

METODOLOGIA PARA DETECÇÃO DE TUMOR EM IMAGENS RM BASEADA EM FUNÇÃO Q-GABOR

Vinicius de Andrade Silva¹, Paulo Sérgio Silva Rodrigues²
 Ciência da Computação, Centro Universitário FEI
 unifvsilva@fei.edu.br psergio@fei.edu.br

Resumo: Na área médica, para o treinamento de redes neurais artificiais de classificação, sobretudo de imagens, a demanda por um grande volume de informação é frequente. Assim, vários modelos de redes têm surgido atualmente para ampliar artificialmente esses dados. O projeto aqui proposto tem por objetivo o estudo e comparação dessas metodologias, utilizando também funções de ativação não extensivas da Gabor. Os resultados mostram um aumento na acurácia em até 30% quando as imagens são ruidosas.

1. Introdução

Redes Neurais Convolucionais (CNNs) são as técnicas fundamentais utilizadas na área da saúde, principalmente para classificação, localização, detecção e segmentação de tumores. Porém, para melhor desempenho dessas técnicas, uma grande quantidade de dados é necessária. Atualmente, para o treinamento dessas redes, os pesquisadores costumam realizar o clássico aumento de dados, que consiste em aplicar transformações geométricas às imagens originais [1]-[3]. No entanto, foi comprovado que modelos modernos de *Deep Learning*, como *Generative Adversarial Networks* (GANs), podem gerar novas amostras artificiais/realistas e melhorar os resultados [4].

A geração de dados artificiais tem tido muito sucesso em vários aplicativos de processamento de imagem, especialmente após o avanço das redes neurais [6]. Essas redes são estruturadas de maneiras diferentes. Uma das principais estratégias é a utilização de funções de ativação em processos convolucionais, como é o famoso caso da CNN. Essas funções também podem ser utilizadas para filtragem espacial em várias dimensões, e sua parametrização costuma ser uma das principais métricas. Tais parametrizações podem ser realizadas de forma pré-fixada ou mesmo aprendidas durante o processo de convergência da rede. Alguns dos trabalhos mais conhecidos neste contexto são: [7]-[10].

Dentre essas funções, provavelmente a mais conhecida é a função exponencial, cujas versões e parametrizações simples facilitam o seu entendimento e implementação. No entanto, na área de aprendizado de máquina, essa função, juntamente com outras variantes, tem sido usada com entusiasmo. Por sua vez, uma função Gabor é a melhor escolha para modelar vários problemas reais, especialmente os biológicos [11].

Contudo, esse trabalho propõe uma metodologia para detecção de tumor em imagens de ressonância magnética baseada em aumento de dados artificiais e função não-extensiva da Gabor.

2. Metodologia

A metodologia desse trabalho consiste em 6 etapas, cada uma das etapas pode ser vista na Figura 1.




Figura 1 – Metodologia proposta.

A base de dados utilizada nesse trabalho foi a BraTS15, com imagens de ressonância magnética de tamanho 240x240 da modalidade T1c. Essas imagens são as entradas da etapa dois, que tem como objetivo realizar os processamentos necessários para que possam ser utilizadas devidamente, como por exemplo remoção de ruído e alteração no tamanho das imagens. A etapa três é subdividida em duas etapas, a etapa 3.1 utiliza as imagens pré-processadas para treinar uma rede PGGAN [12] para gerar amostras de ressonância magnética com tumor, já a etapa 3.2 utiliza as imagens da etapa 2 para gerar amostras sem tumor. Essas imagens são então utilizadas na etapa 4 para treinar uma ResNet-50 [13], para a detecção do tumor. A etapa 4.1 consiste em fazer alterações na ResNet-50 para adicionar uma nova camada proposta por este trabalho, chamada de Camada Convolutiva q-Gabor.

3. Resultados

Seguindo a metodologia proposta, os resultados obtidos com esse trabalho são detalhados nessa seção.

Pode-se observar na Figura 2 exemplos de imagens originais retiradas da base de dados, nela contém: duas imagens contendo tumor (esquerda e centro) e uma imagem sem tumor (direita). Para a etapa 3.1, que teve como objetivo gerar novas imagens de ressonância magnética contendo algum tipo de tumor, os resultados podem ser vistos na Figura 3. Ao final dessa etapa, foi possível a geração de 55.000 novas imagens artificiais e realísticas. A Figura 4 mostra exemplos de saída da etapa 3.2, onde teve como objetivo a geração de imagens sem tumor. Similar a etapa 3.1, também foi possível gerar 55.000 novas imagens ao final da etapa 3.2.




Figura 2 – Imagens retiradas da base de dados BraTS15.




Figura 3 – Imagens artificiais geradas a partir da etapa 3.1.




Figura 4 – Imagens artificiais geradas a partir da etapa 3.2.

As imagens resultantes das etapas 3.1 e 3.2 foram utilizadas como entrada na etapa 4. Durante essa etapa, foram realizados experimentos com o intuito de verificar a eficácia do aumento de dados artificial e como podemos melhorar a acurácia da rede adicionando uma nova camada com filtros q-Gabor. Os resultados dessa etapa podem ser vistos na Figura 5.

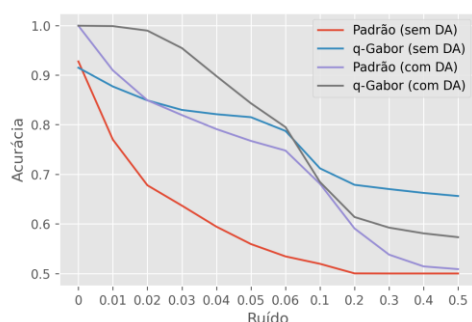


Figura 5 – Gráfico com os resultados obtidos.

A Figura 5 mostra um gráfico de Acurácia x Ruído com os resultados obtidos com os experimentos sem o aumento de dados (sem DA) e com o aumento de dados (com DA). Foi adicionado Ruído Gaussiano nas imagens de teste para analisar o comportamento da rede. Como primeiro experimento, foram realizados dois treinamentos com poucas imagens: (1) arquitetura da ResNet50 original e (2) arquitetura com a camada q-Gabor. Os testes para verificar a acurácia da rede foram feitos nas imagens geradas artificialmente. Os resultados mostram que, quando é adicionada a camada com filtros q-Gabor, a acurácia se mantém alta mesmo quando a imagem fica ruidosa (linha azul). Em comparação, quando a rede utilizada não é modificada a acurácia se mantém baixa (linha vermelha). Para verificar a eficácia do aumento de dados, a rede foi treinada com as imagens geradas artificialmente, e os resultados se equivalem aos obtidos anteriormente: a Camada Convolutiva q-Gabor altera positivamente a performance (linha cinza).

4. Conclusões

Esse trabalho apresentou uma metodologia para detecção de tumor em imagens de ressonância magnética baseada em aumento de dados e função não extensiva da Gabor. A metodologia proposta utilizou Redes Generativas Adversárias, Redes Neurais Convolucionais e uma nova Função Não-extensiva

Gabor. Os resultados mostram que essa metodologia melhora a acurácia da rede em 5% quando as imagens não possuem nenhum tipo de ruído, e 30% quando as imagens são ruidosas. Também foi possível observar que o tempo para treinamento quando utilizando a Camada Convolutiva q-Gabor diminuiu em 50%.

4. Referências

- [1] F. Perez et. al., “Data augmentation for skin lesion analysis” in OR 2.0/CARE/CLIP/ISIC@MICCAI, 2018.
- [2] C. N. Vasconcelos and B. N. Vasconcelos, “Experiments using deep learning for dermoscopy image analysis” Pattern Recognit. Lett., vol.139, pp. 95–103, 2020.
- [3] Y. Liu, S. et al. “A deep convolutional neural network-based automatic delineation strategy for multiple brain metastases stereotactic radiosurgery.” PLoS ONE, vol. 12, 2017.
- [4] X. Yi, E. Walia, and P. S. Babyn, “Generative adversarial network in medical imaging: A review” Medical image analysis, vol. 58, p. 101552, 2019.
- [5] M. Frid-Adar et. al., “Gan-based synthetic medical image augmentation for in-creased cnn performance in liver lesion classification,” Neurocomputing, vol. 321, pp. 321–331, 2018.
- [6] C. Shorten and T. M. Khoshgoftaar, “A survey on image data augmentation for deep learning.” Journal of Big Data, vol. 6, pp. 1–48, 2019.
- [7] C. Nwankpa, W. L. Ijomah, A. Gachagan, and S. Marshall, “Activation functions: Comparison of trends in practice and research for deep learning.” ArXiv, vol. abs/1811.03378, 2018.
- [8] S. Sharma, S. Sharma, and A. Athaiya, “Activation functions in neural networks” 2020.
- [9] L.-L. Huang, A. Shimizu, and H. Kobatake, “Classification-based face detection using gabor filter features.” Sixth IEEE International Conference on Automatic Face and Gesture Recognition, 2004. Proceedings., pp. 397–402, 2004.
- [10] G. Maguolo, L. Nanni, and S. Ghidoni, “Ensemble of convolutional neural networks trained with different activation functions.” Expert Syst. Appl., vol. 166, p. 114048, 2021.
- [11] J. R. Movellan. “Tutorial on gabor filters.” [Online]. Disponível em: <https://inc.ucsd.edu/mplab/tutorials/gabor.pdf>
- [12] T. Karras et. al., “Progressive growing of gans for improved quality, stability, and variation.” ArXiv, vol. abs/1710.10196, 2018.
- [13] K. He et. al., “Deep residual learning for image recognition.” 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770–778, 2016.

Agradecimentos

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico pelo apoio, ao Centro Universitário FEI pelo empréstimo de equipamentos.

¹ Aluno de IC do CNPq. Projeto com vigência de 09/20 a 08/21.