

Reconstrução de imagem mamográfica com alta qualidade usando *deep learning* com imagens de baixa dose

Pedro Moisés de Sousa
Faculdade de Engenharia Elétrica
Universidade Federal de Uberlândia
Uberlândia, Brasil
ORCID: 0000-0003-4563-0033

Ana Cláudia Patrocínio
Faculdade de Engenharia Elétrica
Universidade Federal de Uberlândia
Uberlândia, Brasil
ORCID: 0000-0002-1645-1112

Homero Schiabel
Escola de Engenharia de São Carlos
Universidade de São Paulo
São Paulo, Brasil
ORCID: 0000-0002-7014-948x

Abstract— *This paper presents the preliminary findings of a research whose main objective is to develop methods to reduce the radiation dose required for mammograms without compromising the exams result. The approach used is to improve the quality of images obtained with low radiation doses by detecting characteristic patterns of images resulting from high radiation doses and joining them with the original low radiation images. The quality of images obtained with low radiation doses is lower than those obtained with high doses because there is an increase in quantum noise in the first ones. Our method uses wavelet and deep learning algorithms and was tested on a set of mammogram images obtained with lower radiation doses. Regarding the peak-signal-to-noise ratio (PSNR) metric, there was a media increase from 37 in the control group to 58 in the test group, and the highest PSNR value obtained by an image was 60.7485683800. Regarding the structural similarity index measure (SSIM) metric, the average 80% of the control group increased to approximately 90% in the test group, and the highest similarity value found in an image was 0.912399596. Preliminary results indicate real benefits for patients by showing that it is possible to obtain quality images close to those obtained at high doses by exposing patients to reduced doses*

Keywords— *deep learning, wavelet, breast cancer, radiation dose.*

I. INTRODUÇÃO

De acordo com o Instituto Nacional do Câncer (INCA), o câncer de mama é causado pela multiplicação de células anormais da mama, que então formam um tumor [1]. Pesquisas epidemiológicas demonstram que o câncer é responsável por cerca de 13% dos óbitos no mundo [2]. Estima-se, no Brasil, para o biênio 2018-2019, a ocorrência de 600 mil casos novos de câncer a cada ano, sendo que o cálculo global corrigido para o sub-registro aponta para a ocorrência de 640 mil casos novos [3]. Essas estimativas refletem o perfil de um país que possui os cânceres de próstata, pulmão, mama feminina, cólon e reto entre os mais incidentes [1].

No Brasil, o câncer de mama é o tipo mais comum entre as mulheres, apresentando alta taxa de mortalidade nas que possuem idade acima dos 35 anos, aumentando rapidamente sua incidência até atingir os 50 anos, quando passa a aumentar de forma mais lenta. Este é um comportamento que evidencia o fator idade como fator de risco para o câncer de mama. Contudo, outros fatores de riscos já estão bem estabelecidos como os relacionados à vida produtiva da mulher, histórico familiar de câncer de mama e a densidade do tecido mamário. Além desses, a exposição à radiação ionizante, mesmo que em baixas doses, também é considerada um fator de risco, particularmente durante a puberdade [1].

Apesar das alta taxa de mortalidade, sabe-se que, quando o câncer de mama é diagnosticado nos estágios iniciais, as pacientes contam com maior probabilidade de cura. Com base

nesse cenário, o INCA promove a campanha Outubro Rosa desde 2010 para disseminar informações sobre prevenção e detecção precoce da doença [1], além de outras campanhas feitas pelo Ministério da Saúde.

Atualmente, o exame mais comum para diagnosticar precocemente o câncer de mama é a mamografia, um exame radiológico que gera imagens da mama em tons de cinza. A partir das quais o especialista analisa e identifica visualmente onde as lesões se encontram [2]. No exame mamográfico, paciente é exposto a uma certa quantidade de radiação e, de acordo com Lucas R. Borges [4], sua exposição excessiva à radiação dos raios X poderia induzir novos casos de câncer e doses menores de radiação implicariam imagens de baixa qualidade, o que originou o princípio ALARA (“tão baixo quanto razoavelmente possível”). Na prática, a otimização dessa relação permanece desafiadora, pois com a redução de dose de radiação ocorre o aumento do ruído quântico, o que compromete a qualidade da imagem [4].

Assim, o objetivo deste trabalho é utilizar uma rede *deep learning* e *wavelets* como método para compensar a redução das doses de radiação em mamografia mediante a melhoria das imagens obtidas com baixas doses para que atinjam qualidade compatível com aquelas obtidas com altas doses de radiação.

II. MATERIAIS E MÉTODOS

A. Base de dados

A fim de realizar estudos sobre a redução de radiação em mamografia, é necessário adquirir imagens clínicas repetidas, do mesmo paciente, com doses diferentes [4]. Porém, tal prática seria antiética devido aos riscos relacionados à radiação. Uma solução é simular os efeitos da redução da dose em imagens clínicas. Assim foi utilizado um *phantom* (CIRS 011A) que gerou duas imagens com dimensões 1914 x 2294 pixels. As especificações das imagens são apresentadas na Tabela 1. A base foi ampliada recortando a imagem em subimagens de 400x400 que depois foram rotacionadas em ângulos de 0°, 90°, 180° e 270° graus, o que resultou 96 imagens para treinamento e 5 para teste.

Tabela 1 Especificações do phantom

	Dose alta (HD)	Dose reduzida (LD)
Tensão (kVp)	31	25
Exposure (mAs)	67	100
Organ Dose (mGy)	1,544	0,848
Entrance Dose (mGy)	7,698	5,668

A Tabela 1 apresenta valores referentes as técnicas da aquisição da imagem, tanto para imagem com dose reduzida (LD) como para imagens de alta dose (HD). Observa-se que houve redução de 26,36% na *Entrance Dose* (DEP) e 45,07% no *Organ Dose* (DGM).

B. Transformada wavelet

O trabalho utiliza a decomposição da imagem através da transformada *wavelet*. Foi utilizado como entrada para a rede neural profunda o primeiro nível de decomposição da *Wavelet*, sendo que as sub-bandas de aproximação, vertical, horizontal e diagonal contém informações da estrutura da imagem conforme mostra a Figura 1.

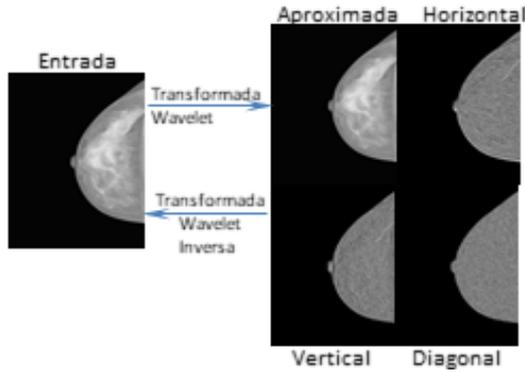


Figura 1 Diagrama geral da transformada *Wavelet*

A transformada *wavelet* inversa é utilizada na saída da rede neural profunda para gerar a nova imagem reconstruída conforme mostra a Figura 4. Assim a transformada *wavelet* de um sinal $f(t)$ é definida como [6]:

$$Wf(a, b) = \int_{-\infty}^{+\infty} f(t)\psi_{a,b}(t)dt \quad (1)$$

Para um sinal discreto de N pontos, a integral acima pode ser aproximada por um somatório, tal que:

$$Wf(a, b) = \sum_{t=0}^{N-1} f(t)\psi_{a,b}(t) \quad (2)$$

A função $\psi_{a,b}(t)$, chamada *wavelet*, é derivada de uma função $\psi(t)$ através da seguinte transformação:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}}\psi\left(\frac{t-b}{a}\right) \quad (3)$$

Em que b representa posição ou translação da *Wavelet* e a chamado parâmetro de escala, o qual está associado à largura da janela. Há uma ampla gama de escolha para função $\psi(t)$, denominada *wavelet* mãe, dentre elas: *daubechies*, *symlets*, *coiflet*, entre outras.

No trabalho foi utilizado a família *Haar*, que fornece informações das bordas nos coeficientes verticais, horizontais e diagonais em sub-bandas *wavelet*. Estes coeficientes podem ser usados para inferir mais informações estruturais sobre a imagem [6].

C. Estrutura da Rede Neural profunda

A rede neural profunda utilizada foi extraída do trabalho [5]. A estrutura da rede apresenta duas camadas de entradas e saída com 4 canais, contendo 64 filtros de tamanho $4 \times 3 \times 3$ na primeira camada e 4 filtros de tamanho $64 \times 3 \times 3$ na última camada. Na parte central da rede tem-se 10 camadas ocultas

do mesmo tamanho com filtros de $64 \times 3 \times 3 \times 64$ cada. A saída de cada camada, exceto a camada de saída, é alimentada na função de ativação *Rectified Linear Unit* - ReLU [8] para gerar um mapa de ativação não linear conforme mostra a Figura 2.

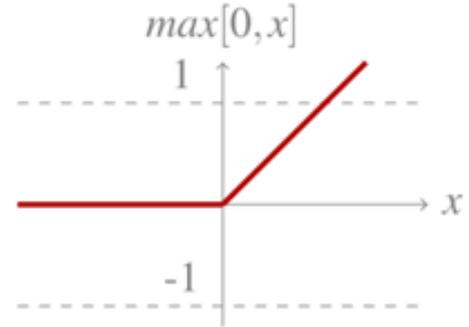


Figura 2 *Rectified Linear Unit* (ReLU): e simples e resulta em treinamento mais rápido para a maioria das redes. Tem saída 0 se a entrada for < 0 . Se a entrada for > 0 , a saída é igual à entrada.

D. Treinamento da Rede

Para treinar a rede, as imagens de treinamento de dose reduzida de radiação (*Low Dose* - LD) são processadas com uma transformada *Wavelet Haar* para produzir quatro sub-bandas: aproximação, vertical, horizontal, e diagonal que são indicadas como:

$$WL = \{LA, LV, LH, LD\} \quad (4)$$

A transformação também é aplicada nas imagens de alta dose de radiação (*High Dose* - HD) para produzir 4 sub-bandas *wavelet*:

$$WH = \{HA, HV, HH, HD\} \quad (5)$$

Na sequência é computada a diferença Δs (residual) entre os coeficientes extraídos da imagem de baixa dose e alta dose, WL e WH:

$$\Delta s = WH - WL = \{HA - LA, HV - LV, HH - LH, HD - LD\}$$

$$WH - WL = \{\Delta A, \Delta V, \Delta H, \Delta D\} \quad (6)$$

Logo, para o treinamento da rede, as entradas são as sub-bandas *wavelet* WL e o *ground truth* (valor de referência) que é o conjunto das diferenças residuais Δs . Conforme apresentado na Figura 3.

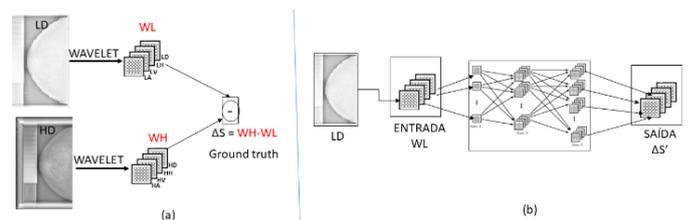


Figura 3. Fase de treinamento da rede neural profunda: a) extração dos coeficientes em cada imagem LD e HD gerando a entrada e o *ground truth* para o treinamento da rede. b) treinamento da rede neural: a entrada LD é processada pela rede neural profunda gerando um novo $\Delta s'$, o qual é comparado com o *ground truth* Δs até que um erro mínimo seja atingido ou um certo número de épocas da rede.

E. Teste da Rede

A entrada da rede neural profunda são as quatro sub-bandas da *wavelet* WL. A rede neural processa a entrada gerando Δs na camada de saída. A seguir é adicionado o Δs com a respectiva entrada WL indicadas como:

$$WS = WL + \Delta S = \{LA + \Delta A, LV + \Delta V, LH + \Delta H, LD = \Delta D\} \quad (7)$$

Finalmente, é aplicada a transformada *Wavelet* inversa gerando uma imagem de alta resolução HD', todo o esquema é apresentado de acordo com Figura 4 :

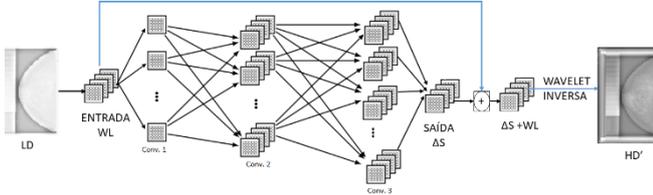


Figura 4. Fase de testes da Rede Neural Profunda: A entrada WL é processada pela rede neural profunda, gerando a saída Δs . Esta é somada a entrada WL para gerar novos coeficientes. A *wavelet* inversa é aplicada no resultado da soma gerando uma nova imagem melhorada HD'.

III. RESULTADOS E DISCUSSÕES

A. Métricas

Foram utilizadas duas métricas para avaliar a qualidade da imagem gerada pela rede neural profunda [7] explicadas a seguir. O pico da relação sinal/ruído (*PSNR*), representada pela Equação 8.

$$PSNR = 10 \log \left(\frac{MAX(I_{out})^2}{MSE} \right) = 20 \log \frac{MAX(I_{out})}{MSE} \quad (8)$$

Nesta equação *MAX* é o valor máximo que o pixel pode assumir na imagem e *MSE* é o erro quadrático médio (ou *Mesure Square Error -MSE*) [7].

A métrica citada pode apresentar problemas na comparação da similaridade, pois uma desvantagem da métrica *MSE* é que grandes distâncias entre intensidades de pixels não significam que o conteúdo das imagens seja muito diferente.

Analisado-se o *MSE*, valores próximos a zero, representam semelhança perfeita, com o erro entre as imagens próximo a zero. Contudo, um valor maior que 1 significa que a similaridade entre as imagens é menor, e pode crescer à medida que a diferença média entre os pixels da imagem aumenta.

O índice de Similaridade Estrutural (*SSIM*) foi proposto para compensar os problemas associados ao *MSE*, sua formulação matemática é dada pela Equação 9 [7].

$$SSIM = \left(\frac{(2\mu_x\mu_y + c_1)(\sigma_{xy} + c_1)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \right) \quad (9)$$

Onde μ representa a média, o σ^2 representa a variância e $\sigma_{x,y}$ representa a covariância. As constantes c_1 e c_2 evitam a instabilidades quando os valores da média e desvio padrão estão próximos de zero. Diferente da métrica *MSE*, o valor entre -1 e 1 pode ser assumido pela métrica *SSIM*, sendo que 1 representa similaridade perfeita e -1 representa não similar.

O objetivo principal do *SSIM* fazer com que as mudanças na informação estrutural da imagem sejam percebidas.

B. Resultados

As Tabelas 2 e 3 apresentam os resultados das métricas *SSIM* e *PSNR*. Na Tabela 2 a comparação é efetuada entre a imagem de alta dose (imagem referência – *ground truth*) e a imagem de dose reduzida, e na Tabela 3 as imagens são as imagens de alta dose e as imagens geradas pela rede neural profunda.

Tabela 2 Métricas *PSNR* E *SSIM* ente a imagem de dose reduzida e a imagem de referência (*Ground truth*)

Imagem alta dose	Imagem dose reduzida	<i>PSNR</i> Imagem dose reduzida	<i>SSIM</i> Imagem dose reduzida
1200_1600	1200_1600	37,88582975	0,813032125
1200_1914	1200_1914	37,62431612	0,799670819
1600_1200	1600_1200	37,40291593	0,839997199
1600_1600	1600_1600	37,80362159	0,815396339
2000_1200	2000_1200	37,61301981	0,813159096

Após o treinamento da rede neural profunda. Tem-se os seguintes resultados apresentados na Tabela 3

Tabela 3 Métricas *PSNR* E *SSIM* ente a imagem alta dose *ground truth* e a imagem gerada pela rede neural profunda

Imagem alta dose	Imagem gerada	<i>PSNR</i> Imagem gerada	<i>SSIM</i> Imagem gerada
1200_1600	1200_1600	60,74856838	0,890774816
1200_1914	1200_1914	59,94966704	0,864184654
1600_1200	1600_1200	55,38522571	0,912399596
1600_1600	1600_1600	60,21786746	0,892988525
2000_1200	2000_1200	54,63861639	0,894458892

Para a métrica *PSNR*, houve um aumento da média 37 para a média 58 aproximadamente. Sendo que o maior *PSNR* foi de 60,7485683800 para a imagem 1200_1600. Enquanto para a métrica *SSIM* a média de 80% aumentou próximo de 90%. A maior similaridade foi encontrada na imagem 1600_1200 com o valor de 0,912399596.

A. Conclusão e Trabalhos Futuros

O trabalho utiliza duas técnicas *Wavelet* e *Deep learning* para reduzir a quantidade de radiação no exame mamográfico, diminuindo assim os riscos de induzir novos casos de câncer.

A técnica apresentou bons resultados para o *PSNR* um aumento de 54% e para o *SSIM* um aumento de 10% em relação as métricas da Tabela 2 após o processamento da rede neural profunda. Os resultados preliminares obtidos, mostra que é um trabalho promissor e deve ser efetuado mais teste nos trabalhos futuros, tais como aumentar a quantidade de imagens para treinamento e testar uma variação de parâmetros da rede neural para melhorar a acurácia da rede.

ACKNOWLEDGMENT

Os autores gostariam de agradecer: Universidade Federal de Uberlândia - UFU, Universidade de São Paulo – USP, Universidade Federal de Viçosa- Campus Rio Paranaíba - UFV, Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES, Brasil, pelo apoio financeiro.

REFERÊNCIAS

- [1] INCA. Instituto Nacional de Câncer José Alencar Gomes da Silva. Disponível em: <http://www2.inca.gov.br/wps/connect/tiposdecancer/site/home/mama>. Acesso em : 29 maio 2018.
- [2] DE SOUZA, Nazareth Hermínia Araújo et al. Câncer de mama em mulheres jovens: estudo epidemiológico no nordeste brasileiro. SANARE-Revista de Políticas Públicas, v. 16, n. 2, 2017.
- [3] INCA. Estimativa 2018. Incidência de Câncer no Brasil- Instituto Nacional de Câncer José Alencar Gomes da Silva. Disponível em: <http://www.inca.gov.br/estimativa/2018/casos-taxas-brasil.asp>. Acesso em: 29 maio. 2018.
- [4] BORGES, Lucas R. et al. Method for inserting noise in digital mammography to simulate reduction in radiation dose. In: Medical Imaging 2015: Physics of Medical Imaging. International Society for Optics and Photonics, 2015. p. 94125J.
- [5] GUO, Tiantong et al. Deep wavelet prediction for image super-resolution. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. 2017. p. 104-113.
- [6] Rafael C. Gonzalez and Richard E. Woods. 2006. *Digital Image Processing (3rd Edition)*. Prentice-Hall, Inc., Upper Saddle River, NJ, USA.
- [7] Rafael C. Gonzalez and Richard E. Woods. 2006. *Digital Image Processing (3rd Edition)*. Prentice-Hall, Inc., Upper Saddle River, NJ, USA.
- [8] PONTI, Moacir Antonelli; DA COSTA, Gabriel B. Paranhos. Como funciona o deep learning. arXiv preprint arXiv:1806.07908, 2018.