

# Seleção Automática do Cérebro em Imagens de Ressonância Magnética Utilizando Redes Neurais Convolucionais

Paulo H. J. Amorim (CTI), Thiago F. de Moraes (CTI),  
Jorge V. L. da Silva (CTI), Hélio Pedrini (UNICAMP)

{paulo.amorim, thiago.moraes, jorge.silva}@cti.gov.br, helio@ic.unicamp.br

## Resumo

*Imagens cerebrais adquiridas por equipamentos de ressonância magnética (RM) possuem diversas aplicações, tais como análise de tumores, análise de doenças neurodegenerativas, planejamento cirúrgico, tratamento e cirurgia guiada. Além do cérebro, essas imagens também apresentam o crânio, meninge e outras partes que não fazem parte do cérebro, o que dificulta a visualização do cérebro em 3D em diversas aplicações. Neste trabalho, exploramos o uso das redes neurais convolucionais (CNN) para seleção automática do cérebro em imagens de RM. Experimentos realizados no conjunto de dados público NFBS demonstram que os resultados obtiveram altas taxas de acurácia quando comparada com a segmentação realizada pelo especialista.*

*Palavras-chave: Imagens Médicas, Segmentação de Imagens, Redes Neurais Profundas.*

## 1. Introdução

Imageamento por ressonância magnética (RM) é utilizado para uso clínico desde a década de 80. Nesse tipo de exame, os prótons presentes nos átomos de hidrogênio do tecido a ser analisado são alinhados a um forte campo magnético. Em seguida, ondas de rádio frequência atingem esses prótons e os alinham no sentido contrário. A onda de rádio frequência é desligada e então os prótons voltam a se alinhar ao campo magnético liberando a energia acumulada. A diferença entre o tempo de relaxamento e energia liberada são medidas, o sinal é processado e transformado em imagem. Tecidos diferentes possuem diferentes quantidades de hidrogênio e conseqüentemente diferentes tempos de relaxamento dos seus respectivos prótons. Isso permite contrastar os diferentes tecidos.

A grande vantagem desse exame é a ausência de radiação ionizante durante a aquisição. Imagens cerebrais adquiridas por esses equipamentos são amplamente utilizadas em diversas aplicações como medição e visualização de diferentes estruturas cerebrais para análise de lesões e o desenvolvimento do cérebro, uso em intervenções guiadas e planejamento cirúrgico (DESPOTOVIĆ et al. 2015).

Existem diferentes modalidades de imagens de RM, como T1, T2, FLAIR, DTI entre outras. No geral, a diferença entre elas é o tempo de relaxamento dos prótons, dependendo do caso espera-se mais ou menos tempo para aquisição, além da aplicação de diferentes filtros para realçar determinadas regiões anatômicas durante a etapa de reconstrução da imagem. A modalidade T1 é uma das modalidades mais utilizadas para visualizar a anatomia do cérebro. Ela realiza a supressão de água e ao mesmo tempo o realce de gordura nas imagens (CHRYSIKOPOULOS, 2009).

Pela característica física elencada anteriormente, as imagens que os equipamentos geram são bastante suscetíveis a ruído, além de possuir tecidos como escalpo, osso, meninge que não fazem parte do cérebro muito próximos dos tecidos cerebrais, como ilustra a figura 1.




Figura 1: Exemplo de imagem de RM T1 com indicativo de tecido não cerebral próximo ao cérebro.

Segmentação de imagens tem como objetivo dividir a imagem em regiões ou objetos (SCHWARTZ & PEDRINI 2007). Elas podem ser classificadas em três abordagens diferentes: (i) segmentação manual, onde o radiologista indica cada pixel da lesão manualmente, (ii) segmentação semi-automática, onde alguns parâmetros são definidos pelo usuário e o algoritmo realiza a seleção do cérebro e (iii) métodos de segmentação automática, onde não há necessidade de configurar nenhum parâmetro, bastando acionar um algoritmo e o resultado final é apresentado.

O objetivo deste trabalho é realizar remoção automática de tecidos não cerebrais em imagens de ressonância magnética T1, utilizando redes neurais convolucionais (CNN), com uma abordagem de *multi-patches*.

Os resultados demonstram que, para o conjunto de dados público NFBS, o método proposto foi capaz de atingir altos níveis próximos de um especialista. A seção 2 apresenta conceitos e trabalhos relacionados. A seção 3 descreve a metodologia proposta. Os resultados são apresentados e discutidos na seção 4. Por fim, a seção 5 conclui o trabalho e apresenta as direções para trabalhos futuros.

## 2. Trabalhos Relacionados

Imagens de ressonância magnética de cérebro são utilizadas em impressão 3D para planejamento cirúrgico e propósitos didáticos (NAFTULIN et al. 2015) (PLOCH et al. 2016), cirurgia guiada (JOLESZ, 2009)(LI, 2014), tratamento por estimulação magnética transcraniana (SOUZA et al. 2018) entre outras aplicações. Essas aplicações requerem que somente o cérebro esteja presente na imagem. Para isso é necessário remover o crânio, escalpo e demais tecidos que não fazem parte do cérebro com técnicas de processamento de imagens.

Alguns trabalhos descrevem técnicas de remoção desses tecidos na literatura. Laha (2018) utiliza operadores morfológicos em conjunto com a técnica de segmentação global baseada em Otsu. Já Sandor e Leahy (1997), utilizam uma combinação de operadores morfológicos em conjunto com modelos deformáveis de superfície. O trabalho de Smith (2002) inicialmente realiza a binarização da imagem baseada em histograma, em seguida, uma esfera deformável é inserida no centro de gravidade. Cada vértice da esfera é deformada até atingir o limite de uma função de custo pré-determinada por um algoritmo de otimização.

Por outro lado, existem trabalhos que são baseados em aprendizagem de máquina, como o de Vrooman (2013), que utilizam o classificador KNN para classificar os pixels que fazem parte do cérebro. Machhale (2015) utiliza os classificadores KNN e SVM para extrair cérebros com tumor em imagens de ressonância magnética de modalidade FLAIR. Métodos que utilizam as redes neurais profundas também são encontrados na literatura como Kleesiek (2016), Dey (2018), Lu (2019) e Ranjbar (2020), ambos utilizam arquiteturas de redes neurais convolucionais (CNN).

### 3. Metodologia

Este trabalho utiliza imagens de ressonância magnética (RM) de modalidade T1 como entrada. As imagens foram obtidas a partir do conjunto de dados público NFBS.

Na etapa de pré-processamento, as imagens são empilhadas, formando um volume. O volume é então normalizado entre os valores 0 e 1.0, pois os valores máximos e mínimos dos exames podem ser diferentes. Em seguida, o volume é dividido em vários sub-volumes (*patches*) de dimensão  $48^3$  com sobreposição de  $1/3$  em relação aos *patches* vizinhos.

Nas etapas de treinamento e predição, é utilizada a rede neural convolucional (CNN) de arquitetura U-Net 3D (RONNEBERGER, 2015), as dimensões das imagens de entrada e os pesos foram alterados em relação ao trabalho original. A figura 2 ilustra a arquitetura e seus respectivos novos valores. Foi empregada a normalização em lote (*batch normalization*), após cada camada de ativação. Na última camada foi empregada a função sigmóide. O otimizador Adam foi usado com uma taxa de aprendizado de 0.0001. A técnica de *data augmentation* também foi utilizada na fase de treinamento. Essa técnica permite gerar novos *patches* a partir dos já existentes, aplicando transformações geométricas como rotação (1-180 graus), cisalhamento (1-60%), zoom (1-30%), reflexão horizontal e vertical.

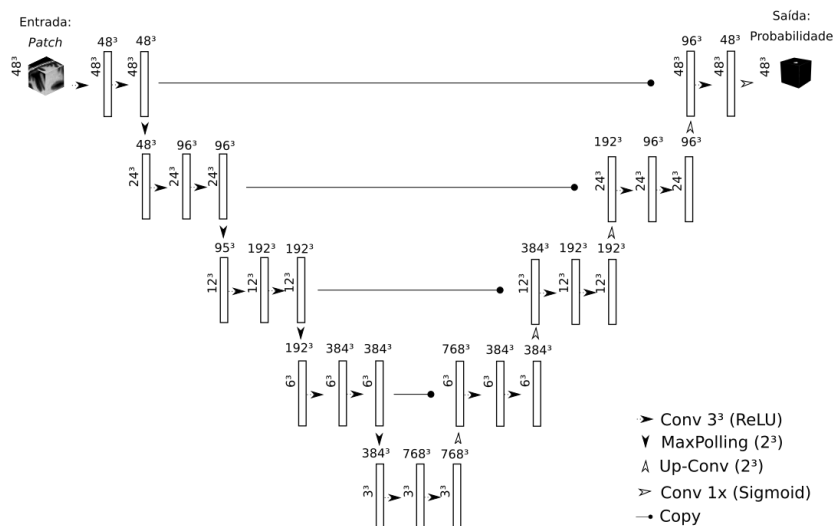


Figura 2: Arquitetura da rede U-Net 3D.

Após a predição, os *patches* são todos unidos formando um único volume. Cada voxel possui um valor entre 0 e 1. Esses valores são a probabilidade de um voxel fazer parte do cérebro ou não. Finalmente, o volume é binarizado, considerando como cérebro voxels com valores maiores ou igual 0.75 (75% de probabilidade) e não cérebro valores menores do que 0.75. A figura 3 ilustra a metodologia desenvolvida.

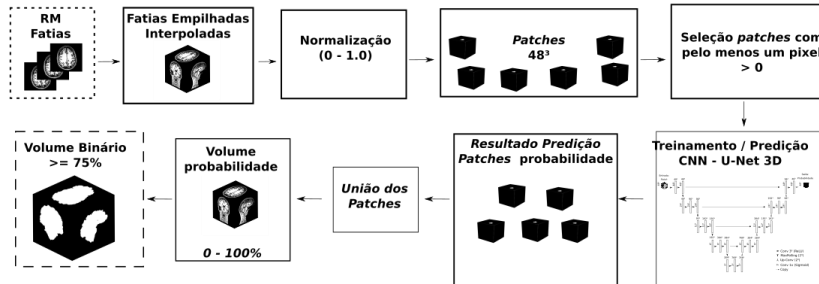


Figura 3: Metodologia desenvolvida no trabalho.

#### 4. Resultados

Experimentos foram realizados utilizando a base NFBS. O conjunto total de 125 exames foi dividido em 70% para treinamento, 20% para validação e 10% para testes. O processo de treinamento foi executado próximo de 200 épocas com *early stopping* para evitar problemas de *overfitting*. Também foi utilizada a validação cruzada. As seguintes métricas foram usadas na etapa de validação: Coeficiente de Sørensen-Dice (DSC) (Equação 1) e interseção sobre união (IoU) ou coeficiente Jaccard (Equação 2). Nas duas equações,  $P$  é o resultado da predição e  $G$  é o *ground truth* (segmentação do especialista), ambas são imagens binárias.

$$\frac{2|P \cap G|}{|P \cap G| + |P \cup G|}$$

Equação 1: Coeficiente de Sørensen-Dice (DSC).

$$\frac{P \cap G}{P \cup G}$$

Equação 2: Interseção sobre união (IoU) ou coeficiente Jaccard.

Em nossos experimentos, foi possível obter 93% de coeficiente de Sørensen-Dice e 96% no coeficiente de interseção sobre a união para 10% das imagens do conjunto de testes. A figura 4 apresenta um comparativo de uma imagem que faz parte de um volume de entrada (figura 4.a), imagem segmentada pelo especialista (figura 4.b) e imagem segmentada pelo método proposto nesse trabalho (figura 4.c). Já na figura 5, são exibidas três vistas diferentes da superfície de um cérebro renderizada após sua extração pelo método proposto.

## 5. Conclusões e trabalhos futuros

Neste trabalho, foi proposto um método para extrair o cérebro a partir de imagens de ressonância magnética de modalidade T1. Os resultados mostraram a eficácia do método proposto. Essa abordagem foi implementada e incorporada no software livre InVesalius (AMORIM et al. 2015). Em trabalhos futuros, pretendemos explorar a segmentação de outras partes do corpo humano, bem como as partes do cérebro.




Figura 5: Comparativo entre imagem que faz parte de uma ressonância magnética (a) com imagem segmentada pelo especialista (b) e resultado do método proposto (c).

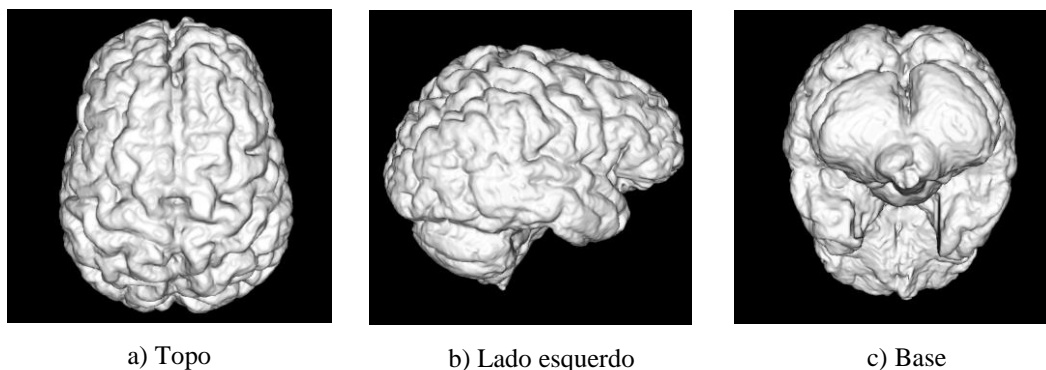


Figura 4: Superfície 3D renderizada após a extração do cérebro pelo método proposto.

## Agradecimentos

Os autores são gratos à comissão de bolsas PCI do CTI Renato Archer e ao CNPq.

## Referências

- AMORIM, P.; MORAES, T.; SILVA, J.; PEDRINI, H. *InVesalius: An Interactive Rendering Framework for Health Care Support*. In: SPRINGER. *International Symposium on Visual Computing*. [S.l.], 2015. p. 45–54. 2015
- CHRYSIKOPOULOS, H. S. *Clinical MR Imaging and Physics*. Verlag Berlin Heidelberg: Springer, 2009.
- DESPOTOVIĆ, I., GOOSSENS, B., & PHILIPS, W. *MRI Segmentation of the Human Brain: Challenges, Methods, and Applications*. *Computational and Mathematical Methods in Medicine*, 2015.
- DEY, R., & HONG, Y. CompNet: Complementary segmentation network for brain MRI extraction. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* (pp. 628-636). Springer, Cham. 2018.

**LI, G., SU, H., COLE, G. A., SHANG, W., HARRINGTON, K., CAMILO, PILITSIS, A. J. G. & FISCHER, G. S.** Robotic System for MRI-guided Stereotactic Neurosurgery. *IEEE Transactions on biomedical engineering*, 62(4), 1077-1088. 2014.

**JOLESZ, F. A.** *MRI-guided focused ultrasound surgery*. *Annual review of medicine*, 60, 417-430. 2009.

**KLEESIEK, J., URBAN, G., HUBERT, A., SCHWARZ, D., MAIER-HEIN, K., BENDSZUS, M., & BILLER, A.** *Deep MRI brain extraction: A 3D Convolutional Neural Network for Skull Stripping*. *NeuroImage*, 129, 460-469. 2016

**LAHA, M., TRIPATHI, P. C., & BAG, S.** *A Skull Stripping from Brain MRI Using Adaptive Iterative Thresholding and Mathematical Morphology*. In 2018 4th International Conference on Recent Advances in Information Technology (RAIT) (pp. 1-6). 2018.

**LU, S., GUO, X., MA, T., YANG, C., WANG, T., & ZHOU, P.** *Effective Multipath Feature Extraction 3D CNN for Multimodal Brain Tumor Segmentation*. In 2019 International Conference on Medical Imaging Physics and Engineering (ICMIPE) (pp. 1-7). IEEE. 2019.

**MACHHALE, K., NANDPURU, H. B., KAPUR, V., & KOSTA, L.** MRI Brain Cancer Classification Using Hybrid Classifier (SVM-KNN). In *2015 International Conference on Industrial Instrumentation and Control (ICIC)*(pp. 60-65). IEEE. 2015.

**NAFTULIN, J. S. KIMCHI, E. Y. & CASH, S. S.** Streamlined, Inexpensive 3D Printing of the Brain and Skull. *PloS one*, 10(8), e 0136198. 2015.

**NFBS Skull-Stripped Repository.** Disponível em: <[http://preprocessed-connectomes-project.org/NFB\\_skullstripped](http://preprocessed-connectomes-project.org/NFB_skullstripped)> Acesso em: 01 de Outubro de 2018.

**PLOCH, C. C. MANSI, C. S. JAYAMOHAN, J. & KUHL, E.** *Using 3D Printing to Create Personalized Brain Models for Neurosurgical Training and Preoperative Planning*. *World neurosurgery*, 90, 668-674. 2016.

**RONNEBERGER, O.; FISCHER, P. & BROX, T.** *U-Net: Convolutional Networks for Biomedical Image Segmentation*. In: SPRINGER. *International Conference on Medical Image Computing and Computer-Assisted Intervention*. [S.l.], 2015. p. 234–241. 2015.

**SANDOR, S., & LEAHY, R.** *Surface-based Labeling of Cortical Anatomy Using a Deformable Atlas*. *IEEE transactions on medical imaging*, 16(1), 41-54. 1997

**SCHWARTZ, W. R. & PEDRINI, H.** *Color Textured Image Segmentation based on Spatial Dependence using 3D Co-occurrence Matrices and Markov Random Fields*. In: 15th International Conference in Central Europe on Computer Graphics, Visualization and Computer Vision. Plzen, Czech Republic: [s.n.]. p. 81–87. 2007.

**SMITH, S. M.** *Fast Robust Automated Brain Extraction*. *Human brain mapping*, 17(3), 143-155. 2002.

**SOUZA, V. H. MATSUDA, R. H. PERES, A. S. C. AMORIM, P. H. J MORAES, T. F. SILVA, J. V. L. BAFFA, O.** *Development and Characterization of the InVesalius Navigator Software for Navigated Transcranial Magnetic Stimulation*. *J Neurosci Methods*. 309:109-120. 2018.

**RANJBAR, S., SINGLETON, K. W., CURTIN, L., RICKERTSEN, C. R., PAULSON, L. E., HU, L. S., MITCHELL J. R. & SWANSON, K. R.** *Robust Automatic Whole Brain Extraction on Magnetic Resonance Imaging of Brain Tumor Patients using Dense-Vnet*. arXiv preprint arXiv:2006.02627. 2020.

**VROOMAN, H., VAN DER LIJN, F., & NIESSEN, W.** *Auto-kNN: Brain Tissue Segmentation Using Automatically Trained Knearest-Neighbor Classification*. In *Proceedings of the MICCAI Workshops—The MICCAI Grand Challenge on MR Brain Image Segmentation (MRBrainS'13)*. 2013.