



CLASSIFICAÇÃO DE LESÕES DERMATOLÓGICAS UTILIZANDO REDES NEURAIS CONVOLUCIONAIS

Autor: Paulo Gamarra Lessa Pinto
pglpinto@inf.ufrgs.br



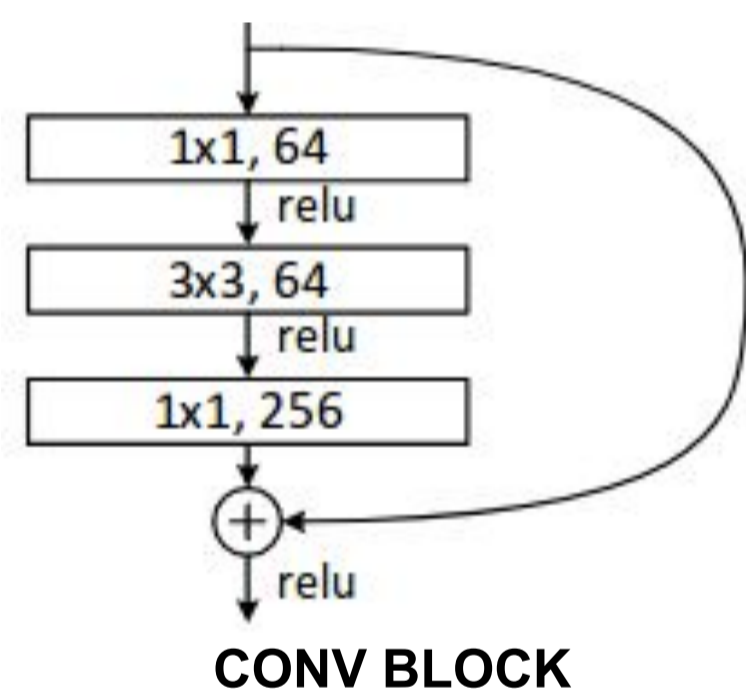
Orientador: Jacob Scharcanski
jacobs@inf.ufrgs.br

1 - INTRODUÇÃO





- O diagnóstico precoce é fundamental para a cura do paciente com câncer de pele.
- Neste trabalho é apresentado um método baseado em redes neurais convolucionais para a classificação de imagens dermatoscópicas de lesões de pele, com o objetivo de dar suporte à profissionais da saúde no diagnóstico dessa doença.
- Nosso método é treinado em dados rotulados por profissionais da área.
- As métricas de avaliação resultantes são comparáveis ao estado da arte

2 - MÉTODO

- O modelo proposto utiliza a ResNet-50^[2] com pesos treinados em dados genéricos como base de extração de *features*.



- É adicionada uma camada *fully-connected* à essa base com 7 neurônios representando as 7 classes do dataset utilizado
- Os pesos são inicializados com valores aleatórios seguindo a distribuição normal
- Durante o treinamento, os pesos são congelados até a última camada de convolução




"MELANOMA"


█ PESOS CONGELADOS
█ PESOS TREINÁVEIS

3 - RESULTADOS EXPERIMENTAIS


- Para o treino e avaliação do modelo proposto, foi utilizado o dataset "Human Against Machine with 10000 training images" (HAM10000)^[1].
- 7 classes: Ceratose actínica (AKIEC), carcinoma basocelular (BCC), ceratose benigna (BKL), dermatofibroma (DF), nevo melanocítico (NV), melanoma (MEL), ou lesão vascular (VASC).



MELANOMA



CERATOSE BENIGNA



NEVO MELANOCÍTICO

- Os dados foram divididos em dois conjuntos de treino e teste com respectivamente 75% e 25% das amostras
- Foi utilizado o otimizador Adam com *learning rate* de 0,001 para treinamento
- Foram utilizadas técnicas de *data augmentation* no conjunto de treino
- O modelo atingiu uma taxa de acerto de **86.44%** no conjunto de teste
- Abaixo, nossos resultados são comparados com os apresentados em [3], que representam o estado da arte, através da métrica ROC AUC

Método	MEL	NV	BCC	AKIEC	BKL	DF	VASC
Estado da Arte	0.896	0.954	0.969	0.968	0.930	0.932	0.992
Nosso Modelo	0.953	0.970	0.984	0.945	0.955	0.993	0.996

- Nosso modelo supera a classificação do estado da arte na maioria das classes, em especial o **melanoma**, que teve um aumento significativo na especificidade, apresentado abaixo

Método	Precisão	Especificidade
Estado da Arte	63%	40%
Nosso Modelo	63%	74%

4 - CONCLUSÃO

- O uso de dropout, inicialização de pesos normalizados e a *data augmentation* apresentados nesse modelo configuram uma estratégia de *fine-tuning* com resultados melhores do que o estado da arte, que utiliza a mesma base de extração de features.

REFERÊNCIAS

- [1] TSHANDL, PHILIPP; ROSENDAHL, CLIFF; KITTLER, HARALD "The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions", Nature Scientific Data, Volume 5, id. 180161, 2018
- [2] HE, K; ZHANG, X; REN, S; SUN, J. "Deep Residual Learning for Image Recognition", [s. l.]: [s. n.], 2015.
- [3] THANDIACKAL, KEVIN; GOKSEL, ORCUN. "A Structure-Aware Convolutional Neural Network for Skin Lesion Classification", OR 2.0 Context-Aware Operating Theaters, Computer Assisted Robotic Endoscopy, Clinical Image-Based Procedures, and Skin Image Analysis, pp 312 - 319, 2018