Materials Processing*. Boston: Academic Press, 2016. p. 343–414. *E-book*. Disponível em: <https://www.sciencedirect.com/science/article/pii/B9780123851321000057>. Acesso em: 24 mar. 2023.

GE, M. *et al.* Deep learning analysis on microscopic imaging in materials science. **Materials Today Nano**, [s. l.], v. 11, p. 100087, 2020.

GROOVER, Mikell P. **Introdução aos processos de fabricação**. Tradução: Ana Carla Araujo. 1. ed. Rio de Janeiro (RJ): LTC, 2018.

HART, Gus L. W. *et al.* Machine learning for alloys. **Nature Reviews Materials**, [s. l.], v. 6, n. 8, p. 730–755, 2021.

HOCENSKI, Željko; MATIĆ, Tomislav; VIDOVIĆ, Ivan. Technology transfer of computer vision defect detection to ceramic tiles industry. *Em*: 2016 INTERNATIONAL CONFERENCE ON SMART SYSTEMS AND TECHNOLOGIES (SST), 2016. **2016 International Conference on Smart Systems and Technologies (SST)**. [S. l.: s. n.], 2016. p. 301–305.

HOLM, Elizabeth A. *et al.* Overview: Computer Vision and Machine Learning for Microstructural Characterization and Analysis. **Metallurgical and Materials Transactions A**, [s. l.], v. 51, n. 12, p. 5985–5999, 2020.

PEDREGOSA, Fabian *et al.* Scikit-learn: Machine Learning in Python. **Machine Learning in Python**, [s. l.], p. 6, 2011.

RIBEIRO, Eraldo; SHAH, Mubarak. Computer Vision for Nanoscale Imaging. **Machine Vision and Applications**, [s. l.], v. 17, n. 3, p. 147–162, 2006.

SZELISKI, Richard. **Computer Vision: Algorithms and Applications**. 2. ed. Cham: Springer Nature, 2022. (Texts in computer science).

WANG, Anthony Yu-Tung *et al.* Machine Learning for Materials Scientists: An Introductory Guide toward Best Practices. **Chemistry of Materials**, [s. l.], v. 32, n. 12, p. 4954–4965, 2020.

WEI, Jing *et al.* Machine learning in materials science. **InfoMat**, [s. l.], v. 1, n. 3, p. 338–358, 2019.

YANG, Zhen *et al.* Superpixel Image Segmentation-Based Particle Size Distribution Analysis of Fragmented Rock. **IEEE Access**, [s. l.], v. 9, p. 59048–59058, 2021.