

Aplicabilidade da segmentação de lesões na Tomografia Computorizada torácica pediátrica



Bebiana Carvalho¹

¹ Técnica de Radiologia no Centro Hospitalar e Universitário do Porto

Introdução

A segmentação de lesões baseia-se em princípios da Inteligência Artificial (IA), sendo uma excelente ferramenta para o pós-processamento de imagens, com elevada importância em doentes oncológicos que vão realizar Radioterapia, mas também para programação cirúrgica que não oncológica. Existem áreas anatómicas em que mais se tem apostado na utilização da segmentação, como o tórax, fígado e cérebro.

São vários os modelos que atualmente estão a aparecer na área médica, surgindo quase diariamente novos artigos de IA no processamento de imagens. Recentemente, assistimos ao aparecimento de modelos adaptados para deteção de patologia cardíaca (1), para deteção de patologia relacionada com as mortes silenciosas, ou ainda a ajuda nas medições nas ecografias obstétricas de difícil leitura, ou a predição da resposta de um doente à quimioterapia.

Quando falamos em IA é importante compreender todos os processos que lhe dão origem, não só para percebermos as vantagens a nível de pós-processamento, mas também perceber qual será o futuro e o impacto que terá ao nível da saúde, mais especificamente na celeridade que poderá trazer a nível de diagnóstico e terapêutica dos utentes.

Respondendo ao desafio apresentado pela cirurgia pediátrica, a segmentação de lesões torácicas na pediatria tornou-se para nós ainda mais relevante, ao auxiliar o planeamento cirúrgico, permitindo avaliar qual a melhor abordagem, quais os planos de

clivagem, aumentando a probabilidade de uma melhor e mais rápida recuperação pós-operatória.

Inteligência Artificial – da ficção à realidade

A IA tem sido desde há vários anos uma temática abordada em filmes, no campo da ficção. Hoje, faz parte da realidade do nosso dia a dia, em processos que consideramos básicos, como, por exemplo, na utilização de telemóveis ou nos equipamentos mais recentes de tomografia computadorizada (TC).

Após a II Guerra Mundial, surge pela primeira vez o conceito de IA, como parte importante no desenvolvimento de atividades realizadas por máquinas em vez de humanos. Com o desenvolvimento de computadores mais sofisticados e potentes no que diz respeito à capacidade de processamento de dados, a IA passa a ter um maior domínio sobre grande parte das nossas atividades do quotidiano, mas passa também pela criação de vários modelos robóticos com diversos fins, como os utilizados pela NASA, capazes de dar uma previsão de sucesso quanto aos modelos aeronáuticos por eles desenvolvidos, ou ainda os carros sem condutor. Se inicialmente estes modelos eram baseados em *machine learning*, com uma algoritmia mais básica, atualmente o *deep learning* e as *redes neuronais convolucionais* (CNN) possuem uma algoritmia e modelos matemáticos mais complexos, que vieram revolucionar a IA, dando-lhe um novo conceito e estatuto de ciência, tornando-a numa excelente aliada na deteção e elaboração de processos

repetitivos, pela capacidade de integração e tratamento de *big data*.

Machine Learning, Deep Learning e CNN – aplicabilidade na Radiologia

Machine learning é um dos pilares da IA e baseia-se numa algoritmia básica de aprendizagem, tendo sido a visão por computador reconhecida como um dos grandes feitos na área da imagem, tendo bastante aplicabilidade clínica. Essa algoritmia assenta num conjunto de aprendizagens automatizadas, sistemáticas e robustas de dados, que serve de treino e, por fim, de execução da tarefa.

É através da visão por computador que obtemos a segmentação de imagens. Baseia-se em quatro princípios: a classificação do objeto, a localização, deteção e segmentação. Este princípio já é utilizado para deteção automática de nódulos pulmonares em alguns equipamentos de pós-processamento de TC (2). Aqui é necessário ainda intervenção humana para validação de resultados.

Quanto ao *deep learning*, este refere-se a um subconjunto de *machine learning* que pode imitar a função de processamento de dados do cérebro humano e criar os mesmos padrões para a tomada de decisões. Ao contrário dos algoritmos baseados em tarefas, os sistemas de *deep learning* aprendem com apresentações de dados não rotulados ou estruturados. Uma das aplicabilidades de *deep learning* na Radiologia prende-se com a criação de modelos de diminuição de dose de radiação e ruído nas imagens, mantendo a fiabilidade da retroprojeção filtrada, aliando-se à atual reconstrução iterativa já bastante implementada nos novos modelos de equipamentos de TC (3,4).

As CNN são compostas por uma variedade de algoritmos que podem interpretar dados sensoriais, através da perceção da máquina e rotular ou agrupar

dados brutos (figura 1). Este agrupamento de dados não rotulados é feito com base nas semelhanças encontradas nos dados de entrada e depois classificada com base no conjunto de dados rotulados. Para serem consideradas CNN, as redes terão de ter cinco ou mais camadas de análise de dados. O facto de a CNN ser uma rede profunda e ter bastantes camadas, ajuda na extração de características mais complexas, que é vital em Medicina. Aqui, encontramos o maior desafio apresentado na área da Radiologia, que passará pela aquisição e reconstrução de imagens, deteção de lesões, segmentação do órgão e lesão e, por fim, recolha de informação com caracterização das lesões, num processo automatizado, que culmina numa resposta mais rápida nos diagnósticos e consequente tratamento da doença.



Figura 1 - Exemplo de um modelo de CNN utilizado na Radiologia.

Segmentação de imagens médicas

São vários os programas que nos permitem de uma forma simples fazer segmentação de lesões ou estruturas, com acesso livre. Entre eles encontramos programas informáticos como o *ITK-Snap*® (figura 2) ou *3D-slicer*®.



Figura 2 – Exemplo de layout ITK-Snap®.

Estes programas permitem fazer uma segmentação manual ou semiautomática. Na segmentação semiautomática do *ITK-Snap*, podemos utilizar o *thresholding*, onde se pré-determinam os vóxeis a serem utilizados; *classifications* (exemplos de duas ou mais classes de tecido; *machine learning*); *clustering* que agrupa vóxeis de imagens semelhantes, e por fim *edge attraction*, que é muito útil quando a densidade dentro de uma imagem varia. O conhecimento do que cada uma das ferramentas de segmentação fornece é fundamental na segmentação semiautomática para determinarmos qual delas nos pode dar um resultado mais útil, mais real e com menos margem de erro na imagem segmentada final.

As segmentações de imagens têm inúmeras vantagens, tais como: a diferenciação de lesões, tumores ou órgãos, sendo para estes um excelente aliado na programação dosimétrica na Radioterapia; a cirurgia, permitindo uma melhor avaliação dos possíveis planos de clivagem e de um melhor planeamento de abordagem cirúrgica; e, por fim, no caso de lesões pericárdicas ou nos lobos superiores,

sendo um bom auxílio para a entubação, por se perceber exatamente em que parte da estrutura poderá existir compressão da via aérea. No entanto, tem também as suas desvantagens, onde os movimentos cardíacos e respiratórios ou os componentes metálicos podem comprometer a fiabilidade do resultado final.

Segmentação de lesões na TC torácica pediátrica

As TC realizadas em pediatria são sempre mais difíceis de avaliar que nos adultos, visto que há uma menor quantidade de gordura que permita uma melhor diferenciação de estruturas, além de que há sempre um incremento de ruído nas imagens.

A segmentação das lesões torna-se mais ou menos eficaz consoante o algoritmo de reconstrução (filtro/kernel) utilizado. Filtros “moles” diminuem a diferenciação de tecidos com densidades semelhantes, o que dificulta a segmentação da imagem e/ou lesão. Já em imagens que comprometam a vascularização dos grandes vasos, como são as lesões pericárdicas, poderá ser necessário uma adaptação do protocolo que nos permita essa diferenciação no pós-processamento, e que poderá, eventualmente, passar por uma dupla injeção de contraste que nos permita a avaliação da lesão, mas também da vascularização em fase arterial.

Na segmentação de imagens pericárdicas pediátricas (figura 3) optamos por fazer em 2D (figura 4) e 3D (figura 5), já que ambas têm interesse para o planeamento cirúrgico, por darem, em conjunto, mais informação e detalhe.



Figura 3 – Teratoma pericárdico em criança de 5 anos. a) Imagem em plano axial; b) Imagem em plano coronal; c) Imagem em plano sagital.




Figura 4 – Segmentação 2D de teratoma pericárdico em criança de 5 anos, no plano axial. a) Thresholding; b) Baseado nas UH, por sistema de cores.

Na figura 4a), pode-se confirmar como o *thresholding* após a pré-determinação dos vóxeis a utilizar, segmenta a lesão e demonstra que existe compressão cardíaca, mas não invasão. Na 4b) consegue-se avaliar a heterogeneidade da lesão e o suprimento vascular.

Na figura 5, a segmentação 3D permite a visualização dos diferentes órgãos, avaliação da lesão tanto quanto à forma, como ao tamanho, ajudando e se perceber e delinear a melhor abordagem cirúrgica.




Figura 5 – Segmentação 3D das imagens: vermelho – pulmão; roxo – coração; verde – teratoma.

Conclusão

As lesões não hipervasculares serão sempre mais difíceis de segmentar, pelo que num futuro próximo a sua segmentação será manual ou semiautomática. A adequação dos protocolos relativamente a doses de

radiação, filtros e tempos de contraste serão os principais desafios que irão surgir, num futuro próximo.

Num futuro mais longínquo, o *deep learning* e as *CNN* andarão de estreitamente relacionadas com a

Radiologia, quer em processos de redução de dose, quer em respostas mais automatizadas, tornando-se mais céleres. Muito do nosso trabalho e da nossa evolução estarão intimamente ligados, sendo que, muito provavelmente, os nossos *workflows* de trabalho irão alterar-se, e as respostas aos diagnósticos e tratamentos serão encurtados.

Referências Bibliográficas

1. <https://middleeast.geblogs.com/en/stories/artificial-intelligence-helps-kuwaiti-doctors-better-diagnose-heart-health/>
2. Teodoro Martín Noguero, et al, *Strengths, Weaknesses, Opportunities, and Threats Analysis of Artificial Intelligence and Machine Learning Applications in Radiology*, Journal of the American College of Radiology Volume 16 n Number 9PB n September 2019.
3. Dufan Wu, et al, *Iterative Low-dose CT Reconstruction with Priors Trained by Artificial Neural Network*, IEEE Trans Med Imaging.
4. Martin J. Willeminck, et al, *The evolution of image reconstruction for CT—from filtered back projection to artificial intelligence*, EurRadiol (2019) 29:2185–2195.
5. Magdalena Bazalovaa) and Edward E. Graves, *The importance of tissue segmentation for dose calculations for kilovoltage radiation therapy*, Department of Radiation Oncology, Molecular Imaging Program at Stanford, Stanford University, Stanford, California 94305.
6. Tongxue Zhou, et al, *A review: Deep learning for medical image segmentation using multi-modality fusion*, Array 3-4 (2019).
7. Preeti Aggarwal Uiet, et al, *Role of Segmentation in Medical Imaging: A Comparative Study*, International Journal of Computer Applications (0975 – 8887) Volume 29– No.1, September 2011.
8. Neeraj Sharma and Lalit M. Aggarwal, *Automated medical image segmentation techniques*, J Med Phys. 2010 Jan-Mar; 35(1): 3–14. doi: 10.4103/0971-6203.58777.
9. Awaish https://www.ncbi.nlm.nih.gov/pubmed/?term=Mansoor%20A%5BAuthor%5D&cauthor=true&cauthor_uid=26172351 Mansoor, PhD, ET AL, *Segmentation and Image Analysis of Abnormal Lungs at CT: Current Approaches, Challenges, and Future Trends*, Radiographics. July-August 2015; 35(4): 1056–1076. doi: 10.1148/rg.2015140232.
10. Xiangrong Zhou, et al, *Automatic segmentation and recognition of anatomical lung structures from high-resolution chest CT images*, Computerized Medical Imaging and Graphics Volume 30, Issue 5, July 2006, Pages 299-313.
11. Julip Jung, et al, *Ground-glass nodule segmentation in chest CT images using asymmetric multi-phase deformable model and pulmonary vessel removal*, Computers in Biology and Medicine 92 (2018) 128–138.
12. Yuma Iwao, et al, *Integrated lung field segmentation of injured region with anatomical structure analysis by failure–recovery algorithm from chest CT images*, Biomedical Signal Processing and Volume 12, July 2014, Pages 28–38.
13. Lorenzo Garzelli, et al, *Improving the prediction of lung adenocarcinoma invasive component on CT: Value of a vessel removal algorithm during software segmentation of subsolid nodules*, European Journal of Radiology, Volume 100, March 2018, Pages 58-6.