

# Análise da Morfologia de Nanofibras Através da Inteligência Artificial

Danilo Reis de Oliveira, Gabriel Guedes Menezes, Mateus Motta Pittol da Silva, Pedro Henrique Russo, Tiago Gomes Oliveira, Prof. Dr. Guilherme Duarte de Barros

Departamento de Engenharia e Tecnologia (Engenharia Mecânica) - Universidade Anhembi Morumbi (UAM)

**Resumo** — Nanofibras poliméricas são filamentos utilizados em aplicações como filtragem de ar e água, catálise de reações, produção e armazenamento energético, como painéis solares e baterias. Em biomedicina podem ser utilizadas no auxílio da reconstrução de tecidos, aplicação de medicamentos através de curativos sob a pele e na indústria como filamentos de impressoras 3D. Porém, sua morfologia pode interferir nas aplicações, onde as imperfeições chamadas *beads* devem ser analisadas para evitar problemas de compatibilidade. Utilizando a Inteligência Artificial é possível identificar essas falhas morfológicas. Para isso, é feito o treinamento da inteligência artificial utilizando imagens obtidas através de Microscopia Eletrônica de Varredura (MEV) para criar um banco de dados de áreas da imagem onde se encontram as anomalias (*beads*). O algoritmo de detecção de objetos (YOLOv4) em linguagem *python* compara esse banco de imagens treinado com um segundo banco de imagens procurando partes semelhantes. Assim, cria-se uma relação entre a quantidade de anomalias encontradas (por material ou processo de fabricação), estabelecendo parâmetros para determinar aplicações ou processos de fabricação dependendo da usabilidade do material que será obtido a partir das nanofibras.

Este trabalho tem por objetivo demonstrar o uso da Inteligência Artificial para a identificação dos erros morfológicos das nanofibras, quantificando as anomalias e procurando observar o que influencia na assertividade desta Inteligência. Obteve-se através do treinamento e testes realizados (feito em duas etapas) a acurácia de 62,61%, no primeiro teste que utilizou 141 imagens no treinamento e 62,79% no segundo teste que utilizou o total de 284 imagens no treinamento (incluindo 141 novas imagens as 141 do primeiro treinamento). Neste segundo teste (com 284 imagens), em 45,3% das imagens analisadas, os *beads* identificados pela IA correspondiam aos mesmos identificados de forma manual. Já em 71,79% das análises do segundo teste a IA conseguiu identificar ausência total ou a presença parcial de *beads* nas imagens. Quanto ao tempo total de predição (abertura da imagem, identificação e demonstração das falhas) houve uma redução significativa comparando os testes 1 e 2 de 9,233 segundos o que para o funcionamento da IA é um valor considerável uma vez que ela processa as imagens na casa de milissegundos.

**Palavras-Chave** — nanotecnologia, nanomateriais, nanofibras, inteligência artificial

## I. INTRODUÇÃO

Nas últimas décadas as áreas de nanociência e nanotecnologia tem oferecido soluções para desafios comerciais, científicos e industriais, desenvolvendo nanomateriais com propriedades otimizadas, sendo um desses materiais as nanofibras. São classificadas como nanofibras as fibras com diâmetro, ou dimensional externo de 1-100 nm e fibras submicrométricas de 101-999 nm. [1-2]. Elas, quando reunidas, podem dar origem a mantas e membranas as quais apresentam características como grande área superficial

específica, alta porosidade e interconectividade, tornando-as adequadas para transporte de nutrientes, comunicação celular e respostas celulares eficientes, sendo possível sua utilização em aplicações biomédicas [3].

Desde a década de 90, as nanofibras poliméricas vêm sendo utilizadas para uso como suporte na engenharia de tecidos como cartilagens, ossos, vasos sanguíneos arteriais, coração e nervos [4].

As nanofibras têm atraído muita atenção pela elevada quantidade de aplicações [5] e por sua flexibilidade de adaptação de estrutura e composição para uma determinada aplicação. Um dos principais fatores influentes na aplicação das nanofibras é a caracterização da morfologia das mesmas, ou seja, fazer a análise, por meio de microscopia eletrônica, do seu formato, comprimento, diâmetro e também saber se durante a síntese as fibras apresentam algum tipo de defeito morfológico, que pode influenciar na eficácia do produto resultante.

Dentre as principais formas de obtenção de nanofibras, a eletrofiação (*electrospinning*), é o mais comumente utilizado, pois além de ser um método econômico e simples traz a possibilidade de produzir fibras de vários tipos de polímeros.

O processo de eletrofiação é considerado de baixo custo, pois se utilizam itens simples, tais como seringa, agulha hipodérmica, fonte de alta tensão, cabos de conexão, suporte universal para fixar a seringa e um substrato, podendo ser uma lâmina de silício ou similar, para coletar as fibras [6-7], conforme esquematizado na figura 1.




Figura 1: Aparato de Eletrofiação [7]

Na eletrofiação, um eletrodo (polo positivo) é colocado na ponta da agulha metálica e o outro eletrodo (polo negativo) é fixado no coletor. Ao se aplicar uma alta tensão DC é gerado um jato eletricamente carregado de solução polimérica, que é expelido através do tubo capilar da agulha metálica, tendo como resultado final a nanofibra [7-8].

Outra forma de produção seria a rotofiação. A máquina de rotofiação é constituída basicamente de três componentes: um reservatório de orifício central com vários capilares na parede, utilizado para a introdução da solução e expulsão da solução; um coletor de forma cilíndrica, onde são depositadas as fibras; e uma base circular acoplada ao motor elétrico com velocidade de rotação controlada [9]. A figura 2 corresponde a máquina de rotofiação disponível no laboratório da Universidade Anhembi Morumbi campus Vila Olimpia localizado na cidade de São Paulo-SP.



Figura 2 – Máquina de produção de Nanofibras da Universidade Anhembi Morumbi Campus Vila Olimpia por rotofiação.

Essas nanofibras eletrofiadas apresentam vantagens, como: alta área superficial, podem ser obtidas numa variedade de formas e tamanhos, possuem propriedades e funcionalidades a partir do controle sobre a composição dessas nanofibras [10]; além de poderem ser produzidas a partir de uma infinidade de polímeros [11]. Uma produção de jatos de fibras poliméricas mais estáveis com redução na tensão superficial favorecem a produção de jatos homogêneos e sem defeitos, assim evidenciado na figura 3.




Figura 3 - Morfologia sem falhas

Os defeitos aparecem quando as fibras não formadas surgem em formas de vesículas e são costumeiramente apelidadas de *beads*. Na figura 4 é possível ver essas formações que ocorrem quando os emaranhados das cadeias não são suficientes para garantir e dar resistência ao campo elétrico ou a densidade de carga na solução do campo elétrico não é forte o suficiente para romper a tensão superficial e obter o jato polimérico durante a produção.




Figura 4 - Defeitos nas nanofibras em forma de vesículas/gotas, retirado de [8]

## II. METODOLOGIA

A análise e identificação desses defeitos é feita de forma visual e requer tempo. Porém por corresponder a identificação de padrões na imagem e visando a celeridade com maiores chances de acerto, é possível a utilização da tecnologia. Assim como a Inteligência Artificial é utilizada atualmente para diversos fins que identificam padrões, como reconhecimento facial, por exemplo, ela tem se mostrado uma forte aliada e com alta taxa de confiabilidade neste tipo de estudo.

Para a realização do treinamento da IA (Inteligência Artificial) assim como o reconhecimento de imagens será utilizado o algoritmo *YOLOV4* (versão 4). O motivo da escolha desse algoritmo decorre dos trabalhos anteriores [17-18] onde foi utilizado o mesmo para inspeção de defeitos em nanofibras. A fim de dar continuidade ao trabalho anterior e obter resultados melhores aumentando o número de imagens analisadas, utilizamos um computador realizando todo o processo localmente. Além do *YOLOV4*, será utilizado também a biblioteca de visão computacional *OpenCV* [13] e a rede neural profunda *Darknet*, um framework criado por Joseph Redmon.[14]

Usando o software *LabelImg* [15] que também foi utilizado nos trabalhos anteriores [17-18], desenhamos as caixas de reconhecimento nos *beads*. Ao salvar as caixas nesse software, será gerado um arquivo de texto contendo o tamanho da caixa e as coordenadas em X e Y, assim como demonstrado na figura 5. Este recurso foi utilizado por ter compatibilidade com o algoritmo *YOLOV4* e facilitar as marcações das falhas morfológicas por apenas exigir a representação de caixas nos *beads* e não o contorno preciso do erro morfológico.




Figura 5 – Reconhecimento de *beads* de forma manual no software *LabelImg*

O treinamento da IA por ser feito por imagens, requer um processamento gráfico para um menor tempo. Pode ser

realizado utilizando o Google Colab, uma plataforma onde é possível utilizar uma GPU (unidade de processamento gráfica) virtual. No entanto devido a influência de outros fatores como oscilações no tráfego de dados pela rede de internet que poderia alterar o tempo de processamento e o limite de dados para processamento gratuito, a IA deste estudo foi utilizada em um computador pessoal equipado com uma GPU GTX-1660 dedicada da Nvidia, onde sua tecnologia CUDA (Arquitetura de Dispositivo de Computação Unificada) permite uma computação paralela, possibilitando que a biblioteca OpenCV seja executada na placa de vídeo, aproveitando do imenso processamento gráfico para treinamento da IA.

Após fazer a instalação e configuração da IA, é hora de realizar o treinamento. Através de um banco de 516 imagens obtidas por Microscopia Eletrônica de Varredura (MEV), coletadas com o Prof. Dr. Guilherme Duarte de Barros [16] as quais também foram objetos de estudo de outros dois trabalhos na Universidade Anhembi Morumbi [17-18], separamos 282 imagens deste banco para treinamento da IA (Inteligência Artificial) em duas etapas, sendo a primeira com 141 imagens e a segunda com as 282 (incluindo 141 novas imagens as 141 do primeiro treinamento), buscado que ela aprenda a identificar nas imagens, cada vez mais rápido, todas as ocorrências de *beads*, além de observar o quanto varia a precisão de detecção conforme o número de imagens utilizadas para aprendizado da IA.

Para determinar a efetividade do método computacional realizamos um cálculo da razão entre o número de *beads* identificados pela Inteligência Artificial (BIA) e a quantidade de *beads* identificados manualmente (BIM), sendo multiplicado por cem o resultado da divisão para encontrar o percentual, assim como na equação 1:

$$Acurácia(\%) = \frac{BIA}{BIM} \times 100$$

## Legenda

**Acurácia:** Valor percentual de precisão do programa

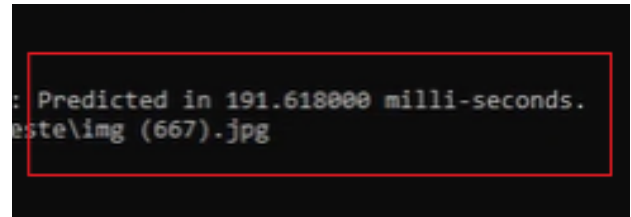
**BIA:** Quantidade de beads identificados pela IA

**BIM:** Quantidade de beads identificados manualmente

### III. RESULTADOS

Inicialmente foram realizados alguns treinamentos utilizando imagens de pássaros e, em seguida, um outro treinamento utilizando imagens de aviões para aprimorar o conhecimento sobre a tecnologia da qual seria utilizada para a realização dos estudos. Após testes com as imagens mencionadas, o banco de imagens correspondente as nanofibras que foram utilizadas neste trabalho foi criado e o treinamento da IA, para detectar as imperfeições, foi iniciado.

Após os testes, observamos que o tempo total para abrir, marcar, contar os *beads* e salvar o arquivo de texto para treinamento da IA pela ação humana para 234 imagens foi de 7488 segundos, correspondendo a 32 segundos por imagem, este tempo foi coletado cronometrando o tempo gasto por cada um dos integrantes para a marcação dos beads, sendo feito uma média aritmética, enquanto a IA levou em média cerca de 0,203 segundos por imagem de acordo com o relatório gerado pelo próprio programa, conforme Figura 6.



*Figura 6 - Tempo de processamento de uma das imagens do teste.*

O tempo de predição da IA se levarmos em conta a resolução de cada imagem de 2048x1886 pixels, assim como o hardware utilizado, é um tempo satisfatório considerando a velocidade e a precisão.

Em alguns casos, no teste do que foi ensinado a IA, observamos que quando a imagem está muito próxima, com magnificação acima de 2000 vezes, conforme figuras 8 e 9, a precisão da IA chegou quase a zero. Isso é esperado, uma vez que as imagens que estão muito próximas, não contêm o contorno concavo dos *beads*. Já nas imagens com magnificação até 2000 vezes a identificação dos beads ocorreu de forma mais assertiva.





Figura 7 - Defeitos nas nanofibras em forma de vesículas/gotas, obtido nos testes com magnificação de 97 vezes.



*Figura 8 - Defeitos nas nanofibras em forma de vesículas/gotas, obtido nos testes com magnificação de 2380 vezes*




Figura 9 - Defeitos nas nanofibras em forma de vesículas/gotas, obtido nos testes com magnificação de 8822 vezes.

Dessa forma, a IA busca um contorno de duas linhas curvas que formam uma gota, mas quando a imagem está muito próxima, não é possível encontrar essas linhas, gerando imprecisão. Portanto, para melhor eficiência da IA, os testes devem ser realizados com imagens compatíveis com o campo de visão das imagens de treinamento (magnificação).

Utilizando a equação de acurácia obtivemos o resultado de 62,61%, no teste 1 que utilizou 141 imagens no treinamento e 62,79% no teste 2 que utilizou o total de 284 imagens no treinamento (incluindo 141 novas imagens as 141 do primeiro treinamento).

No teste 2 (com 284 imagens), em 45,3% das imagens analisadas, os *beads* identificados pela IA correspondiam aos mesmos identificados de forma manual. Já em 71,79% das análises do teste 2 a IA conseguiu identificar ausência total ou a presença parcial de *beads* nas imagens, um exemplo seria uma imagem onde não havia falha morfológica e a IA de forma correta não identificou qualquer falha, confirmando sua assertividade. Ou no caso de haver 4 *beads* em uma imagem e ela (IA) encontrar ao menos 1 corretamente demonstrando um acerto parcial.

|                                               | Teste 1   |        | Teste 2   |        |
|-----------------------------------------------|-----------|--------|-----------|--------|
|                                               | Acertos   | Erros  | Acertos   | Erros  |
| <b>Precisão Beads IA x Beads Manual</b>       | 94        | 140    | 106       | 128    |
|                                               | 40,17%    | 59,83% | 45,30%    | 54,70% |
| <b>Precisão Presença ou Ausência de Beads</b> | 156       | 78     | 168       | 66     |
|                                               | 66,67%    | 33,33% | 71,79%    | 28,21% |
| <b>Acurácia</b>                               | 62,61%    |        | 62,79%    |        |
| <b>Tempo médio por Imagem (ms)</b>            | 206,6929  |        | 202,7645  |        |
| <b>Tempo total (ms)</b>                       | 48366,147 |        | 39133,542 |        |

Tabela 1 – Resultado dos testes 1 e 2 com 234 imagens sem restrição de faixas de magnificação.

Quanto ao tempo total de predição (abertura da imagem, identificação e demonstração das falhas) das 234 imagens houve uma redução significativa comparando os testes 1 e 2 conforme tabela 1, de 9,233 segundos o que para o funcionamento da IA é um valor considerável uma vez que ela processa as imagens na casa de milissegundos.

Filtrando os resultados encontrados para faixa de magnificação de 0 à 2000 vezes, correspondente a 85% da faixa de magnificação utilizada no treinamento, identificamos que nas 124 imagens dos testes realizados dentro desta mesma faixa de magnificação, foi notado que a acurácia da IA reduziu para 54,42% no teste 1 enquanto no teste 2 ficou em 53,01%. No entanto a precisão de presença parcial ou ausência total de *beads* ocorreu uma melhora na assertividade de 80,65% para 86,29% comprovando que o treinamento e teste em mesma faixa de magnificação resulta num aumento da precisão da IA conforme representado na tabela 2.

|                                               | Teste 1   |        | Teste 2   |        |
|-----------------------------------------------|-----------|--------|-----------|--------|
|                                               | Acertos   | Erros  | Acertos   | Erros  |
| <b>Precisão Beads IA x Beads Manual</b>       | 42        | 82     | 49        | 75     |
|                                               | 33,87%    | 66,13% | 39,52%    | 60,48% |
| <b>Precisão Presença ou Ausência de Beads</b> | 100       | 24     | 107       | 17     |
|                                               | 80,65%    | 19,35% | 86,29%    | 13,70% |
| <b>Acurácia</b>                               | 54,42%    |        | 53,01%    |        |
| <b>Tempo médio por Imagem (ms)</b>            | 205,743   |        | 199,138   |        |
| <b>Tempo total (ms)</b>                       | 25512,061 |        | 19714,629 |        |

Tabela 2 – Resultado dos testes 1 e 2 com 124 imagens na faixa de magnificação de 0 a 2000 vezes.

#### IV. CONCLUSÃO

Por fim, os testes comprovam a maior eficiência do método computacional em relação ao método manual, principalmente pelo tempo de detecção que foi em média 157 vezes menor que o método manual para 234 imagens.

Quanto a acurácia da IA esta teve resultado satisfatório, pois considerando o estudo anterior realizado na Universidade Anhembí Morumbi [17-18] que com 150 imagens chegou a uma acurácia de 55,09%, o aumento das imagens (84 imagens a mais analisadas) resultou em uma melhora de 7,7% da acurácia.

Sendo assim, feita uma análise criteriosa dos resultados, compreende-se que o aumento do banco das imagens foi relevante para esse aumento de precisão e eficiência principalmente do tempo de predição.

No entanto, a magnificação das imagens ainda é uma deficiência a ser corrigida, o cenário ideal seria treinar a IA com imagens de magnificação igual ou muito semelhante e adicionar ao treinamento imagens com morfologia sem falhas acompanhadas de um arquivo .txt em branco com o nome da imagem, conforme sugestão de Joseph Redmon [14] para melhorar a precisão, sendo esse um ponto crucial a ser analisado em trabalhos futuros.

#### V. REFERÊNCIAS

- [1] COZMUTA, I.; BLANCO, M.; W. A., III. Gas sorption and barrier properties of polymeric membranes from molecular dynamics and Monte Carlo simulations. Abstracts of Papers of the American Chemical Society, v.231, Aug 19 2007. Link: <https://pubs.acs.org/doi/pdf/10.1021/jp062942h>
- [2] VALIPOURI, A. et al. Experimental and numerical study on isolated and non-isolated jet behavior through centrifuge spinning system. International Journal of Multiphase Flow, v. 69, n. 0, p 93-101, 3/2015. Link: <https://ueaeprints.uea.ac.uk/id/eprint/51256/1/valipouri.pdf>
- [3] GARG K, BOWLIN GL. Electrospinning Jets And Nanofibrous Structures. Biomicrofluidics, v.5, n.1, 13403, março 2011.
- [4] ZHANG, Y.; CHWEE, T. L.; RAMAKRISHNA, S.; and HUANG, Z. M. Recent development of polymer nanofibers for biomedical and biotechnological applications. Journal of Materials Science: Materials in Medicine. v. 16, n. 10, p. 933-946, 2005. Link: <https://pubmed.ncbi.nlm.nih.gov/16167102/>
- [5] YOSHIMOTO, H.; SHIN, Y.M.; TERAI, H.; VACANTI, J.P. A biodegradable nanofiber scaffold by electrospinning and its potential for bone tissue engineering. Biomaterials, v. 24, p. 2077-2082, 2003.
- [6] ANDRADE, S. M. B. Eletrofição e caracterização de membranas biopoliméricas a base de quitosana extraídas dos exoesqueletos de crustáceos. Tese (Doutorado em Engenharia) – Programa de Pós-Graduação em Engenharia Mecânica – UFRGN, Universidade Federal do Rio Grande do Norte, Natal, 2012.
- [7] GOMES, Demetrius Saraiva. Eletrofição de nanofibras poliméricas de poliácridonitrila e polifluoreto de vinilideno, incorporadas com negro de fumo e ftalocianina de cobre, visando aplicações em dispositivos sensores. 2018. 124 f. Tese (Doutorado) - Curso de

- Doutorado em Ciências, Escola Politécnica, Universidade de São Paulo, São Paulo, 2018. Disponível em: <https://www.teses.usp.br/teses/disponiveis/3/3140/tde-10042018-100722/pt-br.php>. Acesso em: 11 out. 2021.
- [8] SATO, J. A. P. **Fabricação e caracterização de sistemas poliméricos nanoestruturados obtidos por meio do uso da técnica de eletrofição**. 2011. 109 f. Dissertação (Mestrado – Programa de Pós-Graduação em Nanociência e Materiais Avançados – Área de concentração: Ciência dos Materiais), Universidade Federal do ABC, Santo André – São Paulo, 2011.
- [9] BRITO, Italita Almeida Vida de. **Preparação e Caracterização de Nanofibras de Blenda PLLA/PCL obtidas pelos Processos de Eletrofição e Rotofiação**. 2013. 108 f. Dissertação (Mestrado) - Curso de Mestra em Engenharia Mecânica, Universidade Estadual de Campinas, Campinas-SP, 2013. Disponível em : <https://docplayer.com.br/111352617-Preparacao-e-caracterizacao-de-nanofibras-da-blenda-llla-pcl-obtidas-pelos-processos-de-eletrofiacao-e-rotofiacao.html>. Acesso em: 11 out. 2021
- [10] BHARDWAJ N, KUNDU SC. **Electrospinning: A fascinating fiber fabrication technique**. Biotechnology Advances, Elsevier, v.28, n.3, p.325-347, jan. 2010.
- [11] SILVA AB, SANTOS JPF, BRETAS RES. 12º CONGRESSO BRASILEIRO DE POLÍMEROS (12ºCBPOL), 2013, Florianópolis, SC. **Sistemas Poliméricos Nanoestruturados Baseados em Mantas de Nanofibras Condutoras**. 2013. 4p
- [12] IWAKI, L. **Nanofibras Eletrofiadas de poliamida 6 e Polialilamina Hidroclorada Funcionalizadas com Nanotubos de Carbono e Nanopartículas de Ouro Aplicadas em Sensores e Biossensores**. Tese Pós-Graduação em Ciência e Engenharia de Materiais, São Carlos, 99p, 20
- [13] Open Source Computer Vision Library. link: <https://docs.opencv.org/3.1.0/d1/dfb/intro.html>.
- [14] REDMON, Joseph. Darknet: Open Source Neural Networks in C, 2016. Disponível em: <https://pjreddie.com/darknet/>. Acesso em: 19/05/2022
- [15] Tzatalin. LabelImg. Git code (2015). <https://github.com/tzatalin/labelImg>
- [16] BARROS, G. D. Influência do tipo de solvente e da temperatura no processo de rotofição de fibras de poliestireno. Tese (Doutorado em Ciência e Engenharia de Materiais) – Engenharia de Materiais, Universidade Federal de Pelotas. Pelotas, RS, p. 138. 2017
- [17] Duarte de Barros, G., De Oliveira, J., Matheus Ferraz Pereira, V., Da Silva Pereira, W., & Luiz Maciel Santana, A. (2021b). **Análise morfológica de Nanofibras. Uma abordagem por visão computacional e aprendizagem de máquina**. *Anais do XII Computer on the Beach - COTB '21*, 537–539. <https://doi.org/10.14210/cotb.v12.p537-539>
- [18] ARAUJO, Caio Tadeu Dias de; OLIVEIRA, Juliana de; PEREIRA, Vitor Matheus Ferraz; PEREIRA, Wesley da Silva; BARROS, Prof. Dr. Guilherme Duarte de. **Uso de Inteligência Artificial na Análise da Morfologia de Nanofibras**. 2020. 6 f. TCC (Graduação) - Curso de Engenharia Mecânica, Engenharia e Tecnologia, Universidade Anhembimorumbi (Uam), São Paulo, 2020.