

Análise de Técnicas de *Deep Learning* para a Medição de Fibras Microscópicas

Nicolli Campos Ortlieb
Unioeste
Foz do Iguaçu, Brasil
nicolli.ortlieb@unioeste.br

Claudio Roberto Marquette Mauricio
Unioeste
Foz do Iguaçu, Brasil
claudio.mauricio@unioeste.br

Fabiana Frata Furlan Peres
Unioeste
Foz do Iguaçu, Brasil
fabiana.peres@unioeste.br

Abstract—The main objective of this study is to review and explore advanced instance-level image segmentation techniques based on deep learning. The ultimate purpose is to apply these techniques for the automatic measurement of microscopic polymeric fibers provided by Prof. Dr. Douglas Cardoso Dragunski. The study is grounded in a comprehensive review of existing literature, encompassing algorithms for image segmentation and measurement, both in microscopic and non-microscopic contexts, to inform the development of an innovative solution.

Keywords—Fiber measurement; Deep Learning; Instance-level segmentation.

Resumo—O objetivo principal deste estudo é revisar e explorar técnicas avançadas de segmentação de imagens a nível de instância, com base em aprendizado profundo. O propósito final é aplicar essas técnicas para a medição automática de fibras poliméricas microscópicas fornecidas pelo Prof. Dr. Douglas Cardoso Dragunski. O estudo baseia-se na revisão abrangente da literatura existente, abordando algoritmos de segmentação e medição de imagens, tanto em escala microscópica quanto não, para informar o desenvolvimento de uma solução inovadora.

Palavras-chave—Medição de fibras; Deep Learning; Segmentação de Instância.

I. INTRODUÇÃO

A medição e análise manual de fibras é uma tarefa demorada e custosa [1]. Nesse processo, operadores precisam realizar medidas precisas de propriedades como comprimento, diâmetro e outras características das fibras individualmente, o que pode ser muito trabalhoso. Além disso, a medição manual está sujeita a variações, erros humanos e vieses, dependendo da habilidade e experiência dos operadores. Isso pode resultar em dados inconsistentes e imprecisos, afetando a qualidade das análises e pesquisas que dependem dessas medições.

Portanto, tanto na análise quanto na medição de fibras, a automação e a aplicação de tecnologias modernas podem revolucionar esses campos, tornando-os mais eficientes, econômicos e confiáveis, beneficiando indústrias e pesquisadores que dependem desses processos.

Seguindo essa ideia, o objetivo geral do presente estudo tem sua origem com a proposta do Prof. Dr. Douglas Cardoso

Dragunski de resolver o problema da medição automática de fibras poliméricas microscópicas que, no contexto atual, são medidas manualmente. Foram, então, fornecidas imagens para testes e a elaboração do esboço de uma solução inicial (Figura 1). No entanto, apresentam-se vários desafios à medição automática devido à natureza complexa das fibras em questão, que aparecem sobrepostas umas às outras e oclusas, tornando a segmentação e medição individual desafiadoras.




Fig. 1. Fibra polimérica fornecida para teste.

Diante disso, nas últimas décadas, com o avanço da tecnologia, houve um aumento significativo na aplicação de algoritmos de *Machine Learning* (ML) e *Deep Learning* (DL) para tarefas de visão computacional, especialmente na análise de objetos microscópicos [2] [1] [3] [4] [5] [6] [7] [8]. Nesse contexto, foi realizada uma busca por algoritmos de código aberto dentro do campo da segmentação de imagens com métodos de DL, e foi identificada uma arquitetura específica denominada “FibeR-CNN”, desenvolvida com foco na medição de fibras microscópicas, o que a torna altamente relevante para o estudo



em questão [1].

O estudo prévio de pesquisas relacionadas à análise de objetos, tanto a de Frei e Kruijs [1] como as de Yang et al. [6], Zhang et al. [4] e Triki et al. [5], retornaram o conhecimento de que a arquitetura Mask R-CNN, baseada em *Region-based Convolutional Neural Networks* e extremamente reconhecida pela sua capacidade de segmentação a nível de instância [9], é uma possível candidata para estudos em busca da resolução do problema proposto, principalmente pela capacidade dessa arquitetura de funcionar muito bem mesmo em situações em que as instâncias da imagens se encontram muito próximas umas das outras. Essa arquitetura, então, pode ser aproveitada por meio do técnica chamada de “aprendizado por transferência” [7], que permite que modelos pré-treinados em grandes conjuntos de dados sejam ajustados para tarefas específicas.

Tendo a segmentação de cada fibra a nível de instância sido realizada, a medição da largura e comprimento, por sua vez, é possível de ser obtida através de métodos especialistas na detecção de pontos-chave (*keypoints*), pelo qual o próprio Mask R-CNN é reconhecido [9] e conforme é feito na arquitetura do FibeR-CNN [1]. É possível também de ser realizada através de métodos numéricos e geométricos, os quais outros estudos de medição de imagem também se baseiam, como os de Triki et al. [5] e Zhang et al. [4].

Os próximos tópicos abordarão diversos aspectos cruciais para a compreensão do estudo em questão. Primeiramente, será explorado o conceito de *Deep Learning*, discutindo o porquê dessa abordagem ter sido escolhida como o método central para a medição das fibras microscópicas. Em seguida, a análise se voltará para a segmentação de imagens em nível de instância, explicando por que a seleção de algoritmos capazes de lidar com essa técnica é fundamental para resolver a primeira parte do desafio de medição das fibras. Finalmente, serão examinados estudos prévios relacionados à segmentação e medição de objetos, tanto em escala microscópica quanto não, utilizando técnicas de DL. Esses estudos servirão como ponto de partida crucial para a pesquisa, orientando a exploração de técnicas e o desenvolvimento futuro de um *software* destinado à medição das fibras microscópicas fornecidas pelo Prof. Dr. Douglas Cardoso Dragunski.

II. TÉCNICAS DE DEEP LEARNING

A. *Deep Learning*

Machine Learning, ou Aprendizado de Máquina, em tradução livre, é um subcampo da Inteligência Artificial (IA), que através de conjuntos de métodos (algoritmos) é capaz de aprender a reconhecer padrões e então usar esses padrões para gerar mais dados e/ou tomar decisões a partir de uma base de

dados, sem ter sido previamente programado especificamente para isso [10]. Monard e Baranauskas [11] também descrevem ML como sistemas construídos para aprenderem de modo automático.

Deep Learning, enquadrado no campo de ML, explora a ideia de usar várias camadas (profundidade) para aprender sequências de transformações que mapeiam dados de entrada em representações úteis. DL muitas vezes envolve o uso de camadas que processam uma entrada de forma hierárquica, capturando relações complexas nos dados originais e encontrando representações adequadas para tarefas específicas. Isso é feito usando operações como convoluções, ativações e camadas totalmente conectadas em redes neurais convolucionais, que são amplamente usadas na Visão Computacional [12].

No campo da medição de fibras microscópicas, as técnicas tradicionais envolvem a segmentação manual e a extração de características, sendo suscetíveis a erros e limitadas em sua capacidade de generalização. Em contrapartida, o uso de técnicas de *Deep Learning* oferece automação, precisão e capacidade de generalização, lidando eficazmente com fibras sobrepostas e complexas, como será melhor explicado no tópico a seguir. Essa transição das abordagens tradicionais para o DL representa um avanço significativo com potencial para revolucionar a pesquisa e a indústria que dependem da medição de fibras microscópicas.

B. *Deep Learning na Segmentação de Imagens Microscópicas a Nível de Instância*

No contexto da análise de fibras, a seleção do algoritmo apropriado é particularmente importante quando as fibras se sobrepõem nas imagens [8], pois, nesse caso, uma abordagem incorreta pode levar a informações conflitantes e dificultar a distinção entre as fibras individuais. Nesse cenário, a busca por algoritmos especializados em segmentação, mais especificamente a nível de instância, surge como a abordagem mais eficaz para resolver esse problema, principalmente por se tratar de imagens microscópicas. A eficácia de seu uso já foi demonstrada em estudos por Liu et al. [8], Modarres et al. [3] e Xing et al. [13].

A segmentação por instância é uma técnica avançada de visão computacional que visa identificar e delimitar objetos individuais em imagens, atribuindo a cada objeto uma máscara de instância única. Isso permite não apenas agrupar *pixels* semelhantes em classes, mas também diferenciar objetos pertencentes à mesma classe [7] [8].

A busca por técnicas avançadas de segmentação, permitindo a identificação individual de objetos em imagens, levou à descoberta do Mask R-CNN [3] [4] [5] [6] [7]. Esse método representa uma evolução das redes *Region-based Convolutional Neural Network* (R-CNN), usando regiões de interesse para detecção e segmentação de objetos em imagens [8]. O Faster



R-CNN, uma etapa anterior, unificou geração de propostas e detecção em um único modelo, tornando-se um marco na detecção de objetos. O Mask R-CNN, por sua vez, estende o Faster R-CNN [14] para segmentação de instâncias, identificando *pixels* de objetos. Ele combina detecção e segmentação em paralelo, fornecendo máscaras de segmentação precisas para objetos [15], sendo valioso para objetos complexos e sobrepostos, como fibras microscópicas

É possível concluir, então, que o Mask R-CNN representa um passo adiante na detecção e segmentação de instâncias em imagens, tornando-o um candidato ideal para a tarefa de extrair fibras individuais em imagens de fibras sobrepostas. Sua capacidade de gerar máscaras de segmentação de alta precisão facilita a medição precisa do comprimento e da largura de cada fibra, contribuindo para uma análise mais detalhada e eficaz desses objetos complexos.

C. FibeR-CNN

O FibeR-CNN é uma arquitetura derivada do Mask R-CNN, criada por Frei e Kruijs [1], para melhor lidar com a análise de fibras. Segundo os autores [1], aplicar apenas o Mask R-CNN a imagens de fibras produz máscaras irregulares devido às características finas e curvas das fibras. O FibeR-CNN, então, foi desenvolvido com o propósito de extrair pontos de referência, largura e comprimento das fibras, melhorando a análise automática. De acordo com os autores [1] em seu artigo publicado, o algoritmo desenvolvido demonstrou realizar detecções de alta qualidade, mesmo em cenários com fibras sobrepostas.

A arquitetura do FibeR-CNN inclui uma cabeça de regressão para pontos-chave e duas cabeças para a largura e comprimento das fibras, baseadas no Mask R-CNN. O uso do *framework* "Detectron2", baseado no PyTorch, foi escolhido para implementar essa arquitetura. De acordo com os autores [1], essas adições melhoraram significativamente a precisão do FibeR-CNN, superando o Mask R-CNN em algumas métricas de avaliação.

Em resumo, o FibeR-CNN apresenta-se como uma solução eficaz para a medição de fibras em imagens microscópicas. O próximo passo será um estudo detalhado da arquitetura FibeR-CNN, compreendendo sua estrutura, camadas de rede, hiperparâmetros e métodos de treinamento, para adaptá-lo às necessidades específicas da medição de fibras microscópicas.

D. Demais Arquiteturas

O estudo de Zhang et al. [4] mostra uma arquitetura, o Segfit, também baseada em Mask R-CNN (utilizando o ResNet como *backbone*), desenvolvida para segmentação a nível de instância de microgotículas, para então realizar a análise da distribuição de diâmetros.

O Segfit detecta cada gotícula individualmente na imagem, identificando os *pixels* que pertencem a cada gotícula. Em seguida, ele ajusta uma forma, como uma elipse, em torno de cada gotícula para medir seu tamanho. Isso é feito de forma automatizada e rápida, tornando o processo altamente preciso e eficiente, mesmo em condições complexas, como gotículas sobrepostas ou parcialmente fotografadas.

Triki et al. [5] falam sobre o modelo desenvolvido por autoria própria, o DeepLeaf, que, ainda mais próximo do problema abordado no atual estudo sobre fibras microscópicas, pretende realizar a segmentação e medição das características morfológicas de folhas, incluindo seu comprimento e largura. O algoritmo tem seu *backbone* modificado, utilizando o ResNet com o acréscimo da arquitetura *Feature Pyramid Network* (FPN).

Para a medição das características foi desenvolvido então um método automatizado que mede o comprimento e a largura da folha com base nas coordenadas dos cantos do retângulo de reconhecimento e, em seguida, converte essas medidas em unidades do mundo real usando a calibração da escala.

Yang et al. [6] realizaram um estudo no qual desenvolveram uma ferramenta para identificar e analisar partículas em imagens de materiais granulares, como cascalho e lastro, também utilizando o Mask R-CNN (utilizando o ResNet como *backbone*), por sua capacidade de segmentar instâncias em imagens. Ele utiliza o Detectron2 como *framework* para treinamento, aproveitando-se também do aprendizado por transferência devido ao seu limitado conjunto de imagens para o treino.

Esses estudos reforçam a relevância das abordagens baseadas em Mask R-CNN e redes neurais profundas na automação da segmentação e medição de objetos em uma variedade de cenários, abrindo portas para aplicações promissoras em diversos campos, incluindo a análise de fibras microscópicas, que é o foco central deste estudo.

III. CONCLUSÃO

A medição precisa de fibras microscópicas é essencial em uma variedade de campos científicos e industriais, desempenhando um papel crucial em setores como a ciência dos materiais e a pesquisa biomédica. O desafio reside na natureza complexa das fibras, que podem variar em forma, tamanho e textura. Isso exige abordagens flexíveis e adaptáveis para medição e segmentação.

Nos últimos anos, houve um avanço notável na aplicação de algoritmos de *Machine Learning* e *Deep Learning* para tarefas de visão computacional, incluindo a análise de objetos microscópicos. O uso desses algoritmos oferece vantagens significativas, como a capacidade de aprender automaticamente características das fibras a partir dos dados, eliminando a necessidade de extração manual de recursos.



Uma arquitetura relevante nesse contexto é o FibeR-CNN, desenvolvido especificamente para a medição de fibras microscópicas. Este modelo estende o Mask R-CNN, permitindo a extração de pontos de referência, largura e comprimento das fibras, tornando-o altamente adequado para a análise de fibras complexas, inclusive em situações de sobreposição. Além disso, outras arquiteturas, como o Segfit e o DeepLeaf, também têm se destacado na análise de objetos microscópicos, indicando o potencial desses métodos para medições precisas.

A. Estudos Futuros

Os próximos passos do estudo consistirão de uma investigação mais aprofundada da literatura existente relacionada à medição de fibras microscópicas e arquiteturas de *Deep Learning*. O aprofundamento trará uma compreensão maior às nuances e desafios específicos enfrentados em diferentes contextos de aplicação. Com base nessa análise, será feita a adaptação e o desenvolvimento de uma nova arquitetura que seja altamente adequada aos propósitos de da pesquisa. Inspirado nas arquiteturas previamente estudadas, será desenvolvido um modelo que seja capaz de lidar com a complexidade das fibras sobrepostas e oclusas, proporcionando medições precisas e detalhadas.

Além disso, os planos futuros envolvem a criação de uma interface de usuário amigável para o uso do algoritmo especializado em medição automática de fibras. A implementação de uma interface intuitiva tornará a aplicação acessível a um público mais amplo, incluindo pesquisadores e profissionais de diversas áreas. Acredita-se que esses objetivos futuros não apenas aprimorarão a compreensão da medição de fibras microscópicas, mas também contribuirão para o desenvolvimento de uma ferramenta valiosa que beneficiará a comunidade científica e industrial.

AGRADECIMENTOS

Gostaria de expressar minha profunda gratidão a todos que contribuíram para o sucesso do meu projeto de pesquisa. Em primeiro lugar, agradeço ao Laboratório de Computação Gráfica (LabCG) da Unioeste, o qual faço parte, com uma menção especial a Profa. Dra. Fabiana Frata Furlan Peres e ao Prof. Dr. Claudio Roberto Marquetto Mauricio, pelo apoio e orientação.

Também agradeço ao Prof. Dr. Douglas Cardoso Dragunski, que gentilmente forneceu as imagens necessárias para esta pesquisa.

Agradeço à conferência Latinoware por oferecer o Latin.Science, onde pude compartilhar e discutir minhas descobertas com a comunidade de tecnologia.

Por último, quero expressar minha profunda gratidão a minha mãe, Ivani. Seu apoio inabalável e encorajamento constante foram o alicerce deste projeto e de todas as minhas realizações.

REFERÊNCIAS

- [1] M. Frei and F. E. Kruijs, "FibeR-CNN: Expanding Mask R-CNN to improve image-based fiber analysis," *Powder Technology*, vol. 377, pp. 974–991, 2021. [Online]. Available: <https://doi.org/10.1016/j.powtec.2020.08.034>
- [2] Y. Aslam and S. N., "A review of deep learning approaches for image analysis," in *2019 International Conference on Smart Systems and Inventive Technology (ICSSIT)*, 2019, pp. 709–714.
- [3] M. Modares, R. Aversa, S. Cozzini, R. Ciancio, A. Leto, and G. Brandino, "Neural network for nanoscience scanning electron microscope image recognition," *Scientific Reports*, vol. 7, 10 2017.
- [4] S. Zhang, X. Liang, X. Huang, K. Wang, and T. Qiu, "Precise and fast microdroplet size distribution measurement using deep learning," *Chemical Engineering Science*, vol. 247, p. 116926, 2022. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0009250921004917>
- [5] A. Triki, B. Bouaziz, J. Gaikwad, and W. Mahdi, "Deep leaf: Mask r-cnn based leaf detection and segmentation from digitized herbarium specimen images," *Pattern Recognition Letters*, vol. 150, pp. 76–83, 2021. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0167865521002361>
- [6] D. Yang, X. Wang, H. Zhang, Z. Yu Yin, D. Su, and J. Xu, "A mask r-cnn based particle identification for quantitative shape evaluation of granular materials," *Powder Technology*, vol. 392, pp. 296–305, 2021. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0032591021005891>
- [7] M. Ge, F. Su, Z. Zhao, and D. Su, "Deep learning analysis on microscopic imaging in materials science," *Materials Today Nano*, vol. 11, p. 100087, 2020. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S258884202030016X>
- [8] Z. Liu, L. Jin, J. Chen, Q. Fang, S. Ablameyko, Z. Yin, and Y. Xu, "A survey on applications of deep learning in microscopy image analysis," *Computers in Biology and Medicine*, vol. 134, p. 104523, 2021. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0010482521003176>
- [9] K. He, G. Gkioxari, P. Dollár, and R. Girshick, "Mask r-cnn," in *2017 IEEE International Conference on Computer Vision (ICCV)*, 2017, pp. 2980–2988.
- [10] K. P. Murphy, *Machine Learning: A Probabilistic Perspective*. Cambridge, Massachusetts, London, England: The MIT Press, 2012. [Online]. Available: http://noiselab.ucsd.edu/ECE228/Murphy_Machine_Learning.pdf
- [11] M. C. Monard and J. A. Baranauskas, "Conceitos sobre aprendizado de máquina," in *Sistemas Inteligentes Fundamentos e Aplicações*, 1st ed. Barueri-SP: Manole Ltda, 2003, pp. 89–114.
- [12] M. A. Ponti, L. S. F. Ribeiro, T. S. Nazare, T. Bui, and J. Collomosse, "Everything you wanted to know about deep learning for computer vision but were afraid to ask," in *2017 30th SIBGRAPI Conference on Graphics, Patterns and Images Tutorials (SIBGRAPI-T)*, 2017, pp. 17–41.
- [13] F. Xing, Y. Xie, H. Su, F. Liu, and L. Yang, "Deep learning in microscopy image analysis: A survey," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 29, no. 10, pp. 4550–4568, 2018.
- [14] P. Bharati and A. Pramanik, "Deep learning techniques—r-cnn to mask r-cnn: A survey," in *Computational Intelligence in Pattern Recognition*, A. K. Das, J. Nayak, B. Naik, S. K. Pati, and D. Pelusi, Eds. Singapore: Springer Singapore, 2020, pp. 657–668.
- [15] X. L. Hao Wu, Qi Liu, "A review on deep learning approaches to image classification and object segmentation," *Computers, Materials & Continua*, vol. 60, no. 2, pp. 575–597, 2019. [Online]. Available: <http://www.techscience.com/cmcc/v60n2/28384>

