

APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA ANÁLISE DE BIOCOMPÓSITO

Autor(es): Arthur Brito Gomes¹ ; Audelis de Oliveira Marcelo Júnior²

¹ Engenharia Civil, CCET, UVA; E-mail: arthurbg951@hotmail.com,

² Docente, CCET, UVA. E-mail: oliveira_marcelo@uvanet.br.

Resumo: Estudos de novos materiais acessíveis e menos poluentes são fundamentais. Nesse contexto, os polímeros se destacam como alternativas sustentáveis. No entanto, a análise de suas propriedades é desafiadora, exigindo especialização. Além disso, a influência de várias variáveis no modelo, juntamente com a falta de precisão nas análises das características do material, contribui para a baixa precisão nas previsões das propriedades mecânicas. Portanto, este estudo explora o uso de técnicas de Visão Computacional (CV) e Inteligência Artificial (IA) para avaliar as propriedades de um polímero reforçado com fibras de sisal e matriz de quitosana. O trabalho descreve o uso das técnicas K-Means, Mask-RCNN e U-Net para desenvolver um modelo computacional com base em imagens, visando verificar com maior precisão as propriedades mecânicas do compósito.

Palavras-chave: Visão Coputacional, Inteligência Artificial, Propriedades Mecânicas e Polímeros.

INTRODUÇÃO

O campo de estudo que descreve a capacidade das máquinas de aprender como os humanos pode ser definido como Inteligência Artificial (IA). Desde que foi impulsionado pelo mercado, os campos da tecnologia e dos negócios mudaram rapidamente (Alsedrah, 2017). Portanto, este trabalho buscou aplicar as técnicas deste campo de estudo em polímeros, pois apresenta um alto potencial de mudanças na forma de avaliar esses materiais. Dentre diversas técnicas, destacam-se os algoritmos K-Means e Redes Neurais.

K-Means é um procedimento iterativo que particiona N objetos em K clusters distintos. É um método de agrupamento relevante na literatura que utiliza centroides para apresentar *clusters* (Oti et al., 2021). É comum utilizar a distância euclidiana como parâmetro para definir a proximidade entre cada entrada de dados.

A rede neural artificial é uma técnica de computação projetada para simular o cérebro humano na resolução de problemas (Zayegh & Al Bassam, 2018). Deep Learning (DL) é uma divisão do *Machine Learning* (ML) que se baseia em um conjunto de algoritmos que tentam modelar abstrações de alto nível em dados. Esses algoritmos desenvolvem uma arquitetura hierárquica em camadas de aprendizagem e representação de dados. Esta arquitetura de aprendizagem hierárquica é inspirada na IA que emula o processo de aprendizagem do cérebro humano (Hordri et al., 2021). É comum a utilização de redes neurais na área de visão computacional para segmentação de imagens. Dentre os algoritmos mais utilizados, podemos citar Mask-RCNN e U-Net.

Mask R-CNN é uma arquitetura de rede neural convolucional que combina técnicas de segmentação de objetos com detecção de objetos, conforme evidenciado por He et al. (2020). A segmentação envolve a identificação individual de cada objeto em uma imagem, enquanto a detecção se concentra no reconhecimento de instâncias desses objetos desenhando uma máscara em torno deles.

Por outro lado, U-Net é uma arquitetura de rede neural convolucional conhecida por seu sucesso na segmentação de imagens biomédicas, conforme evidenciado por Ronneberger et al. (2015). Klein et al. (2018) trabalharam com sua aplicação em ossos corporais a partir de imagens de tomografia computadorizada. Porém, outros estudos mostraram que a rede pode ser utilizada em diversas situações. Maksov et al. (2019) e Chen et al. (2021) utilizaram U-Net na área de materiais, como segmentação de átomos e segmentação de texturas. Além disso, Sharma et al. (2022) discute trabalhos



UNIVERSIDADE ESTADUAL
VALE DO ACARAÚ

Pró-Reitoria de Pesquisa e Pós-Graduação - PRPPG



CEARÁ
GOVERNO DO ESTADO
SECRETARIA DA CIÊNCIA, TECNOLOGIA
E EDUCAÇÃO SUPERIOR

que aplicaram técnicas de ML em compósitos nos quais não apenas limites podem ser previstos em testes de fadiga, flambagem, compressão e impacto de queda, mas também contribuíram para o projeto de materiais além de reduzir o esforço computacional durante os cálculos.

A indústria busca constantemente novos materiais menos prejudiciais ao meio ambiente, disponíveis na natureza e com propriedades comparáveis ou superiores às existentes. Assim, surgiu o interesse em usar um polímero composto por filme de quitosana reforçado com fibra de sisal na caracterização de materiais, utilizando as técnicas mencionadas. É importante ressaltar que o trabalho está em andamento, com foco na criação de modelos treinados para segmentar as fibras, o que é essencial para calcular o módulo de elasticidade fibra-matriz em polímeros.

MATERIAL E MÉTODOS

O conjunto de dados usado inclui 15 imagens de um compósito de matriz de quitosana reforçada com fibras de sisal, que serviram para treinar uma rede neural na segmentação de fibras. Utilizou-se de redes supervisionadas, cuja as regiões de interesse foram delimitadas previamente.

A rede neural identifica padrões automaticamente, ajustando os pesos por meio de processos de *feed forward* e *backpropagation*. O *feed forward* calcula a probabilidade de cada pixel conter um objeto, com pesos iniciais aleatórios. A etapa de *backpropagation* verifica a consistência dos pesos, comparando os resultados com as delimitações do supervisor e ajustando os pesos para minimizar o erro.

Durante o treinamento, podem ocorrer problemas como *overfitting* (ajuste excessivo) ou *underfitting* (ajuste insuficiente), dependendo dos dados utilizados. *Overfitting* ocorre quando a rede se ajusta demasiadamente aos dados, muitas vezes devido a um treinamento prolongado. Por outro lado, *underfitting* ocorre quando a rede não foi treinada o suficiente ou devido à falta de dados de treinamento adequados.

Para lidar com a falta de diversidade nas imagens, aplicamos uma técnica de aumento de dados que envolve a aplicação de filtros e regras a cada pixel da imagem. Utilizou-se a biblioteca *Albumentations*, que oferece várias classes, incluindo *HorizontalFlip*, *VerticalFlip*, *ElasticTransform*, *GridDistortion* e *OpticalDistortion*. Essa abordagem resultou em um total de 75 imagens usadas tanto no treinamento quanto na validação dos modelos.

No desenvolvimento deste trabalho, empregamos três técnicas de inteligência artificial: K-Means, U-Net e Mask-RCNN. K-Means, embora não seja um algoritmo de aprendizado profundo como as outras redes mencionadas, é usado para segmentar informações semelhantes com base na distância euclidiana. A U-Net, por outro lado, possui uma arquitetura com três componentes principais: bloco convolucional, bloco codificador e bloco decodificador. O bloco convolucional gera imagens baseadas em uma matriz de valores aleatórios, o codificador aplica o pooling máximo, e o decodificador reverte o processo de pooling máximo.

Além disso, conforme apresentado por [5], o Mask R-CNN estende o Faster R-CNN para prever máscaras de segmentação em cada região de interesse (RoI), ao lado da classificação e regressão de caixa delimitadora. O ramo da máscara utiliza um pequeno *Fully Convolutional Network* (FCN) para prever máscaras de segmentação pixel a pixel.

RESULTADOS

Tanto a técnica K-Means quanto a Mask-RCNN não alcançaram resultados satisfatórios na segmentação das fibras. O K-Means apresentou um excesso de ruído nos *clusters*, enquanto a Mask-RCNN demonstrou sinais de *underfitting*. No entanto, a abordagem com U-Net se destacou, proporcionando resultados altamente promissores. As Figuras 1 e 2 ilustram, respectivamente, as fibras reais em uma amostra e as previsões geradas pela rede. Para uma avaliação mais precisa, foram calculadas métricas de desempenho.



Figura 1 – Fibras da amostra 7453_1



Figura 2 – Fibras previstas pela rede neural 7453_1

Conforme destacado na Tabela 1, a métrica de *Pixel Accuracy* (PA) revelou-se insuficiente para a validação do modelo durante o treinamento, uma vez que pode indicar um alto nível de precisão sem necessariamente refletir uma segmentação criteriosa. No entanto, ao observar as métricas de Índice de Jaccard (IoU) e *Dice coefficient* (DC), fica evidente que os pesos da rede neural se ajustaram de maneira mais eficaz à segmentação necessária. Esse fato é corroborado pela média aceitável alcançada por essas métricas, sublinhando o desempenho da U-Net.

Tabela 1 – Métricas para cada imagem

Imagem	PA	IOU	DC
7441_5	0.98	0.74	0.68
7465_4	0.98	0.77	0.71
7443_1	0.98	0.76	0.71
7441_1	0.96	0.71	0.63
7453_1	0.99	0.78	0.72
7465_2	0.98	0.77	0.72
7451_4	0.99	0.75	0.68
7443_3	0.95	0.74	0.71
Média	0.98	0.75	0.69

CONCLUSÃO

A utilização de técnicas de Inteligência Artificial se mostra como uma abordagem robusta para a otimização do processo de caracterização de polímeros, e as técnicas aqui apresentadas têm o potencial de contribuir significativamente para a automatização desse processo. No entanto, ao longo deste estudo, os algoritmos K-Means e Mask-RCNN não apresentaram evidências suficientes para justificar sua utilização, especialmente na segmentação das fibras, que não obteve resultados consistentes. Vale ressaltar que a rede Mask-RCNN pode ser refinada, uma vez que observamos indícios de ajustes inadequados de pesos durante o treinamento, sugerindo a possibilidade de *underfitting*. Por outro lado,



UNIVERSIDADE ESTADUAL
VALE DO ACARAÚ

Pró-Reitoria de Pesquisa e Pós-Graduação - PRPPG



CEARÁ
GOVERNO DO ESTADO
SECRETARIA DA CIÊNCIA, TECNOLOGIA
E EDUCAÇÃO SUPERIOR

o algoritmo U-Net se destacou como uma promissora alternativa para a caracterização de materiais, mantendo métricas rigorosas em níveis de precisão interessantes, mesmo com um conjunto de dados relativamente pequeno, atingindo médias de 75% de IoU e 69% de DC. À medida que este trabalho continua em desenvolvimento, a obtenção de informações cruciais, como o módulo de elasticidade do polímero, permanece pendente, uma vez que exige a segmentação das fases da matriz. Este estudo concentrou-se nas fibras, devido à complexidade dessa tarefa. No entanto, esperamos que em futuras etapas do projeto, seja possível empregar ferramentas com Método dos Elementos Finitos para simular o comportamento mecânico do material, ampliando assim o alcance e a aplicabilidade dessas técnicas.

AGRADECIMENTOS

Expresso minha gratidão à Polymar Ciência e Nutrição S/A, sediada em Fortaleza, Brasil, pela generosa contribuição ao fornecer as amostras essenciais para a realização deste estudo. Também, gostaria de estender meus agradecimentos ao professor Audelis pelo apoio e incentivo constantes ao longo da pesquisa.

REFERÊNCIAS

- Chen D, Sun D, Fu J, Liu S (2021) Semi-Supervised Learning Framework for Aluminum Alloy Metallographic Image Segmentation. IEEE Access 9:30858–30867. <https://doi.org/10.1109/ACCESS.2021.3059505>.
- He K, Gkioxari G, Dollár P, Girshick R (2020) Mask R-CNN. IEEE Trans Pattern Anal Mach Intell 42:386–397. <https://doi.org/10.1109/TPAMI.2018.2844175>.
- Hordri NF, Yuhaniz SS, Shamsuddin SM (2021) Deep Learning and its Applications. Nova Science Publishers.
- Klein A, Warszawski J, Hillengaß J, Maier-Hein KH (2018) Towards whole-body CT bone segmentation. In: Informatik aktuell. pp 204–209.
- Maksov A, Dyck O, Wang K, et al (2019) Deep learning analysis of defect and phase evolution during electron beam-induced transformations in WS₂. npj Comput Mater 5:12. <https://doi.org/10.1038/s41524-019-0152-9>.
- Mariam Khalid Alsedrah, "Artificial Intelligence," American University of Middle East, Middle East, Research DOI: 10.13140/RG.2.2.18789.65769, 2017.
- Oti EU, Olusola MO, Eze FC, Enogwe SU (2021) Comprehensive Review of K-Means Clustering Algorithms. Int J Adv Sci Res Eng 07:64–69. <https://doi.org/10.31695/ijasre.2021.34050>.
- Ronneberger O, Fischer P, Brox T (2015) U-Net: Convolutional Networks for Biomedical Image Segmentation.
- Sharma A, Mukhopadhyay T, Rangappa SM, et al (2022) Advances in Computational Intelligence of Polymer Composite Materials: Machine Learning Assisted Modeling, Analysis and Design. Arch Comput Methods Eng 29:3341–3385. <https://doi.org/10.1007/s11831-021-09700-9>.
- Zayegh A, Al Bassam N (2018) Neural Network Principles and Applications. In: Digital Systems. IntechOpen.