

UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO

FILTRAGEM DE RUÍDO EM IMAGENS DE PROJEÇÃO DE TOMOSSÍNTESE MAMÁRIA USANDO MÉTODOS NÃO-LOCAIS.

Roberto Martins de Freitas

São Carlos
2016

Roberto Martins de Freitas

FILTRAGEM DE RUÍDO EM IMAGENS DE PROJEÇÃO DE TOMOSSÍNTESE MAMÁRIA USANDO MÉTODOS NÃO-LOCAIS.

Trabalho de Conclusão de Curso
Escola de Engenharia de São Carlos,
Universidade de São Paulo
Curso de Engenharia de Computação

ORIENTADOR: Prof. Dr. Marcelo Andrade da Costa Vieira

São Carlos
2016

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

MR639f Martins de Freitas, Roberto
Filtragem de Ruído Em Imagens de Projeção de
Tomossíntese Mamária Usando Métodos Não-Locais /
Roberto Martins de Freitas; orientador Marcelo Andrade
da Costa Vieira. São Carlos, 2016.

Monografia (Graduação em Engenharia de Computação)
-- Escola de Engenharia de São Carlos da Universidade
de São Paulo, 2016.

1. Tomossíntese Mamária. 2. Filtragem de Ruído. 3.
NLM. 4. 3DNLM. 5. Ruído Quântico. 6. Transformada de
Anscombe. I. Título.

FOLHA DE APROVAÇÃO

Nome: Roberto Martins de Freitas

Título: “Filtragem de ruído em imagens de projeção de tomossíntese mamária usando métodos não-locais”

Trabalho de Conclusão de Curso defendido em 08/06/2016.

Comissão Julgadora:

Prof. Dr. Marcelo Andrade da Costa Vieira
(Orientador) - SEL/EESC/USP

Prof. Dr. Valdir Grassi Junior
SEL/EESC/USP

Mestre André de Andrade Bindilatti
UFSCar

Resultado:

Aprovado

Aprovado

Aprovado

Coordenador do Curso Interunidades Engenharia de Computação pela EESC:

Prof. Dr. Maximilian Luppe

Agradecimentos

Esse trabalho é fruto de muito esforço e dedicação de cinco anos e meio somados. É resultado de muito Google, música, noites em claro e muito café. E é também minha contribuição com a ciência e retribuição a todo aprendizado que me foi proporcionado durante minha formação acadêmica.

No entanto, minha passagem pela universidade não foi apenas marcada pelo crescimento intelectual, mas também por muito amadurecimento pessoal. E às pessoas que contribuíram com a minha formação, tanto como pessoal mas como acadêmica, dedico este trabalho. Vocês são muito importantes.

Agradeço muito aos meus amigos e colegas do curso de Engenharia de Computação, que me aguentaram diariamente durante todo esse tempo. É, eu sei que não é fácil. Aos meus queridos Zicas da Esquerda da Engenharia Aeronáutica – 2011, que sempre estiveram lá para quando eu precisei. Um agradecimento especial também a todos meus amigos de Glasgow, que contribuíram muito com meu crescimento pessoal.

Agradeço aos meus pais Tania e Fernando, por me proporcionarem todo investimento aos meus estudos. Aos meus irmãos, Rafael e Greice, por sempre me apoiarem, principalmente em momentos que foram difíceis. Muito obrigado.

Agradeço também a todos meus excelentíssimos professores da Universidade de São Paulo. Em especial, quero deixar meu agradecimento ao meu orientador Marcelo Vieira, por me orientar nesse trabalho, e por toda ajuda. E também deixo meu agradecimento especial a Helder Oliveira, por toda assistência e ajuda no laboratório durante o desenvolvimento desse trabalho.

“Sometimes it is the people who no one imagines anything of who do the things that no one can imagine.” - Alan Turing.

Resumo

FREITAS, R. M. (2016). “**Filtragem de Ruído em Imagens de Projeção de Tomossíntese Mamária Usando Métodos Não-Locais**”. Trabalho de Conclusão de Curso – Escola de Engenharia de São Carlos. Universidade de São Paulo, 2016.

A mamografia digital é o exame mais utilizado para a detecção precoce do câncer de mama. No entanto, ela possui uma limitação, que é a sobreposição de estruturas mamárias no processo de formação da imagem. A tomossíntese digital mamária (*Digital Breast Tomosynthesis* – DBT) é uma nova modalidade de imagem médica que resolve esse problema pois reconstrói uma imagem tridimensional da mama, a partir da aquisição de imagens de projeções em diferentes ângulos, no entanto, com uma dose de radiação menor do que da mamografia convencional. Essa baixa dosagem de radiação na aquisição das projeções faz com que essas imagens sejam muito degradadas pelo ruído quântico. Assim, esse trabalho propõe um novo algoritmo de filtragem de ruído para o processamento de imagens de DBT adquiridas com baixa dose de radiação. O método desenvolvido se baseia em métodos não-locais (*Non-Local Means* - NLM), que utilizam a redundância de informações em uma imagem para melhor remoção do ruído. Nessa nova proposta, chamada de 3DNLM (*Tridimensional Non-Local Means*) explora-se a similaridade entre as projeções de tomossíntese mamária estendendo a janela de busca do NLM também para as projeções adjacentes de DBT. O desempenho do 3DNLM foi comparado com o NLM tradicional na filtragem de ruído de imagens de DBT adquiridas com diferentes doses de radiação. Os resultados mostraram que as imagens filtradas com o 3DNLM preservam mais estruturas da imagem original e borram menos que o NLM original.

Palavras-chave: Tomossíntese Digital Mamária, Filtragem de ruído, Método das médias não-locais, Ruído quântico.

Abstract

FREITAS, R. M. (2016). “**Denoising Digital Breast Tomosynthesis (DBT) projections using Non-Local Methods**”. Bachelor Thesis – São Carlos School of Engineering. University of São Paulo, 2016.

The Full Field Digital Mammography – FFDM is the most used exam on breast cancer detection. However, it has its own limitations, due to the overlapping of breast structures on the process of image acquisition. Hence, a new modality in medical imaging has been used since 2011 to detect breast cancer, the Digital Breast Tomosynthesis – DBT. The advantage of DBT over the FFDM is that DBT rebuilds the tridimensionality of the breast, from projections at different angles, removing the tissues overlapping effect. Although, in order to keep the same level of radiation emitted to the patient to the same level of FFDM, each projection is acquired with a fraction of the radiation dose of conventional mammography. This low dosage of radiation in the image acquisition cause great degradation to the projection due quantum noise. Thus, this work proposes a new denoising algorithm for processing DBT images with low dose of radiation. The method developed is based on non-local methods (Non-Local Means – NLM), which explore the information redundancy of a noised image to remove its noise. This new proposal, 3DNLM (Tridimensional Non-Local Means) delve into the similarity of the DBT projections extending the searching window of the NLM also to the adjacent projections of DBT. The performance of this new algorithm was compared then with the traditional NLM algorithm on filtering DBT images acquired with different radiation doses. The results have shown that the performance of the 3DNLM is higher for then the original NLM algorithm.

Keywords: DBT, Non-Local Means, Tridimensional Non-Local Means, Local Filters, Quantum noise.

Lista de Figuras

Figura 1: Tudo de raios X (UTFPR 2008).	5
Figura 2: Esquemático do funcionamento da mamografia digital (UTFPR 2008).	6
Figura 3: Alguns exemplos de modelos de sistemas de DBT clínico. (Digital Breast Tomosynthesis: State of the Art, 2015).	8
Figura 4: Ilustração do sistema de aquisição das imagens de (a) mamografia e (b) tomossíntese mamária de 15 projeções.	9
Figura 5: (a) Imagem sem ruído artificialmente gerada; (b) imagem (a) contaminada com ruído Poisson; (c) Ruído extraído de (b).	12
Figura 6: Função de densidade de probabilidade da distribuição Normal (NIST).	14
Figura 7: (a) Imagem sem ruído artificialmente gerada; (b) imagem (a) contaminada com ruído Gaussiano; (c) Ruído extraído de (b).	15
Figura 8: Regiões similares de uma mesma imagem destacadas [34].	17
Figura 17: Esquemático da aquisição das projeções DBT.	25
Figura 9: Fluxograma do pré-processamento das imagens.	28
Figura 10: (a) “Phantom” antropomórfico; (b) exemplo de uma projeção DBT do “phantom” (a).	29
Figura 11: (a) Imagem original de uma projeção de DBT. O fundo da imagem compõe uma parcela significativa da imagem, e pode ser descartado para a filtragem; (b) Recorte derivado da imagem original (a).	30
Figura 12: Microcalcificações demarcadas na projeção DBT.	31
Figura 13: Deslocamento entre as projeções DBT. (a) Projeção mais à esquerda (-7,5°); Projeção mais à direita (+7,5°).	32
Figura 14: Projeções após recorte dinâmico. (a) A projeção mais à esquerda da DBT (-7,5°); Em seguida, (b), a projeção seguinte de (a) ($\sim -6,5^\circ$); (c) A projeção mais à direita (+7,5°). Por fim, (d), a projeção anterior a (c) ($\sim +6,5^\circ$).	33
Figura 15: (a) Projeção central (0°) contaminada com o ruído que simula a dose de 100%; (b) Projeção com 60% da dose; (c) Projeção com 20% da dose.	37
Figura 16: (a) Projeção com 100% da dose com “AWGN”; (b) A mesma projeção de (a) mas com “AWGN”.	38
Figura 18: Fluxograma dos experimentos conduzidos para comparar os algoritmos NLM e 3DNLM.	41
Figura 19: Variação do PSNR (dB) entre as 15 projeções.	44
Figura 20: Variação do MSSIM entre as 15 projeções.	44
Figura 21: Variação do Sharpness (dB) entre as 15 projeções.	45
Figura 22: Variação do SNR (dB) entre as 15 projeções.	45
Figura 23: Avaliação pelo PSNR (dB) das projeções de 90% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).	50
Figura 24: Valores de MSSIM das projeções de 90% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).	50

Figura 25: Valores de Sharpness (dB) das projeções de 90% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).	51
Figura 26: Valores de SNR (dB) das projeções de 90% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).	51
Figura 27: Valores de PSNR (dB) das projeções de 60% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).	52
Figura 28: Valores de MSSIM das projeções de 60% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).	52
Figura 29: Valores de PSNR (dB) das projeções de 60% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).	53
Figura 30: Valores de PSNR (dB) das projeções de 30% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).	53
Figura 31: Valores de MSSIM das projeções de 30% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).	54
Figura 32: Valores de Sharpness (dB) das projeções de 30% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).	54
Figura 33: (a) Imagem com 90% da dose de ruído original; (b) Imagem (a) filtrada com NLM; (c) Imagem (a) filtrada com 3DNLM; (d) Imagem com 100% da dose.	55
Figura 34: (a) Imagem com 60% da dose de ruído original; (b) Imagem (a) filtrada com NLM; (c) Imagem (a) filtrada com 3DNLM; (d) Imagem com 100% da dose.	56
Figura 35: (a) Imagem com 30% da dose de ruído original; (b) Imagem (a) filtrada com NLM; (c) Imagem (a) filtrada com 3DNLM; (d) Imagem com 100% da dose.	57

Lista de Tabelas

Tabela 1: Avaliação de SNR (dB), PSNR (dB), MSSIM e Sharpness (dB) das 15 projeções com 100% de dose.	43
Tabela 2: Avaliação de SNR (dB), PSNR (dB), MSSIM e Sharpness (dB) das 15 projeções com 90% de dose filtrada com “Non-Local Means”.	46
Tabela 3: Avaliação de SNR (dB), PSNR (dB), MSSIM e Sharpness (dB) das 15 projeções com 90% de dose filtrada com “3-Dimensional Non-Local Means”.	47
Tabela 4: Avaliação de SNR (dB), PSNR (dB), MSSIM e Sharpness (dB) das 15 projeções com 60% de dose filtrada com “Non-Local Means”.	48
Tabela 5: Avaliação de SNR (dB), PSNR (dB), MSSIM e Sharpness (dB) das 15 projeções com 60% de dose filtrada com “3-Dimensional Non-Local Means”.	48
Tabela 6: Avaliação de SNR (dB), PSNR (dB), MSSIM e Sharpness (dB) das 15 projeções com 30% de dose filtrada com “Non-Local Means”.	49
Tabela 7: Avaliação de SNR (dB), PSNR (dB), MSSIM e Sharpness (dB) das 15 projeções com 30% de dose filtrada com “3-Dimensional Non-Local Means”.	49

X

Sumário

1. Introdução	1
1.1. Motivação	1
1.2. Objetivos	3
1.3. Organização do Trabalho	3
2. Revisão Bibliográfica e Métricas de Avaliação	5
2.1. Mamografia Digital	5
2.2. Tomossíntese Digital Mamária	7
2.3. Ruído na imagem mamográfica	10
2.3.1. Ruído Poisson	11
2.3.2. Ruído Gaussiano	13
2.4. Algoritmo de médias não-locais (<i>Non-Local Means</i> -NLM)	16
2.5. Transformada de Anscombe	19
2.6. Métricas e Avaliação	20
2.6.1. SNR	20
2.6.2. MSE e PSNR	21
2.6.3. SSIM	22
2.6.4. Sharpness	23
3. Tridimensional Non-Local Means (3DNLM)	25
4. Materiais e Métodos	27
4.1. Materiais	27
4.1.1. Projeções de DBT obtidas com o Phantom	29
4.1.2. Region Of Interest (ROI)	30
4.1.3. Inserção do Ruído	34
4.1.4. Ruído Poisson	34
4.1.5. Additive White Gaussian Noise (AWGN)	38
4.2. Métodos	39
4.2.1. Transformada de Anscombe	39
4.2.2. Non-Local Means (NLM)	39

4.2.3. Tridimensional Non-Local Means (3DNLM)	39
4.2.4. Transformada inversa generalizada de Anscombe	40
4.3. Experimentos.....	40
4.4. Avaliação	41
5. Resultados.....	43
6. Discussões e Conclusões	59
Referências Bibliográficas.....	61

1. Introdução

Nesse capítulo será introduzida a motivação que impulsionou o desenvolvimento desse trabalho, assim como os objetivos e propostas do projeto. Ademais, o formato em que essa monografia está redigida.

1.1. Motivação

Segundo a Organização Mundial da Saúde [1], em 2012, o câncer foi responsável por 8,2 milhões de mortes, sendo 521 mil apenas de câncer de mama. No Brasil, o Instituto Nacional de Câncer (INCA) [2] estima que no ano de 2016 sejam descobertos 57.960 novos casos de câncer de mama. É o tipo de câncer mais frequente nas mulheres das Regiões Sul, Sudeste, Centro-Oeste e Nordeste, e na região Norte é o segundo tumor mais incidente [2].

Estima-se que a probabilidade de cura do câncer de mama aumenta em 30% se for detectado precocemente, já que o tratamento da doença no estágio avançado é mais complicado [3,4]. Atualmente, o exame mais utilizado no mundo para o rastreamento do câncer de mama é a mamografia digital de campo total (*Full Field Digital Mammography - FFDM*) [5-7], que é bastante limitado. A bidimensionalidade das imagens mamográficas podem gerar uma falha na detectabilidade de nódulos e microcalcificações encobertos por tecidos e estruturas mamárias [8].

A partir de 2011, então, começou-se o uso clínico da mamografia 3D, ou tomossíntese digital da mama (*Digital Breast Tomosynthesis - DBT*) [8,9]. Na DBT, são adquiridas diversas imagens radiológicas (projeções) em diferentes ângulos da mama. Associando todas as projeções, o volume tridimensional da mama é reconstruído por um sistema computacional.

Estudos recentes mostram que a tomossíntese mamária elimina a limitação da mamografia convencional, pois a tridimensionalidade viabiliza a detectabilidade de nódulos e microcalcificações, que na mamografia bidimensional podem estar sendo ocultados por tecidos e outras estruturas mamárias [10].

Porém, é necessário manter o nível de radiação a qual a mama será exposta para garantir a segurança do paciente. Ou seja, todas as projeções da DBT, normalmente em torno de 15 a 20 imagens por exame, precisam somar o mesmo nível de radiação de uma imagem de mamografia convencional. Isso impacta diretamente na qualidade da imagem desse exame, pois a redução da dose de radiação está diretamente ligada com a degradação da imagem devido ao ruído quântico incorporado à imagem em sua aquisição [8,9].

Estima-se que, aproximadamente, para cada 100.000 mulheres que realizam o exame da mamografia todos os anos, 86 novos casos serão induzidos exclusivamente pela exposição à radiação [11,12].

De modo a não comprometer a saúde do paciente, é imprescindível reduzir a dosagem de radiação, minimizando os riscos do exame. O problema é que a diminuição nas doses de radiação piora a relação sinal-ruído da imagem [13,14]. O ruído é fator limitante das imagens de mamografia, e pode exercer mais influência do que a resolução espacial e prejudicar a detecção de microcalcificações e classificação de nódulos pelos radiologistas [15-17].

Levando em consideração todos os fatores limitantes mencionados anteriormente, é fundamental melhorar a qualidade das imagens DBT sem aumentar as doses de radiação, ou também, reduzir as doses de radiação e manter a qualidade da imagem. Uma abordagem atualmente muito utilizada com a finalidade de melhorar a qualidade dessas imagens é o uso de técnicas de filtragem de ruído (*denoising*) [18-21].

Entre os diversos tipos de técnicas de filtragem de ruído, os métodos de filtragem não-locais têm ganhado destaque pelos bons resultados [22,23]. Ênfase especificamente no método *Non-Local Means (NLM)* [22].

Assim, a proposta desse trabalho é a de apresentar um novo algoritmo de filtragem não-local que utilize a redundância entre as projeções adjacentes da tomossíntese mamária para remover o ruído da imagem antes da reconstrução tridimensional. O filtro proposto deve ser capaz de manter a qualidade das imagens adquiridas com doses de radiação reduzidas comparável às aquelas adquiridas com a dose padrão de radiação.

1.2. Objetivos

O objetivo principal desse trabalho é propor um novo algoritmo de filtragem de ruído para imagens de tomossíntese digital mamária (DBT) adquiridas com baixas doses de radiação. O algoritmo proposto, chamado de 3DNLM (*Tridimensional Non-Local Means*) explora a similaridade entre as projeções de tomossíntese mamária estendendo a janela de busca do NLM também para as projeções adjacentes de DBT.

Ademais, deseja-se analisar esse novo método proposto para doses reduzidas de radiação, ou seja, para imagens mais ruidosas, e verificar se a filtragem é realmente eficaz e consegue manter as estruturas e a nitidez da imagem original, mesmo reduzindo a taxa de radiação. Também, é possível traçar uma comparação entre o desempenho do algoritmo proposto com NLM tradicional.

1.3. Organização do Trabalho

Esse trabalho está organizado de maneira que justifique o raciocínio linear da estrutura na qual o projeto foi desenvolvido. As próximas seções desse trabalho servirão como base das decisões de projeto tomadas, descrevem os métodos utilizados nos experimentos e na composição do algoritmo proposto, revelam os resultados e os discutem.

As seções contidas nesse trabalho estão brevemente descritas abaixo:

- Capítulo 1 – Introdução: define os objetivos e motivações desse projeto.
- Capítulo 2 – Revisão Bibliográfica e Métricas de Avaliação: constrói embasamento teórico para o entendimento de Mamografia, Tomossíntese Digital Mamária, *Non-Local Means*, Ruídos, e as métricas de avaliação usadas nesse trabalho.
- Capítulo 3 – Proposta de um novo algoritmo para filtragem de imagens DBT, o 3DNLM.
- Capítulo 4 – Materiais e Métodos: descreve os materiais utilizados para produzir os resultados, assim como, descreve aqui o método proposto, e os experimentos que foram conduzidos.
- Capítulo 5 – Resultados: apresenta os resultados obtidos com os experimentos descritos no *Capítulo 4*.
- Capítulo 6 – Discussões e Conclusões: discute os resultados apresentados no *Capítulo 5*.

2. Revisão Bibliográfica e Métricas de Avaliação

Nesse capítulo, será feita uma revisão de conceitos teóricos necessários para entender esse trabalho, abordando os tópicos de mamografia digital, tomossíntese mamária, ruído em imagens de mamografia, filtros não-locais, transformada de *Anscombe* e métricas de avaliação de imagem.

2.1. Mamografia Digital

A mamografia digital de campo total, ou *Full Field Digital Mammography (FFDM)*, é o exame mais utilizado no mundo para a detecção precoce do câncer de mama e para o rastreamento da doença [5-7]. Consiste de um exame de imagem que tem como objetivo o estudo do tecido mamário. A formação das imagens é feita a partir da radiação eletromagnética (raios X) emitida pelo tubo de raios X (*Figura 1*), que atravessa os tecidos da mama e são detectadas por um sensor digital.




Figura 1: Tudo de raios X (UTFPR 2008).

Os fótons de radiação emitidos pelo tudo de raios X, quando atingem a mama do paciente, perdem energia ao colidirem com as estruturas mamárias. Quanto mais denso o tecido mamário for, mais atenuada será a energia do fóton. Portanto, ao atingirem o detector, as partículas terão sofrido perda de energia, que dependem da densidade das estruturas as quais estas colidiram. Dessa forma, as imagens de mamografia digital são construídas através da detecção da energia das partículas que atingem o detector, gerando um sinal analógico que então é convertido para digital, como mostra a *Figura 2*.




Figura 2: Esquemático do funcionamento da mamografia digital (UTFPR 2008).

Contudo, a mamografia digital possui uma limitação, que é a produção de imagens de apenas duas dimensões, o que, ocasionalmente, pode ocultar lesões mamográficas suspeitas, como nódulos ou microcalcificações, pela sobreposição de tecidos mamários. Essa

sobreposição ocorre na projeção da estrutura tridimensional mamária em um plano bidimensional [8].

2.2. Tomossíntese Digital Mamária


A tomossíntese digital mamária ou *Digital Breast Tomosynthesis (DBT)*, também conhecida como mamografia 3D, é também um exame de imagem mamográfica por raios-X que funciona essencialmente com os mesmos princípios da mamografia digital, contudo são reconstruídas imagens tridimensionais do volume mamário, ao invés de uma projeção 2D.

Na *DBT*, o tubo de raios-X percorre uma trajetória pré-definida, geralmente um arco de 15° , em que são adquiridas múltiplas projeções da mama, como ilustrado na *Figura 3*. Posteriormente, as projeções são processadas e a tridimensionalidade da mama é reconstruída com sistemas computacionais [24].

Na *Figura 3 (a)* é ilustrado um modelo de DBT clínico que o detector é angulado conforme o centro de rotação do tubo de raios-X, enquanto este percorre um arco de comprimento predefinido, realizando as projeções. Já as *Figura 3 (b) e (c)* são exemplos de modelos parecidos, em que o detector não se move, porém, o arco percorrido pelo tubo de raios-x de (c) é maior que de (b). Na *Figura 3 (d)*, o centro de rotação é definido para fora da mama.

A reconstrução tridimensional do volume da mama minimiza a principal limitação da mamografia convencional 2D que é a sobreposição de tecidos, melhorando a detectabilidade de nódulos e microcalcificações, que na mamografia bidimensional podem ser ocultados por tecidos e outras estruturas mamárias densas [10].

Figura 3: Alguns exemplos de modelos de sistemas de DBT clínico. (Digital



Breast Tomosynthesis: State of the Art, 2015)

Porém, é necessário resguardar a saúde dos pacientes e não submetê-los a maiores níveis de radiação do que da mamografia 2D. Em outras palavras, todas projeções da DBT precisam somar, no máximo, o mesmo nível de radiação de uma imagem de mamografia convencional, como ilustra o esquemático da Figura 4.

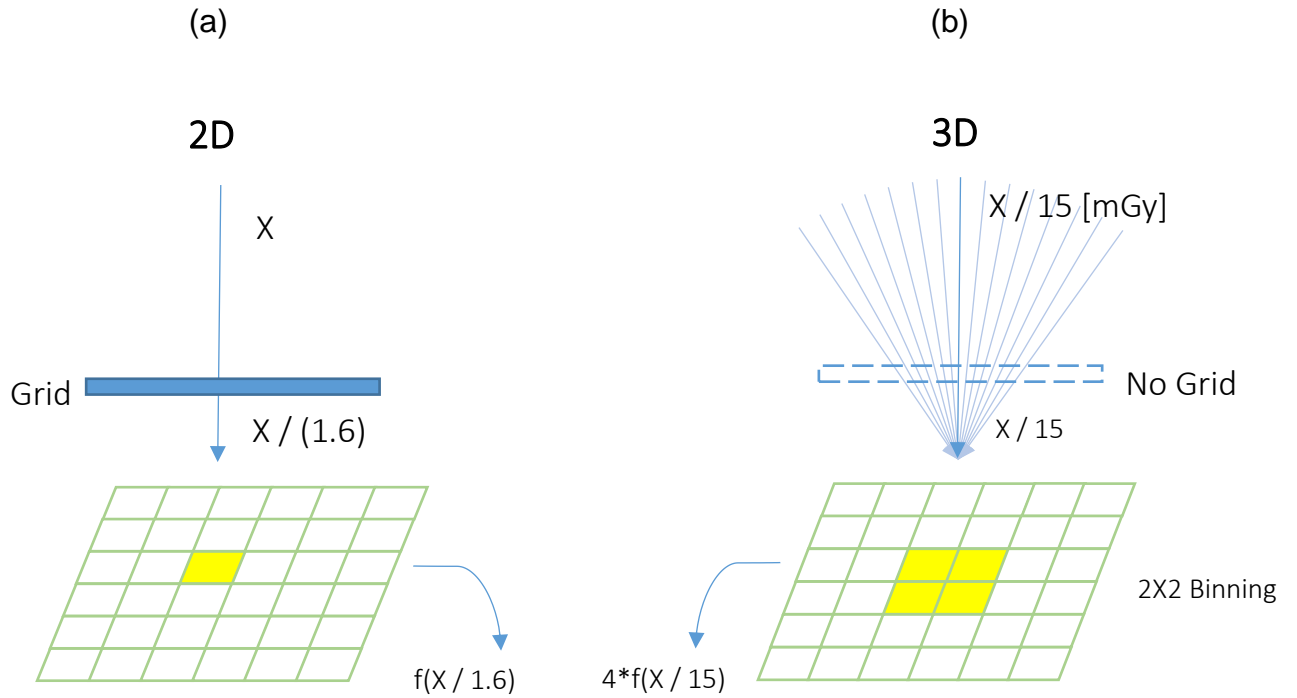


Figura 4: Ilustração do sistema de aquisição das imagens de (a) mamografia e (b) tomossíntese mamária de 15 projeções.

Como a dose de radiação de cada projeção deve ser uma fração da dose de radiação de uma imagem mamográfica convencional, a imagem é severamente degradada pelo ruído quântico. Para minimizar esse problema e melhorar a qualidade da imagem deve-se aumentar o número de fótons que chega ao detector digital. Nesse sentido, duas estratégias são realizadas no processo de aquisição de imagens de DBT: a remoção da grade anti-espalhamento e a realização do *binning* 2 x 2, conforme ilustrado na *Figura 4 (b)*. A grade serve para filtrar a radiação espalhada no processo de aquisição de imagens mamográficas. Ela filtra aproximadamente 60% dos fótons de raios X. Na DBT ela é removida do sistema, fazendo com que o número de fótons que chega no detector seja 60% maior do que na mamografia convencional 2D. O *binning* 2 x 2 consiste em ampliar a área de detecção dos fótons de raios X (em $2 \times 2 = 4$ vezes), o que aumenta o número de fótons melhorando a relação sinal

ruído da imagem (já que o ruído relativo será menor) . No entanto, esse processo reduz a resolução espacial da imagem [24].

Quanto menor é a dose de radiação utilizada, menor o número de fótons, e mais ruidosa será a imagem [13,14]. Uma possível solução para melhorar a qualidade da imagem adquirida com baixa dose de radiação é o uso de algoritmos de filtragem de ruído (*denoising*). Em geral, esses algoritmos removem o ruído da imagem de modo a melhorar sua qualidade em termos da relação sinal-ruído [22].

2.3. Ruído na imagem mamográfica

As imagens originadas de um processo de formação de imagens com número limitado de fótons de luz (ou radiação, como no caso da mamografia e da DBT) são naturalmente degradadas por ruído quântico (*shot noise*). Infelizmente, o comportamento do ruído não é um assunto tão simples, portanto, amplamente estudado nos dias de hoje.

O ruído na DBT trata-se de um ruído misto, que também inclui o ruído eletrônico do processo de conversão analógico-digital, além do ruído quântico [25].

É possível modelar esse ruído como a mistura de ruído Poisson escalado e Gaussiano aditivo. Logo, é possível modelar o ruído da imagem contaminada com um ruído misto, de forma que para cada pixel $n_i, i \in I$, contaminado com ruído da imagem I , temos:

$$n_i = \lambda_{poisson} p + g, \quad (2.1)$$

onde p é variável aleatória Poisson de média igual ao valor dos pixels da imagem original $\mu_{poisson} = a_i$, e g é variável aleatória Gaussiana de média μ_{gauss}

e variância σ_{gauss}^2 . O fator de escala do ruído Poisson é definido como $\lambda_{poisson} = \frac{\sigma_{poisson}^2}{\mu_{imagem}}$ [36].

2.3.1. Ruído Poisson

O ruído Poisson, ou *shot noise*, como mencionado anteriormente, é originado da natureza discreta das cargas elétricas. Como o próprio nome sugere, esse ruído segue o comportamento de uma distribuição estatística de Poisson.

No ruído Poisson, a variância do ruído é dada por $\sigma_{poisson}^2 = \mu_{poisson} = a_i$, como definido anteriormente. Portanto, o desvio padrão do ruído é definido como $\sigma_{poisson} = \sqrt{a_i}$.

Assim tomemos a expressão (2.2), da relação sinal-ruído. É possível afirmar que quanto maior o sinal a_i , menor será a influência da variância $\sqrt{a_i}$. Assim, quanto maior a intensidade do sinal, melhor a relação sinal-ruído, caracterizando dessa maneira a dependência do ruído ao sinal.

$$SNR = \frac{\mu_{poisson}}{\sigma_{poisson}} = \frac{a_i}{\sqrt{a_i}} = \sqrt{a_i} \quad (2.2)$$

A relação (2.2) pode ser também visualmente observada na *Figura 5*. Observe que para regiões mais claras, o ruído é mais significativo, e para regiões mais escuras menos significativo. Em outras palavras, para intensidades baixas, a relação sinal-ruído é baixa, e quanto maior a intensidade do pixel, maior a SNR será.




Figura 5: (a) Imagem sem ruído artificialmente gerada; (b) imagem (a) contaminada com ruído Poisson; (c) Ruído extraído de (b).

Note que como as projeções de tomossíntese têm aproximadamente $\frac{1}{15}$ da intensidade da imagem de mamografia, o ruído Poisson é mais significativo nas projeções DBT do que nas imagens de mamografia convencional, justamente por conta da baixa relação sinal-ruído.

Uma característica das imagens de mamografia e de DBT é a relação entre a variância do ruído Poisson e a média do sinal da imagem, expressada por (2.4).

$$\lambda_{poisson} = \frac{\sigma_{poisson}^2}{\mu_{imagem}} \quad (2.3)$$

Note que para uma distribuição Poisson $\mu_{imagem} = \sigma_{poisson}^2$, temos que $\lambda_{poisson} = 1$. No entanto, em imagens de tomossíntese o ruído Poisson é escalado e o fator de escala é aproximadamente $\lambda_{poisson} = 0,1$ [35].

2.3.2. Ruído Gaussiano

O ruído Gaussiano, ou *Additive White Gaussian Noise* (AWGN), como o próprio nome sugere é um ruído derivado de uma distribuição Gaussiana, ou Normal, que é aditivo e que possui potência uniforme em toda banda de frequência.

Definindo $n_i^{gauss} = a_i + g$, os pixels da imagem I contaminados com ruído Gaussiano de média μ_{gauss} e variância σ_{gauss}^2 , a função de densidade de probabilidade da distribuição Gaussiana é dada por (2.4).

$$f(z) = \frac{1}{\sqrt{2\pi} \sigma_{gauss}} e^{-\frac{1}{2\sigma_{gauss}^2}(z - \mu_{gauss})^2}, \quad (2.4)$$

onde z representa o tom de cinza. Em imagens de tomossíntese mamária e mamografia, esse ruído é modelado com $\mu_{gauss} = 0$ e $\sigma_{gauss}^2 = 9$ [35].

De uma forma geral, a função de densidade de probabilidade da distribuição Normal, descrita por (2.4), tem a forma ilustrada pela *Figura 6*.




Figura 6: Função de densidade de probabilidade da distribuição Normal (NIST).

Diferentemente do ruído Poisson, o ruído Gaussiano não é dependente do sinal, a variância do ruído é uniforme para a imagem toda. A independência do ruído com o sinal pode ser visualizada na *Figura 7*, onde independente da intensidade da região da imagem, o ruído é uniforme.




Figura 7: (a) Imagem sem ruído artificialmente gerada; (b) imagem (a) contaminada com ruído Gaussiano; (c) Ruído extraído de (b).

2.4. Algoritmo de médias não-locais (*Non-Local Means* - NLM)

Em geral, os métodos clássicos de filtragem de ruído estimam o valor livre de ruído de um pixel realizando a média de sua vizinhança local (filtros locais). Esses algoritmos, em geral, não produzem resultados muito bons pois “borram” a imagem, ocasionando perda de pequenos detalhes. Isso ocorre pois no cálculo da média do ruído também se realiza a media do sinal, o que é indesejado na prática.

Diferentemente, os filtros não-locais, procuram meios de estimar com mais precisão o valor livre de ruído de pixel, vasculhando toda a imagem. O algoritmo não-local mais difundido na literatura é o *Non-Local Means* (NLM) [22].

O NLM parte da premissa que a imagem é composta de regiões redundantes, ou seja, pequenas regiões que se repetem na mesma imagem, como mostrado na *Figura 8*. Dessa maneira, o algoritmo busca na imagem por regiões semelhantes à região local do pixel o qual se deseja filtrar, e então é calculado uma média ponderada de todas as regiões avaliadas, em que o fator de ponderação é a similaridade entre as regiões (*patches*). Assim, as regiões mais similares, terão um peso maior do que as dissimilares.

No entanto, é fácil perceber que se o algoritmo for aplicado na imagem toda, a probabilidade de existirem mais regiões dissimilares em uma escala muito maior do que regiões similares à região de interesse é grande. É necessário limitar então a região de busca, em uma janela de busca, para diminuir o viés do acúmulo de pequenos pesos na média, o que geralmente borra a imagem.




Figura 8: Regiões similares de uma mesma imagem destacadas [34].

O algoritmo NLM é construído de maneira que uma janela de busca de tamanho $S \times S$ é definida para limitar o espaço de busca por regiões (*patches*) de tamanho $P \times P$, que sejam similares ao *patch* central da janela de busca. Sendo assim os pixels filtrados $\hat{x}_i, i \in I$, onde i equivale à coordenada (x, y) da imagem I , são dados por:

$$\hat{x}_i = \sum_{j \in J} w_{ij} a_j \quad , \quad (2.5)$$

onde J é o conjunto de todos os *pixels* da janela de busca centrada em i da imagem, com exceção do próprio *pixel* central i ; a_j é a intensidade do pixel j da janela de busca; e w_{ij} é o peso calculado entre o *patch* central e o *patch* centrado em j , e y_j é o *patch* centrado em j . Os pesos são calculados de forma:

$$w_{ij} = \frac{1}{W_i} e^{\frac{-\|y_i - y_j\|_{G_a}^2}{h^2}} \quad , \quad (2.6)$$

onde W_i é o fator de normalização do peso (normalização no intervalo $[0,1]$), dado pela equação (2.7). E h é o parâmetro que controla a intensidade da filtragem.

$$w_i = \sum_{j \in J} w_{ij} \quad (2.7)$$

O fator $\|y_i - y_j\|_{G_a}^2$ é a distância euclidiana entre os *patches* centrados em i e j :

$$\|y_i - y_j\|_{G_a}^2 = \frac{1}{\sum_{b \in U} G_a(b)} (\sum_{b \in U} G_a(b) \cdot (y_{i+b} - y_{j+b})^2) , \quad (2.8)$$

onde $a > 0$ é o desvio padrão do *kernel* Gaussiano G_a . Na expressão (2.8), U é o conjunto que define o *patch* de tamanho $P \times P$ centrado em i ou j . Nesse caso, esse kernel faz com que o pixel central do *patch* tenha maior importância do que os outros, melhorando a filtragem [26].

O parâmetro h é proporcional ao desvio padrão do ruído σ ($h = \gamma\sigma$). Em imagens contaminadas com ruído Poisson, como no caso da *DBT* e mamografia, o uso do NLM não terá bons resultados, pois a variância desse tipo de ruído depende do sinal (4.2), ou seja, para uma mesma imagem, vários valores de h serão definidos para regiões diferentes, dependendo, obviamente, da intensidade média do sinal da região. Esse é um dos desafios de usar o NLM para a filtragem de ruído Poisson.

Note que os pesos nunca serão zero, isso impacta em um efeito negativo na filtragem com NLM. Quando muitos *patches* dissimilares acumulam peso suficiente para manifestar relevância na estimativa do pixel central, o valor estimado será enviesado pelo acúmulo de dissimilaridade.

2.5. Transformada de Anscombe

A transformada de *Anscombe* [27] é uma ferramenta que é utilizada para estabilizar a variância do ruído na imagem, transformando-a em uma outra em que o ruído Poisson se comporta como um ruído Gaussiano de variância $\sigma^2 = 1$, independente do sinal. Pesquisas mais recentes estenderam a transformada de *Anscombe* para o modelo de ruído misto, Poisson e Gaussiano, chamando-a de transformada generalizada de *Anscombe* [28].

Seja $n_i, i \in I$ a intensidade de todo os pixel i da imagem I contaminado com ruído Gaussiano de média μ_{gauss} e variância σ_{gauss}^2 , e com ruído Poisson escalado com fator de escala $\lambda_{poisson} = \frac{\sigma_{poisson}^2}{\mu_{imagem}}$, como definido anteriormente. A transformada de Anscombe é dada por:

$$t_i = A(n_i) = \frac{2}{\lambda_{poisson}} \sqrt{n_i \lambda_{poisson} + \frac{3}{8} \lambda_{poisson}^2 + \sigma_{gauss}^2 - \lambda_{poisson} \mu_{gauss}} \quad (2.9)$$

Então, a variância do ruído na imagem é estabilizada e de valor unitário. Dessa maneira o NLM poderá processar t_i como se fosse um ruído Gaussiano aditivo.

É preciso definir agora, portanto, a transformada generalizada de Anscombe inversa, a fim de obter \hat{n}_i , o valor estimado de n_i sem ruído. É definida a transformada inversa generalizada de *Anscombe* em (2.10).

$$\hat{n}_i = A^{-1}(\hat{t}_i) = \left(\frac{\hat{t}_i}{2}\right)^2 + \frac{1}{4} \sqrt{\frac{3}{2}} \hat{t}_i^{-1} - \frac{11}{8} \hat{t}_i^{-2} + \frac{5}{8} \sqrt{\frac{3}{2}} \hat{t}_i^{-3} - \frac{1}{8} - \sigma_{gauss}^2, \quad (2.10)$$

onde \hat{t}_i é o valor estimado de t_i pela filtragem.

2.6. Métricas e Avaliação

A avaliação precisa ser conduzida dentro de parâmetros, de modo que seja possível uma análise quantitativa dos dados, ou, como no caso, da performance da filtragem.

É possível utilizar diferentes tipos de métricas para quantificar os resultados da filtragem. As mais utilizadas são a relação sinal ruído (SNR), o pico da relação sinal ruído (PSNR), o erro médio quadrático (MSE), o índice de similaridade estrutural (SSIM) e a nitidez da imagem (Sharpness). Essas métricas serão explicadas com mais detalhes nas próximas seções.

2.6.1. SNR

A relação sinal-ruído (*Signal-to-Noise Ratio* - *SNR*) mede a proporção da potência do ruído com a potência da imagem não degradada [30]. Essa métrica é calculada pela expressão:

$$SNR(x, y) = \frac{\sum_{i=1}^N x_i^2}{\sum_{i=1}^N (x_i - y_i)^2} , \quad (2.11)$$

onde $x_i, i \in I$, são todos os pixels da imagem original I , não degradada, e $y_i, i \in I$ os pixels da imagem degradada.

Analisando a expressão (2.11) pode-se inferir que para um mesmo referencial, ou seja, para uma mesma imagem, quanto maior o SNR, ou seja, menor o ruído, melhor.

O SNR também pode ser calculada em decibéis, dado por (2.12):

$$SNR_{dB}(x, y) = 10 \log_{10}(SNR) \quad (2.12)$$

2.6.2. MSE e PSNR

O erro médio quadrático (*Mean Square Error - MSE*), é medido tomando média da potência do ruído [30].

$$MSE(x, y) = \frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2, \quad (2.13)$$

onde novamente $x_i, i \in I$ são os pixels da imagem original não degradada, e y_i os pixels da imagem degradada com ruído.

Uma outra variação do MSE é o PSNR (*Peak Signal-to-Noise Ratio*) dado pela equação abaixo [29]:

$$PSNR(x, y) = \frac{L^2}{MSE}, \quad (2.14)$$

onde L é o valor máximo permitido de intensidades dos pixels da imagem. Em termos práticos, L será o máximo valor entre as imagens comparadas.

Note que o PSNR, utiliza essencialmente o mesmo tipo de informação do que o MSE, no entanto, expressa de uma maneira diferente. Ele também pode ser escrito em decibéis por (2.15):

$$PSNR_{dB}(x, y) = 10 \log_{10} PSNR \quad (2.15)$$

2.6.3. SSIM

O SSIM é um parâmetro que tenta aproximar o sistema de visão humano. Essa métrica é medida calculando a similaridade de luminescência $l(x, y)$, contraste $c(x, y)$, e estruturas $s(x, y)$ das regiões locais x e y , situadas nas mesmas coordenadas das imagens que estão sendo comparadas [29]. A fórmula geral é dada pela equação (2.16):

$$S(x, y) = l(x, y) \cdot c(x, y) \cdot s(x, y) = \left(\frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \right) \left(\frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \right) \left(\frac{\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3} \right), \quad (2.16)$$

onde $l(x, y) = \left(\frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \right)$, $c(x, y) = \left(\frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \right)$ e $s(x, y) = \left(\frac{\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3} \right)$ são calculados tomando regiões locais com as mesmas coordenadas das imagens (x, y) , que estão sendo comparadas. Respectivamente, μ_x e μ_y são as médias locais de x e y , σ_x e σ_y os desvios padrão locais e σ_{xy} é a amostra de correlação cruzada de x e y após remover suas médias. As constantes C_1 , C_2 e C_3 precisam ser pequenas e positivas, apenas para não zerar os fatores $l(x, y)$, $c(x, y)$ e $s(x, y)$.

A região definida irá se deslocar por todos os pixels da imagem, pontuando-os, e, então, ao final, uma pontuação final é tirada calculando a média da pontuação obtida em todas as regiões ($MSSIM$).

O $MSSIM$ está dentro do intervalo de -1 e 1 ($-1 \leq MSSIM \leq 1$), de forma que quanto mais próximo esse parâmetro é de 1, mais similar as imagens são, e quanto mais perto de -1, mais dissimilar.

2.6.4. Sharpness

A nitidez da imagem filtrada é definida pela capacidade de reproduzir pequenos detalhes e definição de bordas. A equação proposta por [33] define que a nitidez da imagem (*Sharpness*) pode ser quantificada medindo-se os gradientes em duas direções na imagem, conforme a equação (2.17):

$$Sharpness = \sum_{i=0}^M \sum_{j=0}^N (w_i G_i^2 + w_j G_j^2), \quad (2.17)$$

onde $w_i(i, j) = [m(i + 1, j) - m(i - 1, j)]^2$ e $w_j(i, j) = [m(i, j + 1) - m(i, j - 1)]^2$. Sendo que $m(i, j)$ denota o valor de intensidade do pixel (i, j) da imagem. E G_x e G_y são os gradientes horizontais e verticais obtidos usando filtros Sobel.

O parâmetro *Sharpness* também pode ser expresso em decibéis (2.18):

$$Sharpness_{dB}(x, y) = 10 \log_{10} Sharpness \quad (2.18)$$

3. Tridimensional Non-Local Means (3DNLM)

O algoritmo desenvolvido nesse trabalho, nomeado de tridimensional Non-Local Means (3DNLM), utiliza-se da similaridade das projeções da tomossíntese mamária para aplicar o *Non-Local Means*, estendendo a janela de busca tridimensionalmente nas projeções adjacentes.

O algoritmo proposto funciona da seguinte forma: considere nas 15 projeções da tomossíntese mamária, como o deslocamento entre cada projeção é de aproximadamente 1° , a diferença da projeção x_w , de angulação w , com a projeção x_{w+1° , e também com a projeção x_{w-1° , podemos assumir que são bastante similares. Dessa maneira, se estendermos a janela de busca em mesmas coordenadas, em três projeções, tridimensionalmente, podemos processar o pixel x_w da janela principal, possivelmente, com mais regiões similares das projeções adjacentes. O tamanho da janela de busca, no entanto, deve ser ajustado a fim de reduzir borramentos pelo tamanho da janela de busca estendida, e também evitar o borramento da imagem por acúmulo de dissimilaridades como discutido na Seção 2.4




Figura 17: Esquemático da aquisição das projeções DBT.

Análogo ao equacionamento do NLM, consideremos agora J_{n-1} , J_n e J_{n+1} os conjuntos de pixels da janela de busca $S \times S$ das projeções adjacentes, como esquematizado na *Figura 17*. Definiremos um conjunto $T = J_{n-1} \cup J_n \cup J_{n+1}$, tal que o pixel filtrado $\hat{x}_i, i \in I$, onde I é o conjunto de pixels da imagem. Assim, o equacionamento do 3DNLM pode ser assim feito:

$$\hat{x}_i = \sum_{j \in T} w_{ij} y_j \quad (3.1)$$

As outras equações do NLM continuam inalteradas (2.5 – 2.8), no entanto com $j \in T$.

4. Materiais e Métodos

Nesse capítulo, é apresentado o processo de preparação das imagens para os experimentos. Aqui também estão descritos os experimentos que foram realizados, assim como a métrica usada para avaliá-los.

4.1. Materiais

O banco de imagens usado nesse trabalho contém apenas projeções de *Digital Breast Tomosynthesis (DBT)* adquiridas em um equipamento comercial a partir da exposição de um *phantom* físico de propriedade da *University of Pennsylvania* [32].

As imagens foram adquiridas com um sistema clínico de *DBT* da fabricante *Hologic*, modelo *Selenia Dimensions*, como ilustrado na *Figura 3 (a)*, que realiza 15 projeções continuamente numa angulação de $-7,5^\circ$ até $+7,5^\circ$, onde a projeção na posição de 0° é obtida com o posicionamento do tubo de raios X o mais perpendicular possível com o detector, que também realiza um movimento rotacional de $-2,1^\circ$ até $+2,1^\circ$, para acompanhar a rotação do tubo. Os pixels dessas imagens são formados com a técnica de *binning* 2×2 [24].

Foram adquiridas 15 imagens de cada projeção e então calculada a projeção média, utilizando a dosagem padrão de radiação, que é definida automaticamente pelo equipamento. Essa imagem calculada a partir da média de 15 projeções é naturalmente bem menos ruidosa do que cada uma das imagens. Nesse trabalho, essas imagens foram consideradas como a imagem padrão sem ruído (*ground-truth*), que é utilizada para o cálculo das métricas de qualidade no processo de avaliação.

As imagens ruidosas foram geradas a partir dessa imagem sem ruído utilizando a simulação do ruído misto Poisson e Gaussiano. Nesse projeto, foi utilizado ruído *Poisson* escalado de média igual à intensidade de cada pixel com

fator de escala $\lambda_{poisson} = 0,1$ misto com ruído *Gaussiano* de média $\mu_{gauss} = 0$ e variância $\sigma_{gauss}^2 = 9$ (Seção 2.3). Então, são utilizados para aplicar então a Transformada Generalizada de Anscombe, que é sensível a esses parâmetros como vemos em (2.9) e (2.10).

Assim, é possível melhorar e padronizar as condições de execução dos algoritmos *Non-Local Means* (NLM) e o *3D Non-Local Means* (3DNLM). Além disso, é possível também simular diferentes doses de radiação na mesma estrutura com modelagem estatística.

Mesmo não utilizando imagens de DBT reais, as imagens simuladas garantem uma boa aproximação da execução dos algoritmos, afinal são simuladas em condições muito similares às imagens reais.

O fluxograma da *Figura 9* mostra o processo de preparo das imagens.

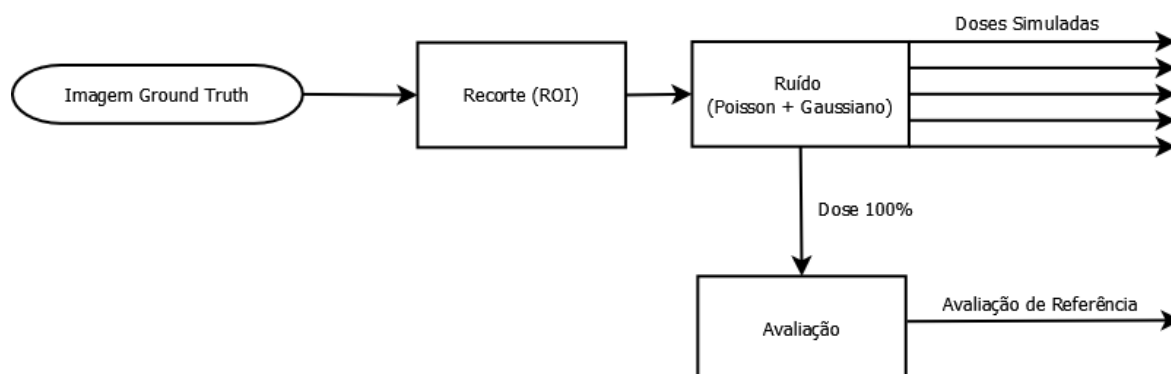


Figura 9: Fluxograma do pré-processamento das imagens.

A imagem *Ground-truth* primeiro passa por um processo de recorte, que garantirá extrair uma região de interesse (*Region of interest* - *ROI*) com estruturas e detalhes importantes da imagem original, e que agilizará enormemente o processamento (filtro) sem prejudicar os resultados. Em seguida, diferentes doses de radiação são simuladas. Por fim, as projeções com a dose padrão de radiação (100%) são avaliadas, para servirem como referência de avaliação.

Ao final desse processo, as imagens com diferentes doses de radiação simuladas são processadas. E os parâmetros obtidos a partir das imagens com 100% da dose padrão serão usados para comparar os algoritmos.

4.1.1. Projeções de DBT obtidas com o Phantom

As imagens de *phantom* foram obtidas a partir de um *phantom* antropomórfico, *Figura 10 (a)*, utilizando um equipamento clínico, produzindo imagens de alta fidelidade com realismo, como mostrado na *Figura 10 (b)*. Essas imagens simulam até tecidos adiposos e fibrogradulares, e microcalcificações.

Para produzir uma imagem *Ground Truth*, isenta de ruído, foram realizadas inúmeras projeções do *phantom*, com 100% da dose ($\sim 6,0$ mGy), e então foi realizada uma média de todas as imagens, produzindo assim uma imagem aproximadamente livre de ruído.



Figura 10:(a) “Phantom” antropomórfico; (b) exemplo de uma projeção DBT do “phantom” (a).

4.1.2. Region Of Interest (ROI)

Os algoritmos de filtragem (NLM e 3DNLM) demandam um tempo longo de processamento para as imagens originais (2048 x 1664 pixels). Especificamente em imagens de tomossíntese e mamografia, como a mostrada na *Figura 11 (a)*, uma grande parte da imagem é tomada pelo fundo preto, que não é de interesse desse estudo. É possível, assim, realizar um simples recorte na imagem original, produzindo as chamadas regiões de interesse (*ROI - Region Of Interest*), *Figura 11 (b)*, limitando a área de processamento do algoritmo.




Figura 11: (a) Imagem original de uma projeção de DBT. O fundo da imagem compõe uma parcela significativa da imagem, e pode ser descartado para a filtragem; (b) Recorte derivado da imagem original (a).

O recorte de uma região é feito de forma a garantir resultados não enviesados pelo processamento do fundo da imagem, além de acelerar a filtragem da imagem.

O recorte foi feito variando o eixo y da imagem original de 851 até 1450 e o eixo x de 1395 até 1664, demarcando regiões de 600 x 270 pixels. O recorte proporciona uma diminuição de aproximadamente 21 vezes da área de processamento.

Um dos critérios para a escolha da região de recorte é a presença de estruturas e de microcalcificações, como mostrado na Figura 12.




Figura 12: Microcalcificações demarcadas na projeção DBT.

Cortar regiões iguais nas mesmas coordenadas em todas as projeções acarreta em um deslocamento natural das estruturas, como é possível observar na *Figura 13*, provocado pela variação do ângulo na aquisição das imagens.




Figura 13: Deslocamento entre as projeções DBT. (a) Projeção mais à esquerda ($-7,5^\circ$); Projeção mais à direita ($+7,5^\circ$).

Além de omitirem algumas das microcalcificações da ROI, esse descolamento impacta obviamente na filtragem do 3DNLM, pela dissimilaridade entre as projeções adjacentes. Assim, para resolver esse problema, foi implementado um corte dinâmico entre as projeções, que corrige esse deslocamento.

Empiricamente, pôde-se observar que deslocando 7 pixels para baixo no eixo y das coordenadas cartesianas do corte a cada projeção, começando pela projeção mais à esquerda ($-7,5^\circ$) até a última ($+7,5^\circ$), já é o bastante para melhorar o alinhamento entre as projeções, como ilustra a *Figura 14*.




Figura 14: Projeções após recorte dinâmico. (a) A projeção mais à esquerda da DBT ($-7,5^\circ$); Em seguida, (b), a projeção seguinte de (a) ($\sim -6,5^\circ$); (c) A projeção mais à direita ($+7,5^\circ$). Por fim, (d), a projeção anterior a (c) ($\sim +6,5^\circ$).

Apesar do alinhamento não ser perfeito, já é o bastante para manter as microcalcificações em todas as projeções, e também para não enviesar a aplicação do 3DNLM.

Observe que apenas algumas estruturas permanecem na imagem com o recorte dinâmico. Outras, menos visíveis, são deslocadas para fora dessa região devido a variação angular entre as projeções na DBT.

4.1.3. Inserção do Ruído

A ideia principal da inserção de ruído nas imagens de phantom é de simular as características físicas das projeções de *DBT* nas imagens *Ground-truth*, além de simular diferentes doses de radiação. Assim, obtém-se controle e conhecimento sob o ruído das imagens, e portanto, facilita na avaliação dos algoritmos.

É preciso simular, portanto, o ruído misto, ruído Poisson (*shot noise*) com a interferência do ruído Gaussiano (*AWGN - Additive White Gaussian Noise*), que se manifesta na prática. É preciso satisfazer a relação entre a variância do ruído Poisson e a média da imagem, escala do ruído Poisson, $\lambda_{poisson} = 0,1$, e definir o ruído Gaussiano com variância $\sigma_{gauss}^2 = 9$ e média $\mu_{gauss} = 0$ (Seção 2.3), que modelam assim características físicas da imagem DBT. E, por fim, é necessário simular o ruído para diferentes doses de radiação.

4.1.4. Ruído Poisson

Primeiramente, é necessário simular $\lambda_{poisson} = 0,1$. Para isso, seja $a_i, i \in I$, a intensidade do pixel i que representa uma coordenada (x,y) da imagem I . Se multiplicarmos todo a_i por 10 para então aplicar o ruído Poisson (sem escala) na imagem, teremos:

$$n_i = 10a_i \pm \sqrt{10a_i} \quad (4.1)$$

Então, dividindo todo n_i por 10, teremos:

$$n_i^* = a_i \pm \frac{\sqrt{10a_i}}{10} \quad (4.2)$$

Como a média do ruído Poisson $\mu_{ruído} = 0$, a média da imagem ruidosa será a mesma.

Se definirmos $n_i^* = a_i + p_i$, em que p_i é a parcela adicional de ruído ao valor original de a_i , e em que:

$$n_i^* = \lambda_{poisson} p \quad , \quad (4.3)$$

onde p é uma variável aleatória de Poisson com média $\mu_{poisson} = a_i$, podemos calcular $\lambda_{poisson}$ como:

$$\lambda_{poisson} = \frac{\sigma_{ruído}^2}{\mu_{imagem}} = \frac{\frac{1}{N} \sum_{i=0}^N (p_i - \mu_{ruído})^2}{\frac{1}{N} \sum_{i=0}^N a_i} \quad (4.4)$$

Como $\mu_{ruído} = 0$, e $p_i = n_i^* - a_i = \left(a_i \pm \frac{\sqrt{10a_i}}{10} \right) - a_i = \frac{\pm \sqrt{10a_i}}{10}$. Podemos escrever, portanto:

$$\lambda_{poisson} = \frac{\frac{1}{N} \sum_{i=0}^N \left(\pm \frac{\sqrt{10a_i}}{10} \right)^2}{\frac{1}{N} \sum_{i=0}^N a_i} = 0,1 \quad (4.5)$$

Note que sem esse procedimento o ruído seria Poisson não-escalado $\lambda = 1$.

É definido, então, a imagem com dose de 100%, que satisfaz $\lambda_{poisson} = 0,1$, e que não é isenta de ruído.

No passo seguinte, são simuladas as doses com valor 20%, 30%, 40%, 50%, 60%, 70%, 80% e 90% da dose padrão de radiação. Para isso, basta multiplicar todo a_i pelo fator da dose ($fator = 1\% = \frac{1}{100} = 0,1$), antes de aplicar

o ruído Poisson. Como discutido anteriormente, esse procedimento irá degradar a imagem diminuindo a relação sinal-ruído, como podemos ver com o exemplo:

$$n_i^{50\%} = (10 \times 0,5)a_i \pm \sqrt{(10 \times 0,5)a_i} = 5a_i \pm \sqrt{5a_i} \quad (4.6)$$

Note que o primeiro procedimento é repetido. Portanto, temos ainda:

$$n_i^{*50\%} = 0,5a_i \pm \frac{\sqrt{5a_i}}{10} \quad (4.7)$$

Calculando $\lambda_{poisson}$ novamente podemos verificar que a relação ainda se mantém:

$$\lambda_{poisson} = \frac{\frac{1}{N} \sum_{i=0}^N (\pm \frac{\sqrt{5a_i}}{10})^2}{\frac{1}{N} \sum_{i=0}^N 0,5a_i} = 0,1 \quad (4.8)$$

Note que a imagem não é dividida pelo fator da dose ao final, pois assim teremos a intensidade simulada com a redução da dose.

A Figura 15 ilustra o resultado da contaminação de ruído Poisson em três diferentes doses simuladas




Figura 15: (a) Projeção central (0°) contaminada com o ruído que simula a dose de 100%; (b) Projeção com 60% da dose; (c) Projeção com 20% da dose.

Observe que na *Figura 15 (c)*, as microcalcificações são bem pouco visíveis.

4.1.5. Additive White Gaussian Noise (AWGN)

O ruído Gaussiano é adicionado então às projeções com ruído Poisson simulando diferentes doses de radiação. Essa etapa é feita de maneira simples: uma máscara de ruído Gaussiano de média $\mu_{gauss} = 0$ e variância $\sigma_{gauss}^2 = 9$ é somada aos pixels.

O resultado é ilustrado pela *Figura 16*.




Figura 16: (a) Projeção com 100% da dose com “AWGN”; (b) A mesma projeção de (a) mas com “AWGN”.

A diferença não é visualmente perceptível, porém, a simulação do AWGN é necessária para uma reprodução do ruído o mais fiel possível a condições

práticas. Ao final desse processo, as imagens estão prontas para serem processadas.

4.2. Métodos

4.2.1. Transformada de Anscombe

Nessa etapa, a transformada generalizada de Anscombe (Seção 2.5) é aplicada em todas as projeções de diferentes doses, a fim de estabilizar a variância do ruído Poisson. Lembrando, que deve-se utilizar $\sigma_{gauss}^2 = 9$ e $\lambda_{poisson} = 0,1$, como definido anteriormente (Seção 2.3 e 2.5)

4.2.2. Non-Local Means (NLM)

O algoritmo do *Non-Local Means* foi implementado com busca exaustiva a se descobrir o parâmetro h tal que a avaliação PSNR (dB) da imagem filtrada fosse próxima da avaliação do parâmetro para a dose de 100% (diferença menor que 1,5 dB).

A janela de busca foi definida como uma região 7×7 pixels, e o *patch* uma região de tamanho 3×3 , dimensões que são comumente utilizados na literatura [26].

4.2.3. Tridimensional Non-Local Means (3DNLM)

O 3DNLM foi aplicado às projeções contaminadas com diferentes taxas de ruído (simulando diferentes doses de radiação) com uma janela de busca $3 \times 7 \times 7$, e patches de tamanho 3×3 .

O algoritmo proposto considerou apenas duas projeções para processar a projeção de menor angulação, $-7,5^\circ$, e a de maior angulação, $+7,5^\circ$. Essa estratégia não produz redundância na filtragem, como criaria se as projeções de borda fossem replicadas, $x_{w-1^\circ} = x_w$.

4.2.4. Transformada inversa generalizada de Anscombe

A última etapa antes da avaliação das imagens é a transformada inversa generalizada de *Anscombe* descrita na *Seção 2.5*, que considera o ruído misto Gaussiano e Poisson. As imagens filtradas pelos algoritmos NLM e 3DNLM são então transformadas inversamente antes de serem avaliadas. Novamente, deve-se utilizar $\sigma_{gauss}^2 = 9$ e $\lambda = 0,1$.

4.3. Experimentos

Em resumo, os experimentos foram conduzidos segundo o esquema mostrado na *Figura 18*.

As imagens ruidosas são, primeiramente, transformadas para o domínio de Anscombe, a fim de estabilizar a variância do ruído Poisson dependente do sinal. Então, os algoritmos são aplicados as imagens, no domínio de *Anscombe*, variando o parâmetro de filtragem h , adequando proximidade de 1,5 dB entre a avaliação PSNR (dB) da imagem filtrada com a de 100% de dose.




Figura 18: Fluxograma dos experimentos conduzidos para comparar os algoritmos NLM e 3DNLM.

4.4. Avaliação

A etapa de avaliação contempla não subjetivar com a qualificação das imagens, mas sim quantificar esse processo. Assim, é feito aqui a pontuação das imagens, para que então possam ser comparadas quantitativamente. Evidentemente, que a aparência visual da imagem é também importante, e será levada em conta para fins de discussão.

As métricas descritas anteriormente conduzirão a discussão dos resultados. Portanto, aqui é preciso definir uma referência de comparação, que serão os valores avaliados para cada métrica das imagens com 100% da dose simulada. Em outras palavras, quanto mais as imagens filtradas se aproximarem da pontuação avaliada das imagens com 100% da dose, melhor será classificado o método de filtragem.

Variando o parâmetro de filtragem h (NLM/3DNLM), é possível atingir a avaliação PSNR (dB) das projeções com 100% da dose, tolerando um erro de 0,15 dB, o que equivale a 0,4% do valor médio de PSNR (dB) com dose 100%.

Em seguida, as imagens são avaliadas nas métricas SNR (dB), MSSIM e Sharpness (dB) em comparação aos valores desses parâmetros para as

projeções com 100% da dose. E assim, tenta-se responder: qual o algoritmo preserva mais estruturas da imagem original? E qual algoritmo borra menos?

5. Resultados

Convenção das projeções analisadas nos resultados segue de forma que a projeção 1 referencie a imagem adquirida com o tubo de raios-x mais à esquerda ($-7,5^\circ$), e a última projeção, 15, a imagem mais à direita ($+7,5^\circ$).

Os resultados são apenas exibidos nesse capítulo, e posteriormente, no *Capítulo 5*, serão discutidos.

Primeiramente, as projeções com dose de 100% foram avaliadas conforme a *Tabela 1*.

Tabela 1: Avaliação de SNR (dB), PSNR (dB), MSSIM e Sharpness (dB) das 15 projeções com 100% de dose.

Número da Projeção	SNR (dB)	PSNR (dB)	MSSIM	Sharpness (dB)
1	35,973	37,524	0,861	86,233
2	36,026	37,422	0,859	86,229
3	36,100	37,371	0,858	86,289
4	36,134	37,431	0,859	86,252
5	36,143	37,453	0,860	86,225
6	36,173	37,535	0,861	86,323
7	36,163	37,449	0,859	85,961
8	36,162	37,533	0,861	86,019
9	36,192	37,474	0,859	85,966
10	36,179	37,516	0,860	86,009
11	36,159	37,399	0,858	86,197
12	36,169	37,444	0,859	86,182
13	36,142	37,373	0,857	85,792
14	36,128	37,440	0,859	85,811
15	36,100	37,445	0,859	85,719
Média	36,131	37,454	0,860	97,482
Desvio Padrão	0,058	0,052	0,001	0,078

As variações de cada parâmetro entre as projeções de 100% da dose podem ser observadas nos gráficos das *Figura 19*, *Figura 20*, *Figura 21* e *Figura 22*, do PSNR (dB), MSSIM, Sharpness (dB) e SNR (dB) respectivamente.




Figura 19: Variação do PSNR (dB) entre as 15 projeções.




Figura 20: Variação do MSSIM entre as 15 projeções.




Figura 21: Variação do Sharpness (dB) entre as 15 projeções.




Figura 22: Variação do SNR (dB) entre as 15 projeções.

Após a etapa de filtragem, as imagens foram avaliadas conforme a Seção 2.6.5. Apesar de ter simulado e filtrado projeções com 20% a 90% da dose de 10% em 10%, apenas três doses diferentes, de 90%, 60% e 30%, que caracterizam, respectivamente, alta, média e baixa dose de ruído na imagem, são suficientes para concluir os resultados mostrados da Tabela 2 à Tabela 7, e da Figura 23 à Figura 35 os resultados visuais obtidos.

Tabela 2: Avaliação de SNR (dB), PSNR (dB), MSSIM e Sharpness (dB) das 15 projeções com 90% de dose filtrada com “Non-Local Means”.

DOSE 90% NLM	Número da Projeção	SNR (dB)	PSNR (dB)	MSSIM	Sharpness (dB)
	1	36,209	37,576	0,870	108,854
	2	35,970	37,338	0,871	113,941
	3	36,032	37,468	0,873	114,142
	4	36,126	37,440	0,872	113,675
	5	36,192	37,424	0,870	113,147
	6	36,297	37,559	0,870	111,967
	7	36,089	37,458	0,873	114,862
	8	36,090	37,459	0,873	114,862
	9	36,063	37,405	0,872	115,034
	10	36,405	37,627	0,870	111,002
	11	36,079	37,292	0,869	114,382
	12	36,137	37,433	0,871	113,765
	13	36,073	37,337	0,869	114,263
	14	36,189	37,397	0,868	112,532
	15	36,105	37,335	0,867	112,823
	Média	36,627	37,899	0,872	96,211
	Desvio Padrão	0,061	0,062	0,001	0,073

Tabela 3: Avaliação de SNR (dB), PSNR (dB), MSSIM e Sharpness (dB) das 15 projeções com 90% de dose filtrada com “3-Dimensional Non-Local Means”.

DOSE 90% 3DNLM	Número da Projeção	SNR (dB) - 3DNLM	PSNR (dB) - 3DNLM	MSSIM - 3DNLM	Sharpness (dB) - 3DNLM
	1	36,017	37,478	0,861	97,316
	2	36,081	37,468	0,861	97,370
	3	35,991	37,425	0,859	97,584
	4	36,027	37,340	0,857	97,659
	5	36,013	37,400	0,858	97,787
	6	36,216	37,552	0,863	97,516
	7	36,036	37,433	0,859	97,788
	8	36,103	37,510	0,861	97,678
	9	36,085	37,410	0,858	97,746
	10	36,260	37,564	0,863	97,455
	11	36,073	37,335	0,856	97,742
	12	36,053	37,347	0,857	97,747
	13	36,028	37,388	0,858	97,723
	14	36,183	37,500	0,861	97,446
	15	36,104	37,396	0,859	97,446
	Média	36,085	37,436	0,859	97,600
	Desvio Padrão	0,076	0,071	0,002	0,156

Tabela 4: Avaliação de SNR (dB), PSNR (dB), MSSIM e Sharpness (dB) das 15 projeções com 60% de dose filtrada com “Non-Local Means”.

DOSE 60% NLM	Número da Projeção	SNR (dB)	PSNR (dB)	MSSIM	Sharpness (dB)
	1	36,074	37,485	0,863	96,671
	2	35,931	37,448	0,861	97,091
	3	36,012	37,418	0,861	96,851
	4	36,028	37,367	0,859	97,134
	5	36,050	37,408	0,859	97,365
	6	36,237	37,604	0,866	96,873
	7	35,996	37,531	0,863	97,148
	8	36,273	37,617	0,866	96,856
	9	36,112	37,414	0,860	97,259
	10	36,139	37,583	0,865	96,823
	11	36,090	37,310	0,857	97,268
	12	36,216	37,370	0,859	97,138
	13	36,055	37,464	0,861	97,169
	14	36,062	37,349	0,858	97,128
	15	36,027	37,360	0,858	97,165
	Média	35,800	37,165	0,853	97,538
	Desvio Padrão	0,073	0,095	0,002	0,067

Tabela 5: Avaliação de SNR (dB), PSNR (dB), MSSIM e Sharpness (dB) das 15 projeções com 60% de dose filtrada com “3-Dimensional Non-Local Means”.

DOSE 60% 3DNLM	Número da Projeção	SNR (dB)	PSNR (dB)	MSSIM	Sharpness (dB)
	1	35,913	37,535	0,863	97,500
	2	35,951	37,515	0,863	97,643
	3	35,874	37,279	0,857	97,935
	4	36,020	37,458	0,862	97,835
	5	35,969	37,454	0,861	97,883
	6	36,067	37,523	0,863	97,859
	7	35,972	37,403	0,859	97,960
	8	36,098	37,468	0,861	97,787
	9	36,046	37,397	0,859	97,845
	10	36,092	37,475	0,861	97,784
	11	36,066	37,384	0,859	97,827
	12	36,132	37,511	0,863	97,722
	13	36,060	37,476	0,861	97,752
	14	36,060	37,456	0,861	97,635
	15	35,919	37,322	0,857	97,790
	Média	36,073	37,500	0,862	97,690
	Desvio Padrão	0,262	0,235	0,007	0,439

Tabela 6: Avaliação de SNR (dB), PSNR (dB), MSSIM e Sharpness (dB) das 15 projeções com 30% de dose filtrada com “Non-Local Means”.

DOSE 30% NLM	Número da Projeção	SNR (dB)	PSNR (dB)	MSSIM	Sharpness (dB)
	1	35,924	37,468	0,864	96,112
	2	35,872	37,401	0,862	96,573
	3	35,908	37,410	0,862	96,790
	4	35,716	37,361	0,859	96,999
	5	35,986	37,414	0,861	96,507
	6	36,219	37,556	0,866	96,016
	7	35,991	37,369	0,859	96,442
	8	36,112	37,615	0,866	96,288
	9	36,093	37,555	0,864	96,319
	10	36,073	37,624	0,867	96,603
	11	35,985	37,502	0,863	96,879
	12	36,019	37,394	0,860	96,533
	13	36,077	37,390	0,860	96,520
	14	35,737	37,351	0,859	96,954
	15	35,916	37,405	0,861	96,420
	Média	36,221	37,687	0,868	95,961
	Desvio Padrão	0,104	0,118	0,003	0,167

Tabela 7: Avaliação de SNR (dB), PSNR (dB), MSSIM e Sharpness (dB) das 15 projeções com 30% de dose filtrada com “3-Dimensional Non-Local Means”.

DOSE 30% 3DLNM	Número da Projeção	SNR (dB)	PSNR (dB)	MSSIM	Sharpness (dB)
	1	36,119	37,623	0,867	97,045
	2	35,777	37,382	0,860	97,105
	3	35,720	37,258	0,856	97,551
	4	35,825	37,465	0,861	97,208
	5	35,990	37,449	0,861	96,959
	6	36,147	37,532	0,864	96,679
	7	35,802	37,333	0,857	97,359
	8	36,053	37,506	0,862	96,837
	9	35,700	37,406	0,858	97,670
	10	35,989	37,459	0,861	97,108
	11	35,802	37,343	0,858	97,619
	12	35,872	37,329	0,857	97,259
	13	35,716	37,351	0,857	97,576
	14	35,877	37,518	0,862	97,056
	15	36,107	37,526	0,863	97,358
	Média	35,771	37,315	0,857	97,503
	Desvio Padrão	0,233	0,206	0,006	0,628




Figura 23: Avaliação pelo PSNR (dB) das projeções de 90% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).




Figura 24: Valores de MSSIM das projeções de 90% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).




Figura 25: Valores de Sharpness (dB) das projeções de 90% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).




Figura 26: Valores de SNR (dB) das projeções de 90% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).




Figura 27: Valores de PSNR (dB) das projeções de 60% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).




Figura 28: Valores de MSSIM das projeções de 60% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).




Figura 29: Valores de PSNR (dB) das projeções de 60% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).




Figura 30: Valores de PSNR (dB) das projeções de 30% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).




Figura 31: Valores de MSSIM das projeções de 30% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).




Figura 32: Valores de Sharpness (dB) das projeções de 30% da dose filtradas com o “Non-Local Means” e “3-Dimensional Non-Local Means”, e de referência (Dose 100%).

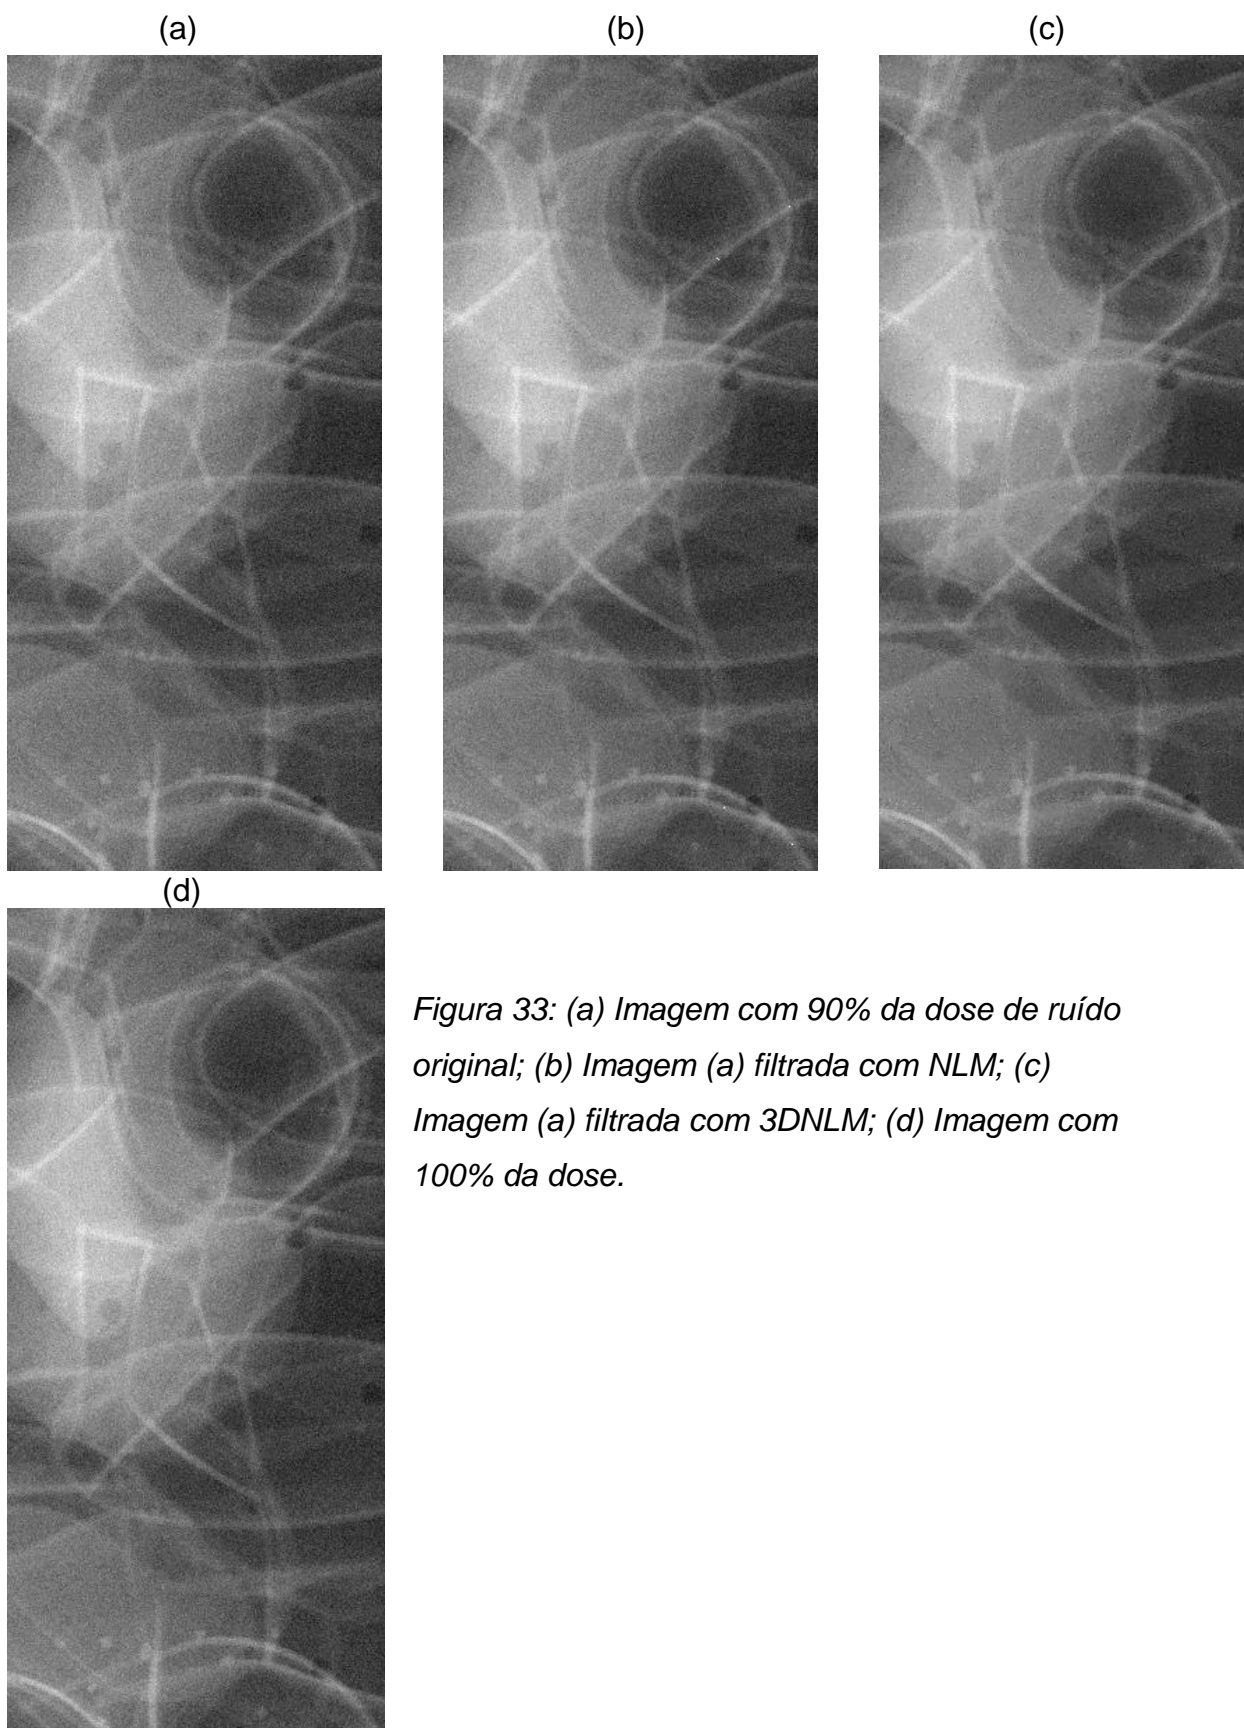


Figura 33: (a) Imagem com 90% da dose de ruído original; (b) Imagem (a) filtrada com NLM; (c) Imagem (a) filtrada com 3DNLM; (d) Imagem com 100% da dose.

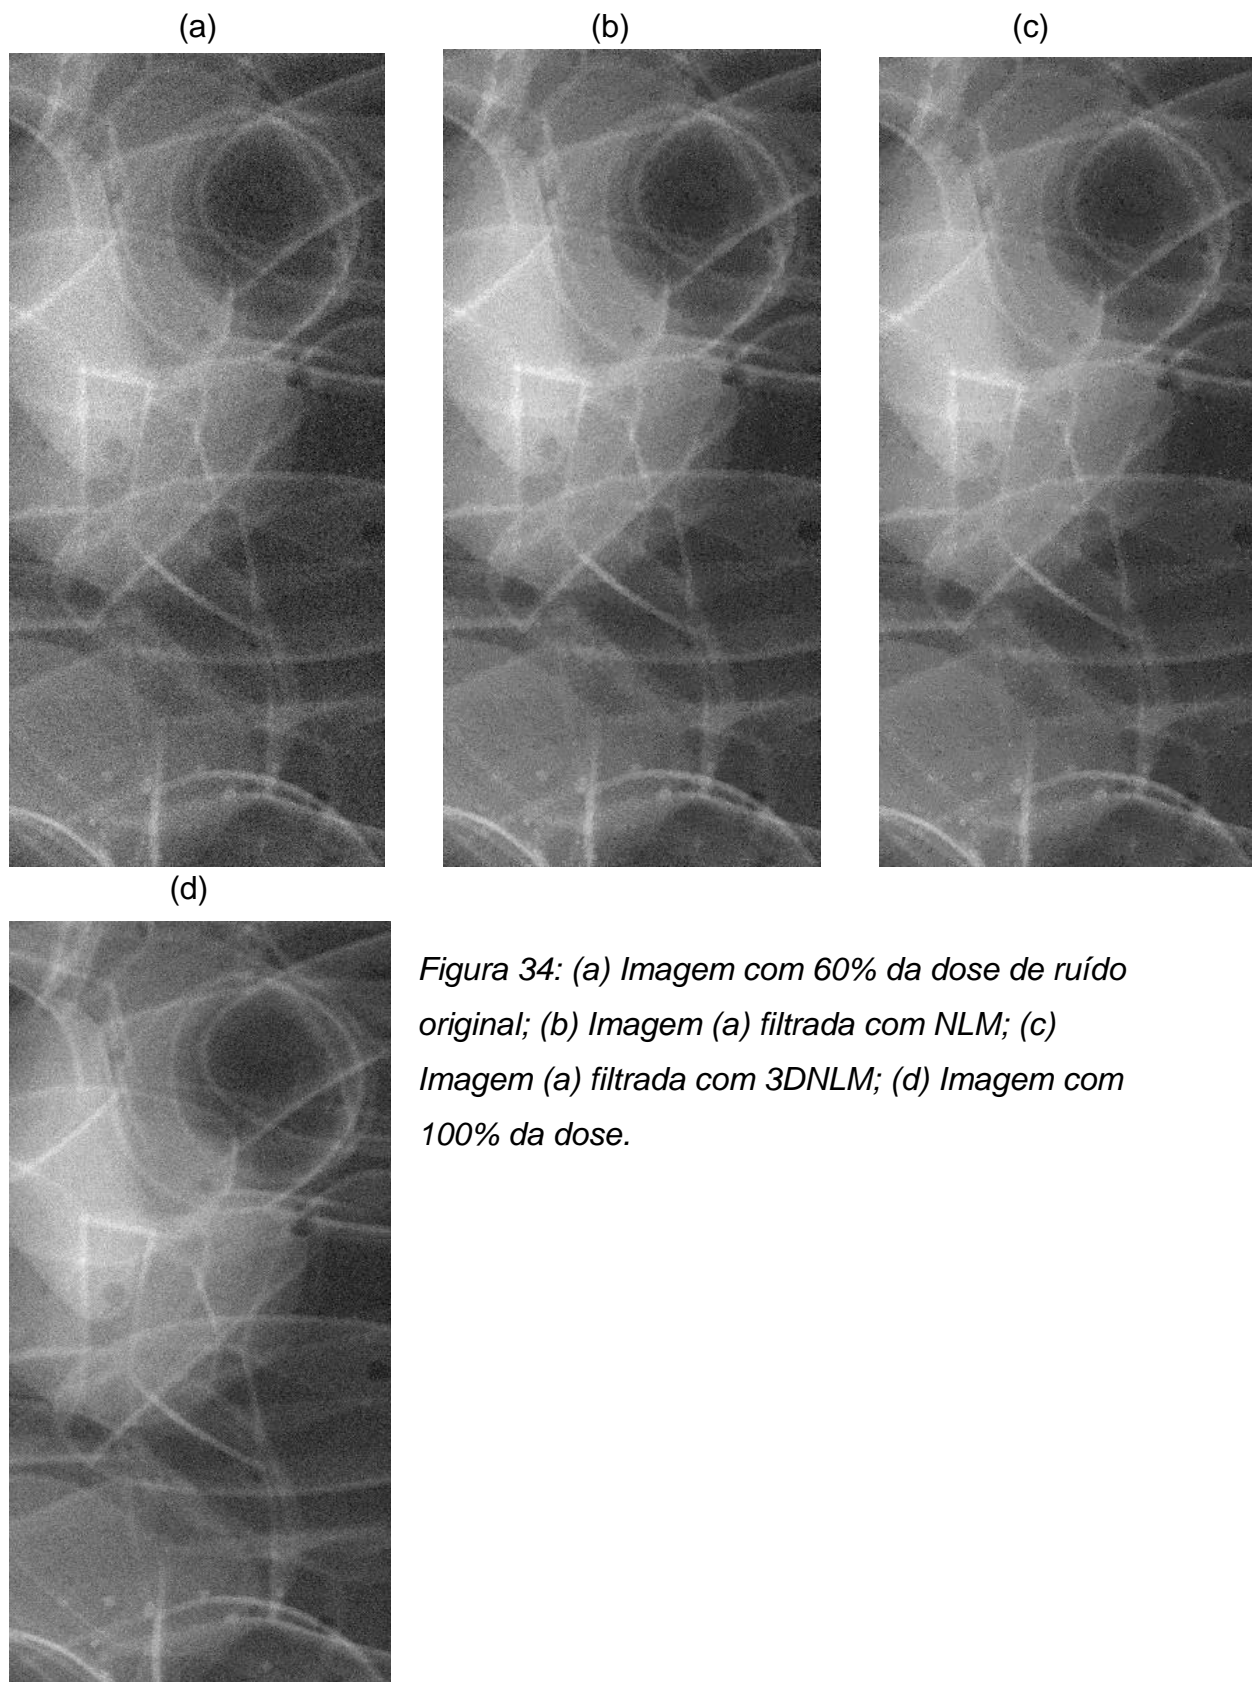


Figura 34: (a) Imagem com 60% da dose de ruído original; (b) Imagem (a) filtrada com NLM; (c) Imagem (a) filtrada com 3DNLM; (d) Imagem com 100% da dose.

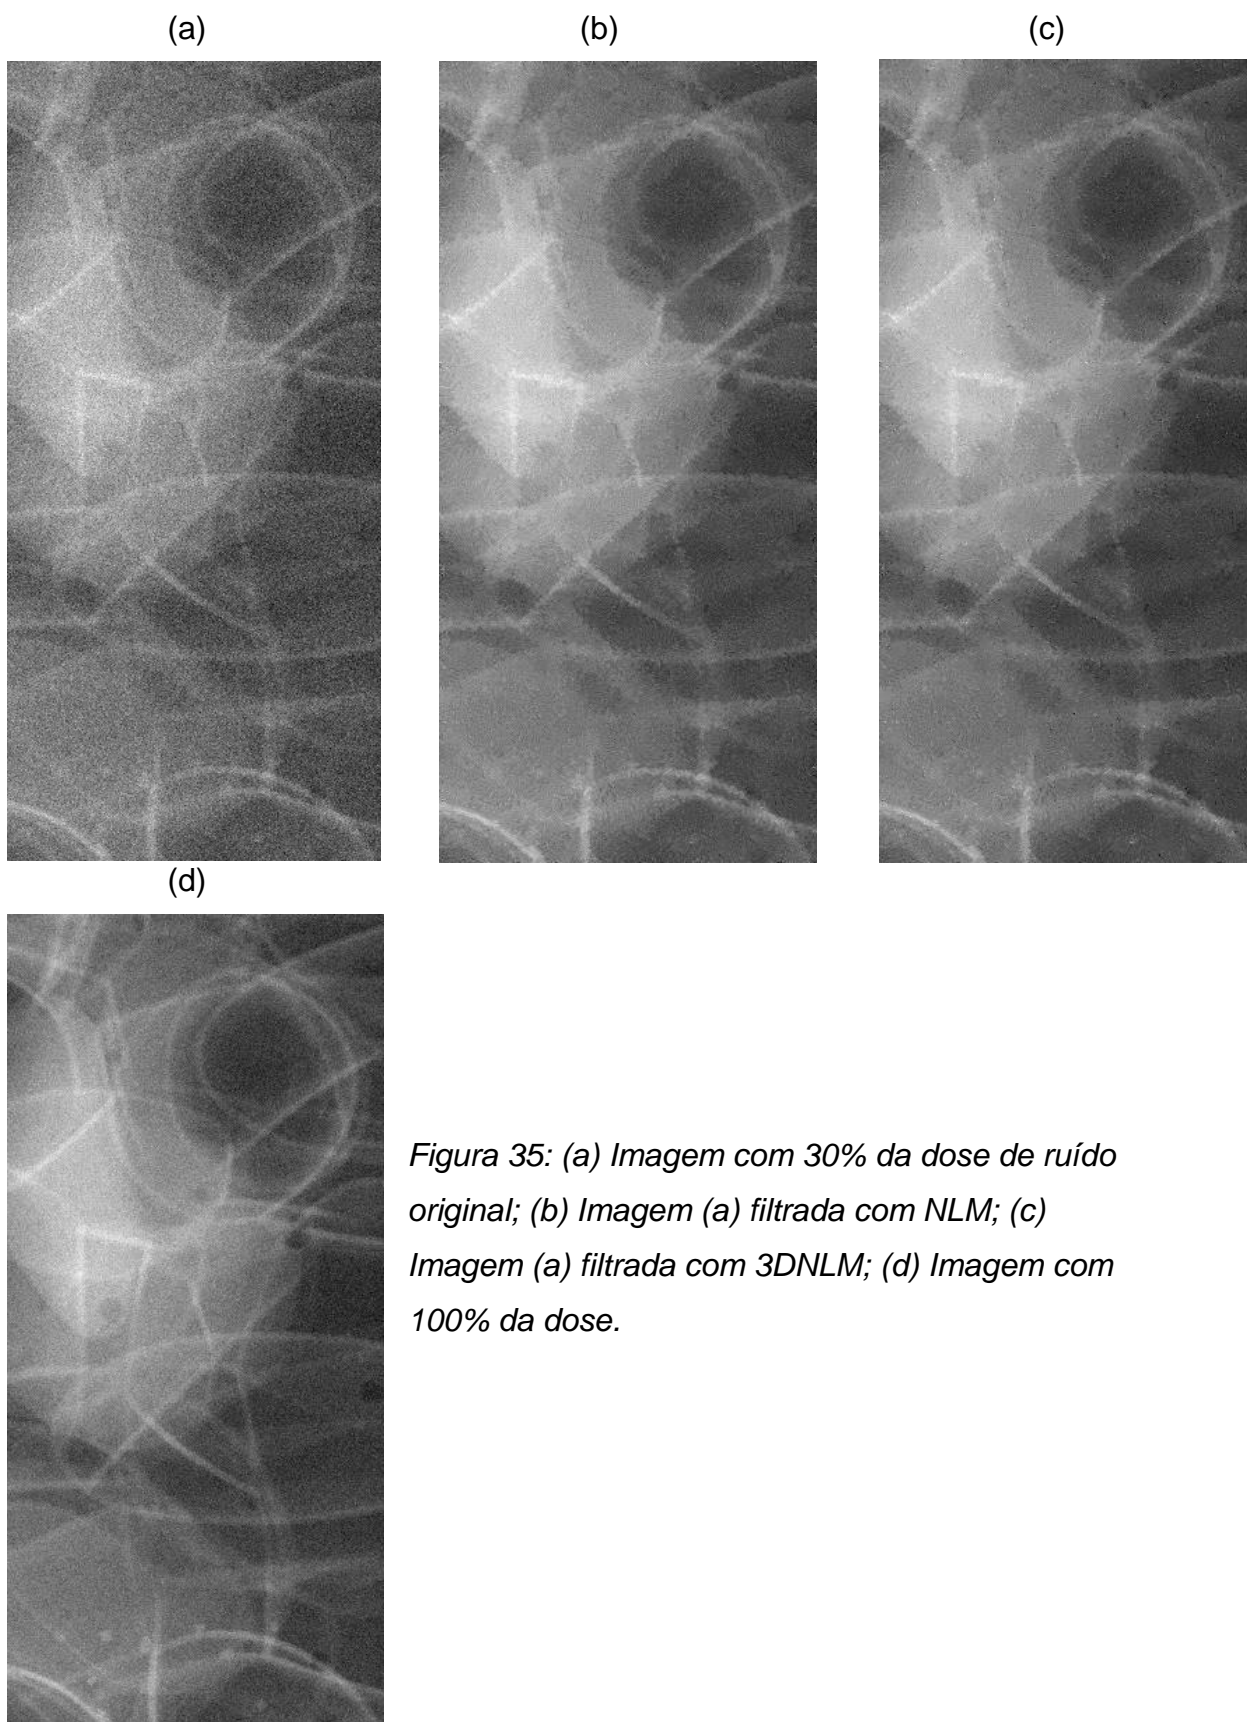


Figura 35: (a) Imagem com 30% da dose de ruído original; (b) Imagem (a) filtrada com NLM; (c) Imagem (a) filtrada com 3DNLM; (d) Imagem com 100% da dose.

6. Discussões e Conclusões

Nessa seção serão discutidos os resultados exibidos no *Capítulo 5*, a fim de chegar a conclusões sobre a qualidade do algoritmo proposto por esse trabalho, o *3-Dimensional Non-Local Means (3DNLM)*, na filtragem de ruído de imagens tomossíntese mamária.

Analizando os valores dos parâmetros MSSIM e Sharpness (dB), essencialmente, é possível verificar a superioridade do 3DNLM sobre o NLM tradicional na filtragem de imagens de DBT com dose reduzida. EM todos os casos o valor do sharpness ficou mais próximo da imagem com 100% da dose quando utilizado o algoritmo proposto, mastrando que a imagem final é menos borrada com a nova proposta.

As imagens de baixa dose são, realmente, muito degradadas. O ruído, quando muito predominante, como nas doses de 30%, omite algumas pequenas microcalcificações como pode ser observado comparando a *Figura 35 (a) e (d)*. E a filtragem do ruído piora ainda mais a visualização da imagem, independentemente do método escolhido, *Figura 35 (b) e (c)*, gerando borramento.

Nas imagens com redução média da dose de radiação, com 60% da dose, o ruído ainda não é tão predominante, *Figura 34 (a)*. A filtragem desse ruído borrou pouco as projeções e preservou as microcalcificações, bem visíveis na *Figura 34 (b) e (c)*. Visualmente as imagens filtradas com ambos algoritmos são parecidas, e assimilam com a projeção com 100% de dose com ligeira vantagem nas imagens filtradas pelo 3DNLM.

Para as projeções com 90% da dose, a melhor desempenho, passível de observação pelos gráficos das *Figura 23 à Figura 26*, é com certeza 3DNLM.

Como comentado na *Seção 2.3*, quanto maior a janela de busca no NLM, maior o viés devido aos pequenos pesos, o que geralmente provoca o borramento da imagem. Com o novo método, a janela de busca foi aumentada me três vezes, e os resultados mostram ainda que as imagens filtradas com o

3DLNM são mais nítidas, para 60% e 30% da dose, por exemplo, do que com o NLM.

É possível concluir que a similaridade entre as projeções, verdadeiramente, adiciona informações relevantes na filtragem do ruído pelo *3DNLM*. Além disso, é preciso ter em mente que as imagens ainda serão utilizadas na reconstrução tridimensional da mama. Assim, em trabalho futuro, deve-se analisar o ganho da filtragem proposta também nas imagens após a reconstrução.

De um modo geral, o algoritmo proposto manteve mais a imagem filtrada similar com a de 100%, contra o método já existente, NLM, apesar de consumir maior processamento computacional. No entanto, são apenas algumas evidências constatadas nos experimentos feitos desse trabalho que nos fazem chegar a essa conclusão, que poderiam ser aprofundados em trabalhos futuros.

Referências Bibliográficas

- [1] WHO - World Health Organization. Acessado em: 21/05/2016.
Disponível em: <http://www.who.int/en/>
- [2] INCA - Instituto Nacional de Câncer. Acessado em: 21/05/2016.
Disponível em: <http://www.inca.gov.br>
- [3] Elmore JG, Nakano CY, Koepsell TD, Desnick LM, D'Orsi CJ, Ransohoff DF: International variation in screening mammography interpretations in community-based programs. J Natl Cancer Inst 95(18):1384-1393, 2003.
- [4] Veronesi U, Boyle P, Goldhirsch A, Orecchia R, Viale G: Breast Cancer. The Lancet 365:1727-1741, 2005.
- [5] Maidment ADA: Digital mammography. Semin Roentgenol 38(3):216-230, 2003.
- [6] Karellas A, Vedantham S: Breast cancer imaging: a perspective for the next decade. Med Phys 35(11):4878-4897, 2008.
- [7] Glynn CG, Farria DM, Monsees BS, Salcman JT, Wiele KN Hildebolt CF: Effect of transition to digital mammography on clinical outcomes. Radiology 260(3):664-670, 2011.
- [8] Sechopoulos I: A review of breast tomosynthesis. Part I. The image acquisition process. Med Phys 40(1):014301-1-12, 2013.
- [9] Baker JA, Lo JY: Breast tomosynthesis: State-of-the-art and review of the literature. Acad. Radiol 18:1298-1310, 2011.
- [10] Rafferty EA, Park JM, Philpotts LE, Poplack SP, Sumkin JH, Halpern EF, Niklason LT: Assessing Radiologist Performance Using Combined Digital Mammography and Breast Tomosynthesis Compared with Digital Mammography Alone: Results of a Multicenter, Multireader Trial. Radiology 266(1): 104-113, 2013.
- [11] Hendrick RE: Radiation doses and cancer risks from breast imaging studies, Radiology 257(1):246-253, 2010.

[12] Yaffe MJ, Mainprize, JG: Risk of radiation-induced breast cancer from mammographic screening, *Radiology* 258(1):98-105, 2011.

[13] Yaffe MJ: Digital Mammography. In: Beutel J, Kundel HL and Van Metter RL (Eds). *Handbook of Medical Imaging Vol 1. Physics and Psychophysics*, Bellingham, WA: SPIE Press, pp 329-372, 2000.

[14] Williams MB, Yaffe MJ, Maidment ADA, Martin MC, Seibert JA, Pisano ED: Image quality in digital mammography: image acquisition. *J Am Coll Radiol* 3(8):589-608, 2006.

[15] Ruschini M, et al.: Dose dependence of mass and microcalcification detection in digital mammography: Free response human observer studies, *Med Phys* 34(2):400-407, 2007.

[16] Samei E, Saunders RS, Baker JA, Delong DM: Digital mammography: effects of reduced radiation dose on diagnostic performance, *Radiology* 243(2):396-404, 2007.

[17] Saunders RS, Baker JA, Delong DM, Johnson JP, Samei E: Does image quality matter? Impact of resolution and noise on mammographic task performance. *Med Phys* 34(10):3971-3981, 2007.

[18] Vieira MAC, Schiabel H, Escarpinati MC: Breast image quality enhancement by using optical transfer function and noise Wiener spectrum. In: 91st Proceedings of RSNA, pp.702, 2005.

[19] Mencattini A, Salmeri M, Lojacono R, Frigerio M, Caselli F: Mammographic images enhancement and denoising for breast cancer detection using dyadic wavelet processing. *IEEE Trans Instrum Meas* 57(7):1422-1430, 2008.

[20] Romualdo LCS, Vieira MAC, Oliveira Jr PD, Schiabel H: Mammography images restoration by quantum noise reduction and inverse MTF filtering, In: XXII SIBGRAPI, p.180-185, 2009.

[21] Romualdo LCS, Vieira MAC, Schiabel H, Mascarenhas NDA, Borges LR: Mammographic image denoising and enhancement using the Anscombe transformation, adaptive Wiener filtering, and the modulation transfer function, *J Digit Imaging* 26(2):183-197, 2013.

[22] Buades A, Coll B, Morel JM: A review of image denoising algorithms, with a new one. *Multiscale Modeling Simulation* (SIAM Interdisciplinary J.), v.4(2):490-530, 2005.

[23] Dabov K, Foi A, Katkovnik V, Egiazarian K: Image denoising by sparse 3D transform-domain collaborative filtering *IEEE Trans Image Process* 16(8): 2080-2095, 2007.

[24] Vedantham, S.; Karellas, A.; Vijayaraghavan, G. R.; Kopans, D. B. (2015) Digital Breast Tomosynthesis: State of the Art, *Radiology*, 277(3), 664 - 666.

[25] Beutel, B.; Kundel, H. L.; Metter, R. L., (2000) Digital Mamography, *Handbook of Medical Imaging*, Vol. 1, 340 - 341. Bellingham, Washington: SPIE.

[26] Salmon, J. On Two Parameters for Denoising With Non-Local Means. *IEEE Signal Processing Letters*, v. 17, n. 3, p. 269–272, mar. 2010.

[27] Mäkitalo M, Foi A: Optimal inversion of the Anscombe transformation in low-count Poisson image denoising. *IEEE T Image Process* 20(1):99-109, 2011.

[28] J.L. Starck, F. Murtagh, and A. Bijaoui, *Image Processing and Data Analysis*, Cambridge University Press, Cambridge, 1998).

[29] Wang, Z. e Bovik, A. “Mean Squared Error: Love it or Leave it?” *Signal Processing Magazine* (IEEE Signal Processing Magazine) 26(1) (2009): 98-117.

[30] Gonzalez, R. C.; Woods, R. E., (2009) Restauração e reconstrução de imagens, *Processamento Digital de Imagens*, 3, 232-233, São Paulo, Pearson Education do Brasil Ltda.

[31] UTFPR, RLE. *Laboratórios DAINF*. 2008. rle.dainf.ct.utfpr.edu.br.

[32] Bakic, P. R., Zhang, C. and Maidment, A. D. A. “Development and characterization of an anthropomorphic breast software phantom based upon region-growing algorithm.” *Medical Physics* 38(6) (2011): 3165-3176.

[33] He, L.; Greenshields, I. R.; (2009) A Nonlocal Maximum Likelihood Estimation Method for Rician Noise Reduction in MR Images. *IEEE Transactions on Medical Imaging*, V. 208, 2.

[34] Bindilatti, A. A.; Abordagens Não-Locais Para Filtragem de Ruído Poisson, 2014; *Figura 2.1 – Conjuntos de Patches Similares*; Universidade Federal de São Carlos, São Carlos – SP.

[35] Young, K.; Okudo, J. Technical evaluation of the Hologic Selenia full eld digital mammography system with a tungsten tube. NHSBSP Equip. Rep. 0801. [S.I.], 2008.

[36] Borges LR, Oliveira HCR, Nunes PF, Bakic PR, Maidment ADA, Vieira, MAC: Method for simulating dose reduction in digital mammography using the Anscombe transformation. Med Phys, 2016. 43(6): 2704-2714.