

Técnicas de Aprendizagem Curricular aplicadas ao Diagnóstico Precoce do Câncer de Pele

Luís F. H. Serrano*, Sandra Avila

Resumo

Detectar precocemente o câncer de pele é crucial: a taxa de sobrevivência é muito alta — cerca de 95% — para o diagnóstico precoce, mas cai substancialmente — para 10% a 15% — se o câncer atingir seus estágios finais. Neste contexto, o principal objetivo deste trabalho é facilitar a identificação precoce das lesões, melhorando dessa forma o prognóstico da doença. Para isso, focamos nas arquiteturas de aprendizado profundo (DLA, *Deep Learning Architectures*). Entretanto, o uso das DLAs para imagens médicas é problemático, devido à escassez de grandes bases de dados disponibilizadas. A utilização de tais dados pode ser melhorada a partir da aprendizagem curricular, uma estratégia de ordenação inteligente de tais dados que facilita o processo de aprendizagem.

Palavras-chave:

Aprendizagem profunda, Aprendizagem curricular, Imagens médicas

Introdução

Arquiteturas de aprendizado profundo (DLAs) são o estado da arte para tarefas de classificação que podem contar com grandes conjuntos de treino anotados. O diagnóstico assistido por computador, no entanto, apresenta sérios desafios devido à escassez de dados anotados, e a sutileza da diferença entre as imagens positivas/malignas e as negativas/benignas.

Esse trabalho visou investigar e aprimorar a classificação automática de imagens de câncer de pele, por meio da aplicação da aprendizagem curricular (*curriculum learning*) [1], uma estratégia de ordenação inteligente dos dados que facilita o processo de aprendizagem.

Resultados e Discussão

A ordem em que dados de treinamento são fornecidos às DLAs pode ser denominado de *currículo*. Tipicamente, este currículo é ordenado de forma aleatória e envolve todo o conjunto de treino. Contudo, humanos e animais aprendem mais facilmente e melhor quando são ensinados por exemplos de complexidade crescente. A estratégia de aprendizagem curricular emula este processo através da geração de um currículo adequado à DLA em questão. Esta estratégia originou diversas abordagens de criação de currículos.

Neste trabalho investigamos duas abordagens de aprendizagem curricular: ScreenerNet [2] e Conjuntos de Dados Crescentes Aleatórios [3].

O ScreenerNet utiliza uma segunda rede neural, que é treinada junto da rede original, para determinar quão relevante é cada exemplo para o treinamento naquele momento.

Os Conjuntos de Dados Crescentes Aleatórios (ROGS, *Random Ordered Growing Sets*) são utilizados para realizar um treinamento dividido em estágios, inicialmente sendo somente uma fração do conjunto original, mas expandido até se tornar o conjunto inteiro.

Primeiramente, avaliamos o ScreenerNet. Os resultados (não reportados aqui) não foram satisfatórios, uma vez que utilizando o código fornecido pelos autores não foi possível reproduzir seus resultados.

Em seguida foram feitos experimentos utilizando a técnica de ROGS. Os resultados foram mais

consistentes ao se garantir que a proporção de classes diferentes era a mesma em todos os estágios (cada estágio contém parte do conjunto de treinamento). O treinamento de um estágio é concluído quando o erro medido num conjunto de validação não melhora por um certo número de épocas sucessivas (tal número é nomeado paciência). Os resultados estão na Tabela 1. A rede utilizada no treinamento é uma adaptação da utilizada por Menegola et al. [4], a rede Inception-v4.

Tabela 1. Resultados (em AUC) para a abordagem Conjuntos de Dados Crescentes Aleatórios no conjunto ISIC Challenge 2017.

Est.	Pac.	Teste1	Teste2	Teste3	Teste4	Teste5
1	20	0.858	0.899	0.871	0.886	0.892
3	3	0.864	0.836	0.849	0.856	0.849
3	6	0.893	0.886	0.850	0.891	0.845
5	3	0.849	0.880	0.889	0.867	0.883
5	6	0.880	0.854	0.872	0.869	0.866

Conclusão

Apesar dos resultados não satisfatórios, é possível que uma configuração de ROGS com mais estágios ou distribuição de classes diferente traga melhores resultados, ou a utilização de outra técnica, como a aprendizagem autodirigida invertida.

Agradecimentos

Agradecemos ao PIBIC/CNPq (#170181/2017-0) pelo financiamento da pesquisa.

¹ Bengio, Y., et al., “Curriculum learning,” in International Conference on Machine Learning, 2009, pp. 41–48.

² Kim, T., and Choi, J., “ScreenerNet: Learning curriculum for neural networks,” arXiv, abs/1801.00904, 2018.

³ Mermer, M., and Amasyali, M., “Training with growing sets: A simple alternative to curriculum learning and self paced learning,” 2018. [Online]. Available: <https://openreview.net/forum?id=SJ1fQYICZ>

⁴ Menegola, A., et al., “RECOD Titans at ISIC Challenge 2017,” arXiv, abs/1703.04819, 2017.