

Classificação de Lesões no Cérebro em Imagens de Ressonância Magnética usando SLIC, Particle Swarm Optimization e Convolutional Neural Network

Carolina L. S. Cipriano¹, Felipe J. P. de Andrade¹, Jonnison L. Ferreira¹,
Giovanni L. F. da Silva¹, Aristófanés C. Silva¹

¹Núcleo de Computação Aplicada – Universidade Federal do Maranhão (UFMA)
65065-545 – São Luís – MA – Brasil

{carol, jonnison, giovannilucca, ari}@nca.ufma.br,
felipejordaopinheiro@gmail.com

Abstract. *Brain tumors are delicate, since they are in a very sensitive and important region that is this human organ. Because its manual analysis is very costly, we aim to automatically classify the sub regions of the lesions (necrosis, edema, non-enhancing tumor and enhancing tumor) found in most regions where there are abnormalities. For this, we will use the Magnetic Resonance (MR) images; the Particle Swarm Optimization (PSO) method for parameter optimization; the Simple Linear Iterative Clustering (SLIC) clustering algorithm for feature extraction and the Convolutional Neural Network (CNN) for classification.*

Resumo. *Os tumores cerebrais são delicados, uma vez que se encontram em uma região muito sensível e importante que é esse órgão humano. Por sua análise manual ser bastante custosa, temos como objetivo classificar de forma automática as sub-regiões das lesões (necrose, edema, núcleo sólido e núcleo) encontradas na maioria das regiões onde há anomalias. Para isso, usaremos as imagens de Ressonância Magnética (RM); o método Particle Swarm Optimization (PSO) para a otimização dos parâmetros; o algoritmo de agrupamento Simple Linear Iterative Clustering (SLIC) para extração de características e a Convolutional Neural Network (CNN) para classificação.*

1. Introdução

Há diversos tipos de tumores cerebrais e independente de sua gravidade e localização, o seu diagnóstico precoce e correto é de extrema importância para a eficácia de seu tratamento. A tarefa de classificação da lesão, além de muito laboriosa está sujeita a erros e divergências entre os especialistas. Não é uma tarefa fácil, pois as lesões apresentam formas, tamanhos e localizações diversas. A classificação das sub-regiões da lesão daria ao especialista uma segunda opinião, auxiliando no seu trabalho.

O objetivo do trabalho é desenvolver um sistema inteligente que possa classificar 4 sub-regiões das lesões que compõem a maioria das lesões cerebrais, são elas : necrose, edema, núcleo sólido e núcleo, usando imagens de Ressonância Magnética (RM) da base de dados Multimodal Brain Tumor Image Segmentation Benchmark (BRATS) [Menze et al. 2015].

Na literatura existem alguns trabalhos relacionados a segmentação e classificação de regiões de tumor com base de dados Multimodal Brain Tumor Image Segmentation Benchmark (BRATS). O primeiro, é a segmentação entre lesão e tecido saudável feita por [Andrade 2018]; o segundo, [Pereira et al. 2016]; além de [Alex et al. 2017]. Somente o ultimo trabalha com as 4 sub-regiões da lesão(necrose, edema, núcleo sólido e núcleo), mas usa a Auxiliary Classifier Generative Adversarial Networks (ACGAN) para classificação.

O artigo está organizado da seguinte forma. A Seção 2 apresentara a metodologia que será dividida em 5 subseções, são elas: Base de dados, Pré-processamento, SLIC's, Particle Swarm Optimization (PSO) e Redes Neurais Convolucionais; A Seção 3 com os Resultados e a Seção 4 com as Conclusões.

2. Metodologia

A metodologia proposta para classificação das sub-regiões da lesão em imagens de ressonância magnética consiste em 5 etapas. A primeira, é a aquisição da base de imagens de ressonância magnética; A segunda, o pré-processamento das imagens, onde é feita normalização dos exames para um mesmo padrão; A terceira, extração de características usando o SLIC; A quarta, otimização de parâmetros usando o PSO; A quinta, classificação usando Redes Neurais Convolucionais (CNN).

2.1. Base de Dados

A base de dados usada para esse trabalho de classificação é a Multimodal Brain Tumor Image Segmentation Benchmark [Menze et al. 2015] composta por 220 pacientes contendo gliomas de alto e baixo grau, mas para este trabalho serão usados somente pacientes com gliomas de alto grau. A marcação dos tumores é feita de forma manual por diversos especialistas e todos os pacientes compartilham de quatro modos de ressonância: T1, T1c,T2, FLAIR.

A Figura 1 mostra as lesões com cores ilustrativas. (A) todo o tumor visto no modo FLAIR; (B) o núcleo sólido do tumor visível em T2 ; (C) estruturas tumorais visíveis em T1c em torno de componentes necróticos do núcleo .




Figura 1. Imagem de lesão e suas as sub-regiões com cores. Edema (amarelo), Núcleo sólido (vermelho), Necrose (verde) e Núcleo (azul) [?]

2.2. Pré-processamento

A Normalização Estatística é a normalização das intensidades de pixel, é feita em todas as fatias e para todos os modos de ressonância (FLAIR, T1, T1C, T2) e tem como objetivo: tornar a média próxima de zero e desvio padrão menor [Pereira et al. 2016]. Para isso, é feita a divisão de todos os valores de pixel da fatia por sua média e o resultado é dividido pelo desvio padrão da fatia.

$$pixel = \frac{pixel - Média(fatia)}{DesvioPadrão(fatia)} \quad (1)$$

2.3. SLIC's

Na extração de características, o Simple Linear Iterative Clustering (SLIC) e sua variação SLICO serão considerados [Achanta et al. 2012]. Eles reduzem a complexidade, aumentam a velocidade e melhoram a qualidade dos resultados, pois geram superpixels que correspondem a grupos pequenos e quase uniformes da imagem.

Cada superpixel será analisado em relação ao ground truth e aquele que obtiver a maior intersecção com determinada classe, tal classe será o seu rótulo. Como mostrado na Figura 2, um exemplo de modo de RM (A), posteriormente sua lesão(B) e o SLIC aplicado a sua lesão. Modo, algoritmo e parâmetros escolhidos de forma empírica não retornaram bons resultados de classificação para todas as classes.




Figura 2. (A) Imagem do cérebro no modo FLAIR, (B) Lesão e (C) SLIC aplicado a lesão

A escolha de qual algoritmo de agrupamento, parâmetros e o modo de RM que serão aplicados implicam diretamente na qualidade da classificação. Primeiro, a escolha do algoritmo de extração de características: SLIC ou SLICO. Segundo, a escolha dos parâmetros consistem no tamanho médio do superpixel (medindo em pixels) e seu fator de compactação. Terceiro, o modo de RM (FLAIR, T1, T1C, T2), pois cada classe de lesão pode estar melhor representada naquele modo de RM que será aplicado. Para otimizar tais parâmetros, será usado o PSO, descrito na próxima seção.

2.4. PSO

O método de otimização Particle Swarm Optimization (PSO) [Eberhart and Kennedy 1995] tenta melhorar a solução inicial usando uma medida de qualidade. Foi criado por James Kennedy e Russell Eberhart, inspirado na inteligência coletiva dos animais e é considerado da família dos algoritmos evolutivos. Por sua fácil implementação e seus ótimos resultados, escolheu-se como etapa crucial deste trabalho.

Este artigo visa encontrar os melhores parâmetros com intuito de melhorar a classificação, pois superpixels que não representam bem a sua classe, principalmente os de fronteira, não serão aprendidos pela rede.

Os parâmetros a serem otimizados são :

- Modo de RM (FLAIR, T1, T1C, T2)
- Algoritmo de agrupamento (SLIC ou SLICO)
- Tamanho do superpixel (Variando de 4 a 10)
- Fator de compactação (Variando de 0 a 10)

Representado como um vetor, como mostrado abaixo:

Partícula = [Modo de RM, Algoritmo de agrupamento, tamanho do superpixel, fator de compactação]

Para simplificar, foram utilizados números (e seus intervalos) para representar cada parâmetro da partícula.

Partícula = [(0...3), (0 ou 1), (4...10), (0...10)]

Após a definição das partículas, é iniciado um conjunto com 10 partículas, 9 de maneira aleatória e 1 conhecida como uma boa partícula, que foi definida empiricamente. Para avaliação da função objetivo foi usado o dice após a segmentação da lesão com tais parâmetros, usando 10 pacientes, também escolhidos aleatoriamente. No fim, tivemos boas partículas encontradas individualmente para cada lesão dentro das 30 iterações definidas.

Após encontrar boas soluções, dentro dos parâmetros definidos, o próximo desafio seria escolher uma única partícula que melhor representasse todas as classes. Para essa tarefa, foi testada cada partícula, isoladamente, em todas as outras classes, como visto na Tabela 1. Foram usadas a média e o desvio padrão entre as classes para escolha da melhor partícula.

Tabela 1. Resultados PSO

	Necrose	Edema	Núcleo Sólido	Núcleo	Média	Desvio Padrão
Necrose	0,86	0,89	0,63	0,82	0,80	0,101242
Edema	0,87	0,89	0,65	0,86	0,8175	0,097308
Núcleo Sólido	0,87	0,89	0,65	0,86	0,8175	0,097308
Núcleo	0,87	0,89	0,65	0,86	0,8175	0,097308

2.5. Redes Neurais Convolucionais(CNN)

As CNNs são os modelos de Deep Learning muito conhecidas e largamente utilizadas para o processamento de imagens [Ponti and da Costa 2018]. São compostas por camadas convolucionais que processam as entradas considerando campos receptivos locais.

Nesta etapa, é feita a preparação dos dados para a entrada da rede. O resultado da busca por melhores parâmetros, usando o PSO, foi a partícula (2,1,4,9). Ou seja, o modo T1c; algoritmo SLICO e seus parâmetros: superpixel de tamanho médio 4 e compactação 9. Em seguida, são gerados superpixels, que passam por uma intersecção

com o ground truth para de saber qual a classe predominante do superpixel em questão. Após a identificação, é retirada a mesma região do superpixel do modo T1c para os demais modos (Flair, T1, T2), empilhando-os em uma estrutura 10x10x4.

A arquitetura da CNN usada no trabalho, como mostrada na Figura 3, é composta pela entrada 10x10x4; por uma camada de convolução de 64 filtros, Dropout, camada de ativação LeakyRelu e stride de 1; a segunda camada de convolução é igual a primeira, exceto pelos 128 filtros; A camada totalmente conectada com função de ativação tangente hiperbólica, possui 512 neurônios; e por fim, a saída é ativada pela função softmax, com 4 neurônios. A arquitetura da rede foi baseada no modelo definido por [Pereira et al. 2016], e ajustada com base em repetitivos testes para chegar a uma melhor classificação do problema a ser solucionado.



Figura 3. Arquitetura CNN

3. Resultados

A avaliação será feita baseada na acurácia. É comum utiliza-la para avaliar o desempenho do classificador, onde a taxa de classificação correta é definida como a razão entre o número de casos na amostra em estudo que foram classificados corretamente e o número total de casos na amostra em estudo.

A rede foi treinada com 74 pacientes de treino, 13 pacientes de teste e 13 pacientes de validação, todos escolhidos de forma aleatória. Para um treinamento de 50 épocas, a acurácia média englobando todas as classes, ou seja, todos os superpixel que foram corretamente classificados pela rede é de 84%.

A Tabela 2, mostra os resultados de classificação para cada classe. A coluna Dados% representa o total de instâncias(sua representação), nos dados de validação, para cada classe. Como podemos observar, os melhores resultados são das classes onde há maior ocorrência de dados.

Tabela 2. Matriz de Confusão

	Necrose	Edema	Núcleo Sólido	Núcleo	Acurácia %	Dados %
Necrose	402	55	188	85	55,07	1,93
Edema	69	20930	857	891	92,01	60,08
Núcleo Sólido	145	758	616	764	26,98	6,03
Núcleo	61	1508	612	9918	81,97	31,96

4. Conclusão

Os tumores cerebrais são problemas graves, independente de sua condição benigna ou não. O objetivo proposto por esse trabalho, ainda requer muitos estudos e testes. O algoritmo de extração de características, ainda deixa a desejar no seu poder de delimitação, por exemplo, na classe núcleo sólido. A rede, por sua vez, é observado um sobreajuste nos gráficos de treinamento e validação. Outro ponto, é que os dados estão desbalanceados, fazendo a rede aprender melhor as classes com maior número de instâncias.

Como trabalhos futuros, baseado nos resultados obtidos, se pretende aumentar o número de pacientes para o modelo, testar outras arquiteturas de CNN e outros tipos de redes, como as Auxiliary Classifier Generative Adversarial Networks (ACGAN), além de buscar métodos para a convergência da rede e resolver seu problema de sobreajuste.

Referências

- Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P., Süsstrunk, S., et al. (2012). Slic superpixels compared to state-of-the-art superpixel methods. *IEEE transactions on pattern analysis and machine intelligence*, 34(11):2274–2282.
- Alex, V., KP, M. S., Chennamsetty, S. S., and Krishnamurthi, G. (2017). Generative adversarial networks for brain lesion detection. In *Medical Imaging 2017: Image Processing*, volume 10133, page 101330G. International Society for Optics and Photonics.
- Andrade, F. J. P. (2018). Segmentação automática de lesões no cérebro em imagens de ressonância magnética usando slic e auxiliary classifier generative adversarial networks.
- Eberhart, R. and Kennedy, J. (1995). A new optimizer using particle swarm theory. In *Micro Machine and Human Science, 1995. MHS'95., Proceedings of the Sixth International Symposium on*, pages 39–43. IEEE.
- Menze, B. H., Jakab, A., Bauer, S., Kalpathy-Cramer, J., Farahani, K., Kirby, J., Burren, Y., Porz, N., Slotboom, J., Wiest, R., et al. (2015). The multimodal brain tumor image segmentation benchmark (brats). *IEEE transactions on medical imaging*, 34(10):1993.
- Pereira, S., Pinto, A., Alves, V., and Silva, C. A. (2016). Brain tumor segmentation using convolutional neural networks in mri images. *IEEE transactions on medical imaging*, 35(5):1240–1251.
- Ponti, M. A. and da Costa, G. B. P. (2018). Como funciona o deep learning. *arXiv preprint arXiv:1806.07908*.