

Algoritmos Bio-Inspirados e Redes Neurais Artificiais Aplicados à Segmentação de Imagens Médicas e Biológicas

Lucas Pampolin Laheras¹, Paulo Sérgio Silva Rodrigues², Gilson Antonio Giraldi³

^{1,2} Centro Universitário FEI

³ LNCC

lucaslaheras@hotmail.com; gilson@lncc.br

Resumo: Este artigo propõe e analisa uma nova metodologia para segmentação de imagens de microscopia confocal em imagens de ultra-sonografia de mama, baseada em técnicas de visão computacional utilizando algoritmos bio-inspirados para auxiliar o treinamento de uma rede neural convolucional (CNN) na tarefa de segmentação de imagens.

Palavras-Chaves: segmentação de imagens médicas, algoritmos bio-inspirados, level-sets.

1. Introdução

Com o desenvolvimento de tecnologia digital, o armazenamento e gerenciamento de informações médicas e biológicas coletadas manualmente tem sido cada vez menos comuns, perdendo o lugar para as tecnologias relacionadas à digitalização automática, tanto em hardware quanto em software. Por conta disso, o desenvolvimento das áreas de processamento de imagens, inteligência artificial, aprendizagem profunda e ciência de dados é estratégico, particularmente para a área médica, uma vez que atualmente, tanto hardware quanto software, tem influenciado em diagnósticos, tratamentos e planejamento cirúrgico [1].

Como exemplo de aplicações onde este problema é recorrente, podemos citar a contagem de células cancerígenas, geralmente obtidas em microscópios digitais através da utilização de marcadores químicos, bem como segmentação de imagens obtidas por microscópio confocal por varredura laser, a qual vem possibilitando a análise visual de células bem como de fenômenos biológicos associados [2].

Recentemente, a literatura de processamento digital de imagens e visão computacional tem demonstrado a crescente efetividade da aplicação de algoritmos bio-inspirados para segmentação de imagens [3, 4].

Por outro lado, métodos em aprendizagem profunda, baseados em redes neurais convolucionais (Convolutional Neural Network - CNN) foram também utilizados para segmentação de imagens, obtendo resultados muito promissores [5]. Vale ressaltar que a área de aprendizagem profunda vem ganhado espaço em inúmeras aplicações em reconhecimento de padrões, jogos, veículos autônomos, além de outras [6]. Porém, o treinamento de uma CNN para segmentação, em geral, necessita de grandes bancos de imagens contendo os dados originais e o padrão-ouro (imagem segmentada por especialista), que na maioria das vezes não estão disponíveis. Assim, o presente projeto propõe uma metodologia para segmentação de imagens microscópicas, baseada no algoritmo bio-inspirado firefly.

2. Metodologia

O presente projeto envolve as seguintes três etapas. A primeira etapa está fundamentada em algoritmos bio-inspirados, também utilizando técnicas baseadas em métodos de contorno ativo, tais como level sets. Neste passo, serão aplicadas técnicas já implementadas pelas equipes envolvidas, as quais serão integradas em um software com interfaces e recursos gráficos específicos para este projeto. Na segunda etapa é utilizado um modelo de CNN desenvolvido recentemente pelas equipes do LNCC e da FEI, utilizado para gerar alguns resultados publicados em [7]. Finalmente, a etapa três depende da integração do software implementado na primeira etapa com o treinamento da CNN.

3. Resultados

O pipeline exibido na Figura 1 foi implementado em Python, sendo composto por seis módulos principais, descritos em mais detalhes a seguir.




Figura 1 – Pipeline utilizado no projeto.




Figura 2 – (a) Imagem original. (b) Firefly aplicado na imagem após ajuste de contraste. (c) Máscaras delimitando as regiões obtidas. (d) Equalização do histograma aplicado localmente. (e) Resultado da aplicação do método de Level set. (f) Composição e coloração das regiões.

O primeiro bloco (bloco 1, Figura 1) altera a imagem original, mostrada na Figura 2(a), para tons-de-cinza. Pode-se observar o fraco contraste entre os objetos e o fundo da imagem, o que dificulta o tratamento automático destas imagens.

Na etapa correspondente ao bloco 2 da Figura 1, a imagem fornecida pela etapa 1 é processada pelo algoritmo bio-inspirado *firefly* (Figura 2(b)).

No passo correspondente à construção da máscara (bloco 3, Figura 1) a imagem de saída da etapa 2 é composta por $N > 1$ regiões de interesse. Se a área de uma dessas regiões for menor que um limiar $L > 0$, $L \in \mathbb{N}$, então essa região é definida como sendo uma máscara binária. Sendo assim, a saída dessa etapa é o conjunto $S = \{m_1, m_2, \dots, m_N\}$ de máscaras binárias. Esta etapa está representada na Figura 2(c).

Cada máscara binária definida na etapa anterior é utilizada para a etapa de histograma local (Bloco 4, Figura 1), sobre a imagem original para delimitar a região onde uma equalização local será executada. A razão da aplicação da equalização local é o fato de que, localmente, as regiões inomogêneas são reduzidas. A Figura 2(d) é o resultado da equalização da Figura 2(a) utilizando a região branca da Figura 2(c).

Na etapa referente ao bloco 5 da Figura 1, para cada imagem de saída da etapa anterior, é utilizado o algoritmo level sets de forma a realçar e delimitar as regiões locais, para obter um resultado melhor na contagem de células (Figura 2(e)).

Na última etapa (bloco 6, Figura 1), é feito o agrupamento de cada imagem de saída da etapa anterior em uma única imagem. Após o agrupamento, a cada região é atribuída uma cor aleatoriamente, de maneira que possam ser distinguidas visualmente, como pode ser observado na Figura 2(f).




Figura 3 – Layout da interface gráfica desenvolvida.

O *pipeline* de segmentação descrito acima foi implementado em uma plataforma interativa (Figura 3) para que os biólogos e médicos das equipes envolvidas possam determinar o padrão ouro das imagens que farão parte do banco de dados que irá ser treinado da CNN.

4. Conclusões

Este artigo apresenta os resultados parciais do projeto definido na Seção 2. Foi implementada uma interface que está na sua versão beta (Figura 3) e encontra-se em teste. Esta interface executa o algoritmo de segmentação e com base na imagem gerada, o

usuário seleciona regiões que precisam ser corrigidas, definindo assim o padrão ouro.

Como continuidade do projeto será implementado a rede neural utilizando a imagem original e o resultado do algoritmo bio-inspirado como treinamento.

5. Referências

- [1] Kunio Doi. Computer-aided diagnosis in medical imaging: historical review, current status and future potential. *Computerized medical imaging and graphics*, 31(4-5):198–211, 2007.
- [2] David J Stephens and Victoria J Allan. Light microscopy techniques for live cell imaging. *science*, 300(5616):82–86, 2003.
- [3] Valentín Osuna-Enciso. Bioinspired metaheuristics for image segmentation. 2014.
- [4] G. A. Wachs Lopes, F. S. Beltrame, R. M. Santos, and P. S. Rodrigues. Comparison of bio-inspired algorithms from the point of view of medical image segmentation. In 2018 IEEE International Work Conference on Bioinspired Intelligence (IWOBI), pages 1–7, July 2018.
- [5] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-net: Convolutional networks for biomedical image segmentation. In International Conference on Medical image computing and computer-assisted intervention, pages 234–241. Springer, 2015.
- [6] Philosophia Naturalis. 30 amazing applications of deep learning, Jun 2018.
- [7] Paulo Sergio Rodrigues, Guilherme Wachs-Lopes, Ricardo Morello Santos, Eduardo Coltri, and Gilson Antonio Giraldi. A q-extension of sigmoid functions and the application for enhancement of ultrasound images. *Entropy*, 21(4):430, 2019.

Agradecimentos

Agradeço ao orientador Gilson Giraldi, ao co-orientador Paulo Sérgio, ao CNPq (Projeto 155130/2019-6), assim como à FEI (Fundação Educacional Inaciana) e ao LNCC (Laboratório Nacional de Computação Científica), pelo suporte deste trabalho.

¹ Aluno de IC do CNPq. Projeto com vigência de 05/19 a 06/20.