

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

Lucas Pampolin Laheras¹, Paulo Sérgio Silva Rodrigues², Gilson Antonio Giraldi³
^{1,2} Centro Universitário FEI
³ LNCC

lucaslaheras@hotmail.com; psergio@fei.edu.br; gilson@lncc.br

Resumo: Este artigo propõe e analisa uma nova metodologia para aumento de dados médicos usado para segmentação de imagens de ultrassonografia de mama, baseada em técnicas de visão computacional. Utilizando auto codificadores, métodos de projeção 2D e triangulação de Delaunay para a ampliação de informação e algoritmos bio-inspirados para auxiliar o treinamento da rede neural U-Net na tarefa de segmentação de imagens. O conjunto utilizando a nova metodologia tem alcançado resultados promissores, atingindo precisão de 96,01% e erro quadrático de 0,0954.

Palavras-Chaves: segmentação de imagens médicas, aumento de dados, algoritmos bio-inspirados.

1. Introdução

Com o desenvolvimento de tecnologia digital, o armazenamento e gerenciamento de informações médicas e biológicas coletadas manualmente têm 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 têm influência em diagnósticos, tratamentos e planejamento cirúrgico [1].

Recentemente na literatura, processamento digital de imagens e visão computacional têm demonstrado a crescente efetividade da aplicação de algoritmos bio-inspirados para segmentação de imagens [2]. 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 [3]. Vale ressaltar que a área de aprendizagem profunda vem ganhando espaço em inúmeras aplicações, como reconhecimento de padrões, jogos, veículos autônomos, além de outras [4].

Porém, o treinamento de uma CNN para segmentação, em geral, necessita de grandes bancos de imagens que na maioria das vezes não estão disponíveis. Para acumular dados suficientes e melhorar o desempenho de modelos de aprendizado profundo em classificação de imagens, várias estratégias de aumento de dados foram propostas [5][6]. Estas estratégias podem ser adaptadas para o contexto de segmentação de imagens, que é o tema central nesta pesquisa.

2. Metodologia

Para o aumento de dados foi utilizado um banco de imagens de ultrassonografia de mama, composta por 250 imagens que contém tanto as imagens segmentadas quanto o padrão-ouro da classificação entre tumor maligno e benigno.

A técnica para aumento de dados foi adaptada de Peixinho *et. al* [5]. A técnica consiste em, após treinar o auto codificador, usá-lo para codificar o conjunto de imagens de entrada, transformando-as em vetores n-dimensionais e projetar cada imagem em coordenadas bidimensionais utilizando a técnica *Local Affine Multidimensional Projection* (LAMP) [7]. Dado os pontos da projeção, aplica-se a triangulação de Delaunay. Em seguida, são criados pontos usando a distribuição normal gaussiana no plano, assim permitindo a geração de pontos menos afastados. Os novos pontos serão considerados novas imagens codificadas no espaço n-dimensional, somente se estiverem dentro de um triângulo que possuir todos os pontos com a mesma classificação. Após a seleção, todos os novos pontos são decodificados e transformados em imagens que antes não existiam e a segmentação será gerada pelo pipeline (*CellDetectionImage*) que consiste em aplicar o algoritmo bio-inspirado *firefly* para a construção de uma máscara que possa ser utilizada para obtenção de uma imagem equalizada pelo histograma localmente e, por fim, o uso do algoritmo *level set*.

3. Resultados

Com relação à metodologia para aumento de dados, o primeiro passo foi o treinamento de uma rede auto codificadora. Posteriormente, os resultados do codificador são projetados no espaço bidimensional. Os resultados gerados após o treinamento do auto codificador mostraram-se satisfatórios usando a função de perda do erro quadrático médio, com erro de 0,00529. O codificador contém três camadas de convolução compostas pela ativação ReLU, seguidas pelo *pooling* máximo 2 x 2 com iteração 2. O decodificador tem a mesma configuração de convolução, porém é seguido pelo *up-sampling* 2 x 2, onde a entrada do decodificador é a saída do codificador. Apesar de ser utilizada 5000 épocas para o treinamento os resultados convergiram perto da época 600.

A Figura 1.a mostra uma imagem original da base de dados, onde é redimensionada para 52 x 52 *pixels* por conta da padronização da rede (Figura 1.b). O resultado obtido na saída do auto codificador, para a imagem de entrada da Figura 1.b, está representada na Figura 1.c. Apesar da perda de detalhes da imagem original, observamos que o codificador gerou um vetor de características eficiente para nossa proposta.

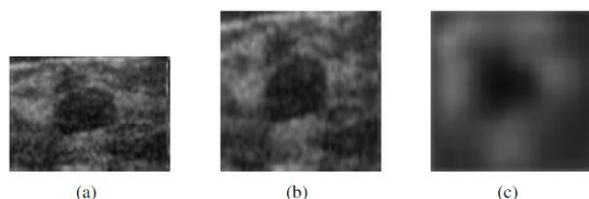


Figura 1 - (a) Imagem original 99 x 71. (b) Imagem remodelada para 52 x 52. (c) Saída do auto codificador.

Após o treinamento, o auto codificador é utilizado para a geração de novas imagens, como descrito na Seção 2. A Figura 2.a ilustra a representação de cada imagem no plano bidimensional após passar pelo codificador. A Figura 2.b mostra a triangulação de Delaunay no plano, que é utilizada para selecionar os novos pontos de acordo com um esquema baseado na classificação das imagens originais em benignas ou malignas. Os pontos em vermelho na Figura 2.c serão usados para gerar por interpolação novos vetores de características no espaço do codificador. Em seguida, estes vetores são processados pelo decodificador para gerar novas imagens. A Figura 3.a mostra uma nova imagem gerada neste processo e a Figura 3.b mostra sua segmentação via o software *CellDetectionImage* desenvolvido neste projeto. Apesar do efeito de suavização já comentado anteriormente, as novas imagens geradas são consideradas satisfatórias para o aumento de dados no treinamento da U-Net.

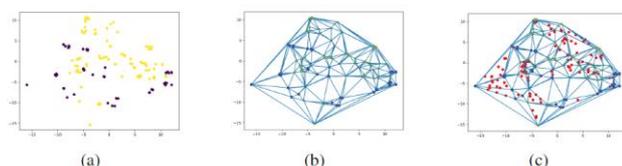


Figura 2 - (a) Representação bidimensional das imagens. (b) Aplicação da triangulação de Delaunay. (c) Criação dos novos pontos em vermelho, que posteriormente serão convertidos em imagens.

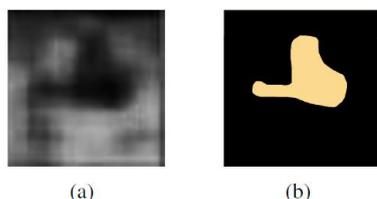


Figura 3 - (a) Imagem gerada pelo aumento de dados. (b) Segmentação gerada pelo software *CellDetectionImage*.

Atualmente, estamos avaliando o efeito do aumento de dados no treinamento da U-Net. Esperamos concluir esta etapa final em breve. Para estes testes foram utilizados três conjuntos de imagens para treinamento: (A) 100 imagens da base original; (B) 100 imagens da base com utilização do aumento de dados padrão, rotacionando a imagem em 90, 180 e 270 graus, totalizando 400 imagens (C) as imagens do conjunto (B) com as imagens geradas com a nova metodologia de aumento de dados. Nos resultados foi observado que a

rede treinada com o conjunto (A) alcança uma precisão de 94,82% e perda por entropia cruzada binária de 0,001194, o conjunto (B) teve precisão de 95,38% e perda de 0,1111, e por fim, o conjunto (C) atingiu precisão de 96,01% e perda de 0,0954. Apesar da semelhança entre as precisões, os testes preliminares mostram que o treinamento usando o conjunto (A) gerou uma rede hiper especializada no conjunto de treinamento o que não é bom para a aplicação da rede.

4. Conclusões

O aumento de dados está sendo testado, mostrando resultados promissores. Foi observado que na base sem o aumento de dados está ocorrendo *overfitting* e ambos os métodos de aumento de dados melhoram a rede, com vantagem de 0,63% maior de precisão usando ambos os métodos. Estamos realizando novos testes para melhorar o auto codificador na tentativa de obter melhores resultados.

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] 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.
- [3] 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.
- [4] Philosophia Naturalis. 30 amazing applications of deep learning, Jun 2018.
- [5] Alan Zanoni Peixinho, Bárbara Caroline Benato, Luis Gustavo Nonato, and Alexandre Xavier Falção. Delaunay triangulation data augmentation guided by visual analytics for deep learning. In 2018 31st SIBGRAPI Conference on Graphics, Patterns and Images (SIB-GRAPI), pages 384–391. IEEE, 2018.
- [6] Connor Shorten and Taghi M Khoshgoftaar. A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1):60, 2019.
- [7] Paulo Joia, Fernando Paulovich, Danilo Coimbra, Jose Cuminato, and Luis Nonato. Local affine multidimensional projection. *IEEE transactions on visualization and computer graphics*, 17:2563–71, 12 2011.

Agradecimentos

Agradeço 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.