

REDE CONVOLUCIONAL PARA DETECÇÃO DE CÂNCER EM MAMOGRAFIA DE DUAS VISTAS USANDO TPU

Sergio Ariel Gonzales Fuentes

Daniel Gustavo Pellacani Petrini

Hae Yong Kim

Escola Politécnica/Universidade de São Paulo

sergio.a.g.fuentes@gmail.com

Objetivos

Este trabalho visa verificar as vantagens de implementar uma rede neural convolucional que detecta câncer em mamografias em TPU (*Tensor Processing Unit*).

Tipicamente são utilizadas GPU (*Graphics Processing Unit*) para tarefas desse tipo, mas TPUs possuem em geral muito mais memória interna, permitindo treinar e testar mamografias em altas resoluções. Queremos verificar se o aumento de resolução das imagens de entrada provoca uma melhora na detecção desse tipo de câncer. Para isso, vamos usar o *framework Tensorflow/Keras* que está bem adaptado para rodar em TPU.

Alguns tipos de câncer apresentam-se como texturas no exame, por isso uma maior resolução pode melhorar a detecção desses.

Métodos e Procedimentos

O primeiro passo foi transcrever a rede neural convolucional que detecta câncer de mama em mamografias desenvolvida por Petrini et al. [1], do *framework PyTorch* para *Tensorflow*, para poder executar o modelo em TPU. *Tensorflow* está melhor adaptado do que *PyTorch* para rodar em TPU, pois tanto *TensorFlow* quanto TPU foram produzidos pela mesma empresa *Google*.

O modelo obtido é baseado no *EfficientNet-B0* [2], a partir do qual são gerados o classificador de *patches*, classificador de vista única e o classificador de duas vistas, apresentados na figura 1.

Foi utilizado o dataset público CBIS-DDSM (*Curated Breast Imaging Subset of Digital Database for Screening Mammography*) [3], seguindo a divisão original em conjunto de treino e teste e utilizando diferentes resoluções para os testes.

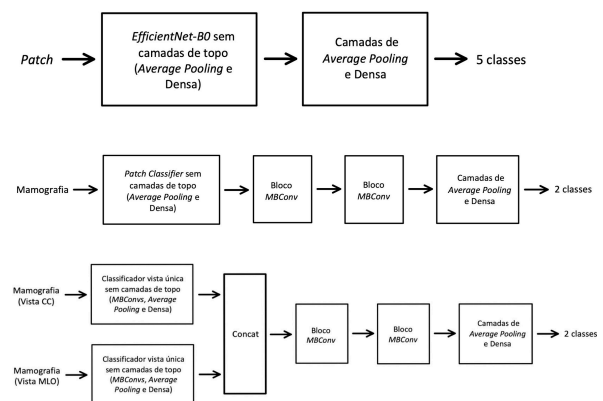


Figura 1: Componentes do classificador

Resultados

Na tabela 1, estão presentes as métricas de performance para cada componente.

Importante notar que a resolução do classificador de patches é de 224x224 para o caso em que o classificador completo apresenta resolução de 1152x896, e 448x448 para o outro. Já na tabela 2, estão presentes os dados quanto ao tempo de treinamento por época.

Tabela 1: Resultados de cada componente

Classificador (Métrica) / Dispositivo (Resolução)	Patches (Acurácia)	Vista Única (AUC-ROC)	Duas Vistas (AUC-ROC)
Original	75,54%	0,8033±0,0183	0,8419±0,0258
GPU (1152x896)	74,04%	0,8143±0,0179	0,8498±0,0227
TPU (1152x896)	76,37%	0,8003±0,0184	0,8327±0,0264
TPU (2304x1792)	79,52%	0,8154±0,0178	0,8466±0,0264

Tabela 2: Tempo de treinamento por época de cada componente em segundos

Classificador/ Dispositivo (Resolução)	Patches	Vista Única	Duas Vistas
GPU (1152x896)	363	376	73
TPU (1152x896)	19	22	17
TPU (2304x1792)	50	71	28/

Com base nos resultados acima, apenas o classificador de *patches* apresentou uma melhora considerável ao aumentar a resolução utilizando a TPU. Mas houve uma diminuição significativa no tempo de treinamento por época chegando a ser dezenove vezes mais rápido no melhor caso e quatro vezes mais rápido no pior.

Conclusões

Considerando o desempenho de classificação do sistema, não houve uma melhora significativa ao usar uma maior resolução, que pode ser decorrente do uso de um *dataset* formado a partir de imagens escaneadas. Isso decorre do fato de já ter existido uma perda de informação durante o processo de escaneamento, suprimindo assim os detalhes de uma imagem em maior resolução. Um teste com um *dataset* com imagens inatamente digitais poderia ser utilizado para verificar essa hipótese.

Apesar disso, o uso da TPU não foi em vão. O aumento considerável na velocidade de treinamento permite realizar um maior número de testes de hiperparâmetros, obtendo assim modelos mais refinados. Também facilita o uso de uma maior quantidade de dados. E finalmente, viabiliza o uso de modelos mais complexos.

Agradecimentos

Um agradecimento especial ao CNPq – Conselho Nacional de Desenvolvimento Científico e Tecnológico pelo apoio financeiro deste trabalho.

Referências

- 1 D. G. P. Petrini, C. Shimizu, R. A. Roela, G. V. Valente, M. A. A. K. Folgueira and H. Y. Kim, "Breast Cancer Diagnosis in Two-View Mammography Using End-to-End Trained EfficientNet-Based Convolutional Network," in *IEEE Access*, vol. 10, pp. 77723-77731, 2022, doi: 10.1109/ACCESS.2022.3193250.
- 2 M. Tan, and Q. Le. "Efficientnet: Rethinking model scaling for convolutional neural networks." *International conference on machine learning*. PMLR, 2019.
- 3 Lee, R., Gimenez, F., Hoogi, A. et al. A curated mammography data set for use in computer-aided detection and diagnosis research. *Sci Data* 4, 170177 (2017). <https://doi.org/10.1038/sdata.2017.177>