



Exploração da Aprendizagem Curricular no Diagnóstico Precoce do Melanoma

Luís Felipe H. Serrano*, Sandra Avila

Resumo

O melanoma é o tipo mais agressivo de câncer de pele. A gravidade do câncer de pele geralmente se dá pelo diagnóstico tardio. Visamos investigar e aprimorar a classificação automática de imagens de câncer de pele através da aprendizagem curricular (*curriculum learning*), uma ordenação inteligente dos dados que pode facilitar o processo de treinamento de arquiteturas de aprendizado profundo.

Palavras-chave:

Aprendizagem profunda, Aprendizagem curricular, Melanoma.

Introdução

O treinamento de arquiteturas de aprendizado profundo (DLAs) para a classificação de imagens de câncer de pele é desafiador em razão dos poucos dados anotados disponíveis e sua difícil obtenção. Em razão disso, é importante utilizá-los da melhor maneira possível.

A ordem em que dados são fornecidos às DLAs durante o treinamento pode ser chamada de currículo. A aprendizagem curricular (*curriculum learning*) original [1], ranqueia as imagens segundo um critério de dificuldade e as fornece em ordem crescente, obtendo resultados positivos sobre outros problemas. A determinação deste critério e da ordem ideal para qualquer conjunto de dados é um problema em aberto na literatura. Anteriormente [2], investigamos a utilização de estágios crescentes aleatórios, uma variação promissora de aprendizagem curricular, contudo sem sucesso. Neste trabalho investigamos outras abordagens de aprendizagem curricular baseadas no treinamento dividido em dois estágios, de forma que a rede é treinada em sequência em dois conjuntos não idênticos.

clínicas existem em maior quantidade, porém possuímos poucas em relação a dermatoscópicas.

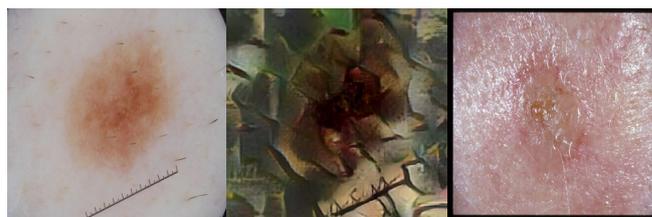


Figura 1. Da esquerda para direita: imagem dermatoscópica, sua versão texturizada e imagem clínica de outra lesão.

Verificamos a possibilidade de um estágio dedicado a um tipo de imagem específico melhorar o treinamento. De acordo com Geirhos et al. [3] o pré-treinamento de DLAs sobre o ImageNet (IN), gera uma tendência nas redes de diferenciar imagens principalmente através de texturas ao invés de formas. Adicionando um estágio que incluía versões das imagens originais com texturas modificadas melhorou o desempenho. Aplicamos esta técnica em nosso problema, uma vez que Menegola et al. utilizam pré-treinamento sobre o IN.

Resultados e Discussão

Estágio 1	Estágio 2	AUC
Clínica + Dermato	---	0.91 ± 0.01
Dermato	---	0.93 ± 0.01
Clínica + Dermato	Dermato	0.94 ± 0.01

Estágio 1	Estágio 2	AUC
Original	---	0.82 ± 0.03
Original + Texturizada	Original	0.82 ± 0.01

Tabela 1. Resultados para testes sobre o conjunto ISIC Challenge 2017 para estágios de tipo específico (topo) e para imagens texturizadas.

Este trabalho procura melhorar a rede e treinamento desenvolvidos por Menegola et al. [4], que venceram o ISIC Challenge 2017. A arquitetura utilizada foi a Inception-v4.

Nosso conjunto de dados de lesões de pele possui imagens de dois tipos: clínicas e dermatoscópicas. As últimas são imagens de alta qualidade que permitem observar atributos não visíveis em imagens clínicas. As

Conclusão

Para uma melhor avaliação dos nossos resultados, precisamos de um conjunto maior de imagens clínicas. Os treinamentos terminados com um estágio somente de imagens dermatoscópicas tiveram maior desempenho, potencialmente em razão do conjunto de testes ser formado somente por imagens deste tipo. O estágio com imagens de texturas modificadas também não melhorou os resultados, de forma que ainda não foi possível encontrar uma variação de aprendizagem curricular adequada ao problema.

Agradecimentos

PIBIC/CNPq, FAEPEX (3125/17), FAPESP (2017/16246-0), e Google LARA 2018.

1 Bengio, Y., et al., "Curriculum learning," in ICLR, 2009, pp. 41–48.

2 Serrano, L. F. H. & Avila, S., "Técnicas de aprendizagem curricular aplicadas ao diagnóstico precoce do câncer de pele," in Revista dos Trabalhos de Iniciação Científica da UNICAMP, 2018

3 R. Geirhos, et al., "Imagenet-trained cnn's are biased towards texture; increasing shape bias improves accuracy and robustness," in ICRL, 2018.

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