

Extração de Características de Imagens Mamográficas Baseada em Técnicas de Aprendizado Profundo

Ariadne N. Matos¹, Paulo E. Ambrósio²

¹Departamento de Ciências Exatas e Tecnológica – Universidade Estadual de Santa Cruz (UESC)
Ilhéus – BA – Brasil

²Departamento de Ciências Exatas e Tecnológica – Universidade Estadual de Santa Cruz
Ilhéus – BA – Brasil.

ariadnenascime6@gmail.com, peambrosio@uesc.br

Abstract. *Despite the constant advances in the fight against breast cancer, it is still one of the main causes of death in women. Based on technological advances, deep learning techniques can assist in the detection and classification of nodules, which contributes to the diagnosis. In this paper we present the proposal and construction of a convolutional neural network with regularization techniques called MiDNet for feature extraction from mammographic images. The model was validated with the CBIS DDSM and Mini DDSM datasets, obtaining accuracy rates with 98 percent for mass differentiation and 74 percent for classification of images in benign or malignant.*

Resumo. *Apesar dos constantes avanços no combate ao câncer de mama, ainda é uma das principais causas no óbito de mulheres. A partir do avanço tecnológico, as técnicas de deep learning podem auxiliar na detecção e classificação dos nódulos, o que contribui com o diagnóstico. Apresentamos, neste artigo a proposta e a construção uma rede neural convolucional juntamente com técnicas de regularização denominada MiDNet para extração de características de imagens mamográficas. O modelo foi validado com o conjunto de dados da base CBIS DDSM e Mini DDSM, obtendo índices de acurácia com 98 por cento para diferenciação de massas e 74 por cento para classificação de imagens em benignas ou malignas.*

1. Introdução

O câncer de mama é uma enfermidade que se manifesta com maior frequência em pessoas do gênero feminino, tendo com maior incidência mulheres com idade por volta de 50 anos [Vieira 2012]. A elevada incidência, associada a alta taxa de mortalidade e custo elevado do tratamento, são variáveis que convergem para que essa doença torne-se um preocupante quadro clínico para os sistemas de saúde.

Diante do exposto, as técnicas de aprendizado profundo (deep learning), são de extrema importância, uma vez que, consegue abranger questões computacionais. As redes neurais convolucionais (CNN) no que tange um grande volume de dados possuem a habilidade em lidar com variações nos dados de entrada, compartilhamento de pesos [LECUN 2003] e possibilita a extração de características de imagens mamográficas de maneira automática, de acordo com a base de treinamento.

2. Revisão Bibliográfica

As redes convolucionais apresentam neurônios de aprendizado individuais, com a utilização de matrizes responsáveis por realizar a extração de características. De acordo como [Chollet 2017] a camada convolutiva aplica filtros e através desses filtros é possível o reconhecimento de padrões. No desenvolvimento dos modelos um desafio comum é o sobreajuste dos dados, sendo assim, surge a importância das técnicas de regularização que tem como objetivo reduzir o ajuste excessivo.

Dentre essas técnicas está o *dropout*, que ao ser aplicado em uma camada, desativa aleatoriamente alguns neurônios e de acordo com [Krizhevsky et al. 2012], possibilita que cada parâmetro do modelo seja fortemente regularizado. Uma outra técnica utilizada é a regularização L2, conforme [Goodfellow et al. 2016], essa estratégia foca na alteração da função de custo, acrescentando um termo de regularização.

A análise e uso de técnicas de aprendizado profundo tem sido recorrentes na área de detecção de massas no tecido mamário e classificação. No trabalho proposto por [Martins 2020] foi aplicado um detector convolucional denominado RetinaNet, com a utilização de etapas de pré-processamento e o conjunto dados da CBIS DDSM para detecção de massas. O trabalho proposto por [Yu et al. 2020], também aplicou o uso de redes convolutivas, ao utilizar um bloco residual da ResNet50 e adaptar as camadas para detecção de massas e posterior classificação. Assim como nos trabalhos citados, [Zhou et al. 2017] utilizou redes convolucionais, contudo aplicando uma implementação própria para detecção e posterior classificação de imagens mamográficas, a partir da base mini-MIAS.

3. Metodologia

A metodologia geral empregada para o desenvolvimento consistiu na aquisição das imagens com a base de dados CBIS DDSM e Mini DDSM, sendo realizado o processamento de imagens e posterior extração de características com o desenvolvimento de uma rede própria, para detecção de anormalidades e posterior classificação em benigno ou maligno.

Inicialmente foram obtidas cerca de 2.620 mamografias escaneadas com massas benignas e malignas da base CBIS DDSM, uma base pública que abrange imagens mamográficas com nódulos benignos e malignos. Por conter apenas mamas sem nódulos foi escolhida também a base Mini DDSM para obtenção de imagens normais, sendo que, para ambas as bases foi utilizado o formato PNG, com tamanho de 1152x832 *pixels* cada imagem.

3.1. Processamento das Imagens

O processamento de imagem é uma etapa importante para retirada de ruídos das imagens, informações indesejadas e possibilita melhorar determinados aspectos. Portanto, para remoção de etiquetas e ruídos presentes em ambas as bases públicas, foi empregado o filtro gaussiano, que é mais eficiente na remoção de ruídos aleatórios, além de fornecer destaque aos detalhes mais importantes de uma imagem, como bordas, por exemplo. Uma outra técnica utilizada foi a aplicação do filtro morfológico *opening*, que possibilita suavizar o contorno, remoção de pontos pretos aleatórios presentes na imagem e ruídos.

Como a base era composta por imagens que também continham tecido peitoral, foi necessário aplicar um limiar ideal que variava entre 141 a 187 de acordo com o nível

de cinza do músculo. Esse limiar foi importante para delimitar o tecido muscular, sendo assim, após a delimitação aplicou-se uma equalização do histograma da imagem e ao final a segmentação por *Watershed*, que permite separar as regiões de interesse das que não são, possibilitando portanto, a extração do músculo.

Para obtenção da região do tecido mamário que continha somente nódulos, utilizou-se as imagens originais da base CBIS DDSM e foram multiplicadas tais imagens com suas respectivas máscaras. Após essa multiplicação foi aplicado o *bounding box*, técnica que permite delimitar o objeto, nesse caso o nódulo, ampliando o mesmo sem perda de informação, como representado na Figura 1. Essa mesma técnica foi utilizada para obtenção de pequenas regiões sem nódulos, ao aplicar a máscara em regiões normais. Cabe destacar, que para aplicação das técnicas de processamento foi utilizado o OpenCV, uma biblioteca (*library*) com funções para visão computacional.

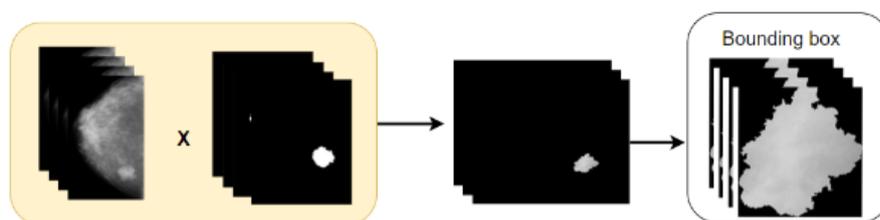


Figura 1. Segmentação da Região de Interesse

3.2. Arquitetura Proposta

A arquitetura utilizada para detecção de anormalidades em imagens mamográficas, ou seja, presença ou não de nódulos e posterior classificação dos mesmos foi construída tomando como ponto de partida o artigo "*Mammogram Classification Using Convolutional Neural Network*" [Zhou et al. 2017], onde foram descritas partes importantes da rede neural convolucional para classificação de massas e calcificações, além desse artigo foram utilizados conceitos basilares presentes na literatura.

Inicialmente foram desenvolvidas camadas convolutivas com *kernel* 3x3, sendo que após cada camada convolucional foi aplicada a normalização em lotes para padronização de variáveis de entradas, também conhecida como *Batchnormalization*. O modelo proposto portanto, se diferencia do artigo utilizado como base inicial, ao estruturar as camadas convolutivas com posteriores normalizações em lotes e aplicação de sucessivas técnicas de regularização, desde a utilização do *dropout* a aplicação da regularização L2.

Após a normalização, foi utilizada função ReLU, também conhecida como função de ativação, permite zerar todos os valores negativos e mantém o valor para saídas positivas. Por manter alguns neurônios não ativados, a rede torna-se mais esparsa, por esse motivo foi aplicada ao longo do modelo. Além disso foi empregado o uso do *Maxpooling* com tamanho 2x2 com a finalidade de obter as características mais preponderantes de cada camada.

Ao longo da construção do modelo um dos problemas comumente enfrentados foi o *overfitting* e para que o mesmo fosse sanado foram aplicadas técnicas de regularização, inicialmente foram empregadas a regularização L2 após camadas convolutivas e aplicado

o *dropout* com taxa de 0.1 que consistiu na fração de unidades de entrada a serem diminuídas, sendo empregado após camadas de *Maxpooling* e ao final do modelo. Com o intuito de aumentar a variabilidade da base, foi utilizada a técnica de *data augmentation* totalizando 4.000 imagens com massas com tamanho 256×256 pixels e 4000 imagens mamográficas.

Para um melhor ajuste nos hiperparâmetros da rede, empregou-se *callbacks* como métodos para redução das taxas de aprendizagem caso houvesse uma estagnação do aprendizado e interrupção do treinamento com o uso do *EarlyStopping* e para compilação a entropia cruzada. Ao final foi realizado um comparativo com as redes InceptionV3 e ResNet50 além de alguns trabalhos presentes na literatura para detecção de regiões suspeitas ou com nódulos e classificação desses nódulos em malignos ou benignos.

4. Resultados

Para avaliação precisa dos resultados obtidos com a rede MiDNet, proposta e implementada, o resultado foi validado com um conjunto de imagens, cerca de 30 por cento do total utilizado e realizado um comparativo inicial com a ResNet50 e InceptionV3 para regiões com massas e sem massas. Os resultados obtidos estão apresentados na Tabela 1 sendo possível observar que a arquitetura proposta obteve desempenho semelhante a InceptionV3.

Tabela 1. Resultados Obtidos

Classes	Precision	Recall	F1-Score	Accuracy	Rede
Sem Nódulos	0.61	0.56	0.59	0.72	ResNet50
Com Nódulos	0.77	0.80	0.78	0.72	ResNet50
Sem Nódulos	0.97	0.96	0.97	0.97	InceptionV3
Com Nódulos	0.96	0.99	0.97	0.97	InceptionV3
Sem Nódulos	0.96	0.99	0.98	0.98	MiDNet
Com Nódulos	0.99	0.96	0.98	0.98	MiDNet

Com o emprego da normalização em lotes e do *EarlyStopping* foi possível reduzir o número de épocas durante o treinamento da rede MiDNet, ocorrendo em 16 épocas e foi possível notar uma redução do *overfitting* com a utilização das técnicas de regularização, como pode ser observado na Figura 2(c), em comparação a rede InceptionV3 e ResNet50.

Percebe-se que a arquitetura proposta apresentou ótimos resultados, sendo possível analisar uma redução do sobreajuste, quantidade de épocas e uma aumento significativo das métricas de avaliação, com cerca de 98 por cento de acurácia e 96 por cento de sensibilidade, resultado adequado para saber se um determinado tecido mamográfico possui ou não algum nódulo.

Em comparação com alguns trabalhos propostos na literatura que apresentam implementações de redes convolucionais para detecção de massas como o trabalho de [Zhou et al. 2017] percebe-se que com a arquitetura desenvolvida neste trabalho foi possível reduzir o tempo de treinamento, sem que ocorra a necessidade de cerca de 10.000 épocas mesmo com a utilização do aumento de dados, como foi utilizado no trabalho do [Zhou et al. 2017].

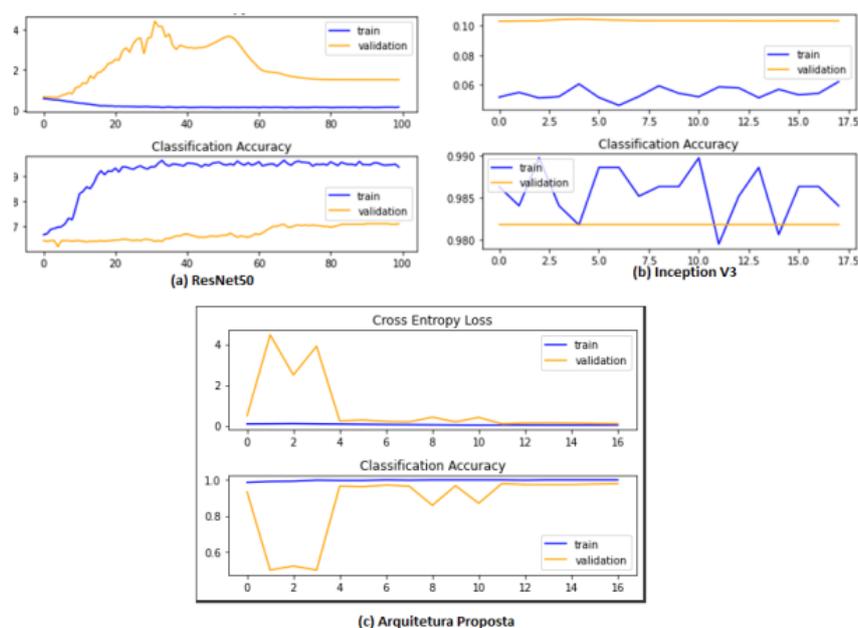


Figura 2. Gráfico referente ao treinamento das redes

Um outro fator importante foi que além do resultado convergir mais rapidamente com apenas 16 épocas, tem-se uma maior precisão sobretudo para classificar nódulos malignos e identificar regiões com nódulos. Além disso, diferencia-se no que diz respeito a obtenção de resultados mais precisos sem um elevado custo computacional, como nas redes ResNet50 e InceptionV3, por exemplo, onde se tem um elevado número de camadas, o que é custoso computacionalmente. Ao comparar com demais redes já propostas na literatura como a RetinaNet e ResNet50, foi possível analisar que o modelo proposto obteve um desempenho superior por uma margem significativa em termos de sensibilidade da rede ou taxa de verdadeiro positivo (TPR), como apresentado na Tabela 2.

Tabela 2. Tabela Comparativa com trabalhos correlatos. Métrica avaliada TPR(Taxa de verdadeiro positivo)

Trabalho	TPR	Objetivo Específico
Este Trabalho	0.96	Detecção de Massas
[Martins 2020]	0.85	Detecção de Massas
[Yu et al. 2020]	0.92	Detecção de Massas
[Zhou et al. 2017]	0.50	Detecção de Massas Malignas

Após a utilização da rede proposta neste trabalho para diferenciação entre regiões normais e com nódulos, a mesma rede foi empregada para classificação das respectivas imagens que continham massas, em malignas ou benignas. Para utilização da rede para classificar imagens mamográficas e não somente a região de interesse, percebe-se que os resultados foram um pouco inferiores, tendo em vista também a complexidade e um maior tamanho da imagem. Os resultados da classificação dos nódulos podem ser vistos na Tabela 3, os resultados foram satisfatórios para nódulos malignos com 82 por cento na taxa do F1-Score, o que é relevante, uma vez que implica em maior risco ao paciente.

Tabela 3. Resultados Obtidos para Classificação de Massas

Classes	Precision	Recall	F1-Score	Accuracy
Benigno	0.68	0.48	0.56	0.74
Maligno	0.76	0.88	0.82	0.74

5. Conclusão

Conclui-se que os resultados obtidos neste trabalho demonstram a eficácia parcial do modelo proposto para extração de características de imagens mamográficas, pois obteve ótimos resultados para diferenciação de regiões com massas e sem massas com cerca de 98 por cento de acurácia e 96 por cento de sensibilidade para regiões com nódulos.

Além disso foi possível obter uma drástica redução na duração do treinamento no que diz respeito a quantidade de épocas e redução do *overfitting* com o emprego das técnicas de regularização citadas neste trabalho. No que diz respeito a utilização do modelo para classificação de imagens como um todo e não somente regiões de interesse, os resultados obtidos foram satisfatórios, tendo em vista a dificuldade para diferenciar nódulos benignos de malignos. Ao analisar os trabalhos correlatos, percebe-se que este trabalho obteve um desempenho considerável, uma vez que, reduz o custo computacional, em comparação com a RetinaNet, ResNet50 e InceptionV3 que utilizam sucessivas camadas e que mesmo aplicando a normalização em lotes, como no caso da ResNet50, os resultados podem não apresentar desempenhos satisfatórios.

Como trabalhos futuros, pretende-se modificar o modelo para que receba imagens sem processamento algum e validar o modelo proposto também com outros problemas de detecção na área médica.

Referências

- Chollet, F. (2017). *Deep Learning with Python*. Manning Publications Company.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning*. MIT Press. <http://www.deeplearningbook.org>.
- Krizhevsky, A., Sutskever, I., and Hinton, G. (2012). Imagenet classification with deep convolutional neural networks. *Neural Information Processing Systems*, 25.
- LECUN, Y.; BENGIO, Y. (2003). *The Handbook of Brain Theory and Neural Networks*. Press.
- Martins, R.A.P.;Silva, D. (2020). Aplicação de redes convolucionais profundas para detecção de massas em mamografias.
- Vieira, S. (2012). *Oncologia básica*. Teresina, 1 edition.
- Yu, X., Kang, C., Guttery, D. S., Kadry, S., Chen, Y., and Zhang, Y.-D. (2020). Resnet-sca-50 for breast abnormality classification. *IEEE/ACM transactions on computational biology and bioinformatics*, 18(1):94–102.
- Zhou, H., Zaninovich, Y., and Gregory, C. (2017). Mammogram classification using convolutional neural networks. In *International conference on technology trends*, volume 2.