



## Classificação de lesões de mama utilizando *Transfer Learning* com a rede neural convolucional AlexNet

A.H. Fuchs<sup>1\*</sup>, K. El Zein<sup>1,2</sup>, W.C.A. Pereira<sup>3</sup>, S. Battistella<sup>4</sup>, A. Kauati<sup>5</sup>

<sup>1</sup>Ciência da Computação/UNIOESTE, Foz do Iguaçu, Brasil

<sup>2</sup>Centro Latino-Americano de Tecnologias Abertas/PTI, Foz do Iguaçu, Brasil

<sup>3</sup>Programa de Engenharia Biomédica/COPPE/UFRJ, Rio de Janeiro, Brasil

<sup>4</sup>Departamento de Engenharia Elétrica/ UNIOESTE, Foz do Iguaçu, Brasil

<sup>5</sup>Programa de Pós-Graduação em Eng. Elétrica e Computação/UNIOESTE, Foz do Iguaçu, Brasil

\*henrique\_adrian@hotmail.com

**Fundamentos, Motivação e Objetivo.** A mamografia tem sido considerada uma técnica diagnóstica que contribui, por meio de um programa de acompanhamento periódico, para a redução da mortalidade por câncer de mama (PMID:10693544). No entanto, sua especificidade ainda deixa a desejar, uma vez que um número considerável de massas sólidas suspeitas é geralmente recomendado para biópsia cirúrgica. Por isso a ultrassonografia de mama é usada para melhorar a qualidade diagnóstica e diminuir o número de biópsias desnecessárias, já que os tumores malignos tendem a apresentar bordas irregulares e convexas, enquanto os benignos geralmente são arredondados e bem definidos ([10.1016/j.compbiomed.2010.10.003](https://doi.org/10.1016/j.compbiomed.2010.10.003)). Entretanto a interpretação das imagens de ultrassom provenientes destes exames é bastante dependente da experiência do médico. Para auxiliar na interpretação destes exames, surgiram os sistemas *Computer-Aided Diagnosis* (CAD, em português, Diagnóstico Assistido por Computador) que buscam fornecer uma segunda opinião para os especialistas (ISSN:2359-3164). Neste trabalho, pretende-se desenvolver a etapa de classificação de um CAD, para imagens de ultrassom mamário, utilizando transferência de aprendizado de rede neural convolucional profunda, mais especificamente a AlexNet, em que o classificador irá identificar os tipos de lesões (benigna ou maligna).

**Métodos.** O banco de imagens utilizado consiste em 641 imagens pertencentes ao Programa de Engenharia Biomédica da COPPE/UFRJ, sendo destas, 413 ultrassonografias que apresentam lesões benignas e 228 malignas. Sabendo que a transferência de recursos já aprendidos de uma rede neural convolucional para uma nova tarefa necessita de um número relativamente pequeno de imagens, torna-se muito mais rápido e fácil do que treinar uma rede inteira desde o início ([10.1007/s11263-015-0816-y](https://doi.org/10.1007/s11263-015-0816-y)), as imagens foram separadas na proporção de 80% para treino e 20% para validação. Operações especiais foram realizadas nas imagens de treinamento como rotação aleatória de até 30 pixels na horizontal e na vertical para evitar possível *overfitting*. A rede neural AlexNet tem suas três últimas camadas pré-configuradas para 1000 classes e, portanto, tiveram de ser substituídas para que reconheçam apenas duas classes. Foram realizados 10 testes em que o resultado foi dado por uma matriz de confusão, que indica a proporção entre as classes testadas na classificação. Da matriz de confusão pode-se retirar dados como Verdadeiros Positivos (VP - lesões malignas corretamente classificadas), Falsos Negativos (FN - lesões malignas classificadas como benignas), Falsos Positivos (FP - lesões benignas classificadas como malignas) e Verdadeiros Negativos (VN - lesões benignas corretamente classificadas), que são usados para os cálculos de acurácia, eficiência, especificidade (que é a medida da eficiência do sistema em

identificar um diagnóstico negativo) e sensibilidade (que é uma medida que identifica a confiabilidade do sistema de fornecer o diagnóstico correto para um caso positivo).

$$ACURÁCIA = \frac{VP + VN}{VP + VN + FP + FN}$$

$$ESPECIFICIDADE = \frac{VN}{VN + FP}$$

$$SENSIBILIDADE = \frac{VP}{VP + FN}$$

$$EFICIÊNCIA = \frac{SENSIBILIDADE + ESPECIFICIDADE}{2}$$

**Resultados.** Na Tabela 1 é mostrada a média aritmética dos 10 testes feitos assim como seus respectivos desvios padrões sobre as métricas de especificidade, sensibilidade, acurácia e eficiência.

**Tabela 1.** Média dos resultados com seus respectivos Desvios Padrões (DP).

Especificidade	Sensibilidade	Acurácia	Eficiência
86,62% (DP: 0,0902)	81,08% (DP: 0,1060)	84,65% (DP: 0,0440)	83,85% (DP: 0,0415)

**Discussão e Conclusões.** Os resultados encontrados são inferiores aos da literatura quando comparados com SVM (*Support Vector Machine*, em português, Máquinas de Vetor de Suporte) e RBFNN (*Radial Basis Function Neural Network*, em português, Redes Neurais com Função de Ativação de Base Radial), porém melhores quando comparados com LDA (*Linear Discriminant Analysis*, em português, Análise Discriminante Linear)(Gómez *et al*, 2010, Anais do XXII CBEB, p. 399). Como a AlexNet tem suas primeiras camadas treinadas com imagens das mais diversas classes e a base de estudos deste trabalho são imagens médicas, este pode ser o motivo. A proposta de continuação deste trabalho é treinar a rede convolucional AlexNet desde as primeiras camadas com um banco de dados maior para melhores resultados. Além disso, as redes neurais convolucionais profundas GoogLeNet e Inception serão avaliadas e treinadas para a busca de aumentar o desempenho, ambas utilizadas no Large-Scale Visual Recognition Challenge 2014 ([arXiv:1409.4842v1](https://arxiv.org/abs/1409.4842v1)).

**Agradecimentos.** CNPq 311.650/2017-1, FAPERJ E-26/203.041/2015 e CAPES/PROEX

**Palavras-chave.** Câncer de mama; Classificação; *Deep Learning*; AlexNet.