

EDITORIAL

Redes Neurais Convolucionais na Saúde

Marly Guimarães Fernandes Costa

Professora Titular do Departamento de Eletrônica e Computação da Universidade Federal do Amazonas - UFAM, Manaus (AM), Brasil.

A pesquisa com redes neurais artificiais (RNA), a mais importante ferramenta do aprendizado de máquina, é marcada por ondas. A primeira, que remonta à década de 60 do século passado, traz consigo a proposta do neurônio artificial e as primeiras arquiteturas de RNA, o *perceptron* e o *adaline*. Essas redes limitavam-se a resolução de problemas com classes linearmente separáveis e os algoritmos de treinamento aplicavam-se apenas a redes com apenas uma camada. A segunda onda, na década de 80, com o advento do método de retropropagação para o treinamento de redes com camadas escondidas, imprime um impulso significativo a pesquisa e as aplicações na área. No final do século passado, a proposta de novas redes para a resolução de problemas complexos, como a análise de imagens, carecia da concepção de novas arquiteturas de RNA, bem como de um maior poder computacional, que permitisse o treinamento de redes com um maior número de camadas, ou mais profundas. As redes neurais profundas, que surgem no final da primeira década deste século, constituem-se na terceira onda. Dentre elas, as redes neurais convolucionais são as que têm aplicações mais difundidas. Elas trazem consigo uma mudança fundamental na arquitetura das RNA, qual seja, o protagonismo de camadas de convolução. Ao invés da multiplicação de grandes matrizes de peso pelas ativações de camadas anteriores, temos agora a convolução de pequenos filtros com um pequeno número dessas ativações. Isso reduz significativamente a memória utilizada para armazenar os dados da arquitetura. Além disso, inspirado no processamento do córtex visual dos mamíferos, é introduzido uma nova camada, a camada de amostragem. Essa última confere às redes a invariância em relação a translações de pequenos detalhes em uma imagem. Por fim, porém não menos importante, uma mudança fundamental advinda com a terceira onda é que, diferentemente das ferramentas de aprendizado da geração anterior, as redes convolucionais não mais carecem de uma etapa prévia de extração de características. Essa tarefa é agora delegada às primeiras camadas da arquitetura. Do ponto de vista computacional, as unidades de processamento gráfico, GPU's, conferiram o poder computacional necessário a evolução tecnológica em curso. As redes convolucionais foram consideradas um dos 10 maiores avanços tecnológicos do ano de 2013⁽¹⁾.

Ao longo das três ondas mencionadas, observa-se um aumento significativo da profundidade das redes, ou seja, no número de camadas e, por conseguinte, do número de neurônios nas redes. Adicionalmente, para o treinamento supervisionado de arquiteturas cada vez mais profundas, faz-se necessário a disponibilidade de bases de dados rotuladas com milhares de exemplos. Assim, os principais desafios para aplicação das redes convolucionais são a disponibilidade de grandes bases de dados rotuladas, a construção de uma *expertise* na comunidade de informática em saúde para o treinamento dessas redes e a disponibilidade de hardware com GPU's. Atualmente, as principais ferramentas utilizadas para o desenvolvimento de aplicações com redes convolucionais são a plataforma *Caffe*, da Universidade de Berkeley e o *MatLab*, versão 2017b.

Numa pesquisa a base de dados PubMed com o termo “deep learning” foram identificadas, nos últimos 4 anos, 1804 publicações. Registra-se, assim, na área de saúde, um crescente interesse na pesquisa científica no tema. As principais aplicações em imagens médicas se concentram nas áreas de detecção e segmentação. Na área de detecção de imagens destacamos as seguintes aplicações: detecção automática de pólipos em vídeos de colonoscopia⁽²⁾, detecção de embolia pulmonar em imagens de CT⁽³⁾, detecção de células mitóticas em exames histopatológicos⁽⁴⁾. Todos os sistemas desenvolvidos demonstraram um desempenho superior a outros desenvolvidos com ferramentas de aprendizado da geração anterior, que exigiam, *a priori*, extração manual de características. Na área de segmentação de imagens são utilizadas redes convolucionais

semânticas. Nessas redes, a saída da rede é comparada com uma imagem do mesmo tamanho da imagem de entrada, em que os pixels são rotulados com rótulos distintos, em função da classe a que os mesmos pertencem. A arquitetura da rede é constituída de duas partes principais que se sucedem, uma referente a redução de tamanho da imagem original (*downsample*) e outra referente a restituição do tamanho da imagem original (*upsample*). As camadas de amostragem são responsáveis pelo *downsample*, enquanto que as camadas de deconvolução são responsáveis pelo *upsample*. Exemplos de aplicações são: segmentação do pâncreas em imagens de CT⁽⁵⁾, de tumores em imagem de ressonância magnética⁽⁶⁾, da cartilagem do joelho em imagens de MRI⁽⁷⁾ e do miocárdio em imagens de MRI⁽⁸⁾.

Para o futuro, um dos principais desafios na área é trabalhar com dados 3D, pois as dimensões dos dados crescem dramaticamente no trânsito de 2D para 3D. Assim novos saltos na velocidade e capacidade de processamento serão necessários para fazer frente ao desafio que ora já se impõe!

REFERÊNCIAS

1. Hof HD. MIT Technol Rev. 10 breakthrough technologies [Online]. 2017. Available from: <http://www.technologyreview.com/featuredstory/513696/deeplearning/>
2. Tajbakhsh N, Gurudu SR, Liang J. Automatic polyp detection in colonoscopy videos using an ensemble of convolutional neural networks. Proceeding of the. IEEE 12th Int Symp on Biomed Imag; 2015 Apr 16-19.
3. Tajbakhsh N, Liang J. Computer-aided pulmonary embolism detection using a novel vessel-aligned multi-planar image representation and convolutional neural networks. Proceeding of the Medical Image Computing and Computer Assisted Interventions. MICCAI; 2015 Oct 6-9; Munich, Germany; 2015.
4. Cire_an DC, Giusti A, Gambardella LM, Schmidhuber J. Mitosis detection in breast cancer histology images with deep neural networks. Proceeding of the Medical Image Computing and Computer Assisted Interventions. MICCAI; 2013 Sep 22-26; Nagoya, Japan. p. 411-8.
5. Roth HR, Farag A, Lu L, Turkbey EB, Summers RM. Deep convolutional networks for pancreas segmentation in CT imaging. Proceedings of the SPIE Medical Imaging; 2015 Feb 21-26; Orlando, Florida, USA. p.94
6. Havaei M, Davy A, Warde-Farley D, Biard A, Courville A, Bengio Y, Pal C, et al. Brain tumor segmentation with deep neural networks. Med Image Anal. 2017 Jan;35:18-31.
7. Prasoon A, Petersen K, Igel C, Lauze F, Dam E, Nielsen M. Deep feature learning for knee cartilage segmentation using a triplanar convolutional neural network. Proceeding of the Medical Image Computing and Computer Assisted Interventions. MICCAI; 2013 Sep 22-26; Nagoya, Japan. P 246-53.
8. Romanguera LR, Costa MGF, Romero FP, Costa Filho CFF. Left ventricle segmentation in cardiac MRI images using fully convolutional neural networks. Proceeding of the SPIE Medical Imaging; 2017 Feb 11-16. Orlando, Florida, USA. p. 101342Z-101342Z-11.