

UNIVERSIDADE FEDERAL DE SÃO CARLOS  
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO  
DEPARTAMENTO DE COMPUTAÇÃO

DENIS HENRIQUE PINHEIRO SALVADEO

**FILTRAGEM DE RUÍDO EM IMAGENS TOMOGRÁFICAS COM BAIXA  
TAXA DE CONTAGEM UTILIZANDO UMA ABORDAGEM BAYESIANA  
CONTEXTUAL**

SÃO CARLOS

2013

DENIS HENRIQUE PINHEIRO SALVADEO

# **Filtragem de Ruído em Imagens Tomográficas com Baixa Taxa de Contagem Utilizando uma Abordagem Bayesiana Contextual**

*Tese apresentada ao Programa de Pós-Graduação em Ciência da Computação do Departamento de Computação da Universidade Federal de São Carlos como parte dos requisitos para obtenção do título de Doutor em Ciência da Computação.*

Orientador: Prof. Dr. Nelson Delfino d'Ávila Mascarenhas

Co-orientador: Prof. Dr. Alexandre Luis Magalhães Levada

São Carlos

2013

**Ficha catalográfica elaborada pelo DePT da  
Biblioteca Comunitária/UFSCar**

S182fr

Salvadeo, Denis Henrique Pinheiro.

Filtragem de ruído em imagens tomográficas com baixa taxa de contagem utilizando uma abordagem bayesiana contextual / Denis Henrique Pinheiro Salvadeo. -- São Carlos : UFSCar, 2013.  
245 f.

Tese (Doutorado) -- Universidade Federal de São Carlos, 2013.

1. Processamento de imagens. 2. Filtragem de ruído. 3. Tomografia computadorizada. 4. Campos aleatórios de Markov. 5. Filtro de Wiener. 6. Estimação de ruído. I. Título.

CDD: 006.42 (20<sup>a</sup>)

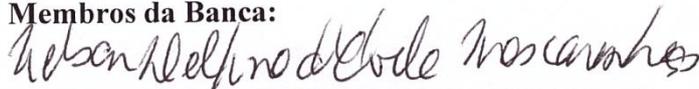
**Universidade Federal de São Carlos**  
**Centro de Ciências Exatas e de Tecnologia**  
**Programa de Pós-Graduação em Ciência da Computação**

**“Filtragem de Ruído em Imagens Tomográficas  
com Baixa Taxa de Contagem Utilizando uma  
Abordagem Bayesiana Contextual”**

Denis Henrique Pinheiro Salvadeo

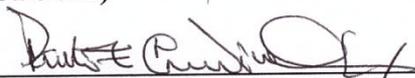
Tese de Doutorado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Doutor em Ciência da Computação

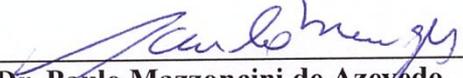
Membros da Banca:

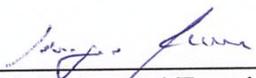


Prof. Dr. Nelson Delfino d'Ávila Mascarenhas  
(Orientador - DC/UFSCar)

Prof. Dr. Ricardo José Ferrari  
(DC/UFSCar)

  
Prof. Dr. Paulo Estevão Cruvinel  
(Embrapa Instrumentação Agropecuária)

  
Prof. Dr. Paulo Mazzoncini de Azevedo  
Marques  
(FMRP/USP)

  
Prof. Dr. Sergio Shiguemi Furuie  
(POLI/USP)

São Carlos  
Março/2013

Dedico este trabalho aos meus pais Cidinha e Vitor pelo incentivo e apoio incondicionais e à minha eterna esposa Juliana por seu carinho e amor.

## AGRADECIMENTOS

A Deus por me permitir sonhar e realizar este projeto.

Aos meus pais Vitor Manoel e Cidinha e ao meu irmão Vitor Augusto pela força, apoio, incentivo, pelas palavras nos momentos de angústia, pelas orações, pela minha formação e especialmente, pelo amor incondicional e irrestrito.

À minha esposa Juliana, que tanto amo, pelo seu amor, carinho, inspiração, paciência, compreensão, por sua beleza e graciosidade encantadoras, por tornar os meus dias mais felizes e por compartilhar dos meus sonhos e realidades.

Ao prof. Nelson Mascarenhas, pela orientação durante o meu doutorado, pela amizade e confiança depositadas em mim, pela sua disponibilidade, pela oportunidade de fazer o meu estágio de doutorado no exterior, pela sua experiência, por todo o aprendizado, pelas conversas, questionamentos, ideias, sugestões e discussões, que contribuíram para a minha formação como pesquisador e pela sua brilhante carreira e incrível humildade, as quais tenho como exemplo para continuar trilhando o meu caminho e realizando os meus sonhos profissionais.

Ao Alexandre Levada, um dos meus melhores amigos, antes mesmo de se tornar também meu orientador, pela sua enorme capacidade, por toda a ajuda com o trabalho e de novas ideias, pela força, otimismo e incentivo, pela orientação, disponibilidade e presença sempre constante, também contribuindo enormemente para a minha formação como pesquisador.

À Embrapa, em especial ao Prof. Paulo E. Cruvinel pelos dados de tomografia CT de ciência do solo usados neste trabalho.

Às minhas supervisoras de estágio de doutorado na França, Isabelle Bloch e Florence Tupin da Télécom ParisTech, pela acolhida, supervisão, discussões e excelentes contribuições para a minha carreira, especialmente por me permitir ter esta experiência muito enriquecedora profissionalmente e pessoalmente, o que tem aberto novas possibilidades e ideias.

Aos meus amigos, integrantes e ex-integrantes do GAPIS, especialmente à Débora, Michelle, Márcia, Talita, Eduardo, Rafael, Pedro, Gustavo, Ana Luísa, André, João, Zorzan, Moacir e Mayra pela amizade, pelos momentos de descontração, por toda ajuda e importantes discussões e colaborações.

À professora Sandra Abib, pela amizade, por todas as oportunidades de crescimento, pela confiança, pela torcida e pela sua disponibilidade em ajudar.

Ao professor Jander Moreira, que me apresentou a área de Processamento de Imagens na disciplina de Construção de Algoritmos, durante o meu primeiro semestre de graduação na UFSCar, e aceitou me orientar logo no início da minha graduação em 2004, também me iniciando na área científica, tendo me acompanhado e orientado inclusive durante o meu mestrado, sem deixar de destacar a amizade, as ótimas aulas e tantas outras oportunidades que me proporcionou.

Aos demais docentes e funcionários do DC e demais alunos do PPG-CC e graduação, por todo auxílio, amizade, atenção, cooperação, aprendizado e companheirismo.

A todos os meus professores do CTI/UNESP de Bauru/SP, do ensino fundamental e da educação infantil, por todo o aprendizado de base, pela contribuição na minha formação como cidadão e por todo o incentivo, tendo sido essenciais para que eu pudesse atingir esta etapa tão desejada.

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pelo suporte financeiro imprescindível para o desenvolvimento do meu doutorado e também à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo mesmo motivo, pois financiou este projeto por seis meses, antes da aprovação da bolsa da FAPESP.

Enfim, a todas as pessoas que de alguma forma contribuíram para que este sonho fosse concretizado, que é a realização do meu doutorado.

*“Rien n'est tel que le rêve pour engendrer  
l'avenir. Utopie aujourd'hui, chair et os  
demain.” (Victor Hugo – ‘Les misérables’)*

## RESUMO

Imagens de tomografia computadorizada (CT), em diversos casos, precisam ser adquiridas com baixa contagem de fótons devido ao baixo tempo de exposição aos raios do tomógrafo para reduzir a dose de radiação ao máximo possível (na Medicina, princípio ALARA – As Low As Reasonably Achievable) ou mesmo por questões de custo, fazendo com que as projeções obtidas sejam corrompidas por ruído Poisson. Invocando o Teorema Central do Limite, as imagens reconstruídas tendem a ser corrompidas por ruído Gaussiano. Além disso, observou-se que este ruído continua a ser dependente do sinal, depois da reconstrução. Desta forma, este trabalho propôs a filtragem de ruído da imagem reconstruída (pós-filtragem), adotando um modelo a priori contextual pela utilização de Campos Aleatórios Markovianos (MRF), a fim de melhorar a qualidade visual da imagem. Basicamente, para a filtragem contextual foram consideradas duas abordagens. Uma utilizando algoritmos iterativos de otimização combinatória como ICM (*Iterated Conditional Modes*), GSA (*Game Strategy Approach*) e MPM (*Maximizer of the Posterior Marginals*). E outra, utilizando variações do filtro de Wiener, considerando Informação de Fisher (Generalizado), MRF Separável e MRF Isotrópico. Ainda, para tratar a questão de ruído dependente do sinal, três novos métodos de estimação de suas variâncias locais, como também maneiras de se considerar este modelo tanto nos métodos iterativos quanto nos baseados em Wiener foram investigados. Os métodos foram aplicados em imagens simuladas e reais de CT reconstruídas por Retroprojeção Filtrada e POCS (*Projections Onto Convex Sets*). Além disso, foi proposto o uso de Non Local Means para uma melhor estimativa da imagem livre de ruído. Finalmente, diversos experimentos foram realizados e os resultados foram compilados e apresentados comparando os diversos métodos, inclusive com o método em estado-da-arte Non Local Means, mostrando que o contexto e a consideração de ruído dependente do sinal podem contribuir para a filtragem de ruído em CT pela melhora na relação Sinal-Ruído e, conseqüentemente, permitir a redução da dose de radiação.

## ABSTRACT

Computed Tomography (CT) images, in many cases, need to be acquired with low photon counting due to low exposure time to the rays of the CT scanner to reduce the radiation doses to the maximum possible (in Medicine, the ALARA principle – As Low As Reasonably Achievable) or even for reasons of cost, obtaining projections corrupted by Poisson noise. Invoking the Central Limit Theorem, the reconstructed images tend to be corrupted by Gaussian noise. Moreover, it was observed that this noise remains signal-dependent after the reconstruction. Thus, this work proposes to denoise the reconstructed images (post-filtering), by adopting an a priori contextual model by using Markov Random Field (MRF), to improve the visual quality of the image. Basically, for contextual filtering two approaches were considered. One uses iterative algorithms for combinatorial optimization such as ICM (*Iterated Conditional Modes*), GSA (*Game Strategy Approach*) and MPM (*Maximizer of the Posterior Marginals*). And the other uses variations of the Wiener filter by considering Fisher Information, Separable MRF and Isotropic MRF. Also, to address the issue of signal-dependent noise, three new methods for its local variance estimation, as well as ways to consider this model in both iterative and those based on Wiener filter methods were investigated. The proposed methods were applied to simulated and real CT images that were reconstructed by Filtered Backprojection (FBP) and Projections Onto Convex Sets (POCS) algorithms. Furthermore, the use of Non Local Means method has been proposed for a better estimate of the noise-free image. Finally, several experiments were conducted and the results were compiled and presented comparing the various methods, including the state-of-the-art Non Local Means method, showing that the context and the consideration of signal-dependent noise can contribute to CT denoising by improving the Signal-to-Noise Ratio and therefore allow a reduction in the radiation dose.

## LISTA DE FIGURAS

<b>Figura 1.1.</b> Minitomógrafo de mesa (Cruvinel, 1987). Retirada de (Cnpdia-Embrapa, 2011). .....	28
<b>Figura 1.2.</b> Diagrama de blocos de imageamento em CT. Os processos marcados por linha tracejada são opcionais dentro do processo de imageamento em CT. Entretanto, a parte destacada engloba os processos considerados nesta tese e corresponde de forma genérica à metodologia utilizada. ....	30
<b>Figura 2.1.</b> Tomografia de Transmissão. Baseada em (Kak e Slaney, 1988; Pereira, 2007)..	38
<b>Figura 2.2.</b> Transformada de Radon. Baseada em (Rangayyan, 2005). ....	46
<b>Figura 2.3.</b> Teorema do Corte de Fourier. Baseada em (Rangayyan, 2005) .....	47
<b>Figura 2.4.</b> Operação de Retroprojeção. Baseada em (Kak e Slaney, 1988; Pereira, 2007)..	51
<b>Figura 2.5.</b> Representação da imagem em ART. Adaptado de (Kak e Slaney, 1988). ....	53
<b>Figura 2.6.</b> Método de Kaczmarz. Adaptado de (Kak e Slaney, 1988). ....	54
<b>Figura 2.7.</b> Convergência dos Algoritmos de Reconstrução por POCS: a) POCS Sequencial e b) POCS Paralelo. Baseado em (Combettes, 1993; Salina, 2007). ....	56
<b>Figura 4.1.</b> Ordem de Sistemas de Vizinhança: a) primeira ordem (4 vizinhos), b) segunda ordem (8 vizinhos) e c) terceira ordem (12 vizinhos). Adaptado de (Won e Gray, 2004). ....	73
<b>Figura 4.2.</b> Cliques para um sistema de vizinhança de segunda ordem. Baseada em (Won e Gray, 2004). ....	74
<b>Figura 4.3.</b> Exemplos de funções de custo: a) quadrática e b) uniforme. Baseada em (Kay, 1993). ....	79
<b>Figura 5.1.</b> Princípio da Ortogonalidade: a) Situação Inicial e b) Projeção . Baseada em (Kay, 1993). ....	92
<b>Figura 6.1.</b> Diagrama de blocos representando a metodologia para filtragem utilizada nesta tese. ....	96
<b>Figura 6.2.</b> Versão preliminar do método proposto de estimação de ruído dependente de sinal. ....	103
<b>Figura 6.3.</b> Versão final do método proposto de estimação de ruído dependente de sinal. ..	105

<b>Figura 6.4.</b> Tela da ferramenta para a escolha do número de bins do histograma e limiar do detector de bordas para o método de estimação do ruído dependente do sinal. ....	106
<b>Figura 7.1.</b> Imagens do <i>phantom</i> de Shepp-Logan: a) original reconstruída por FBP, b) ruidosa reconstruída por FBP, c) original reconstruída por POCS e d) ruidosa reconstruída por POCS. ....	116
<b>Figura 7.2.</b> Resultados de Filtragem para a Imagem do <i>phantom</i> de Shepp-Logan reconstruído por FBP. As imagens exibidas estão na ordem da Tabela 7.2. ....	119
<b>Figura 7.3.</b> Mapas do Ruído para o <i>phantom</i> de Shepp-Logan reconstruído por FBP do método Preliminar (limiar = 0,85 e número de bins: (a) K = 1, (b) K = 5 e (c) K = 256) e do Final (limiar = 0,22 e número de bins: (d) K = 1, (e) K = 8 e (f) K = 256). ....	119
<b>Figura 7.4.</b> Resultados de Filtragem para a Imagem do <i>phantom</i> de Shepp-Logan reconstruído por POCS. As imagens exibidas estão na ordem da Tabela 7.3. ....	123
<b>Figura 7.5.</b> Mapas do Ruído para o <i>phantom</i> de Shepp-Logan reconstruído por POCS do método Preliminar (limiar = 0,61 e número de bins: (a) K = 1, (b) K = 5 e (c) K = 256) e do Final (limiar = 0,24 e número de bins: (d) K = 1, (e) K = 5 e (f) K = 256). ....	124
<b>Figura 7.6.</b> Imagens do <i>phantom</i> Homogêneo: a) original reconstruída por FBP, b) ruidosa reconstruída por FBP, c) original reconstruída por POCS e d) ruidosa reconstruída por POCS. ....	125
<b>Figura 7.7.</b> Resultados de Filtragem para a Imagem do <i>phantom</i> Homogêneo reconstruído por FBP. As imagens exibidas estão na ordem da Tabela 7.5. ....	129
<b>Figura 7.8.</b> Mapas do Ruído para o <i>phantom</i> Homogêneo reconstruído por FBP do método Preliminar (limiar = 0,56 e número de bins: (a) K = 1, (b) K = 2 e (c) K = 256) e do Final (limiar = 0,99 e número de bins: (d) K = 1, (e) K = 2 e (f) K = 256). ....	130
<b>Figura 7.9.</b> Resultados de Filtragem para a Imagem do <i>phantom</i> Homogêneo reconstruído por POCS. As imagens exibidas estão na ordem da Tabela 7.6. ....	133
<b>Figura 7.10.</b> Mapas do Ruído para o <i>phantom</i> Homogêneo reconstruído por POCS do método Preliminar (limiar = 0,56 e número de bins: (a) K = 1 e (b) K = 256) e do Final (limiar = 0,99 e número de bins: (c) K = 1, (d) K = 2 e (e) K = 256). ....	133
<b>Figura 7.11.</b> Imagens do <i>phantom</i> Simétrico: a) original reconstruída por FBP, b) ruidosa reconstruída por FBP, c) original reconstruída por POCS e d) ruidosa reconstruída por POCS. ....	135

<b>Figura 7.12.</b> Resultados de Filtragem para a Imagem do <i>phantom</i> Simétrico reconstruído por FBP. As imagens exibidas estão na ordem da Tabela 7.8. ....	138
<b>Figura 7.13.</b> Mapas do Ruído para o <i>phantom</i> Simétrico reconstruído por FBP do método Preliminar (limiar = 0,24 e número de bins: (a) K = 1, (b) K = 3 e (c) K = 256) e do Final (limiar = 0,09 e número de bins: (d) K = 1, (e) K = 9 e (f) K = 256).....	139
<b>Figura 7.14.</b> Resultados de Filtragem para a Imagem do <i>phantom</i> Simétrico reconstruído por POCS. As imagens exibidas estão na ordem da Tabela 7.9. ....	142
<b>Figura 7.15.</b> Mapas do Ruído para o <i>phantom</i> Simétrico reconstruído por FBP do método Preliminar (limiar = 0,35 e número de bins: (a) K = 1, (b) K = 3 e (c) K = 256) e do Final (limiar = 0,19 e número de bins: (d) K = 1, (e) K = 9 e (f) K = 256).....	143
<b>Figura 7.16.</b> Imagens do <i>phantom</i> Assimétrico: a) original reconstruída por FBP, b) ruidosa reconstruída por FBP, c) original reconstruída por POCS e d) ruidosa reconstruída por POCS. ....	144
<b>Figura 7.17.</b> Resultados de Filtragem para a Imagem do <i>phantom</i> Assimétrico reconstruído por FBP. As imagens exibidas estão na ordem da Tabela 7.11.....	148
<b>Figura 7.18.</b> Mapas do Ruído para o <i>phantom</i> Assimétrico reconstruído por FBP do método Preliminar (limiar = 0,54 e número de bins: (a) K = 1, (b) K = 2 e (c) K = 256) e do Final (limiar = 0,39 e número de bins: (d) K = 1, (e) K = 2 e (f) K = 256).....	149
<b>Figura 7.19.</b> Resultados de Filtragem para a Imagem do <i>phantom</i> Assimétrico reconstruído por POCS. As imagens exibidas estão na ordem da Tabela 7.12.....	153
<b>Figura 7.20.</b> Mapas do Ruído para o <i>phantom</i> Assimétrico reconstruído por POCS do método Preliminar (limiar = 0,27 e número de bins: (a) K = 1, (b) K = 3 e (c) K = 256) e do Final (limiar = 0,14 e número de bins: (d) K = 1, (e) K = 5 e (f) K = 256).....	154
<b>Figura 7.21.</b> Imagens de Madeira 1: a) original reconstruída por FBP, b) ruidosa reconstruída por FBP, c) original reconstruída por POCS e d) ruidosa reconstruída por POCS. ....	154
<b>Figura 7.22.</b> Resultados de Filtragem para a Imagem de Madeira 1 reconstruído por FBP. As imagens exibidas estão na ordem da Tabela 7.14.....	158
<b>Figura 7.23.</b> Mapas do Ruído para Madeira 1 reconstruído por FBP do método Preliminar (limiar = 0,26 e número de bins: (a) K = 1, (b) K = 5 e (c) K = 256) e do Final (limiar = 0,99 e número de bins: (d) K = 1, (e) K = 9 e (f) K = 256).....	158

<b>Figura 7.24.</b> Resultados de Filtragem para a Imagem de Madeira 1 reconstruído por POCS. As imagens exibidas estão na ordem da Tabela 7.15. ....	162
<b>Figura 7.25.</b> Mapas do Ruído para Madeira 1 reconstruído por POCS do método Preliminar (limiar = 0,15 e número de bins: (a) K = 1, (b) K = 5 e (c) K = 256) e do Final (limiar = 0,09 e número de bins: (d) K = 1, (e) K = 52 e (f) K = 256).....	163
<b>Figura 7.26.</b> Imagens de Madeira 2: a) original reconstruída por FBP, b) ruidosa reconstruída por FBP, c) original reconstruída por POCS e d) ruidosa reconstruída por POCS. ....	164
<b>Figura 7.27.</b> Resultados de Filtragem para a Imagem de Madeira 2 reconstruído por FBP. As imagens exibidas estão na ordem da Tabela 7.17.....	167
<b>Figura 7.28.</b> Mapas do Ruído para Madeira 2 reconstruído por FBP do método Preliminar (limiar = 0,8 e número de bins: (a) K = 1, (b) K = 5 e (c) K = 256) e do Final (limiar = 0,22 e número de bins: (d) K = 1, (e) K = 9 e (f) K = 256).....	167
<b>Figura 7.29.</b> Resultados de Filtragem para a Imagem da Madeira 2 reconstruído por POCS. As imagens exibidas estão na ordem da Tabela 7.18. ....	171
<b>Figura 7.30.</b> Mapas do Ruído para Madeira 2 reconstruído por POCS do método Preliminar (limiar = 0,27 e número de bins: (a) K = 1, (b) K = 3 e (c) K = 256) e do Final (limiar = 0,14 e número de bins: (d) K = 1, (e) K = 18 e (f) K = 256).....	171
<b>Figura A.1.</b> Diagrama de blocos do esquema de geração das imagens simuladas. ....	191
<b>Figura A.2.</b> Exemplos de imagens sintéticas geradas.....	193
<b>Figura B.1.</b> Imagens sintéticas originais e ruidosas com dez classes usadas para a análise de dependência de sinal.....	195
<b>Figura B.2.</b> Áreas homogêneas selecionadas para o phantom Homogêneo reconstruído por FBP: (a) imagem ruidosa, (b) região do objeto e (c) região fora do objeto.....	196
<b>Figura B.3.</b> Áreas homogêneas selecionadas para o phantom Homogêneo reconstruído por POCS: (a) imagem ruidosa e (b) região do objeto (borda escura desconsiderada). ....	196
<b>Figura B.4.</b> Áreas homogêneas selecionadas para o phantom Assimétrico reconstruído por FBP: (a) imagem ruidosa, (b) furos cheios de ar, (c) estrutura de plexiglass e (d) região fora do objeto. ....	197
<b>Figura B.5.</b> Áreas homogêneas selecionadas para o phantom Assimétrico reconstruído por POCS: (a) imagem ruidosa, (b) furos cheios de ar e (c) estrutura de plexiglass. ....	197

<b>Figura B.6.</b> Áreas homogêneas selecionadas para o phantom Simétrico reconstruído por FBP: (a) imagem ruidosa, (b) furos de alumínio, (c) furos cheios de ar, (d) corpo do phantom (plexiglass) e (e) região fora do objeto. ....	198
<b>Figura B.7.</b> Áreas homogêneas selecionadas para o phantom Simétrico reconstruído por POCS: (a) imagem ruidosa, (b) furos de alumínio, (c) furos cheios de ar e (d) corpo do phantom (plexiglass). ....	198
<b>Figura B.8.</b> Áreas homogêneas selecionadas para Madeira 1 reconstruída por FBP: (a) imagem ruidosa, (b) região central, (c) região interna mais clara e (d) região fora do objeto. ....	198
<b>Figura B.9.</b> Áreas homogêneas selecionadas para Madeira 1 reconstruída por POCS: (a) imagem ruidosa, (b) região central e (c) região interna mais clara. ....	199
<b>Figura B.10.</b> Áreas homogêneas selecionadas para Madeira 2 reconstruída por FBP: (a) imagem ruidosa, (b) regiões de estruturas claras, (c) parte escura do objeto, (d) parte escura do suporte e (e) fora do suporte. ....	199
<b>Figura B.11.</b> Áreas homogêneas selecionadas para Madeira 2 reconstruída por FBP: (a) imagem ruidosa, (b) regiões de estruturas claras, (c) parte escura do objeto e (d) parte escura do suporte. ....	199
<b>Figura C.1.</b> Resultados comparativos dos métodos de estimação do ruído em termos de (a) PSNR e (b) SSIM para a imagem Lena com $I_0 = 8000$ . ....	202
<b>Figura C.2.</b> Resultados comparativos dos métodos de estimação do ruído em termos de (a) PSNR e (b) SSIM para a imagem Mandril com $I_0 = 8000$ . ....	203
<b>Figura C.3.</b> Resultados comparativos dos métodos de estimação do ruído em termos de (a) PSNR e (b) SSIM para a imagem “sim_class_128_beta_1000_iter_30000” com $I_0 = 8000$ . ....	204
<b>Figura C.4.</b> Resultados comparativos dos métodos de estimação do ruído em termos de (a) PSNR e (b) SSIM para a imagem “sim_class_2_beta_50_iter_5000” com $I_0 = 8000$ . ....	205
<b>Figura C.5.</b> Resultados comparativos dos métodos de estimação do ruído em termos de (a) PSNR e (b) SSIM para a imagem “sim_class_3_beta_50_iter_5000” com $I_0 = 8000$ . ....	206
<b>Figura D.1.</b> Melhores resultados de filtragem em termos de (a) PSNR e (b) SSIM para a imagem “Lena” com $I_0 = 8000$ . ....	211
<b>Figura D.2.</b> Melhores resultados de filtragem em termos de (a) PSNR e (b) SSIM para a imagem “Mandril” com $I_0 = 8000$ . ....	212

<b>Figura D.3.</b> Melhores resultados de filtragem em termos de (a) PSNR e (b) SSIM para a imagem “sim_class_128_beta_1000_iter_30000” com $I_0 = 8000$ .....	213
<b>Figura D.4.</b> Melhores resultados de filtragem em termos de (a) PSNR e (b) SSIM para a imagem “sim_class_2_beta_50_iter_5000” com $I_0 = 8000$ .....	214
<b>Figura D.5.</b> Melhores resultados de filtragem em termos de (a) PSNR e (b) SSIM para a imagem “sim_class_3_beta_50_iter_5000” com $I_0 = 8000$ .....	215
<b>Figura D.6.</b> Comparação entre as diferentes configurações dos parâmetros do Wiener Pontual em termos de (a) PSNR e (b) SSIM para a imagem “Lena” com $I_0 = 8000$ .....	216
<b>Figura D.7.</b> Comparação entre as diferentes configurações dos parâmetros do Wiener com MRF Isotrópico em termos de (a) PSNR e (b) SSIM para a imagem “Lena” com $I_0 = 8000$ . .....	217
<b>Figura D.8.</b> Comparação entre as diferentes configurações dos parâmetros do Wiener com MRF Separável em termos de (a) PSNR e (b) SSIM para a imagem “Lena” com $I_0 = 8000$ . .....	218
<b>Figura D.9.</b> Comparação entre as diferentes configurações dos parâmetros do Wiener Generalizado com estimativa da imagem livre de ruído dada pelo Filtro da Média em termos de (a) PSNR e (b) SSIM para a imagem “Lena” com $I_0 = 8000$ .....	219
<b>Figura D.10.</b> Comparação entre as diferentes configurações dos parâmetros do Wiener Generalizado com estimativa da imagem livre de ruído dada pelo Non Local Means em termos de (a) PSNR e (b) SSIM para a imagem “Lena” com $I_0 = 8000$ .....	220
<b>Figura D.11.</b> Comparação entre as diferentes configurações do parâmetro $\alpha$ do GSA em termos de (a) PSNR e (b) SSIM para a imagem “Lena” com $I_0 = 8000$ .....	221
<b>Figura D.12.</b> Comparação entre as diferentes configurações dos parâmetros do Wiener Pontual em termos de (a) PSNR e (b) SSIM para a imagem “Mandril” com $I_0 = 8000$ .....	222
<b>Figura D.13.</b> Comparação entre as diferentes configurações dos parâmetros do Wiener com MRF Isotrópico em termos de (a) PSNR e (b) SSIM para a imagem “Mandril” com $I_0 = 8000$ . .....	223
<b>Figura D.14.</b> Comparação entre as diferentes configurações dos parâmetros do Wiener com MRF Separável em termos de (a) PSNR e (b) SSIM para a imagem “Mandril” com $I_0 = 8000$ . .....	224

<b>Figura D.15.</b> Comparação entre as diferentes configurações dos parâmetros do Wiener Generalizado com estimativa da imagem livre de ruído dada pelo Filtro da Média em termos de (a) PSNR e (b) SSIM para a imagem “Mandrill” com $I_0 = 8000$ .....	225
<b>Figura D.16.</b> Comparação entre as diferentes configurações dos parâmetros do Wiener Generalizado com estimativa da imagem livre de ruído dada pelo Non Local Means em termos de (a) PSNR e (b) SSIM para a imagem “Mandrill” com $I_0 = 8000$ .....	226
<b>Figura D.17.</b> Comparação entre as diferentes configurações do parâmetro $\alpha$ do GSA em termos de (a) PSNR e (b) SSIM para a imagem “Mandrill” com $I_0 = 8000$ .....	227
<b>Figura E.1.</b> Resultados de filtragem do phantom Assimétrico reconstruído por FBP em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior).....	229
<b>Figura E.2.</b> Resultados de filtragem do phantom Assimétrico reconstruído por POCS em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior).....	230
<b>Figura E.3.</b> Resultados de filtragem do phantom Homogêneo reconstruído por FBP em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior).....	231
<b>Figura E.4.</b> Resultados de filtragem do phantom Homogêneo reconstruído por POCS em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior).....	232
<b>Figura E.5.</b> Resultados de filtragem de Madeira 1 reconstruído por FBP em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior). .....	233
<b>Figura E.6.</b> Resultados de filtragem de Madeira 1 reconstruído por POCS em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior).....	234

<b>Figura E.7.</b> Resultados de filtragem de Madeira 2 reconstruído por FBP em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior). .....	235
<b>Figura E.8.</b> Resultados de filtragem de Madeira 2 reconstruído por POCS em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior). .....	236
<b>Figura E.9.</b> Resultados de filtragem do phantom Simétrico reconstruído por FBP em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior). .....	237
<b>Figura E.10.</b> Resultados de filtragem do phantom Simétrico reconstruído por POCS em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior). .....	238
<b>Figura F.1.</b> Resultados de Filtragem do ICM do <i>phantom</i> Assimétrico reconstruído por FBP com modelos a priori GIMLL (1ª linha), GIMLL-L1 (2ª linha), Potts (3ª linha) e GMRF (4ª linha) com verossimilhança Gaussiana e seus respectivos estados nas iterações 5, 10, 15, 20 e 25, apontados nas colunas de 1 a 5, respectivamente. .....	240
<b>Figura F.2.</b> Convergência do ICM em termos de diferença entre iterações (primeira coluna), PSNR (segunda coluna) e SSIM (terceira coluna) para o phantom Assimétrico reconstruído por FBP com modelos a priori GIMLL (linha superior) e GIMLL-L1 (linha inferior) com verossimilhança Gaussiana. .....	241
<b>Figura F.3.</b> Convergência do ICM em termos de diferença entre iterações (primeira coluna), PSNR (segunda coluna) e SSIM (terceira coluna) para o phantom Assimétrico reconstruído por FBP com modelos a priori Potts (linha superior) e GMRF (linha inferior) com verossimilhança Gaussiana. .....	242
<b>Figura F.4.</b> Resultados de Filtragem do ICM do <i>phantom</i> Homogêneo reconstruído por POCS com modelos a priori GIMLL (1ª linha), GIMLL-L1 (2ª linha), Potts (3ª linha) e GMRF (4ª linha) com verossimilhança Gaussiana e seus respectivos estados nas iterações 5, 10, 15, 20 e 25, apontados nas colunas de 1 a 5, respectivamente. Vale ressaltar que o item (s)	

marcado por um \* corresponde ao resultado final (usando o modelo a prior GMRF, ICM convergiu na iteração 17). .....243

**Figura F.5.** Convergência do ICM em termos de diferença entre iterações (primeira coluna), PSNR (segunda coluna) e SSIM (terceira coluna) para o phantom Homogêneo reconstruído por POCS com modelos a priori GIMLL (linha superior) e GIMLL-L1 (linha inferior) com verossimilhança Gaussiana.....244

**Figura F.6.** Convergência do ICM em termos de diferença entre iterações (primeira coluna), PSNR (segunda coluna) e SSIM (terceira coluna) para o phantom Homogêneo reconstruído por POCS com modelos a priori Potts (linha superior) e GMRF (linha inferior) com verossimilhança Gaussiana.....245

## LISTA DE TABELAS

<b>Tabela 7.1.</b> Resultados das medidas de avaliação da imagem ruidosa comparada com a imagem original para o <i>phantom</i> de Shepp-Logan, reconstruídas tanto por FBP quanto por POCS.....	116
<b>Tabela 7.2.</b> Melhores resultados para o <i>phantom</i> de Shepp-Logan reconstruído por FBP, onde * representa o uso de técnica de realce de contraste.....	117
<b>Tabela 7.3.</b> Melhores resultados para o <i>phantom</i> de Shepp-Logan reconstruído por POCS, onde * representa o uso de técnica de realce de contraste.....	120
<b>Tabela 7.4.</b> Resultados das medidas de avaliação da imagem ruidosa comparada com a imagem original para o <i>phantom</i> Homogêneo, reconstruídas tanto por FBP quanto por POCS. ....	125
<b>Tabela 7.5.</b> Melhores resultados para o <i>phantom</i> Homogêneo reconstruído por FBP, onde * representa o uso de técnica de realce de contraste.....	126
<b>Tabela 7.6.</b> Melhores resultados para o <i>phantom</i> Homogêneo reconstruído por POCS, onde * representa o uso de técnica de realce de contraste.....	131
<b>Tabela 7.7.</b> Resultados das medidas de avaliação da imagem ruidosa comparada com a imagem original para o <i>phantom</i> Simétrico, reconstruídas tanto por FBP quanto por POCS. ....	135
<b>Tabela 7.8.</b> Melhores resultados para o <i>phantom</i> Simétrico reconstruído por FBP, onde * representa o uso de técnica de realce de contraste.....	136
<b>Tabela 7.9.</b> Melhores resultados para o <i>phantom</i> Simétrico reconstruído por POCS, onde * representa o uso de técnica de realce de contraste.....	140
<b>Tabela 7.10.</b> Resultados das medidas de avaliação da imagem ruidosa comparada com a imagem original para o <i>phantom</i> Assimétrico, reconstruídas tanto por FBP quanto por POCS. ....	144
<b>Tabela 7.11.</b> Melhores resultados para o <i>phantom</i> Assimétrico reconstruído por FBP, onde * representa o uso de técnica de realce de contraste.....	146
<b>Tabela 7.12.</b> Melhores resultados para o <i>phantom</i> Assimétrico reconstruído por POCS, onde * representa o uso de técnica de realce de contraste.....	150

<b>Tabela 7.13.</b> Resultados das medidas de avaliação da imagem ruidosa comparada com a imagem original para a Madeira 1, reconstruídas tanto por FBP quanto por POCS.....	155
<b>Tabela 7.14.</b> Melhores resultados para Madeira 1 reconstruído por FBP, onde * representa o uso de técnica de realce de contraste. ....	156
<b>Tabela 7.15.</b> Melhores resultados para Madeira 1 reconstruído por POCS, onde * representa o uso de técnica de realce de contraste. ....	160
<b>Tabela 7.16.</b> Resultados das medidas de avaliação da imagem ruidosa comparada com a imagem original para a Madeira 2, reconstruídas tanto por FBP quanto por POCS.....	164
<b>Tabela 7.17.</b> Melhores resultados para a Madeira 2 reconstruído por FBP, onde * representa o uso de técnica de realce de contraste. ....	165
<b>Tabela 7.18.</b> Melhores resultados para a Madeira 2 reconstruído por POCS, onde * representa o uso de técnica de realce de contraste. ....	169

## LISTA DE ABREVIATURAS E SIGLAS

ALARA	As Low As Reasonably Achievable
ART	Algebraic Reconstruction Technique
CNPDIA	Centro Nacional de Pesquisa e Desenvolvimento de Instrumentação Agropecuária
CT	Computed Tomography
DC	Departamento de Computação
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
FBP	Filtered Backprojection
FFT	Fast Fourier Transform
FINAL	Método Final para a estimação do ruído
FORM	Método Formal (analítico) para a estimação do ruído
GIMLL	Generalized Isotropic Multi-Level Logistic
GIMLL-L1	Generalized Isotropic Multi-Level Logistic (L1 Norm)
GMRF	Gaussian Markov Random Field
GRF	Gibbs Random Field
GSA	Game Strategy Approach
ICM	Iterated Conditional Modes
ISNR	Improvement in Signal-To-Noise Ration
LMMSE	Linear Minimum Mean Square Error
MAN	Método Manual para a estimação do ruído
MAP	Maximum a Posteriori
MCMC	Markov Chain Monte Carlo

MÉD	Filtro da Média
MMSE	Minimum Mean Square Error
MPM	Maximizer of the Posterior Marginals
MPV	Máxima Pseudo-Verossimilhança
MRF	Markov Random Field
MSE	Mean Square Error
NLM	Non Local Means
POCS	Projections Onto Convex Sets
PRELIM	Método Preliminar para a estimação do ruído
PSF	Point Spread Function
PSNR	Peak Signal-To-Noise Ratio
SSIM	Structural Similarity Index
UFSCar	Universidade Federal de São Carlos
UIQ	Universal Image Quality Index

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>25</b>
	1.1 Motivação e Objetivos .....	27
	1.2 Uma visão geral da metodologia proposta.....	29
	1.3 Trabalhos Relacionados .....	31
	1.4 Principais contribuições deste trabalho.....	35
	1.5 Organização do Texto.....	35
<b>2</b>	<b>PRINCÍPIOS DE TOMOGRAFIA COMPUTADORIZADA .....</b>	<b>37</b>
	2.1 Evolução Histórica dos Tomógrafos .....	40
	2.2 Tomografia por Transmissão x Emissão .....	42
	2.3 Reconstrução.....	43
	2.3.1 Transformada de Radon.....	45
	2.3.2 Teorema do Corte de Fourier.....	46
	2.3.3 Retroprojeção Filtrada (FBP) .....	48
	2.3.4 Técnica de Reconstrução Algébrica (ART).....	52
	2.3.5 Projeções em Conjuntos Convexos (POCS).....	55
	2.4 Caracterização do Ruído em CT.....	57
	2.5 Considerações Finais .....	58
<b>3</b>	<b>FILTRAGEM EM TOMOGRAFIA COMPUTADORIZADA .....</b>	<b>60</b>
	3.1 Revisão de Técnicas de Filtragem Pré-Reconstrução: Domínio das Projeções ou do Sinograma.....	61
	3.2 Revisão de Técnicas de Filtragem Pós-Reconstrução: Domínio da Imagem .....	65
	3.3 Discussão e Considerações Finais .....	70
<b>4</b>	<b>ABORDAGEM MAP-MRF .....</b>	<b>71</b>
	4.1 Campos Aleatórios Markovianos (MRF) .....	72
	4.2 Modelos de Campos Aleatórios Markovianos.....	75

4.3	Estimação de Parâmetros por Máxima Pseudo-Verossimilhança para Potts, GIMLL e GIMLL-L1 .....	77
4.4	Estimação Bayesiana .....	78
4.5	Algoritmos de Otimização Combinatória .....	82
4.5.1	Iterated Conditional Modes (ICM) .....	82
4.5.2	Game Strategy Approach (GSA) .....	84
4.5.3	Maximizer of Posterior Marginals (MPM) .....	86
4.6	Considerações Finais .....	87
<b>5</b>	<b>FILTRO DE WIENER.....</b>	<b>89</b>
5.1	Filtro de Wiener Pontual.....	89
5.2	Filtros de Wiener com MRF Separável e MRF Isotrópico.....	90
5.3	Filtro de Wiener Generalizado (com Informação de Fisher).....	93
5.4	Considerações Finais .....	94
<b>6</b>	<b>FILTRAGEM DE RUÍDO EM CT NO DOMÍNIO DA IMAGEM UTILIZANDO UMA ABORDAGEM BAYESIANA CONTEXTUAL .....</b>	<b>96</b>
6.1	Modelagem e Método de Estimação do Ruído Dependente do Sinal.....	97
6.1.1	Non Local Means.....	98
6.1.2	Métodos para Estimação de Ruído Dependente de Sinal .....	102
6.1.2.1	Método Preliminar .....	102
6.1.2.2	Método Final.....	105
6.1.2.3	Método Formal .....	106
6.2	Metodologia .....	108
6.3	Avaliação dos Resultados .....	110
6.4	Resultados Esperados e considerações finais .....	112
<b>7</b>	<b>RESULTADOS PRINCIPAIS DE FILTRAGEM DE RUÍDO EM IMAGENS DE CT.....</b>	<b>113</b>
7.1	Imagem Simulada: <i>Phantom</i> de Shepp-Logan .....	115
7.1.1	FBP .....	116

7.1.2 POCS .....	120
7.2 <i>Phantom</i> Homogêneo .....	124
7.2.1 FBP .....	125
7.2.2 POCS .....	130
7.3 <i>Phantom</i> Simétrico .....	134
7.3.1 FBP .....	135
7.3.2 POCS .....	139
7.4 <i>Phantom</i> Assimétrico .....	144
7.4.1 FBP .....	144
7.4.2 POCS .....	149
7.5 Madeira 1 .....	154
7.5.1 FBP .....	155
7.5.2 POCS .....	159
7.6 Madeira 2 .....	164
7.6.1 FBP .....	164
7.6.2 POCS .....	168
7.7 <i>Considerações Finais</i> .....	172
<b>8 CONCLUSÕES, CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS .....</b>	<b>173</b>
8.1 Artigos Publicados e Submetidos .....	176
<b>REFERÊNCIAS .....</b>	<b>178</b>
<b>APÊNDICE A – Geração das Imagens Sintéticas .....</b>	<b>189</b>
<b>APÊNDICE B – Testes de Ruído Dependente do Sinal .....</b>	<b>194</b>
<b>APÊNDICE C – Resultados Comparativos dos Métodos de Estimação do Ruído Dependente do Sinal .....</b>	<b>200</b>
<b>APÊNDICE D – Resultados de Filtragem das Imagens Simuladas.....</b>	<b>207</b>
<b>APÊNDICE E – Estudo dos parâmetros de limiar e número de bins dos métodos Preliminar e Final.....</b>	<b>228</b>
<b>APÊNDICE F – Estudo da Convergência do ICM e GSA e outras questões .....</b>	<b>239</b>

# 1 INTRODUÇÃO

A tecnologia de Tomografia Computadorizada (CT) tem revolucionado e permitido novas aplicações desde a construção do primeiro tomógrafo de CT na década de 1970, pois imagens de estruturas internas de corpos ou objetos podem ser capturadas de forma não destrutiva e não invasiva. Os equipamentos de CT conseguem produzir imagens com qualidade visual superior aos equipamentos convencionais de raios X, além de capturar elementos adicionais que para o último não são possíveis de se identificar, já que CT consegue distinguir diferenças de densidades de cerca de 0,5% contra aproximadamente 5% da radiografia convencional (Tsui, 1980; Kumar, 2011). Assim, esta tecnologia possibilitou a realização de novos diagnósticos e de análises mais precisas para as tomadas de decisão em diversas aplicações nas mais variadas áreas do conhecimento como Medicina, Indústria e Agricultura.

Na Medicina, por exemplo, CT é utilizado para o diagnóstico de diversos tipos de câncer, como o de pulmão, onde imagens de tórax podem ser produzidas e depois processadas para a detecção de nódulos e extração de informações como forma, intensidade e localização que permitiriam inclusive a classificação de um nódulo como sendo provavelmente maligno ou benigno (Mughal e Ikram, 2004).

Na indústria, por sua vez, a tomografia computadorizada é muito aplicada com a finalidade de inspecionar peças (Schneberk e Shashishekar, 2008), como pás de turbinas (Bronnikov e Killian, 1999), na busca por defeitos (trincas, por exemplo) e também na análise de poros e morfologia de objetos (Hofmann, Flisch *et al.*, 2004).

Já na agricultura podemos destacar o trabalho realizado pelo Centro Nacional de Pesquisa e Desenvolvimento de Instrumentação Agropecuária (CNPDia) <sup>1</sup> da Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), um importante centro de pesquisa brasileiro nesta área que fica sediado na cidade de São Carlos/SP, especialmente pelo desenvolvimento de novos tomógrafos (Cruvinel, 1987; Naime, 1994; Macedo, 1997; Naime, 2001) e aplicações. Algumas das aplicações de CT em suas pesquisas incluem o cálculo de densidades de madeira como parâmetro para a avaliação de sua qualidade (Vaz, Pereira *et al.*, 1996), estudo de solos para manejo adequado de solos e culturas (Naime, 1994; Vaz, Crestana *et al.*, 1996; Macedo,

---

<sup>1</sup> <http://www.cnpdia.embrapa.br>

1997; Naime, 2001; Pedrotti, Pauletto *et al.*, 2003; Fernandes, Reis *et al.*, 2005), visualização de estruturas internas de árvores que pode ser usada para identificar pragas ou mesmo selecionar matrizes (Naime, 1994; Macedo, 1997; Ereno, 2006).

No processo de aquisição de imagens de CT, o corpo a ser imageado é exposto aos raios emitidos pelo tomógrafo. Estes raios, ao atravessarem o corpo, têm parte de sua energia atenuada e a energia restante é detectada pelo tomógrafo. O conjunto de energias detectadas para um feixe de raios, emitido em um determinado ângulo ao redor do corpo, define uma projeção deste. Por sua vez, o conjunto de projeções obtidas pode ser processado por um algoritmo de reconstrução e assim produzir uma imagem bidimensional de CT, que corresponde ao mapa da atenuação sofrida pelos raios do CT ao atravessar determinada parte (fatia) do corpo.

Assim, apesar dos benefícios desta tecnologia, sempre houve uma grande preocupação com os níveis de radiação necessários para obter uma imagem de qualidade visual adequada sem que haja uma exposição excessiva do paciente ou objeto alvo à radiação. Em Medicina, por exemplo, a Comissão Internacional de Proteção Radiológica (ICRP) definiu alguns princípios básicos que devem ser seguidos para o uso adequado e definição das doses de radiação. Um destes princípios é conhecido como princípio ALARA (*As Low As Reasonably Achievable*) que determina que a exposição à radiação deve ser mantida tão baixa quanto razoavelmente exequível (Icrp, 1977). Na área industrial, por sua vez, um dos grandes interesses é na redução de custos devido à redução do tempo de aquisição das imagens.

Desta forma, diversos estudos foram propostos a fim de encontrar um balanço adequado entre qualidade visual e dose de radiação. Porém, mesmo com estes estudos, trabalhos recentes têm demonstrado que há uma necessidade de se reduzir ainda mais o nível de radiação. Em um destes estudos foram apresentados dados que confirmam que a utilização de tomografia computadorizada pode aumentar o risco de câncer consideravelmente, devido ao aumento no número de exames (Savage, 2010).

Porém, diminuir a quantidade de radiação para a aquisição das imagens de CT implica na redução da quantidade de energia emitida (fótons) que atingem o paciente e, conseqüentemente, o receptor de imagem (radiação residual). Isto caracteriza a baixa contagem de fótons. Com baixa taxa de contagem, a distribuição dos dados de projeção, condicionada à taxa do sinal, tende a uma distribuição de Poisson. Estas projeções são, portanto, corrompidas por ruído Poisson.

Por outro lado, o processo de reconstrução das imagens, quer utilizando técnicas no domínio da frequência, como filtragem-retroprojeção, quer utilizando técnicas no domínio do espaço, como os métodos algébricos, envolvem uma combinação linear de um grande número de variáveis aleatórias (pontos em cada uma das projeções). Deste modo, invocando o Teorema Central do Limite, é possível afirmar que, no domínio do espaço, os pixels da imagem reconstruída devem estar sujeitos a ruído gaussiano. Além disso, foi verificado empiricamente, analisando as variâncias de áreas homogêneas, que este ruído continua sendo dependente do sinal, o que é uma suposição razoável.

Imagens reconstruídas a partir de projeções ruidosas, deste modo, possuem baixa qualidade visual. Assim, se faz necessário o uso de técnicas de filtragem do sinal ruidoso antes ou depois da reconstrução a fim de se reduzir o ruído e obter uma melhora na qualidade visual da imagem, de forma que, ao diminuir a dose de radiação, ainda possamos produzir uma imagem de qualidade adequada para a sua análise.

Portanto, o problema investigado neste trabalho consiste na filtragem do ruído gaussiano dos pixels da imagem reconstruída de CT. No restante deste capítulo, são apresentadas as motivações para esse trabalho, os objetivos a serem atingidos, uma visão geral da metodologia proposta e desenvolvida, alguns trabalhos relacionados que foram desenvolvidos, especialmente, por alunos do Programa de Pós Graduação em Ciência da Computação da UFSCar, as principais contribuições deste trabalho e a organização deste documento.

## **1.1 Motivação e Objetivos**

Com o aumento da utilização de tomografia computadorizada como meio para a aquisição de imagens diagnósticas, estima-se que, de 1980 até 2007, o número de equipamentos de CT avançou de três para setenta milhões. Como um efeito estocástico da radiação ionizante, cuja probabilidade de ocorrência é uma função da dose de radiação (mas não a sua severidade) e está relacionado com a mutação celular (Hall, 1991; Umisedo, 2007), calcula-se que isto pode ocasionar cerca de 29 mil novos casos de câncer a cada ano, onde aproximadamente 50% destes casos levam o paciente a óbito (Savage, 2010). Além disso, têm-se outras motivações como a redução de custos e a tentativa de manter a exposição o menor possível (princípio ALARA), como apontado anteriormente. Desta forma, há um grande interesse por parte

dos pesquisadores em criar novos equipamentos ou mesmo meios que permitam a redução da quantidade de radiação necessária para a aquisição das imagens.

Entretanto, ao reduzir a quantidade de radiação temos um problema de baixa contagem de fótons, o que implica em projeções ruidosas. Neste caso, invocando o Teorema Central do Limite, as imagens reconstruídas têm a sua qualidade visual prejudicada por ruído aproximadamente Gaussiano e faz-se necessária a utilização de técnicas que atenuem este ruído e seus efeitos nas imagens reconstruídas. Considerando informação contextual de um pixel (a informação contida nos seus pixels vizinhos e nas suas relações), podemos obter informações adicionais sobre o sinal, permitindo desta forma uma melhor estimativa do mesmo.

Dessa forma, o principal objetivo deste trabalho consiste em utilizar uma abordagem Bayesiana contextual para filtrar o ruído em imagens tomográficas com baixa taxa de contagem, inclusive investigando formas para estimar e adicionar na formulação deste problema de filtragem a questão do ruído dependente do sinal nas imagens reconstruídas. Para a validação dos resultados foram utilizadas imagens de CT geradas por um minitomógrafo de mesa (veja a Figura 1.1) produzido pelo CNPDIA-EMBRAPA, com enfoque principal em aplicações de Ciência dos Solos (Cruvinel, 1987), além de imagens geradas por simulações.



**Figura 1.1.** Minitomógrafo de mesa (Cruvinel, 1987). Retirada de (Cnpdia-Embrapa, 2011).

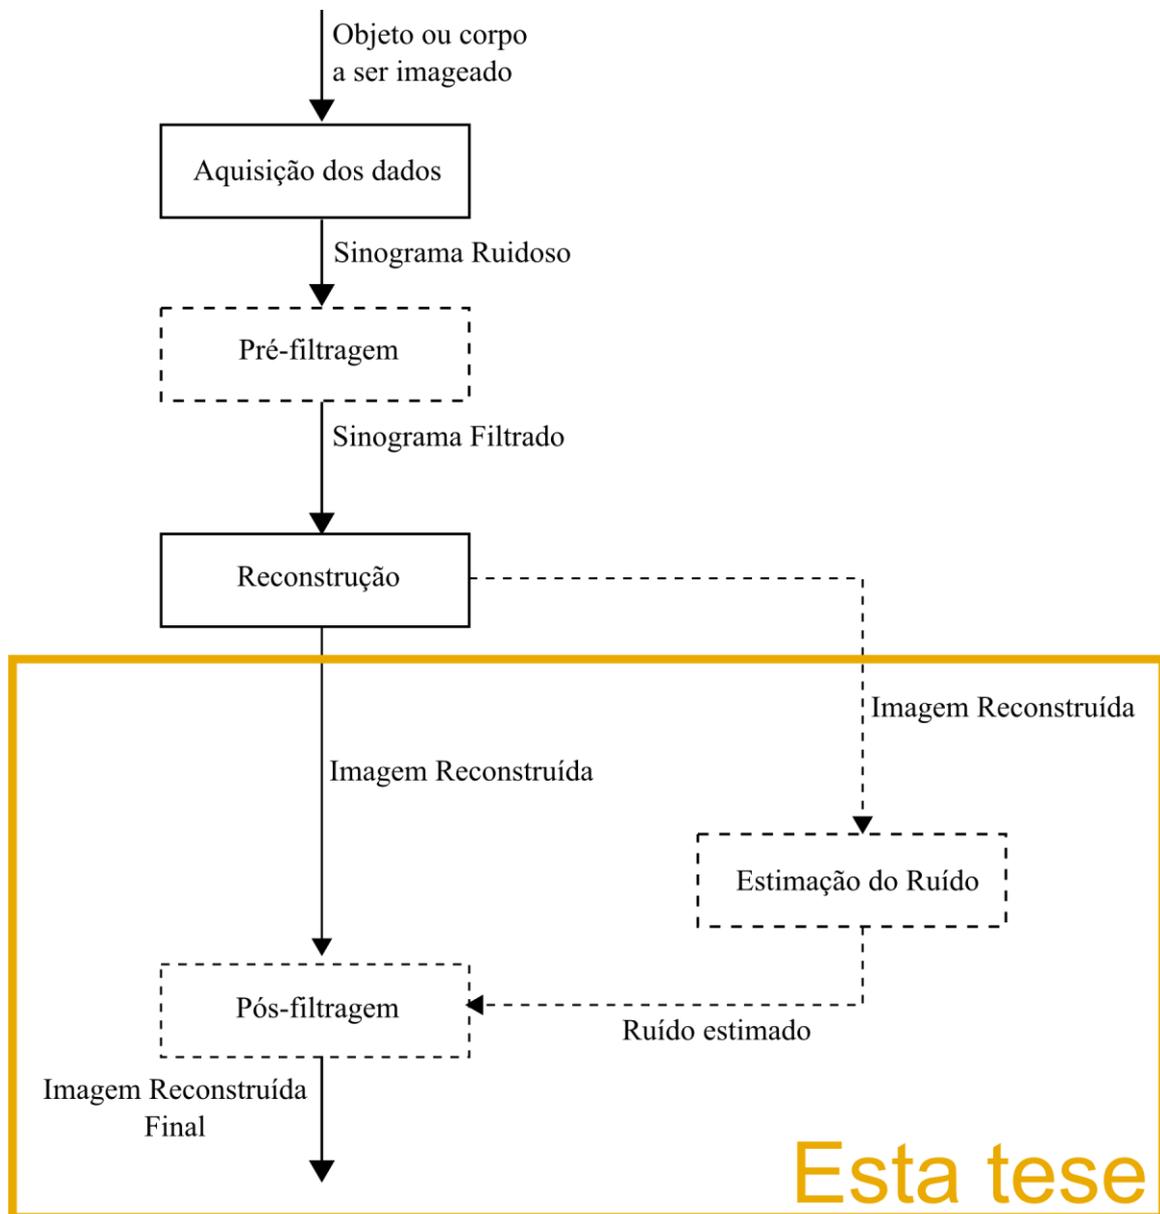
## 1.2 Uma visão geral da metodologia proposta

Basicamente, a metodologia proposta nesta tese para a filtragem de imagens de tomografia computadorizada está representada no diagrama de blocos da Figura 1.2, dentro do sistema de imageamento de CT. Dada uma imagem tomográfica reconstruída por Retroprojeção Filtrada (FBP) (Ramachandran e Lakshminarayanan, 1971; Logan e Shepp, 1975) ou *Projections Onto Convex Sets* (POCS) (Salina, 2007) como entrada, o objetivo é reduzir o ruído presente nestas imagens. Para isto, inicialmente, uma estimação do ruído (ou mais especificamente, da variância do ruído) presente na imagem de entrada deve ser realizada, de acordo com um modelo da formação da imagem ruidosa. Considerando um modelo aditivo representando a formação da imagem ruidosa, um ruído pode ser estacionário ou não estacionário se suas estatísticas forem invariantes ou variantes à posição (Papoulis, 1991), respectivamente. No caso de CT, resultados apresentados nesta tese indicam que o ruído é dependente do sinal, o que implicaria em variâncias definidas como uma função do sinal original. Assim, assumimos um modelo de ruído Gaussiano, aditivo, de média zero e dependente do sinal. Entretanto, vale ressaltar que foram considerados nos testes ruído dependente e independente do sinal. Aqui foram apresentados três novos métodos de estimação do ruído para CT, que consideram a dependência do sinal.

Após a estimação de um mapa do ruído contendo as variâncias em cada ponto, alguns métodos de filtragem utilizam esta informação para realizar a filtragem das imagens. Basicamente, os métodos propostos nesta tese para esta finalidade utilizam ainda a informação contextual dos pixels por meio de Campos Aleatórios Markovianos (MRF) (Hammersley e Clifford, 1971; Besag, 1974; Geman e Geman, 1984; Besag, 1986; Won e Gray, 2004; Li, 2009) e uma estimativa da imagem livre de ruído sendo obtida por um simples filtro da média ou pelo método estado da arte em filtragem de ruído Non Local Means (Buades, Coll *et al.*, 2005; Deledalle, 2011).

Os métodos contextuais utilizados podem ser divididos em duas abordagens, baseadas em filtros de Wiener (Kuan, Sawchuk *et al.*, 1985) ou métodos iterativos de otimização combinatória. Na primeira abordagem estão os clássicos filtros de Wiener com MRF Separável e Isotrópico (Kay, 1993; Mascarenhas, Banon *et al.*, 1996; Zaniboni e Mascarenhas, 1998; Zhang, Nosratinia *et al.*, 2000; Wang, Fu-Cheng *et al.*, 2005), além do recente filtro de Wiener Generalizado (baseado em Informação de Fisher) (Levada e Mascarenhas, 2010). Além das variâncias do ruído, estes métodos utilizam informações de média local da imagem ruidosa.

sa e variâncias e médias locais da imagem livre de ruído. A dependência do sinal nestes métodos foi considerada pelo uso das variâncias do ruído diretamente.



**Figura 1.2.** Diagrama de blocos de imageamento em CT. Os processos marcados por linha tracejada são opcionais dentro do processo de imageamento em CT. Entretanto, a parte destacada engloba os processos considerados nesta tese e corresponde de forma genérica à metodologia utilizada.

Já na segunda abordagem temos os tradicionais algoritmos *Iterated Conditional Modes* (ICM) (Besag, 1986; Dubes e Jain, 1993; Won e Gray, 2004), *Game Strategy Approach* (GSA) (Yu e Berthod, 1995; Berthod, Kato *et al.*, 1996) e *Maximizer of Posterior Marginals* (MPM) (Dubes e Jain, 1993; Won e Gray, 2004). Nesta última foram considerados os seguin-

tes modelos a priori Potts (Geman e Geman, 1984), *Generalized Isotropic Multi-Level Logistic* (GIMLL) (Martins, Levada *et al.*, 2009) e uma variação que utiliza a norma L1 (GIMLL-L1) e *Gaussian Markov Random Fields* (GMRF) (Li, 2009). Para a verossimilhança, que corresponde ao modelo de formação da imagem, foi utilizado o modelo Gaussiano, sendo que a variância do ruído foi considerada na definição do parâmetro da variância da Gaussiana.

Os diversos métodos propostos foram avaliados com a sua aplicação sobre imagens reais e simuladas de CT. O processo de geração das imagens simuladas está descrito no Apêndice A. Por fim, o restante deste documento está organizado de forma a descrever as teorias que embasam esta tese e a metodologia utilizada.

### 1.3 Trabalhos Relacionados

Nesta seção, serão apresentados alguns trabalhos relacionados a esta tese, tendo a maioria destes sido desenvolvidos por alunos do Programa de Pós-Graduação da UFSCar. Basicamente, podemos dividir estes trabalhos de acordo com o problema principal que atacam. Assim, teremos principalmente trabalhos que investigaram os problemas de reconstrução tomográfica, restauração e filtragem (pré e pós-reconstrução), além de outros que lidaram com classificação e visualização 3-D em imagens de CT. Entretanto, os trabalhos com filtragem não serão revisados agora, mas no Capítulo 3, onde teremos seções dedicadas a uma revisão mais completa de filtragem em CT, que é o tema principal desta tese.

Entre os trabalhos com enfoque na reconstrução tomográfica, podemos citar as dissertações de mestrado de Gilmar C. Ribeiro (Ribeiro, 1994), Edson R. Minatel (Minatel, 1997), Fernando V. Salina (Salina, 2001) e a na dissertação de mestrado (Pereira, 2001) e tese de doutorado (Pereira, 2007) de Maurício F. L. Pereira.

Na dissertação de Gilmar Ribeiro (Ribeiro, 1994) foi proposta uma versão modificada da Técnica de Reconstrução Algébrica (ART) por considerar um fator de correção, que corresponde à área de que cada raio intercepta na matriz de reconstrução, ponderando as suas respectivas medidas de projeção a cada iteração. Este versão modificada foi chamada ARTAM e foi utilizada para a reconstrução 2-D de cada fatia. Por fim, para se obter uma reconstrução 3D, foi utilizada a interpolação Spline das fatias intermediárias. O método proposto apresentou melhor desempenho para reconstrução de objetos assimétricos se comparado à Retroprojeção.

Edson R. Minatel (Minatel, 1997), por sua vez, propõe uma plataforma completa de reconstrução e visualização 3-D. Neste sistema, as projeções podem ser filtradas por *shrinkage* em Wavelets Haar 1-D ou Hamming 1-D ou ainda por uma técnica de restauração. Os dados de projeção filtrados são reconstruídos por Retroprojeção, obtendo assim uma imagem 2D. Por sua vez, esta imagem 2-D pode ainda ser filtrada por uma nova técnica adaptativa baseada em *shrinkage* de Wavelets Haar 2-D, podendo ser visualizadas em níveis de cinza, pseudocores ou limiarizada. Por fim, interpolação baseada em funções B-Wavelets pode ser usada para a reconstrução 3-D e uma série de operações como rotação, iluminação, escala compõem o ferramental da visualização 3-D. Este sistema mostrou-se adequado para estudos e análises em Ciência dos Solos.

Utilizando-se do sistema proposto por Minatel (Minatel, 1997), M. F. L. Pereira propôs em sua dissertação de mestrado (Pereira, 2001), o uso de plataforma DSP para a paralelização de algoritmos utilizados para a reconstrução e visualização 3D tomográfica, tais como as técnicas de filtragem Wavelet 1-D e 2-D, a reconstrução 2-D por Wavelets e a reconstrução 3-D por interpolação baseada em B-Wavelets. Em geral, houve grande melhora no desempenho dos métodos, especialmente para a reconstrução 3-D.

Na dissertação de Fernando Salina (Salina, 2001), quatro algoritmos baseados em POCS (*Projection Onto Convex Sets*) foram implementados para a reconstrução a partir de projeções tomográficas e comparados com relação à robustez ao ruído nas projeções e ângulos limitados. Os métodos implementados foram o ART (*Algebraic Reconstruction Technique*), o SIRT (*Simultaneous Iterative Reconstructive Technique*), e as versões paralela e sequencial do POCS. Tanto na presença de ruído quanto de ângulos limitados, o POCS paralelo apresentou melhores resultados na reconstrução, especialmente ao considerar o uso de restrições sobre as soluções.

Por sua vez, Maurício Pereira propôs em sua tese (Pereira, 2007), um modelo para reconstrução 3-D de objetos a partir de fatias reconstruídas de projeções de CT. Inicialmente, antes da reconstrução da imagem bidimensional, as projeções são filtradas pelo filtro de Wiener no domínio de Anscombe. Neste domínio, o ruído torna-se aproximadamente independente do sinal. Para reconstruir as projeções e assim, obter uma imagem 2-D, foi utilizado o algoritmo de Retroprojeção Filtrada. Já para a reconstrução 3-D foi utilizado um algoritmo baseado em B-Wavelets. Além disso, outras contribuições do trabalho em questão foram o uso de

versões paralelas destes algoritmos e aplicação de visualização para permitir uma análise adequada dos objetos reconstruídos, especialmente em Ciência dos Solos.

Outro trabalho relevante, especialmente, para a análise 3-D em Ciência dos Solos foi desenvolvido na dissertação de mestrado de Leonardo C. Botega (Botega, 2008). Sua principal contribuição foi o desenvolvimento de um ambiente de Realidade Virtual para a manipulação e visualização dos objetos de estudo.

Para a restauração de imagens, temos as dissertações de mestrado de Luis F. Granato (Granato, 1998), Aparecida C. Guerra (Guerra, 1998) e Vital C. Ferreira (Ferreira, 2000).

No trabalho de Luis Granato (Granato, 1998) é proposta uma técnica para correção do mapa de coeficientes de atenuação linear em múltiplas energias, cujo fator de correção é definido em termos da ponderação dos desvios (entre as médias locais e o valor do pixel) pelos coeficientes de atenuação de massa, especialmente para a redução de ruído. Além disso, propõe-se o uso de equalização, hiperbolização ou hiperbolização quadrática do histograma para o realce de contraste.

Na dissertação de Aparecida Guerra (Guerra, 1998) foi proposto um método de restauração das imagens reconstruídas considerando borramento e ruído. Para isso, inicialmente foi feita uma análise da resposta impulsiva que caracteriza a imagem reconstruída por FBP, onde se identificou que a função de Hankel (ou sua aproximação separável dada pela função Sinc) é um modelo adequado. Em seguida, aplicou-se o filtro Inverso com regularização (para resolver o malcondicionamento do filtro Inverso), adotando-se a regularização do problema de mínimos quadrados com restrição quadrática de igualdade. Neste método, um fator correspondente a um multiplicador de Lagrange deve ser escolhido, tendo sido feito por uma das seguintes formas: visual, teste de comparação e teste do Chi-Quadrado. O método foi aplicado em imagens reais e sintéticas, tendo sido eficiente na não amplificação do ruído.

Por sua vez, Vital Ferreira (Ferreira, 2000) propôs o uso de métodos de restauração iterativos como Landweber e suas derivações e POCS, incorporando restrições (como positividade, limitação de amplitude, suporte finito) no processo iterativo a fim de atenuar ruído e borramento em imagens reconstruídas por Retroprojeção Filtrada. A identificação da Função de Espalhamento Pontual (PSF) foi realizada no domínio do espaço usando uma imagem de uma fonte pontual imersa em uma região plana. Os métodos propostos foram comparados aos métodos clássicos em restauração como filtro Inverso, filtro de Wiener e filtro por restrição de

mínimos quadrados. Resultados mostraram que os métodos iterativos são mais robustos do que os métodos diretos, além do Landweber convergir mais rápido que o POCS Paralelo.

Para a classificação de imagens temos as dissertações de Murillo R. P. Homem (Homem, 1998), Moacir P. Ponti Jr. (Ponti Jr, 2004) e Fabricio A. Breve (Breve, 2006) e a tese de doutorado de Alexandre L. M. Levada (Levada, 2010). Todos estes trabalhos realizam classificação de imagens multiespectrais de CT adquiridas com múltiplas energias. Entretanto, vale ressaltar que no trabalho de Alexandre Levada (Levada, 2010), o foco de aplicação foi em Imagens de Ressonância Magnética (MRI). Além disso, nos três últimos foram utilizados métodos de combinação de classificadores para obter a decisão final de classificação. É importante ressaltar que combinando os resultados dos classificadores individuais, em geral, um desempenho superior é atingido, sendo inclusive mais robusto à presença de ruído.

Na dissertação de Murillo Homem (Homem, 1998) foram utilizados classificadores pontuais de Máxima Verossimilhança (MaxVer) e K-Médias, além da classificação contextual por *Iterated Conditional Modes* (ICM) com modelo de Potts. Eles foram aplicados sobre imagens reconstruídas das projeções por Retroprojeção Filtrada utilizando ou não um filtro MAP (Maximum a Posterior) pontual com diferentes densidades a priori Gaussiana, Gama, Beta e Log-Normal para a filtragem das projeções, proposto no trabalho (Santos, 1996), apresentado no Capítulo 3. Ainda, foram utilizadas a Transformação de Karhunen-Lòeve e a distância de Jeffreys-Matusita para realizar extração de atributos a fim de analisar as diferentes bandas correspondentes às diferentes energias na aquisição de imagem CT. Resultados mostraram que a classificação contextual foi superior aos métodos pontuais e que a classificação sobre imagens reconstruídas a partir das projeções filtradas por MAP com densidade Beta apresentou os melhores resultados.

No trabalho de Moacir Ponti Jr. (Ponti Jr, 2004) foram utilizados os classificadores individuais Parzen, K-Vizinhos Mais Próximos, Logístico e Bayesiano Linear, cujos resultados foram combinados por meio de métodos não treináveis como a Votação por Maioria, Regra da Soma, Regra do Produto, Regra da Mediana, Regra do Máximo e Regra do Mínimo.

No trabalho de Fabrício Breve (Breve, 2006) foram analisados diferentes classificadores individuais e métodos de combinação. Aqui, os classificadores individuais utilizados foram o *Perceptron* Multicamadas e Redes de Função de Base Radial, enquanto os métodos de combinação necessitavam de uma etapa de treinamento como é o caso do *Bagging*, *Decision Templates* e Dempster-Shafer.

Por fim, Alexandre (Levada, 2010) propõe um sistema de classificação contextual utilizando uma abordagem MAP-MRF (*Maximum a Posteriori-Markov Random Fields*), cujo conhecimento a priori é definido por um Modelo de Potts e a verossimilhança é modelada por GMRF (*Gaussian Markov Random Fields*). Essa abordagem é utilizada nos algoritmos de otimização combinatória com diferentes inicializações dadas por diferentes classificadores individuais. Os mapas de rótulos obtidos após a otimização combinatória são combinados pelos mesmos métodos usados em (Ponti Jr, 2004) para gerar uma decisão final. Finalmente, vale lembrar novamente que este trabalho foi proposto para classificação em MRI e não para Tomografia. Entretanto, alguns resultados aplicados em imagens de CT multiespectrais adquiridas com múltiplas energias também foram obtidos.

#### **1.4 Principais contribuições deste trabalho**

Nesta Seção são apontadas as principais contribuições de trabalho que visam aumentar o desempenho da filtragem de ruído ou melhorar caracterizar a imagem reconstruída de CT. Podemos destacar:

- 1) Pós filtragem contextual de CT, como três métodos baseados em Wiener (Generalizado e com MRF Separável e Isotrópico) e outros três de otimização combinatória (ICM, GSA e MPM);
- 2) A melhor caracterização do ruído na imagem reconstruída de CT, considerando-o como aditivo, Gaussiano, de média zero e dependente do sinal, com comprovação empírica desta dependência;
- 3) Proposta de três novos métodos de estimação do ruído;
- 4) Uso de Non Local Means para obter a estimativa da imagem livre de ruído e sua inserção nos métodos baseados em Wiener;
- 5) Adaptação dos métodos de filtragem, especialmente os iterativos, para considerarem o uso de ruído dependente do sinal.

#### **1.5 Organização do Texto**

O restante deste documento está dividido em oito capítulos e seis apêndices de forma a permitir o entendimento dos Princípios da Tomografia Computadorizada e seus problemas

envolvidos, revisar os métodos propostos na literatura para a Filtragem de Ruído em CT, além de apresentar a Teoria de Campos Aleatórios Markovianos, o Filtro de Wiener, a abordagem sendo proposta, os experimentos e estudos realizados e os resultados e conclusões obtidas.

No Capítulo 2, que aborda o Princípio da Tomografia Computadorizada, serão apresentados um histórico desta tecnologia, seus conceitos básicos, alguns algoritmos de reconstrução, além de caracterizar com maiores detalhes o ruído tanto nas projeções quanto na imagem reconstruída.

No Capítulo 3, dedicado ao problema da filtragem em CT, teremos uma breve revisão de soluções já propostas em filtragem de ruído de CT, tanto para filtragem antes quanto depois da reconstrução.

No Capítulo 4, a Teoria de Campos Aleatórios Markovianos é apresentada, considerando seus conceitos básicos, modelos *a priori* e algoritmos de otimização combinatória.

O Capítulo 5 aborda o Filtro de Wiener, discorrendo sobre seus princípios e apresentando a derivação de versões pontuais e contextuais do mesmo. Ainda, formas de se considerar ruído dependente do sinal ou não estacionários nestes filtros são identificadas.

No Capítulo 6, toda a metodologia é esmiuçada, apresentando e discutindo as propostas e contribuições deste trabalho.

No Capítulo 7 temos os resultados de filtragem e suas discussões, especialmente para a filtragem aplicada nas imagens reais a fim de avaliação da proposta. Complementando este Capítulo, temos os Apêndices A a F que tratam da descrição da geração das imagens simuladas, do teste empírico de dependência do sinal, da comparação dos métodos propostos de estimação do ruído, dos resultados para as imagens simuladas, do estudo dos parâmetros dos métodos propostos de estimação do ruído e estudo das convergência dos métodos iterativos, respectivamente.

Finalmente, no Capítulo 8 são apresentadas as conclusões obtidas neste trabalho, sugestões de trabalhos futuros para a continuidade deste trabalho e a indicação das publicações decorrentes desta tese.

## 2 PRINCÍPIOS DE TOMOGRAFIA COMPUTADORIZADA

Tomografia é uma palavra de origem grega (*tomo* = corte, fatia + *grafia* = escrita, registro) que denomina o processo de representação de um corpo tridimensional por seus cortes bidimensionais em dada direção (plano). No interesse particular deste trabalho, ela consiste em métodos que geram uma imagem bidimensional do interior de um corpo, onde um pixel corresponde à atenuação sofrida por raios num dado ponto de um plano cruzando este corpo. Originalmente, raios X foram utilizados, mas atualmente diversos tipos de radioisótopos são empregados em CT (Ribeiro, 2010).

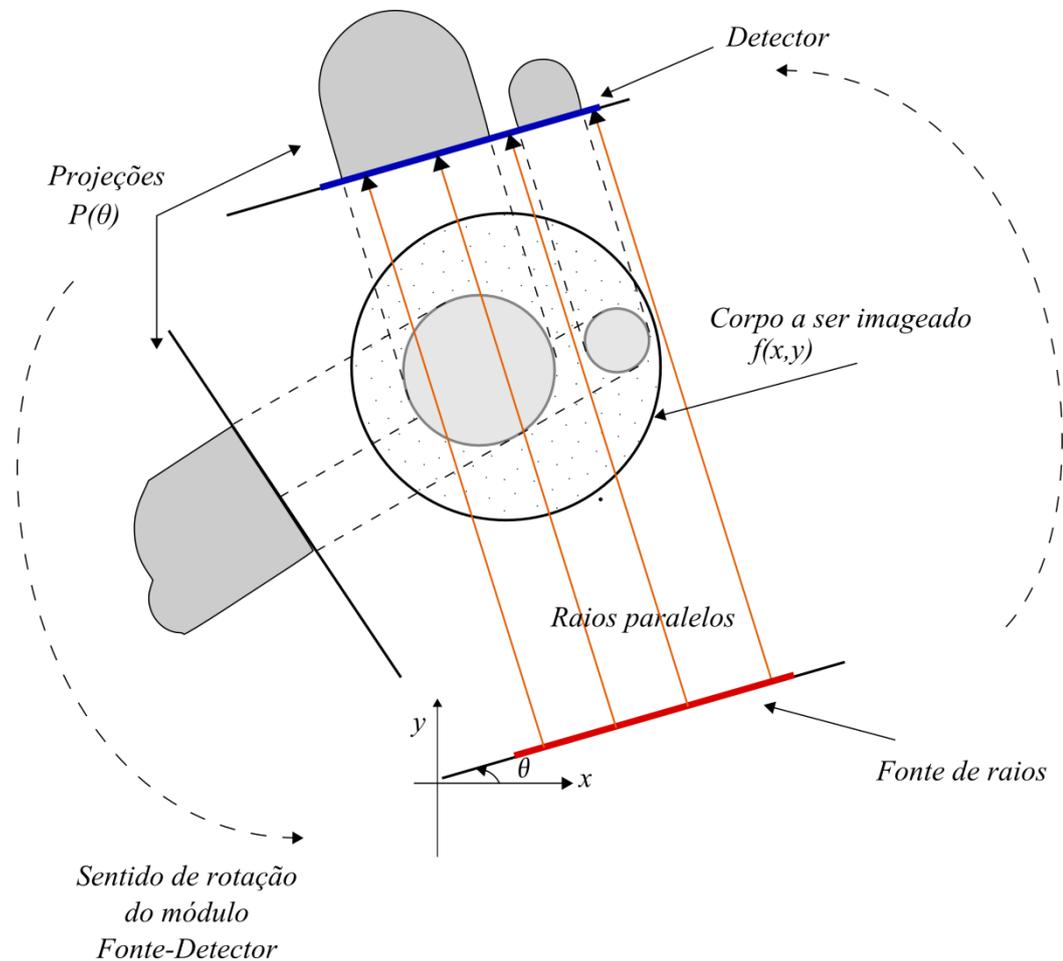
Para um maior entendimento, o processo de aquisição de imagens de Tomografia Computadorizada por Transmissão será detalhado agora. Considere um módulo onde temos uma fonte emissora de feixes de raios (raios X e raios  $\gamma$ , por exemplo) e um detector de radiação residual (aquela que resta após atravessar o corpo), que são mantidos alinhados, em lados opostos do corpo  $f(x, y, z)$  a ser imageado. Os feixes de raios paralelos são emitidos com intensidade  $I_0$  em um determinado ângulo  $\theta$  ao redor do objeto com a direção  $z$  fixa e estes são colimados, reduzindo o seu espalhamento e definindo um plano vertical tão fino quanto o feixe, onde cada linha  $l_i$  corresponde a um raio (Cruvinel, 1987; Pereira, 2007).

Quando atravessa o corpo, os raios podem ser atenuados, a radiação residual com intensidade  $I$  de uma linha  $l_i$  é capturada pelo detector e indica a soma da atenuação sofrida pelo raio nos pontos sobre esta linha (integral de linha). O conjunto de valores de intensidade de  $I_0$  e  $I$  para um feixe definem uma projeção  $P(\theta)$  do corte do objeto naquela direção  $\theta$  (Kak e Slaney, 1988; Fessler, 2000; Rangayyan, 2005; Buzug, 2008).

O problema em tomografia, portanto, consiste em como obter o corte bidimensional na direção  $z$  a partir de suas projeções, processo chamado de reconstrução. Para gerarmos uma imagem tridimensional basta um conjunto de cortes variando  $z$ . A Figura 2.1 resume o processo de aquisição.

Para solucionar esta questão, o primeiro trabalho publicado a resolver o problema de obter uma função a partir de seus valores integrais de linha foi realizado pelo matemático aus-

tríaco Johann Radon no ano de 1917. Seu artigo original foi escrito em alemão (Radon, 1917), mas uma tradução para o inglês pode ser encontrada em (Radon, 1986).



**Figura 2.1.** Tomografia de Transmissão. Baseada em (Kak e Slaney, 1988; Pereira, 2007).

Entretanto, desconhecendo o trabalho de Radon, o físico sul-africano (naturalizado americano) Allan MacLeod Cormack, que era professor do Departamento de Física da *University of Cape Town* em 1956, foi chamado para supervisionar durante alguns meses a administração de radioisótopos radioativos no *Groote Schuur Hospital* (também em *Cape Town*). Em certo dia neste hospital, um radiologista apontou a necessidade de resolver um problema de quantificar os coeficientes de absorção (atenuação) de raios X em meios não homogêneos (onde o coeficiente de absorção varia no espaço) para ajudar pacientes de câncer. Foi quando ele começou a investigar este problema tendo concluído a pesquisa quando já havia se transferido para os Estados Unidos. No ano de 1963, ele publicou o trabalho (Cormack, 1963) com a sua solução proposta, que correspondia ao método da retroprojeção, que considerava um nú-

mero finito de projeções (Henderson, 1979; Cruvinel, 1987; Pereira, 2007; Ribeiro, 2010; Cierniak, 2011).

Em 1967, Godfrey Newbold Hounsfield, um engenheiro que trabalhava nos laboratórios da EMI Ltda. e pesquisando independentemente de Cormack, incluiu um novo elemento para realizar os cálculos custosos de reconstrução: o computador. Após alguns anos validando suas ideias, no ano de 1973, ele lançou o primeiro tomógrafo computadorizado comercial (Cierniak, 2011). Os trabalhos de Cormack e Hounsfield foram tão importantes, que em 1979 foram laureados com o prêmio Nobel de Medicina (Henderson, 1979; Cierniak, 2011).

Antes do surgimento dos primeiros tomógrafos de CT, a radiografia convencional era o principal método utilizado para a realização de diagnósticos clínicos por imagem. Nela, o processo de aquisição de imagem utiliza um filme radiográfico, onde a radiação residual fica impressionada. Apesar de utilizar fonte de radiação também contemplada em CT, na radiografia convencional não conseguimos visualizar diferença entre tecidos sobrepostos, ao contrário do CT. Vale ressaltar que para esta finalidade, planigrafia era o método utilizado antes do surgimento de CT (Barreno, 1998; Val, 2006). Além desta grande vantagem de CT, temos também a possibilidade de se obter uma imagem tridimensional e também uma maior resolução de contraste (Bushong, 2000).

Assim, CT encontrou diversas aplicações e tornou-se de vital importância para muitas áreas, especialmente em Medicina, no que consistiu em uma nova forma de realizar o diagnóstico de diversas doenças com mais precisão e detalhes.

Isto gerou um interesse contínuo e cada vez maior pela evolução desta tecnologia, atraindo interesse de muitos pesquisadores em empresas e institutos de pesquisa, sendo propostas diversas melhorias desde a sua criação. Desta forma, apresentamos no restante do capítulo um breve resumo da evolução dos tomógrafos na Seção 2.1, a diferença entre Tomografia por Transmissão e Emissão na Seção 2.2, os princípios da tomografia, a formulação matemática e alguns algoritmos de reconstrução para se obter os cortes bidimensionais (Seção 2.3), uma análise do ruído em CT na Seção 2.4 e finalizando, na Seção 2.5, algumas considerações finais.

## 2.1 Evolução Histórica dos Tomógrafos

Após a criação do primeiro tomógrafo por Hounsfield, com o interesse de diversos profissionais neste equipamento, melhorias foram sugeridas, concentrando-se normalmente no “modo que tubos de raios X e detector são construídos e o modo que eles se movem ao redor do paciente” (Buzug, 2008). Estas melhorias, em geral, são regidas pelos seguintes fatores: redução do tempo de aquisição dos dados, de exposição de raios-X e de custo (Buzug, 2008). Basicamente, surgiram quatro gerações principais de tomógrafos. Entretanto, (Bushberg, Seibert *et al.*, 2001), considera mais três além destas, totalizando sete gerações que serão descritas a seguir.

A primeira geração foi o projeto mecânico proposto e utilizado no primeiro tomógrafo por Hounsfield. Basicamente, ele era composto de uma única fonte de feixes e um único detector, movendo-se de forma síncrona. A fonte produz feixes pontuais (*pencil beam*) como um único raio. Aqui, a aquisição de uma fatia, utiliza um processo de rotação/translação. Neste processo, partindo de um dado ângulo, temos que o conjunto fonte-detector é transladado linearmente cobrindo todo o seu campo de visão, adquirindo raios paralelos. Quando este movimento é completado, o sistema inteiro é rotacionado em um dado passo angular e o movimento de translação é novamente iniciado, agora em sentido oposto, para adquirir a nova projeção. Este processo será repetido até que atinja 180° de rotação (em passos de 1°) (Bushberg, Seibert *et al.*, 2001). Sua principal vantagem está na redução do espalhamento com o uso de feixes pontuais e a desvantagem está no tempo de aquisição (Buzug, 2008), que toma cerca de 5 minutos para adquirir uma fatia (Fosbinder e Orth, 2011).

Na segunda geração, um arranjo de detectores (cerca de 30) e um feixe em forma de leque (*fan beam*) com largura estreita (*narrow beam*) de cerca de 10° é utilizado. O processo de aquisição basicamente é o mesmo. Já que o arranjo detector consegue capturar mais intensidades simultaneamente, temos uma redução no tempo de aquisição como uma de suas vantagens. Porém, a geometria em forma de leque, não consegue rejeitar o espalhamento tanto quanto feixes pontuais, que seria uma de suas desvantagens (Buzug, 2008). O tempo de aquisição de uma fatia por tomógrafos desta geração foi reduzido para cerca de 10 a 90 segundos (Fosbinder e Orth, 2011).

Nos tomógrafos de terceira geração, um número ainda maior de detectores (mais de 800) foi utilizado. Porém, a sua principal mudança consistiu em estender a ideia do uso de um feixe em leque mais amplo (*wide beam*), para cerca de 40 a 60° de abertura, pois desta forma

o movimento de translação poderia ser eliminado, já que ele foi identificado como um dos grandes obstáculos para uma aquisição mais rápida. Assim, o processo de aquisição destes tomógrafos pode ser caracterizado como sendo rotação/rotação (ou seja, puramente rotação de ambos o detector e tubo de raios X). Apesar da grande redução no tempo de aquisição, que leva cerca de 1 segundo por fatia (Fosbinder e Orth, 2011), tomógrafos nesta geração produzem artefatos de anel (*ring*) (Bushberg, Seibert *et al.*, 2001; Buzug, 2008).

Assim, nos tomógrafos de quarta geração, preocupou-se em resolver o problema destes artefatos. A proposta desta geração foi considerar um arranjo detector estacionário, definindo-os fixos em 360° ao redor do paciente. Isto implicou na necessidade de um maior número de detectores, para cerca de 5000. Esta geometria foi denominada rotação/estacionário (Bushberg, Seibert *et al.*, 2001), sendo que a sua principal desvantagem é a elevação da dose de radiação sobre o paciente (Fosbinder e Orth, 2011). Quanto ao tempo de aquisição, cerca de 1 segundo por fatia é necessário (Fosbinder e Orth, 2011).

A quinta geração, por sua vez, interessou especialmente aos cardiologistas. Estes tomógrafos consideram uma geometria estacionário/estacionário, pois o anel detector e a fonte estão fixos. Ele não utiliza uma fonte de raios X convencional, mas um grande arco de tungstênio ao redor do paciente, oposto aos detectores. Um raio com elétron de alta energia é emitido e atinge o alvo de tungstênio que por sua vez emite raios X. Assim, este método usa um raio de elétron (*electron beam*) e tomógrafos desta geração são conhecidos também como Cine-CT (Bushberg, Seibert *et al.*, 2001). Tomógrafos desta geração apresentam tempos de aquisição de aproximadamente 100 milissegundos por fatia, cerca de 10 vezes mais rápido que tomógrafos de terceira e quarta gerações (Fosbinder e Orth, 2011).

Os tomógrafos da sexta geração resolvem outro problema que restringia a capacidade de redução no tempo de aquisição: o tubo de raios X e detectores eram conectados por fios, que rotacionavam junto a estes (quando este não era estacionário), o que não permitia a aquisição de novas fatias sem uma determinada pausa para desenrolar o fio. Assim, surgiu uma nova tecnologia chamada *slip-ring*, onde a energia é fornecida por contatos deslizantes. Com isto, fonte e detector poderiam rotacionar continuamente, enquanto está se movimentando. Isto faz com que o tubo de raios X tenha um movimento helicoidal ou forma de espiral ao redor do paciente. Desta forma, estes tomógrafos foram chamados de CT helicoidal ou espiral e possuem a grande redução no tempo de aquisição como vantagem. Além disto, para se obter uma seção planar, métodos de interpolação são necessários (Bushberg, Seibert *et al.*, 2001;

Buzug, 2008). Pode-se dizer que a partir desta geração houve uma mudança de paradigma de imageamento fatia por fatia para uma varredura por volume (Kalender, 2006). Enquanto que exames fatia por fatia levavam cerca de 20 a 40 minutos para se completar (Kalender, 2006), a introdução da sexta geração permitiu que exames fossem completados em menos de 1 minuto (Fosbinder e Orth, 2011).

Por fim, tomógrafos da sétima geração se utilizam de múltiplos arranjos de detectores. Com isto, pode-se adquirir mais de um corte axial por vez (Bushberg, Seibert *et al.*, 2001). Se considerarmos a evolução que houve do raio pontual para o raio em leque, poderia se pensar em um avanço semelhante que seria usar um raio em formato de cone (*cone beam*). Portanto, tomógrafos nesta geração constituem em uma evolução natural das gerações anteriores. Além disso, os tomógrafos em estado da arte correspondem ao CT helicoidal com multidetectores (multisllice), o que tem feito que exames sejam realizados em cerca de 5 a 15 segundos (Kalender, 2006). Por fim, além da maior eficiência, temos que os tomógrafos desta geração foram projetados para reduzir a exposição do paciente à radiação e melhorar a resolução da imagem (Fosbinder e Orth, 2011), especialmente.

## **2.2 Tomografia por Transmissão x Emissão**

Ao processo de aquisição de tomografia descrito até aqui, onde raios são emitidos por uma fonte externa sobre o corpo a ser imageado, capturando radiação residual, dá-se o nome de Tomografia por Transmissão.

Em contraste, tem-se outro processo, chamado de Tomografia por Emissão, cuja diferença básica consiste em que fonte emissora de raios está dentro do paciente. Esta fonte consiste de um isótopo radiativo que pode ser administrado ao paciente por meio intravenoso, ingestão ou inalação (Ribeiro, 2010), caracterizando uma modalidade diferente do CT para a aquisição de imagens, sendo esta chamada de Imageamento por Medicina Nuclear.

Geralmente, o produto a ser administrado ao paciente é projetado de acordo com o órgão de interesse no imageamento, a fim de que seja absorvido e assim, localizado neste órgão (Rangayyan, 2005). Isto ocorre, pois uma das aplicações desta modalidade é gerar um mapeamento funcional de determinado órgão, já que o número de fótons ou pósitrons emitidos por segundo é proporcional à concentração da fonte naquele ponto (Kak e Slaney, 1988).

Os dois Tomógrafos por Emissão mais conhecidos são o PET (*Positron Emission Tomography*) e o SPECT (*Single Photon Emission Computed Tomography*). Uma diferença básica entre eles é que no PET ocorre a emissão de um pósitron, enquanto no SPECT, de um fóton de raio Gama.

No PET, o processo de aquisição da imagem baseia-se na característica de que, quando um pósitron (carga de energia positiva) encontra um elétron (carga de energia negativa), estes se aniquilam liberando dois fótons de raios Gama em direções opostas. Estes pósitrons são emitidos quando o decaimento de um radioisótopo ocorre devido à instabilidade de seu núcleo. Já no SPECT, um fóton de raio Gama é emitido diretamente pelo isótopo radioativo. Assim, estes raios Gama atravessam o corpo sofrendo atenuações e são detectados pelo tomógrafo, gerando as projeções. Em seguida, algoritmos de reconstrução devem ser utilizados para se recuperar a função que descreve a distribuição de radioatividade no órgão em função do tempo, podendo ser os mesmos da Tomografia por Transmissão com algumas adaptações (Kak e Slaney, 1988; Wagner Jr., 1998; Rangayyan, 2005; Ribeiro, 2010).

O objetivo desta seção foi realçar algumas das diferenças entre Tomografia Computadorizada por Transmissão e por Emissão. Mas, a partir de agora continuaremos assumindo o modelo para a Tomografia por Transmissão, que é a modalidade abordada nesta tese.

### 2.3 Reconstrução

Na tomografia de transmissão, um raio emitido com intensidade  $I_0$ , atravessa o corpo sendo imageado sobre uma dada linha  $L_i$ , sofrendo atenuação  $\mu(s)$  a cada posição  $s$  até atingir um detector que captura a sua intensidade final  $I$ . Este problema pode ser modelado, considerando uma função de intensidade  $I(s)$ , que nos fornece a intensidade em cada posição  $s$  que o raio atravessa. Assim, podemos modelar a intensidade  $I(s)$  após uma distância  $\Delta s$  ser percorrida pelo raio como (Buzug, 2008; De Cezaro e De Cezaro, 2010)

$$I(s + \Delta s) = I(s) - \mu(s).I(s).\Delta s. \quad (2.1)$$

Podemos rearranjar esta equação de forma a obtermos

$$\frac{I(s + \Delta s) - I(s)}{\Delta s} = -\mu(s).I(s). \quad (2.2)$$

Fazendo com que  $\Delta s \rightarrow 0$ , caímos em uma equação diferencial definida como

$$\frac{dI}{ds} = -\mu(s).I(s). \quad (2.3)$$

A partir da integração da Equação 2.3 sobre linha  $L_i$  e lembrando que a intensidade inicial do raio emitida pela fonte é definida por  $I_0$ , chegamos a uma equação para  $I$ , conhecida como Lei de Beer, que nos diz que a intensidade é atenuada exponencialmente ao longo de  $L$  (De Cezaro e De Cezaro, 2010)

$$I = I_0 \cdot e^{-\int_{L_i} \mu(s).ds}. \quad (2.4)$$

Entretanto, em geral, uma simplificação pelo uso do logaritmo natural é considerada na Equação 2.4 a fim de tornar o problema aproximadamente linear. Desta forma, temos a seguinte equação (De Cezaro e De Cezaro, 2010)

$$P(L_i) = -\ln \frac{I}{I_0} = \int_{L_i} \mu(s).ds \quad (2.5)$$

onde  $P(L_i)$  equivale à soma dos coeficientes de atenuação ao longo de  $L_i$  (especialmente se olharmos no caso discreto) e é chamado de raio-soma.

Apesar de na formulação acima o problema estar definido em termos unidimensionais,  $s$  equivale a um determinado ponto  $(x, y)$  no plano bidimensional. Considerando que o mapa de coeficientes bidimensional é dado por  $\mu(x, y)$ , temos

$$P(\theta_i, r_j) = \int_{L_i} \mu(x, y).ds, \quad (2.6)$$

onde  $P(\theta_i, r_j)$  é a integral de linha do  $j$ -ésimo raio paralelo de um feixe emitido no ângulo  $\theta_i$  ao redor do corpo. Assim, o conjunto de raios-soma de um feixe é chamado uma projeção. E o plano  $\theta$ - $r$  definido pelo conjunto de valores de  $P(\theta_i, r_j)$  é denominado um sinograma (Kak e Slaney, 1988; Buzug, 2008).

Desta forma, o problema em tomografia é como obter um corte bidimensional  $f(x, y)$  de um corpo, que corresponde ao seu mapa bidimensional de atenuações  $\mu(x, y)$  a partir do seu conjunto de projeções obtidas de feixes emitidos em várias direções ao redor do corpo. Ao método que realiza este procedimento, damos o nome de algoritmo de reconstrução. Portanto, no restante desta Seção, apresentaremos a formulação matemática fornecida pela Transformada de Radon (Seção 2.3.1), o importante resultado dado pelo Teorema de Corte de Fourier

(Seção 2.3.2), além de alguns algoritmos de reconstrução tomográfica (Seções 2.3.3 a 2.3.5). Outras abordagens de reconstrução podem ser encontradas em (Fessler, 2000).

### 2.3.1 Transformada de Radon

A Transformada de Radon proposta por Johann Radon em 1917 (Radon, 1917) foi a primeira solução publicada para solucionar o problema de reconstruir uma função bidimensional  $f(x, y)$  a partir suas projeções  $P_\theta(t)$ .

A solução proposta por Radon parte da modelagem de um raio em coordenadas polares. Aqui um raio, definido como um segmento  $\overline{AB}$  é representado por (Kak e Slaney, 1988; Rangayyan, 2005)

$$x \cdot \cos \theta + y \cdot \sin \theta = t_1. \quad (2.7)$$

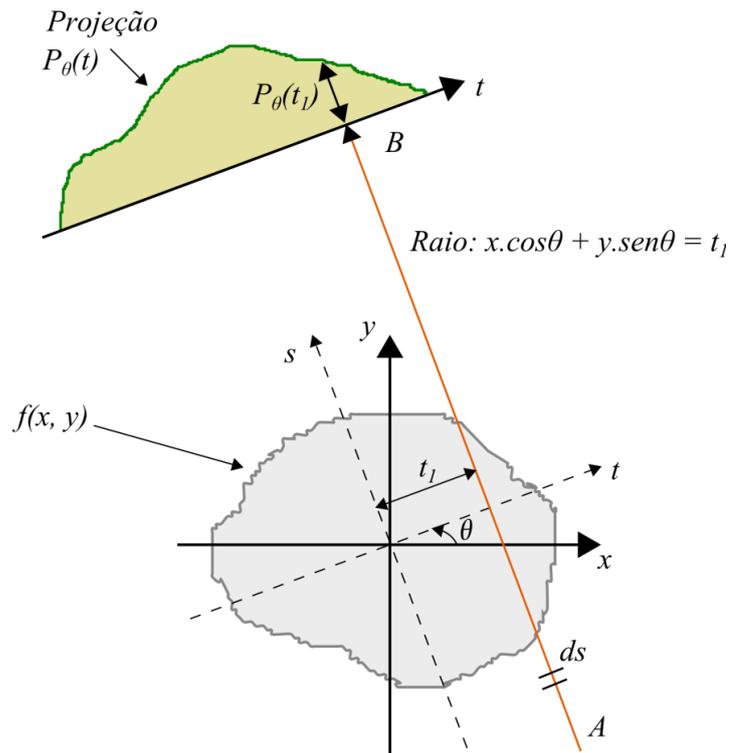
onde  $t_1$  indica a distância do raio à origem do sistema de coordenadas e  $\theta$  é a orientação do raio com relação ao eixo  $x$ .

Assim, a integral de  $f(x, y)$  ao longo de um raio é dada por

$$\begin{aligned} P_\theta(t_1) &= \int_{AB} f(x, y) ds \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \cdot \delta(x \cdot \cos \theta + y \cdot \sin \theta - t_1) dx dy. \end{aligned} \quad (2.8)$$

onde  $\delta$  é a função Delta de Dirac e  $s = -x \cdot \sin \theta + y \cdot \cos \theta$  é a posição ao longo do raio  $\overline{AB}$ . Um conjunto de raios paralelos é representado no sistema de coordenadas  $(t, s)$ , que são rotacionados por um ângulo  $\theta$  com relação ao sistema de coordenadas  $(x, y)$ . Naquele sistema cada raio é definido por uma distância  $t$  da origem do sistema, sendo paralelo ao eixo coordenado  $s$ . Avaliando os valores das integrais para os diversos raios  $t_j$  em uma dada direção, temos uma projeção  $P_\theta(t)$  tal que esta é chamada a Transformada de Radon de uma função  $f(x, y)$  (Rangayyan, 2005). A Figura 2.2 ilustra esta transformada.

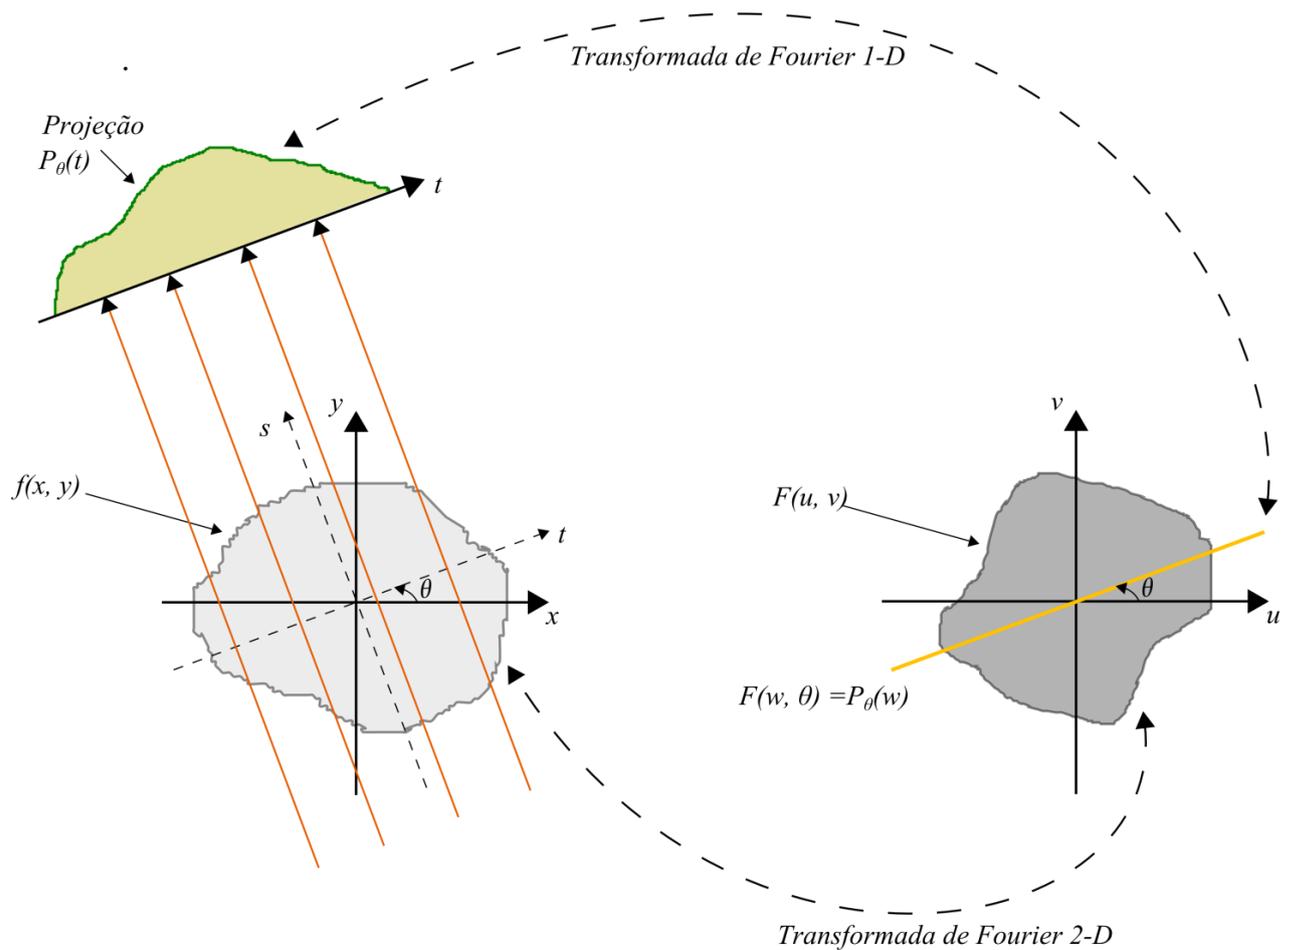
Por fim, observe que um algoritmo de reconstrução pode ser definido pela Transformada de Radon Inversa. Entretanto, um importante resultado será apresentado na próxima Seção, de tal forma a permitir que a Inversa da Transformada de Radon seja obtida via Transformada de Fourier.



**Figura 2.2.** Transformada de Radon. Baseada em (Rangayyan, 2005).

### 2.3.2 Teorema do Corte de Fourier

O Teorema de Corte de Fourier apresenta um importante resultado, relacionando a Transformada de Radon e a Transformada de Fourier, que é utilizado em alguns algoritmos de reconstrução. Este resultado diz que a Transformada de Fourier 1-D  $S_\theta(w)$  de uma projeção  $P_\theta(t)$  equivale a um corte 1-D na direção  $\theta$  (com relação ao eixo  $u$ ) da Transformada de Fourier 2-D da imagem  $f(x, y)$ , dada por  $F(u, v)$ . Assim, se tomarmos projeções em todos os ângulos  $\theta$  de 0 a 180°, podemos gerar  $F(u, v)$ , permitindo que ao aplicá-la a Transformada Inversa de Fourier, obtemos  $f(x, y)$  (Kak e Slaney, 1988; Rangayyan, 2005). Entretanto, na prática apenas um número limitado de projeções estão disponíveis. Portanto, podemos observar que apenas um número finito de pontos de  $F(u, v)$  estará disponível. Estes estarão sobre linhas radiais definidas pelas projeções. Desta forma, será necessária a interpolação para algumas direções, o que implicaria em degradações na imagem. Assim, teremos uma aproximação da estimativa de  $f(x, y)$ . A Figura 2.3 ilustra este Teorema.



**Figura 2.3.** Teorema do Corte de Fourier. Baseada em (Rangayyan, 2005)

Para a demonstração deste Teorema, considere as definições da Transformada Fourier 2-D  $F(u, v)$  de uma função  $f(x, y)$  dada por

$$F(u, v) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \cdot e^{-j2\pi(u \cdot x + v \cdot y)} dx dy, \quad (2.9)$$

da sua Inversa definida como

$$f(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} F(u, v) \cdot e^{j2\pi(u \cdot x + v \cdot y)} du dv \quad (2.10)$$

e da Transformada de Fourier 1-D  $S_\theta(w)$  de uma projeção  $P_\theta(t)$  dada pela equação (Kak e Slaney, 1988; Rangayyan, 2005)

$$S_\theta(w) = \int_{-\infty}^{\infty} P_\theta(t) \cdot e^{-j2\pi w t} dt. \quad (2.11)$$

Seja  $f(t, s)$ , a imagem  $f(x, y)$  rotacionada por um ângulo  $\theta$ , definida pela transformação (Kak e Slaney, 1988; Rangayyan, 2005)

$$\begin{bmatrix} t \\ s \end{bmatrix} = \begin{bmatrix} \cos \theta & \sin \theta \\ -\sin \theta & \cos \theta \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix}. \quad (2.12)$$

Então, uma projeção  $P_\theta(t)$  em  $(t, s)$  é dada por

$$P_\theta(t) = \int_{-\infty}^{\infty} f(t, s) \cdot ds. \quad (2.13)$$

Substituindo a Equação 2.13 em 2.11, temos (Kak e Slaney, 1988; Rangayyan, 2005)

$$S_\theta(w) = \int_{-\infty}^{\infty} \left[ \int_{-\infty}^{\infty} f(t, s) \cdot ds \right] \cdot e^{-j2\pi wt} dt. \quad (2.14)$$

Assim, retornando de  $(t, s)$  para  $(x, y)$  e lembrando que  $t = x \cdot \cos \theta + y \cdot \sin \theta$ , obtemos (Kak e Slaney, 1988; Rangayyan, 2005)

$$\begin{aligned} S_\theta(w) &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \cdot e^{-j2\pi w(x \cdot \cos \theta + y \cdot \sin \theta)} dx dy \\ &= F(u, v) \text{ com } u = w \cdot \cos \theta \text{ e } v = w \cdot \sin \theta \end{aligned} \quad (2.15)$$

Como  $u$  e  $v$  são parametrizados por  $w$  e  $\theta$ , temos a igualdade que define o Teorema do Corte de Fourier (Kak e Slaney, 1988; Rangayyan, 2005)

$$S_\theta(w) = F(w, \theta). \quad (2.16)$$

Este resultado é a base para o algoritmo de Retroprojeção Filtrada que será apresentado na próxima Seção.

### 2.3.3 Retroprojeção Filtrada (FBP)

O método da Retroprojeção Filtrada (*Filtered Backprojection*) foi inicialmente proposto no trabalho (Ramachandran e Lakshminarayanan, 1971). Diversas propostas de melhorias surgiram, como o trabalho de Shepp e Logan (Logan e Shepp, 1975). Este método propõe reconstruir funções bidimensionais de suas projeções no Domínio de Fourier usando filtragem e convolução, a fim de se reduzir a degradação sofrida por reconstrução com número finito de projeções. A seguir, a derivação deste método de reconstrução será apresentada.

Começamos definindo a Equação 2.17, que descreve a Inversa da Transformada de Fourier Bidimensional, trocando as coordenadas no domínio da frequência de retangulares  $(u, v)$  para polares  $(w, \theta)$ , onde  $w = \sqrt{u^2 + v^2}$  e  $\theta = \tan^{-1}\left(\frac{v}{u}\right)$ . Para isto, fazemos as substituições  $u = w \cdot \cos \theta$ ,  $v = w \cdot \sin \theta$  e de seus diferenciais  $du dv = w dw d\theta$  na Equação 2.10, obtendo (Kak e Slaney, 1988; Rangayyan, 2005)

$$f(x, y) = \int_0^{2\pi} \int_0^{\infty} F(w, \theta) \cdot e^{j2\pi w(x \cdot \cos \theta + y \cdot \sin \theta)} w dw d\theta. \quad (2.17)$$

Se considerarmos os limites para  $\theta$  variando de 0 a  $\pi$  e depois de  $\pi$  a  $2\pi$ , podemos dividir a equação acima em duas partes considerando estes intervalos, ficando como (Kak e Slaney, 1988; Rangayyan, 2005)

$$\begin{aligned} f(x, y) &= \int_0^{\pi} \int_0^{\infty} F(w, \theta) \cdot e^{j2\pi w(x \cdot \cos \theta + y \cdot \sin \theta)} w dw d\theta \\ &+ \int_0^{\pi} \int_0^{\infty} F(w, \theta + \pi) \cdot e^{j2\pi w[x \cdot \cos(\theta + \pi) + y \cdot \sin(\theta + \pi)]} w dw d\theta. \end{aligned} \quad (2.18)$$

Porém, podemos simplificá-la ainda, considerando a propriedade  $F(w, \theta + \pi) = F(-w, \theta)$  e usando  $t = x \cdot \cos \theta + y \cdot \sin \theta$ . Desta forma, obtemos a seguinte equação (Kak e Slaney, 1988; Rangayyan, 2005)

$$f(x, y) = \int_0^{\pi} \left[ \int_{-\infty}^{\infty} F(w, \theta) |w| e^{j2\pi w t} dw \right] d\theta. \quad (2.19)$$

Agora, podemos considerar o Teorema do Corte de Fourier definido na Seção anterior, de modo que tenhamos  $f(x, y)$  dependendo da Transforma de Fourier 1-D das projeções dado por  $S_{\theta}(w)$  e não mais diretamente da Transformada de Fourier 2-D  $F(w, \theta)$  da imagem. Portanto, temos (Kak e Slaney, 1988; Rangayyan, 2005)

$$f(x, y) = \int_0^{\pi} \left[ \int_{-\infty}^{\infty} S_{\theta}(w) |w| e^{j2\pi w t} dw \right] d\theta. \quad (2.20)$$

A fim de facilitar o entendimento e discussão da equação acima, vamos reescrevê-la como (Kak e Slaney, 1988; Rangayyan, 2005)

$$f(x, y) = \int_0^{\pi} Q_{\theta}(x \cdot \cos \theta + y \cdot \sin \theta) d\theta, \quad (2.21)$$

onde  $Q_{\theta}$  é definida como (Kak e Slaney, 1988; Rangayyan, 2005)

$$Q_{\theta}(t) = \int_{-\infty}^{\infty} S_{\theta}(w) |w| e^{j2\pi w t} dw. \quad (2.22)$$

Basicamente, a Equação 2.22 descreve uma operação de filtragem da projeção por um filtro, cuja resposta em frequência é dada por  $|w|$ . Este processo pode ser definido também por uma operação de convolução entre a projeção e o filtro. Este filtro corresponde também a uma função de apodização que tem por finalidade reduzir problemas de truncamento e ruído que ocorrem devido à discretização do problema. Assim, temos que  $Q_{\theta}(t)$  fornece projeções filtradas unidimensionais para diferentes ângulos  $\theta$ , que por sua vez, serão adicionadas para formar a estimativa da imagem bidimensional  $f(x, y)$ , como descreve a Equação 2.21, definindo a etapa conhecida como retroprojeção. Devido a isto, este método é chamado de Retroprojeção Filtrada ou filtragem-retroprojeção ou mesmo convolução-retroprojeção (Kak e Slaney, 1988; Rangayyan, 2005).

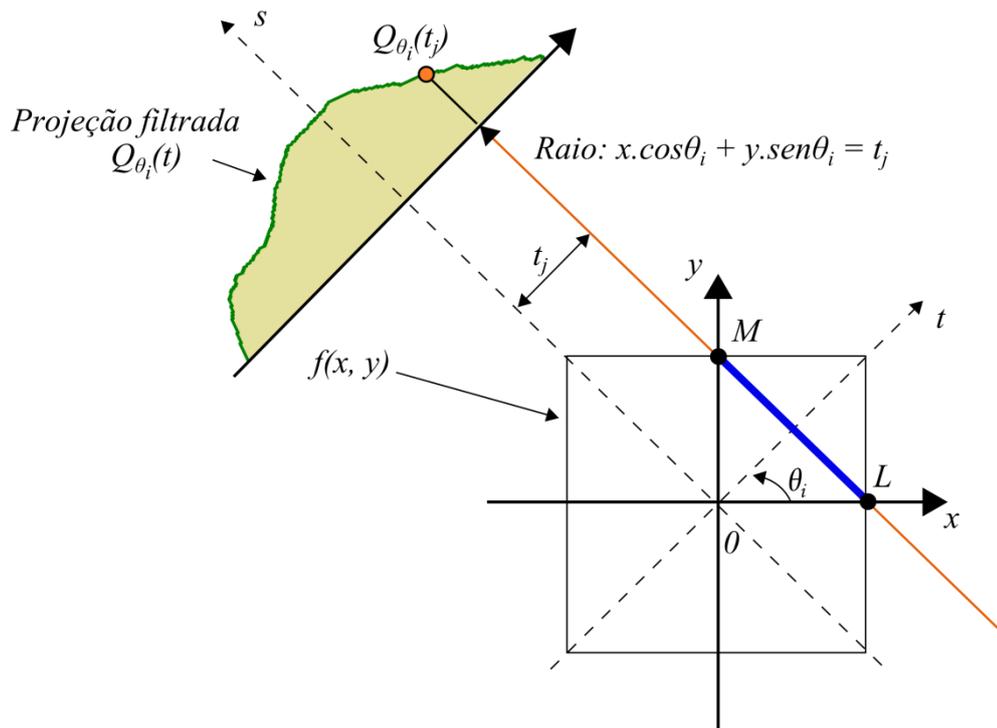
Para explorar em maiores detalhes a Equação 2.21 e, assim, entender como funciona a operação de retroprojeção, considere a Figura 2.4. Nela, os pixels  $(x, y)$  sobre segmento  $\overline{LM}$ , que descreve um determinado raio  $t_j = x \cdot \cos \theta_i + y \cdot \sin \theta_i$  emitido na direção  $\theta_i$ , interferem em apenas um valor da projeção filtrada  $Q_{\theta_i}(t)$ , que é  $Q_{\theta_i}(t_j)$ . Assim, na retroprojeção,  $Q_{\theta_i}(t)$  fornecerá a mesma contribuição para estes pixels. Deste modo, se considerarmos as projeções tomadas nos diversos ângulos  $\theta_i$ , um pixel  $(x, y)$  será definido como a soma dos  $Q_{\theta_i}(t_j)$ , tal que  $(x, y)$  satisfaça  $t_j = x \cdot \cos \theta_i + y \cdot \sin \theta_i$ , que indica o raio  $j$  que atravessa este pixel para a projeção tomada no  $i$ -ésimo ângulo (Kak e Slaney, 1988; Rangayyan, 2005).

Como já observado anteriormente, na prática, um número inteiro  $K$  de projeções é obtido, ou seja, um feixe será emitido no intervalo  $[0, \pi]$  a cada  $\pi/K$  radianos, sendo este último o passo angular de rotação. Por sua vez, em cada feixe há um número finito de raios paralelos, que denotaremos aqui por  $N$ . Sendo que a distância entre dois raios num feixe é  $\tau$  e representa o intervalo de amostragem das projeções. Assim, para se evitar o surgimento de artefatos devido à discretização do problema, trabalha-se com uma versão truncada, com as projeções  $P_{\theta}(t)$  e o filtro  $h(t)$  sendo limitados em banda. Assim, reescrevemos a Equação 2.22, que descreve a filtragem de uma projeção em termos da seguinte operação de convolução (Kak e Slaney, 1988; Rangayyan, 2005)

$$Q_{\theta}(n\tau) = \tau \sum_{k=0}^{N-1} h(n\tau - k\tau) P_{\theta}(k\tau), \quad n = 0, \dots, N-1, \quad (2.23)$$

onde  $P_{\theta}(k\tau) = 0$  para  $k$  fora do intervalo  $[0, N-1]$  e  $h(n\tau)$  é a versão amostrada da resposta impulsiva do filtro, sendo definida por

$$h(n\tau) = \begin{cases} \frac{1}{4\tau^2}, & \text{se } n = 0 \\ 0, & \text{se } n \text{ é par} \\ -\frac{1}{(n\pi\tau)^2}, & \text{se } n \text{ é ímpar.} \end{cases} \quad (2.24)$$



**Figura 2.4.** Operação de Retroprojeção. Baseada em (Kak e Slaney, 1988; Pereira, 2007).

Como o problema está discretizado, podemos utilizar alguma implementação da Transformada Discreta de Fourier (DFT) e de sua inversa que podem ser a Transformada Rápida de Fourier (FFT) e a Inversa da mesma (IFFT). Assim, podemos definir o algoritmo da operação de filtragem das projeções, pela operação descrita na Equação 2.25, que está no domínio de Fourier (Kak e Slaney, 1988; Pereira, 2007) e, portanto, a operação de convolução torna-se uma multiplicação.

$$Q_{\theta}(n\tau) = \tau \times \text{IFFT}\{ \text{FFT}[P_{\theta}(n\tau)] \times \text{FFT}[h(n\tau)] \}. \quad (2.25)$$

Assim, podemos reescrever também para o caso discreto, a operação de retroprojeção das projeções filtradas dada pela Equação 2.21, nos fornecendo desta maneira uma estimativa da função  $f(x, y)$  (Kak e Slaney, 1988; Rangayyan, 2005)

$$\hat{f}(x, y) = \frac{\pi}{K} \sum_{i=1}^K Q_{\theta_i}(x \cdot \cos \theta_i + y \cdot \sin \theta_i). \quad (2.26)$$

Como já observado anteriormente, caso não haja um raio  $t_k = x \cdot \cos \theta_i + y \cdot \sin \theta_i$ , uma interpolação será necessária. Desta forma, temos as operações de filtragem e retroprojeção definidas no caso real em que são aplicadas.

Por fim, nas próximas duas Seções, outros dois métodos de reconstrução serão apresentados. Porém, estes diferem do FBP, principalmente, por não serem baseados no Domínio de Fourier, além de serem processos de otimização iterativos.

### 2.3.4 Técnica de Reconstrução Algébrica (ART)

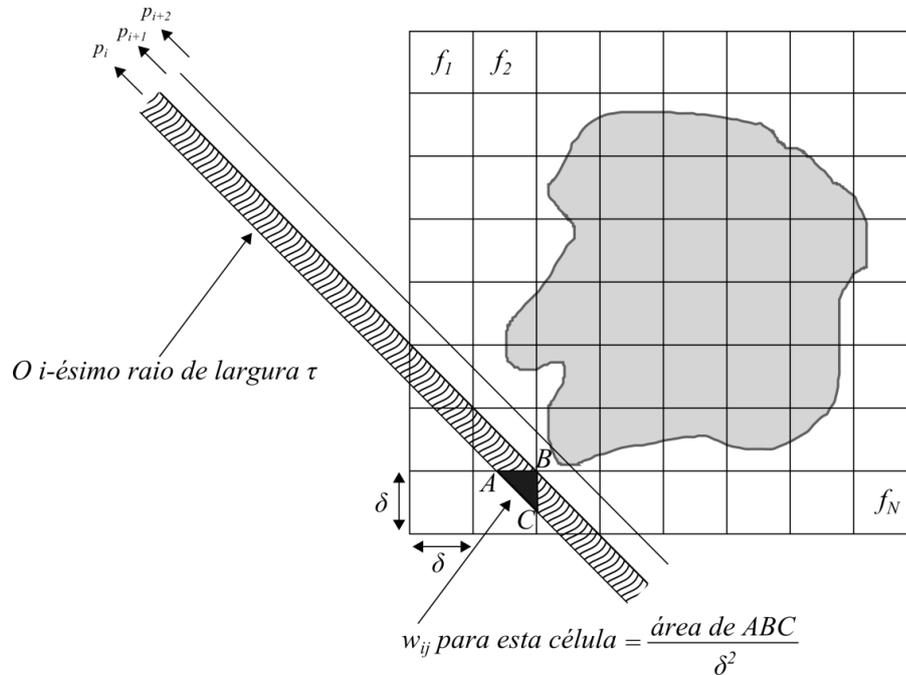
A abordagem de reconstrução algébrica considera um sistema de equações simultâneas, definidos com base em raios-soma, que são as integrais de linha de cada raio ao atravessar um corpo. Ao resolver este sistema, a imagem reconstruída é obtida.

Nesta abordagem, vamos assumir que uma imagem com  $N$  células seja representada por um vetor  $f_j$  em notação lexicográfica. Assuma também que temos ao todo  $M$  raios-soma, agrupando os raios tomados em diferentes ângulos, cujo  $i$ -ésimo raio tem o valor integral dado por  $p_i$ . Aqui, um raio é definido com certa largura. Geralmente, esta largura é aproximadamente a mesma da largura de célula da imagem.

Equações relacionando os raios-soma e as células são definidas por (Kak e Slaney, 1988; Rangayyan, 2005)

$$\sum_{j=1}^N w_{ij} f_j = p_i, \quad i = 1, \dots, M. \quad (2.27)$$

onde  $w_{ij}$  é um peso que indica a contribuição da  $j$ -ésima célula ao  $i$ -ésimo raio-soma. Geralmente, este peso é proporcional à área da  $j$ -ésima célula atravessada pelo  $i$ -ésimo raio (Kak e Slaney, 1988; Rangayyan, 2005). Veja a Figura 2.5 para facilitar a compreensão.

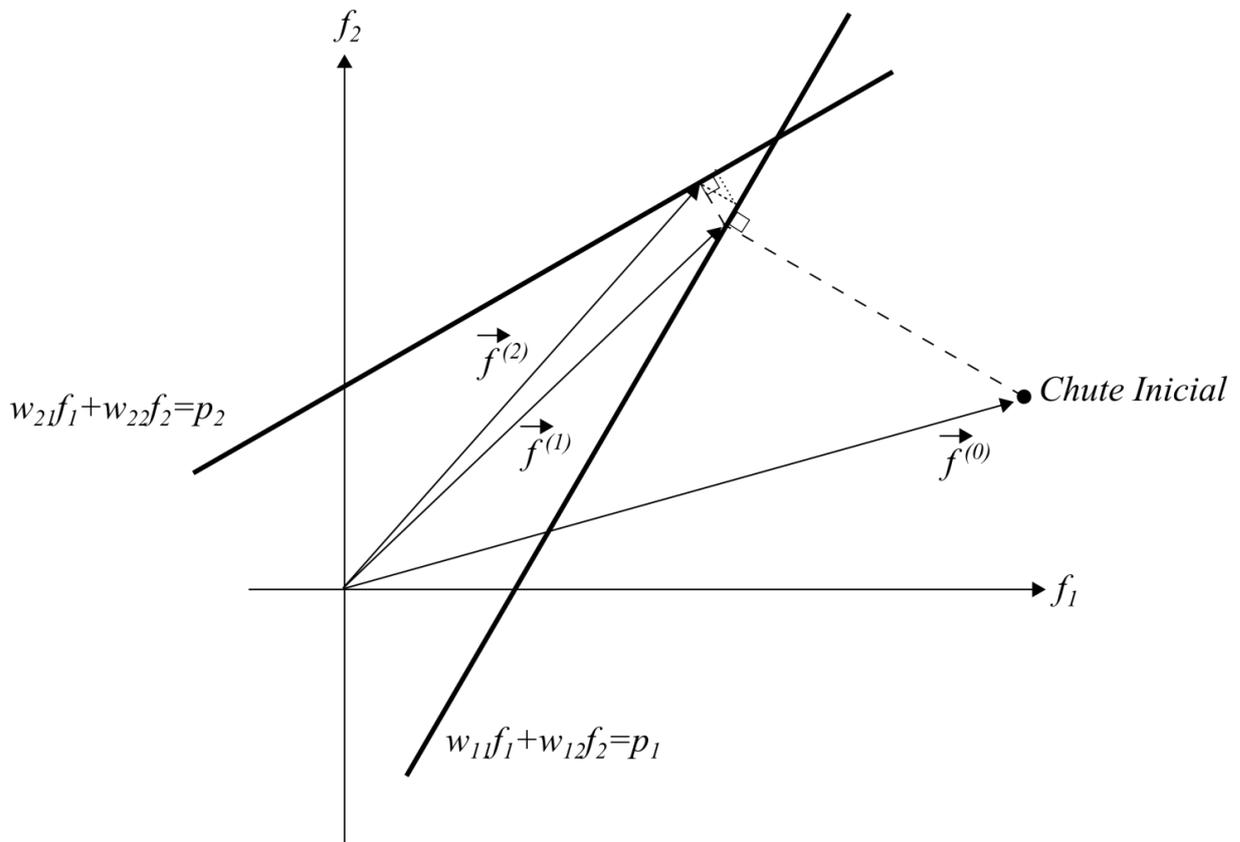


**Figura 2.5.** Representação da imagem em ART. Adaptado de (Kak e Slaney, 1988).

Desta forma, teremos um sistema de  $M$  equações e  $N$  incógnitas, estas dadas por  $f_j$ , a ser resolvido. No caso de  $M$  e  $N$  pequenos, podem-se usar métodos tradicionais de inversão direta de matrizes para resolver este problema. Porém, no caso de dados ruidosos ou de  $M < N$  (sistema subdeterminado), estes métodos não podem ser utilizados. Já com  $M$  e  $N$  grandes, o maior problema está no custo computacional, especialmente de memória. E, normalmente, é este o caso (Kak e Slaney, 1988; Rangayyan, 2005).

Entretanto, estes problemas podem ser superados utilizando o método de projeções para equações simultâneas de Kaczmarz. Vale ressaltar que projeções neste contexto, referem-se à operação de projeção algébrica. Neste método, uma imagem pode ser considerada como um ponto em um espaço  $N$ -dimensional, definido por  $\vec{f} = (f_1, f_2, \dots, f_N)$ . E cada equação representa um hiperplano neste espaço, sendo que no caso de haver uma única solução, ela será dada pelo ponto de intersecção entre todos estes hiperplanos (Kak e Slaney, 1988; Rangayyan, 2005). A Figura 2.6 ilustra este método, considerando para exemplificar  $N = 2$  e  $M = 2$ .

O algoritmo do ART é iterativo. Para entender o processo, vamos considerar o caso da Figura 2.6. Ele parte de uma estimativa inicial da imagem  $\vec{f}^{(0)} = (f_1^{(0)}, f_2^{(0)}, \dots, f_N^{(0)})$ , geralmente definida por  $N$  valores constantes. Em seguida, o ponto  $\vec{f}^{(0)}$  é projetado no hiperplano definido pela primeira equação, obtendo o ponto  $\vec{f}^{(1)}$ . Este por sua vez é projetado no segundo hiperplano, obtendo  $\vec{f}^{(2)}$  que será reprojetoado no primeiro hiperplano e, assim por diante. Se houver uma única solução o método convergirá para este ponto. Caso contrário, ele poderá ficar oscilando entre os hiperplanos, como pode ocorrer em condições de ruído ou como no caso de sistema subdeterminado convergirá para a solução de mínima variância (Rangayyan, 2005).



**Figura 2.6.** Método de Kaczmarz. Adaptado de (Kak e Slaney, 1988).

Assim, podemos definir a  $i$ -ésima iteração deste método como (Kak e Slaney, 1988; Rangayyan, 2005)

$$\vec{f}^{(i)} = \vec{f}^{(i-1)} - \frac{(\vec{f}^{(i-1)} \cdot \vec{w}_i - p_i)}{\vec{w}_i \cdot \vec{w}_i} \vec{w}_i, \quad (2.28)$$

onde  $\vec{w}_i = (w_{i1}, w_{i2}, \dots, w_{iN})$  é o vetor de pesos para o  $i$ -ésimo raio e o ponto  $(.)$  denota o produto interno entre dois vetores.

Por fim, na próxima Seção veremos outro algoritmo iterativo para reconstrução, sendo que o método ART é considerado um caso particular dele.

### 2.3.5 Projeções em Conjuntos Convexos (POCS)

O método das Projeções em Conjuntos Convexos (*Projections Onto Convex Sets*) vem da Teoria de Conjuntos. Ele busca a solução para um dado problema descrito por  $N$  conjuntos de restrições convexas  $C_i$ . No método ART, cada conjunto  $C_i$  corresponde a um hiperplano definido por  $f \cdot w_i = p_i$  (Salina, 2007).

Entretanto, muitos outros conjuntos de restrições convexas podem ser descritos. Sendo que informação *a priori* pode ser descrita por meio de um conjunto de restrição. Na tese (Salina, 2007), outros conjuntos são utilizados para a imagem a ser reconstruída. Destes podemos citar: 1) Restrição de Não Negatividade que define que os valores para os pixels da imagem sejam maiores ou iguais a zero, 2) Restrição de Amplitude Limitada que pode ser entendida como limitantes superior e inferior aos valores dos pixels (0 a 255, por exemplo) e 3) Restrição de Suporte Finito que basicamente delimita a região (suporte) do objeto, assumindo valores nulos aos pontos fora da região de interesse.

Uma solução POCS é encontrada se ela satisfaz todos os conjuntos de restrições definidas, ou seja, se um ponto de intersecção  $C_0$  entre estes conjuntos existe ( $C_0 \neq \emptyset$ ), dado por (Salina, 2007)

$$C_0 = \bigcap_{i=1}^N C_i. \quad (2.29)$$

Semelhante ao algoritmo iterativo do método ART, partimos de uma estimativa inicial da imagem reconstruída, definida pelo ponto  $x_0$ . Projeções sucessivas são realizadas em cada conjunto de restrições  $C_i$ , obtendo-se uma nova estimativa da imagem reconstruída a cada passo.

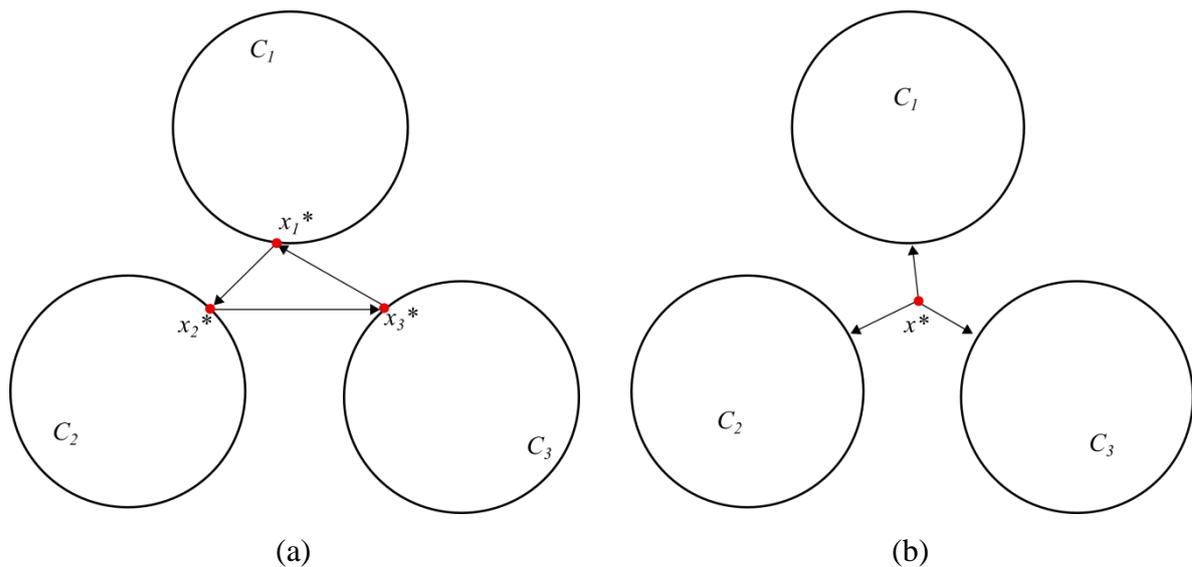
O algoritmo POCS sequencial pode ser definido pela equação (Sezan e Stark, 1982; Youla e Webb, 1982; Salina, 2007)

$$x_{k+1} = P_{C_k} \dots P_{C_2} P_{C_1} x_k, \quad k = 1, 2, 3, \dots \quad (2.30)$$

Uma implementação paralela também está disponível. Neste caso, um ponto  $x_k$  é projetado em todos os conjuntos de restrição, sendo que o novo ponto  $x_{k+1}$  será definido em função de uma combinação linear das distâncias entre o ponto atual  $x_k$  e as suas projeções no  $i$ -ésimo conjunto de restrição  $C_i$ , cujo somatório dos pesos  $w_i$  é igual a 1. Assim, podemos representar o algoritmo de POCS paralelo por (Combettes e Puh, 1993; Salina, 2007)

$$x_{k+1} = x_k + \sum_{i=1}^N w_i (P_{C_i} x_k - x_k). \quad (2.31)$$

Em casos onde não há intersecção entre os conjuntos de restrições, como ocorre com o sinal na presença de ruído, a solução do POCS sequencial fica oscilando entre os conjuntos de restrições. Já a sua versão paralela, apresenta-se mais robusta, pois convergirá para uma solução que minimize a distância desta para os conjuntos de restrições, podendo convergir para uma solução de mínimos quadrados ponderados (Combettes, 1993). A Figura 2.7 representa esta ideia.



**Figura 2.7.** Convergência dos Algoritmos de Reconstrução por POCS: a) POCS Sequencial e b) POCS Paralelo. Baseado em (Combettes, 1993; Salina, 2007).

Assim, a apresentação de alguns algoritmos para a Reconstrução Tomográfica é concluída. Na próxima Seção, o ruído tanto nas projeções (Transformada de Radon), quanto no domínio da imagem será mais bem caracterizado. Isto é importante, pois afeta diretamente a qualidade dos métodos de reconstrução e filtragem.

## 2.4 Caracterização do Ruído em CT

O ruído branco se espalha igualmente sobre todas as frequências. Por sua vez, em geral, detalhes finos da imagem como bordas compreendem principalmente as componentes de alta frequência, enquanto a maior parte da energia comumente está concentrada nas baixas frequências, tal como regiões homogêneas (Rangayyan, 2005). Assim, em filtragem, o objetivo consiste em remover ou reduzir o ruído, sem afetar os detalhes importantes e sem acrescentar artefatos.

Em CT, o ruído é gerado pela própria natureza estatística do processo de emissão de fótons por uma fonte e detecção por um sensor (Rangayyan, 2005), o que leva a uma aleatoriedade nas medidas de projeção tomadas. Esta aleatoriedade de  $N_{\theta_i}(t)$  é descrita estatisticamente pela distribuição de probabilidade de Poisson (Kak e Slaney, 1988)

$$p\{N_{\theta_i}(k\tau)\} = \frac{[\bar{N}_{\theta_i}(k\tau)]^{N_{\theta_i}(k\tau)}}{N_{\theta_i}(k\tau)!} e^{-\bar{N}_{\theta_i}(k\tau)} \quad (2.32)$$

onde  $N_{\theta_i}(k\tau)$  é o número de fótons detectados do  $k$ -ésimo raio emitido no ângulo  $\theta_i$ ,  $p$  é a probabilidade e  $\bar{N}_{\theta_i}(k\tau)$  é o valor esperado ( $E$ ) de fótons  $\bar{N}_{\theta_i}(k\tau)$

$$\bar{N}_{\theta_i}(k\tau) = E\{N_{\theta_i}(k\tau)\}. \quad (2.33)$$

Assim, como esta é uma distribuição de Poisson, podemos definir a variância como (Kak e Slaney, 1988)

$$Var\{N_{\theta_i}(k\tau)\} = \bar{N}_{\theta_i}(k\tau). \quad (2.34)$$

Desta forma, podemos dizer que as projeções são governadas por um ruído Poisson, que é dependente do sinal, com variância igual a sua média. Entretanto, foi mostrado que na Transformada de Radon, assumindo um número fixo de fótons incidentes, a variância de uma medida é inversamente proporcional ao número fótons medido (Epstein, 2008). Isto implica que

em quanto menor a contagem de fótons, maior será o ruído. Outra maneira de ver isto é pela Razão Sinal-Ruído (SNR), que é definida pela razão da média sobre o desvio padrão. Como no caso de distribuição Poisson, temos que a média é igual à variância, o SNR será dado por média sobre raiz quadrada da média, ou seja, por raiz quadrada da média. Portanto, o SNR diminui à medida que a média cai.

Na imagem reconstruída, podemos definir o ruído como sendo Gaussiano (distribuição normal), pois se considerarmos que tanto a reconstrução no domínio de Fourier quanto a reconstrução por métodos algébricos envolvem uma combinação linear de um grande número de variáveis aleatórias, podemos invocar o Teorema Central do Limite (Epstein, 2008). Este Teorema estabelece que seja qual for a distribuição original de  $n$  variáveis aleatórias independentes e identicamente distribuídas, quando  $n \rightarrow \infty$ , se considerarmos uma nova variável aleatória  $Z$  como a média amostral destas variáveis aleatórias, ela será aproximadamente normalmente distribuída. Portanto, temos que os pixels no domínio da imagem são governados aproximadamente por ruído Gaussiano. Vale ressaltar ainda, que no caso do POCS, uma porcentagem muito baixa dos pixels do objeto é sujeita a restrições não lineares de não negatividade e suporte finito, considerados nesta tese, o que não invalida os argumentos do Teorema Central do Limite.

Enfim, foi verificado empiricamente (veja o Apêndice B), pelo cálculo das variâncias de áreas homogêneas claras e escuras, que o ruído na imagem reconstruída também é dependente do sinal, já que a variância não é constante ao longo de toda imagem e depende da tonalidade média da área. Esta é uma suposição razoável, pois a imagem é reconstruída de variáveis aleatórias Poisson nas projeções, dependentes de sinal.

## 2.5 Considerações Finais

Neste capítulo, um breve histórico sobre a tecnologia de Tomografia foi apresentado, a diferenciação entre Tomografia por Emissão x Transmissão, sendo este o caso do CT. Assim, foi dada atenção especial à modelagem do processo de aquisição de projeções na Tomografia de Transmissão pela Transformada de Radon.

A partir disto, basicamente três abordagens para se reconstruir a representação bidimensional de um corte a partir das projeções unidimensional capturadas foram apresentadas, sendo que duas delas serão utilizadas em nossos experimentos: FBP e POCS paralelo.

A primeira abordagem derivada foi a Retroprojeção Filtrada (FBP) que é definida como um método de reconstrução no Domínio de Fourier, que realiza a filtragem das projeções neste domínio e depois as reprojeta para gerar a imagem, baseado no Teorema do Corte de Fourier que definiu uma equivalência entre projeção e imagem no domínio da frequência.

Em seguida, foram apresentados os métodos de reconstrução iterativos ART e POCS, sendo aquele um caso particular deste. Estes métodos se baseiam na operação de projeção algébrica em conjuntos de restrições, a fim de se atingir a solução (ou próximo dela), que corresponde à intersecção entre estes conjuntos.

Finalmente, o ruído em CT foi mais bem caracterizado, tanto no domínio das projeções, quanto no domínio das imagens reconstruídas. Isto é de fundamental importância, pois em filtragem, uma modelagem adequada do ruído pode levar a uma filtragem mais robusta e eficaz, reduzindo-se maior quantidade de ruído. Desta forma, no próximo capítulo faremos uma revisão de alguns métodos propostos na literatura para a filtragem em CT.

### 3 FILTRAGEM EM TOMOGRAFIA COMPUTADORIZADA

Ruído corresponde a um tipo de degradação que pode estar presente nas imagens, sendo causado pelos próprios dispositivos (sensores) ou processo de aquisição, como o ruído Poisson devido à aleatoriedade estatística do processo de emissão e detecção de fótons, ou mesmo por processamentos posteriores como é o caso do ruído Gaussiano nas imagens reconstruídas (como visto na Seção 2.4 anteriormente).

Ele prejudica a análise de uma imagem por humanos ou máquinas. No caso de diagnósticos, por exemplo, ele pode reduzir o contraste entre vários tecidos humanos dificultando a diferenciação entre eles, adicionar elementos que não fazem parte do objeto sendo analisado ou mesmo reduzir a definição dos elementos da imagem. Além disso, o ruído corresponde geralmente a componentes de alta frequência, como os detalhes de bordas e texturas. Desta forma, podemos ter diagnósticos errados ou imprecisos, o que pode provocar graves acidentes. No caso do processamento destas imagens ruidosas, sem se considerar o ruído presente, pode-se reduzir o desempenho do método, tornando-o até mesmo inadequado.

Por estes motivos, o ruído consiste em um tipo de degradação que deve ser reduzido a fim de aumentar a relação sinal-ruído. Para isto, métodos de restauração de imagens, que se utilizam primordialmente do conhecimento *a priori* do fenômeno que gerou a degradação, se propõem a recuperar o sinal (imagem) a partir da modelagem do fenômeno que gerou o ruído e depois aplicando a solução inversa ou algum outro método que estime a imagem (Gonzalez e Woods, 2002). A este processo chamamos de filtragem de ruído.

Como examinado na Seção 2.4, podemos ter principalmente dois tipos de ruído em CT (informações sobre outros tipos de ruído podem ser encontradas em (Hanson, 1981; Rangayyan, 2005)). Nas projeções, lidamos com ruído Poisson que é dependente do sinal, cujo processo de degradação pode ser modelado como

$$g(n) \sim \text{Poisson}(f(n)), \quad (3.1)$$

onde  $g(n)$  é a projeção observada,  $f(n)$  é a projeção livre de ruído.

Na imagem reconstruída, por sua vez, o ruído pode ser modelado considerando um modelo aditivo

$$g(x, y) = f(x, y) + v(x, y), \quad (3.2)$$

onde  $g(x, y)$  é a imagem ruidosa observada,  $f(x, y)$  é a imagem original livre de ruído e que deseja ser estimada e  $v(x, y)$  é um ruído Gaussiano dependente do sinal original  $f(x, y)$ . Entretanto, muitos métodos de filtragem consideram este ruído independente do sinal ou nem fornecem uma modelagem.

Considerando estes modelos de ruído, apresentaremos nas duas próximas seções um levantamento de métodos e abordagens propostos na literatura para filtrar em CT, as projeções (ou suavizar sinogramas) (Seção 3.1) ou imagens reconstruídas (Seção 3.2). Por fim, na última Seção deste capítulo (Seção 3.3), apresentaremos uma breve discussão destes métodos, como também algumas considerações finais.

### **3.1 Revisão de Técnicas de Filtragem Pré-Reconstrução: Domínio das Projeções ou do Sinograma**

Em geral, os métodos de reconstruções já aplicam algum filtro nas projeções de forma implícita ou mesmo explicitamente, como é o caso da Retroprojeção Filtrada. Nesta Seção, apresentaremos métodos que dão enfoque ao passo de filtragem antes da reconstrução, independente do método de reconstrução utilizado. Estes métodos são apresentados a seguir.

Em (Mascarenhas, Santos *et al.*, 1996), correspondente à dissertação de mestrado de Saulo S. L. Santos (Santos, 1996) desenvolvida no DC/UFSCar, foi proposto o uso de estimação da projeção livre de ruído usando o critério MAP (*Maximum a Posteriori*). Sendo que a verossimilhança foi definida como Poisson e densidades *a priori* Gaussiana, Exponencial, Rayleigh, Chi-Quadrado, Gama, Beta e Log-normal foram consideradas. Para a reconstrução foi utilizado o método FBP com filtro Ram-Lak (Rampa). Experimentos mostraram que adicionando este método de pré-filtragem ao FBP com filtro da Rampa, pode-se obter uma maior redução do ruído.

Já em (Mascarenhas, Santos *et al.*, 1999) foi proposto filtrar o ruído Poisson das projeções aplicando inicialmente a Transforma de Anscombe. Esta Transformada converte um ruído dependente do sinal em aproximadamente gaussiano, independente do sinal, aditivo com

média zero e variância unitária. Assim, neste domínio, um filtro de Wiener usando filtragem de blocos sobre o domínio da Frequência foi proposto. Após realizar a filtragem, a Inversa da Transformada de Anscombe é aplicada para voltar ao domínio das projeções. Por fim, FBP com filtro Ram-Lak foi utilizado para a reconstrução. Experimentos mostraram que adicionando este método de pré-filtragem ao FBP, houve uma melhora no sinal, reduzindo o ruído consideravelmente.

No artigo (Hongbing, Hsiao *et al.*, 2001) verificou-se empiricamente que o ruído nas projeções calibradas pode ser aproximado por uma Gaussiana com variância dependente do sinal. Assim, a fim de se estabilizar o ruído, uma transformação de escala foi proposta, usando a transformação de logaritmo segmentada. Desta forma, a variância do ruído torna-se aproximadamente constante. A partir disto foi utilizado um filtro de Wiener 2-D no domínio do sinograma para suavizá-lo e reconstrução por FBP com filtro Ram-Lak.

Em (Li, Li *et al.*, 2004) foi proposta a utilização do algoritmo ICM (*Iterated Conditional Modes*) para se obter uma estimativa MAP do sinograma livre de ruído. Aqui, o ruído foi modelado como Gaussiano, mas dependente do sinal. As projeções filtradas foram reconstruídas pelo método FBP.

La Rivière (La Riviere, 2005) propôs utilizar um método para estimar integrais de linha livres de ruído, e assim suavizar o sinograma, pela maximização de uma função objetivo de verossimilhança penalizada (PL) Poisson. O ruído foi modelado como Poisson, mas seu parâmetro incluiu informações para considerar ruído eletrônico Gaussiano. Para maximizar esta função um algoritmo *surrogate* parabólico separável foi utilizado. Seus resultados foram comparados com um método de maximização de PL baseado em Spline (La Riviere e Billmire, 2005), um filtro ATM (*Adaptive Trimmed Mean*) e FBP com filtro de Hanning. Todos os sinogramas suavizados foram reconstruídos por FBP. O método proposto apresentou melhores resultados, especialmente considerando um balanço resolução-variância.

Em (Wang, Li *et al.*, 2006) são propostos dois métodos para filtragem de ruído no domínio do sinograma (além de um de reconstrução), baseados em minimização de função de custo de mínimos quadrados ponderados penalizados (PWLS). Ambos os métodos consideram um funcional de Gibbs para modelar a correlação espacial entre bins e/ou entre projeções adquiridas em ângulos próximos na penalidade e FBP para a reconstrução. O primeiro método tenta estimar o sinograma ideal utilizando um algoritmo iterativo de atualização de Gauss-Seidel para minimizar a função de custo, sendo chamado de GS-PRWLS (onde RW significa

Reponderado). O segundo método KL-PWLS, utiliza a Transformada de Karhunen-Loève (KL) para decorrelacionar projeções adquiridas em ângulos próximos e assim, tentar minimizar uma função de custo em cada componente KL adaptativamente e analiticamente. Os métodos apresentaram bons resultados e semelhantes.

Na tese de doutorado de Fernando V. Salina (Salina, 2007) são propostas e comparadas quatro abordagens para filtragem das projeções: 1) Estimção MAP (*Maximum a Posteriori*), 2) Filtro de Wiener Pontual no Domínio de Anscombe, 3) Limiarização no Domínio Wavelet da Transformada de Anscombe e 4) Filtro de Goodman-Belsher. Para o MAP as densidades *a priori* Gaussiana, Chi-Quadrado, Beta e Gama foram consideradas. Na limiarização no Domínio Wavelet, diferentes limiares foram considerados, sendo utilizadas as famílias Wavelet de Haar e Daubechies. O Filtro de Goodman-Belsher, por sua vez, também trabalha diretamente com o ruído Poisson. Aqui, as projeções filtradas foram reconstruídas por POCS paralelo. Os melhores resultados foram obtidos por Wiener Pontual.

Na dissertação de mestrado de Marcos A. M. Laia (Laia, 2007), desenvolvida no PPG-CC/UFSCar, uma abordagem baseada em filtro de Kalman foi utilizada para filtrar o ruído Poisson das projeções. Entre as várias versões propostas deste método, que é baseado num processo de previsão-correção para estimção da solução, considerou-se a utilização de redes neurais multicamadas do tipo perceptron, filtragem no domínio de Anscombe e diferentes configurações do Kalman. As projeções filtradas foram reconstruídas por FBP. Nos testes realizados, o melhor resultado foi obtido pelo filtro de Kalman descentralizado com uma rede neural do tipo *Perceptron* com três camadas.

No trabalho de (Jiao, Wang *et al.*, 2008) é proposto o uso de Transformada Wavelet Estacionária para filtragem de ruído Gaussiano não estacionário por análise multiescala a partir do sinograma. Em cada escala, os coeficientes Wavelet são restaurados por uma estimativa Bayesiana do coeficiente ideal baseado na estimativa local da variância do ruído. Comparado a outros métodos como Wiener e limiarização no Domínio Wavelet por *Hard e Soft Thresholding*, seu desempenho foi superior.

Em (Wang, Lu *et al.*, 2008), o método GS-PRWLS utilizado em trabalho anterior (Wang, Li *et al.*, 2006) é aplicado sobre coeficientes da Transformada Wavelet Diádica de Mallat-Zhong, considerando que o ruído no sinograma é Gaussiano, dependente de sinal. Os resultados são superiores ao método aplicado diretamente no domínio do sinograma.

Fang e seus colegas (Fang, Zhou *et al.*, 2009) propuseram filtrar um sinograma ruidoso no domínio Wavelet usando uma estimação de MAP que foi derivada da suposição de ruído Gaussiano. A reconstrução foi feita por FBP. O método foi comparado com outros de limiarização no Domínio Wavelet (*Soft e Hard Thresholding*), apresentando melhores resultados.

Em (Zhang, Zhang *et al.*, 2010), um método de filtragem do sinograma baseado em segmentação com reconstrução FBP foi proposto. O primeiro passo do método consiste na remoção de pontos isolados a fim de que não prejudique a estatística de áreas homogêneas do sinograma, mantendo uma distribuição aproximadamente Gaussiana. Para isto foi utilizado um critério para definir os pontos isolados. Em seguida, uma segmentação baseada em corte em grafos é aplicada. Para cada segmento a média e a variância são determinadas e utilizadas para a estimação MAP do sinograma livre de ruído, com verossimilhança Gaussiana (do ruído) e probabilidade *a priori* dada por modelo de Campos Aleatórios Markovianos Gaussianos (GMRF), aplicando o algoritmo iterativo de Gauss-Seidel (GS). O método foi comparado com abordagens PWLS propostas anteriormente, apresentando resultados superiores.

Outra dissertação de mestrado, também desenvolvida no PPG-CC/UFSCar, foi a de Eduardo S. Ribeiro (Ribeiro, 2010), sendo propostas extensões de três abordagens para a comparação. A primeira abordagem considera novas densidades de probabilidade *a priori* para a solução MAP, sendo a Gaussiana Inversa, Nagakami e Weibull. Além disso, foi utilizado janelamento adaptativo para as estimativas locais e teste de hipóteses para se escolher para cada projeção, a densidade mais adequada. A segunda abordagem usa filtros de Wiener Pontual e FIR (*Finite Impulse Response*) no Domínio de Ascombe, também com janelamento adaptativo. Por fim, a terceira abordagem estende o trabalho de (Salina, 2007) ao considerar para a Limiarização no Domínio Wavelet, as bases Symmlets e Coiflets e também outros métodos para se definir o valor de limiar. O método de reconstrução das projeções filtradas usado foi o POCS paralelo.

No artigo (Shtok, Elad *et al.*, 2011), tenta-se recuperar o sinograma livre de ruído baseado em representação esparsa e reconstrução FBP. Os resultados apresentados mostram uma melhora de cerca de 5 dB na relação sinal-ruído (SNR).

No trabalho de (Hu, Liao *et al.*, 2012a) foi proposto aplicar o filtro bilateral no sinograma suavizado por um filtro Gaussiano. O objetivo desta pré-suavização é reduzir a influência de ruídos e artefatos não estacionários. A reconstrução do sinograma filtrado foi realizado por FBP. O método foi comparado ao filtro bilateral, a um filtro contextual, ao filtro

bilateral mediano, ao filtro bilateral multiresolução, ao um método baseado em Non Local Means definido em (Chen, Chen *et al.*, 2011), todos aplicados ao sinograma diretamente. Resultados mostraram que o método proposto apresentou melhor supressão de ruídos, artefatos e preservação de bordas do que os outros métodos.

Os mesmos autores do trabalho anterior propuseram em (Hu, Liao *et al.*, 2012b) substituir a derivada de ordem inteira da difusão Perona-Malik (PMD) por uma derivada de ordem fracional (G-L), obtendo-se assim a difusão Perona-Malik de ordem fracional (FPMD). O método foi comparado ao filtro da mediana, ao filtro de Wiener, ao filtro Gaussiano e à PMD, aplicados no domínio do sinograma, obtendo um bom desempenho em termos visuais e de Raiz do Erro Quadrático Médio (RMSE).

Por fim, em (Tang e Tang, 2012) propuseram um método PWLS multiescala no domínio da projeção, levando em consideração a taxa de amostragem angular. O método foi derivado da conversão de uma equação diferencial parcial de difusão da imagem para o domínio da projeção. Para a filtragem de ruído em cada escala, o método considera funções objetivo MRF (PWLS-MRF) ou soft thresholding (PWLS-ST), com estimativa da variância dos dados de projeção ruidosos em cada escala sendo consideradas. Após, as imagens filtradas são reconstruídas por FBP. Ainda, um método baseado em operador de diferença de Gaussianas foi utilizado para o realce das bordas. Os métodos propostos foram comparados à difusão anisotrópica multiescala no domínio da imagem, sendo que PWLS-MRF apresentou resultado superior, especialmente na preservação da nitidez da imagem.

### **3.2 Revisão de Técnicas de Filtragem Pós-Reconstrução: Domínio da Imagem**

Nesta Seção, apresentaremos métodos que dão enfoque ao passo de filtragem depois da reconstrução, também independente do método de reconstrução utilizado. Vale ressaltar que não estão listados aqui trabalhos que consideram o uso de informações adicionais vindas de fatias adjacentes (3-D) ou de dual CT (duas imagens são adquiridas da mesma cena, o que possibilita utilizar-se de uma mistura delas para reduzir o ruído), como também trabalhos que adicionavam o ruído para simular imagens de baixa dose de radiação. A primeira condição é justificada, pois não estamos considerando também nenhuma informação adicional. Já a última condição se justifica, pois o ruído na imagem reconstruída não tem um modelo bem defi-

nido como é o caso do Poisson nas projeções (Giraldo, Kelm *et al.*, 2009; Geraldo e Mascarenhas, 2011). A seguir, são descritos os trabalhos encontrados.

Em (Sauer e Liu, 1991) foi proposto o uso de uma abordagem de mínimos quadrados restrita não estacionária (NCLS) para filtrar imagens reconstruídas por FBP. O NCLS é baseado em estimativas de autocorrelação local do ruído.

Keselbrenner e seus colegas (Keselbrenner, Shimoni *et al.*, 1992) propuseram o uso de alguns filtros não lineares para filtrar a imagem de CT produzidas por dois tomógrafos proprietários. O modelo do ruído não foi definido, como também os algoritmos de reconstrução não foram citados. Os métodos propostos foram: 1) Suavização baseada em ligação de vizinhos (NLK), 2) Filtro da mediana de K vizinhos mais próximos (KNNM), 3) Filtro da média de K vizinhos mais próximos (KAV) e 4) Um filtro de média ponderada definido por um kernel. Os três primeiros métodos são adaptativos para se definir o número de elementos considerados na estimação dos valores livre de ruído. O método NLK calcula a força de ligação de um caminho de vários pixels vizinhos (passando pelo central) de acordo com o tipo de vizinhança (4- ou 8-conectados) e o número de pontos do caminho. Esta medida de força é definida em termos da maior variação dos níveis de cinza do caminho. Quanto maior a variação, menor é a força de ligação. Isto será utilizado para escolher o número  $k$  de ligações mais fortes que serão utilizados na média ponderada. Por sua vez, o KNNM e o KAV, selecionam  $k$  valores mais próximos ao do pixel central em uma janela de tamanho  $w^2$  que entrarão no cálculo da mediana ou da média a fim de se definir o valor filtrado, respectivamente. Nos testes realizados, o NLK apresentou o melhor resultado.

No trabalho (Escalante-Ramirez e Martens, 1992) foi utilizada uma técnica para representação de imagens chamada transformação polinomial (com polinômios ortonormais a uma função de janela), que no caso de funções de janela Gaussianas, ela consiste na convolução da imagem com derivadas de Gaussianas. Fisicamente, temos que os pesos (coeficientes) dos polinômios obtidos podem ser utilizados para a detecção de mudanças na intensidade. Baseado nos trabalhos de Canny, que indicam que as bordas são bem aproximadas pela derivada de primeira ordem de uma Gaussiana, eles consideram uma medida de energia de primeira ordem para determinar pontos de borda. Entretanto, ruído também é detectado. Para resolver isto um limiar é determinado para escolher entre borda e ruído. Assim, onde sinal for detectado, os coeficientes serão mantidos e no restante serão definidos como zero. Após, uma transformação inversa é executada. Isso fará com que os pontos ruidosos sejam substituídos por

uma média ponderada da janela naquela região. Ainda, uma versão multirresolução é obtida, considerando os coeficientes de ordem zero como a nova imagem de entrada (uma versão borrada da entrada original) a cada nova resolução. Vale ressaltar que eles assumem que o ruído na imagem reconstruída é Gaussiano, aditivo, estacionário de média zero e que a reconstrução foi realizada por FBP com filtro Rampa. Por fim, o método proposto foi testado e comparado com o filtro de Lee e o filtro da Mediana, apresentando desempenho superior, especialmente a versão multirresolução.

Em (Rabbani, 2008) foi proposto para a filtragem de imagens de CT abdominais o uso de um estimador MAP para o coeficiente livre de ruído no domínio de Pirâmide *Steerable*, dado o pixel ruidoso corrompido por ruído Gaussiano, aditivo, branco com média zero. Neste estimador MAP, a densidade de probabilidade *a priori* foi definida como sendo de Laplace local. Os resultados foram comparados com o método de *Bayes Least Squared Gaussian Scale Mixture* (BLS-GSM) e Filtro de Wiener, sendo superiores a estes métodos.

Já em (Ke e Zhang, 2010), o filtro de Wiener foi aplicado em imagens decompostas por Transformada Wavelet 2-D, considerando apenas as duas primeiras escalas. Os resultados apresentados comparam a imagens filtrada e original em diferentes níveis de radiação, onde o PSNR (*Peak Signal-to-Noise Ratio*) melhorou até pouco mais de 2 dB.

Por sua vez, Chen e seus colegas em (Chen, Bao *et al.*, 2010; Chen, Chen *et al.*, 2011) propuseram o uso do método de média ponderada (Non Local Means), cujos pesos são inversamente proporcionais à distância (ou dissimilaridade) entre as áreas do pixel atual e de seus vizinhos. Porém, a vizinhança considerada está dentro de uma área grande de busca de vizinhança. A ideia principal que baseou o uso deste método foi que vizinhanças de pixels do mesmo tecido devem ser mais similares do que de outros. O método proposto apresentou melhora visual e em termos quantitativos de ruído e relação contraste-ruído nas imagens com baixa dose de radiação. Ainda, vale ressaltar que as imagens foram reconstruídas por FBP e que uma implementação paralela deste método foi realizada e seus resultados discutidos em (Wu, Zhang *et al.*, 2011).

Em (Michel-Gonzalez, Cho *et al.*, 2011) um novo filtro de difusão anisotrópica considerando a topologia local da imagem em um modelo de difusão não linear foi proposto. Para definir a topologia local, parâmetros geométricos são derivados da distribuição de intensidades dos pixels locais. Comparado a outros métodos de difusão anisotrópica, Perona-Malik e Weickert, o filtro proposto apresentou resultados similares de filtragem e preservação de bor-

das, mas com maior desempenho computacional. Aqui, as imagens foram reconstruídas pelo algoritmo Feldkamp modificado.

Em (Tao, Brunner *et al.*, 2011) foi proposto filtrar a imagem de diferenças no domínio Wavelet dado pela decomposição Wavelet Não Diádica. A imagem das diferenças corresponde à diferença entre a imagem original ruidosa e uma filtrada ( $I_p$ ) por um filtro da média 5 x 5 (passa-baixa). Medidas de correlação espacial da imagem das diferenças no domínio Wavelet foram calculadas para determinar se uma dada posição é borda ou não, sendo que no último caso os coeficientes serão descartados. Assim, a imagem final filtrada é dada pela soma de  $I_p$  com a imagem obtida pela síntese da componente de bordas. Resultados de filtragem obtidos sobre imagens reconstruídas por FBP mostram boa redução do ruído e boa preservação de resolução espacial.

Geraldo e Mascarenhas em (Geraldo e Mascarenhas, 2011), propuseram o uso de estimação MAP para a filtragem do ruído no domínio da imagem. A verossimilhança tem função de densidade Gaussiana com média zero (ruído considerado). E duas densidades de probabilidade *a priori* foram usadas: Rayleigh e Log-Normal. Os resultados foram comparados com o Filtro de Wiener Pontual, sendo que *a priori* Log-Normal apresentou melhores resultados, melhorando em mais de 2 dB o PSNR na imagem ruidosa.

Os métodos e resultados do parágrafo anterior são apenas uma parcela do que foi feito na dissertação de mestrado de Rafael. J. Geraldo (Geraldo, 2011), também desenvolvida no DC/UFSCar. Além das densidades de probabilidade *a priori* Rayleigh e Log-Normal, foram utilizadas também Beta, Gama, Normal, Nakagami, Weibull, Gaussiana Inversa, Chi-Quadrado e Exponencial. Para uma filtragem adaptativa por considerar a distribuição mais adequada para filtrar cada segmento, um método de segmentação de histograma foi utilizado para encontrar estes segmentos e o teste do Chi-Quadrado foi realizado para determinar a distribuição que mais ajusta os dados do segmento. Ainda, foi considerado também ruído dependente do sinal. Para isto, foi utilizado o método preliminar de estimação de ruído dependente do sinal proposto nesta tese e apresentado na Seção 6.1.2.1. Os diversos métodos foram aplicados a imagens reais reconstruídas por POCS paralelo e seus resultados comparados ao Wiener Pontual, sendo que as versões MAP apresentaram resultados superiores, especialmente a versão adaptativa para os casos de grande variação dos coeficientes de atenuação linear, MAP 2D com as densidade Beta e Weibull para imagens com grande variação na resolução espacial e MAP 2D com densidades Log-Normal e Weibull para imagens homogêneas. Entretanto, o

resultado mais interessante foi que a suposição de ruído dependente do sinal e o consequente uso do método proposto de estimação das variâncias locais do ruído aumentou consideravelmente o desempenho dos métodos.

No trabalho (Li, Yu *et al.*, 2012), foi proposto usar o método Non Local Means (NLM) adaptando ao nível de ruído local, considerando o parâmetro  $h$  que controla a quantidade de suavização do método NLM proporcional ao desvio padrão do ruído. A principal contribuição está na estimação do mapa do ruído que é feita pelo seguinte processo: obtenção dos dados de sinograma pela transformada de Radon, seguido de estimativa da variância do ruído no sinograma (considerando o ruído Poisson e outros efeitos físicos) e aplicação da fórmula analítica propagando o mapa do ruído pelo algoritmo de reconstrução (aqui, considerou-se o FBP). Resultados mostram que incorporando o nível de ruído local, o desempenho de filtragem é superior se comparado ao NLM com valores fixos de  $h$ .

Em (Chen, Yang *et al.*, 2012) foi proposto um algoritmo de dois passos. No primeiro passo, para suprimir especialmente artefatos *streak* (relacionado a altas densidades), difusão não linear 1-D direcional em domínio Wavelet estacionário foi aplicado. O segundo passo, consiste de aplicar o método de Non Local Means com vizinhança de grande escala na imagem obtida no passo anterior. Comparado a um filtro de difusão anisotrópico híbrido (HDCS) e ao Non Local Means, o método proposto apresenta melhor preservação de estrutura e de redução de ruído e artefatos.

Ainda, podemos destacar dois sistemas comerciais iterativos de reconstrução baseados em um problema de otimização segundo um framework Bayesiano (Thibault, Sauer *et al.*, 2007): *Adaptive Statistical Iterative Reconstruction* (ASIR) (Hara, Paden *et al.*, 2009; Silva, Lawder *et al.*, 2010; Van De Casteele, Parizel *et al.*, 2012) e *Iterative Reconstruction in Image Space* (IRIS) (Tipnis, Ramachandra *et al.*, 2010; Bittencourt, Schmidt *et al.*, 2011; Hu, Ding *et al.*, 2011; Hur, Lee *et al.*, 2012). Eles executam pós-filtragem, modelando o problema como uma função objetivo, sendo que a verossimilhança, que representa a formação da imagem, utiliza uma matriz de reprojeção (relacionando assim os dados do sinograma à imagem estimada) e assim, simula o processo de CT a partir da imagem estimada atual. A estimativa inicial é dada por Retroprojeção Filtrada das projeções ruidosas originais. Assim, desvios das projeções calculadas e medidas podem ser utilizados para determinar no domínio da imagem um mapa da correção a ser feita, obtendo assim a nova estimativa da imagem livre de ruído. Este processo é repetido iterativamente, reduzindo o ruído a cada passo. Vale ressaltar ainda

que estes algoritmos consideram um termo de regularização a priori que penaliza estatísticas pobres e preserva os dados. Aplicações destes métodos nas mais diferentes modalidades de CT apontam uma redução de até 70% da dose de radiação, mantendo qualidade. Isto mostra a importância prática do problema de filtragem de ruído em CT.

Por fim, houveram alguns trabalhos que aplicaram uma filtragem no domínio da imagem, porém consideraram informações vindas do sinograma (Borsdorf, Kappler *et al.*, 2008; Borsdorf, Kappler *et al.*, 2009) ou aplicaram filtragem dupla (antes e depois da reconstrução) (Laia, Levada *et al.*, 2008; Ma, Huang *et al.*, 2011).

### 3.3 Discussão e Considerações Finais

Em geral, encontra-se que a maioria dos trabalhos de filtragem em CT são realizados no domínio do sinograma. Como já levantado na seção anterior, isto se justifica pela existência de um modelo bem definido nas projeções como é o caso do Poisson, o que não ocorre no domínio da imagem reconstruída (Giraldo, Kelm *et al.*, 2009; Giraldo e Mascarenhas, 2011). Nota-se inclusive que a filtragem em CT no domínio da imagem é mais recente, tendo atraído maior atenção dos pesquisadores nos últimos três anos. E ainda mais, dos trabalhos encontrados de pós-filtragem, em alguns não há citação ou formulação do modelo do ruído no domínio da imagem. E quando há uma formulação, ela não considera o ruído dependente do sinal.

Além disso, a informação contextual dos pixels foi geralmente ignorada. Com estas motivações para o método, neste trabalho foi proposto o uso de filtragem contextual no domínio da imagem com abordagem de Campos Aleatórios Markovianos e modelagem do ruído como Gaussiano, dependente do sinal (definido a partir de experimentos e justificativas teóricas como o Teorema Central do Limite). Esta abordagem será vista em maiores detalhes, especialmente nos Capítulos 4, 5 e 6, a seguir.

## 4 ABORDAGEM MAP-MRF

Muitas aplicações na área de Processamento de Imagens consistem de problemas inversos mal condicionados, como é o caso de restauração, reconstrução e filtragem de imagens. Matematicamente, um problema é dito mal condicionado no sentido de Hadamard se a sua solução não satisfaz alguma das seguintes condições: 1) ela é única, 2) ela existe ou 3) ela depende continuamente dos dados (Bertero e Boccacci, 1998; Li, 2009).

Por exemplo, se considerarmos apenas os dados iniciais de um sinograma em CT, sem nenhuma outra informação sobre a física embutida no processo de aquisição, podemos ter um espaço de soluções muito grande para o corpo imageado (imagem reconstruída) que geraram este sinograma, especialmente devido ao ruído aleatório. Assim, se considerarmos informações adicionais *a priori*, como o tipo de ruído gerado ou alguma outra informação conhecida sobre o processo físico envolvido na aquisição, pode-se reduzir ou limitar o espaço de soluções para um subconjunto seu. Isto pode implicar em tornar o problema bem condicionado (Bertero e Boccacci, 1998; Won e Gray, 2004; Li, 2009).

Um modo bastante robusto, formal e elegante de se incorporar restrições à solução do problema é pelo uso da Estimacão Bayesiana. Uma restrição importante é a suavidade, que pode ser definida pelo uso de probabilidades *a priori*, considerando o contexto espacial dos pixels (vizinhança de um dado pixel) (Li, 2009; Levada, 2010), que podem ser modeladas por meio de Campos Aleatórios Markovianos (MRF).

Em filtragem, por exemplo, temos que pixels pertencentes a áreas homogêneas devem ter o mesmo nível ou próximos. Desta forma, o uso de filtragem contextual é bastante adequado para a redução de ruído.

Além disso, em geral, para obter a solução Bayesiana, métodos de otimização são utilizados. Portanto, abordaremos no restante deste capítulo os princípios de Campos Aleatórios Markovianos (Seção 4.1), modelos MRF *a priori* (Seção 4.2), métodos para estimacão dos parâmetros destes modelos (Seção 4.3), os princípios de estimacão Bayesiana (Seção 4.4), os algoritmos de otimização combinatória (Seção 4.5) e, completando, algumas considerações finais (Seção 4.6).

#### 4.1 Campos Aleatórios Markovianos (MRF)

A base teórica para trabalhos sobre Campos Aleatórios Markovianos (*Markov Random Fields*) em Processamento de Imagens surgiram, principalmente, a partir da década de 1970 com os trabalhos (Hammersley e Clifford, 1971) e (Besag, 1974), sendo que este primeiro não foi publicado. Nestes trabalhos, a principal contribuição foi o estabelecimento de equivalência entre MRF e GRF (*Gibbs Random Fields*) em estruturas de reticulados (*lattices*) 2-D, que pode corresponder a uma imagem, por exemplo. Esta teoria possui forte embasamento na mecânica estatística, em sistemas de interação de partículas.

A partir destes trabalhos, na década seguinte, começaram a surgir trabalhos mostrando a aplicação de MRFs e GRFs no Processamento de Imagens, especialmente na área de análise de imagens (basicamente em segmentação e restauração de imagens) como os famosos trabalhos dos irmãos Geman (Geman e Geman, 1984) e de Julian Besag (Besag, 1986). Após isto, diversas propostas têm sido apresentadas com importantes avanços, sendo uma área muito ativa atualmente.

Para definirmos o que é um MRF, antes precisamos entender os conceitos de Campo Aleatório e Vizinhança, inclusive com uma notação formalizada.

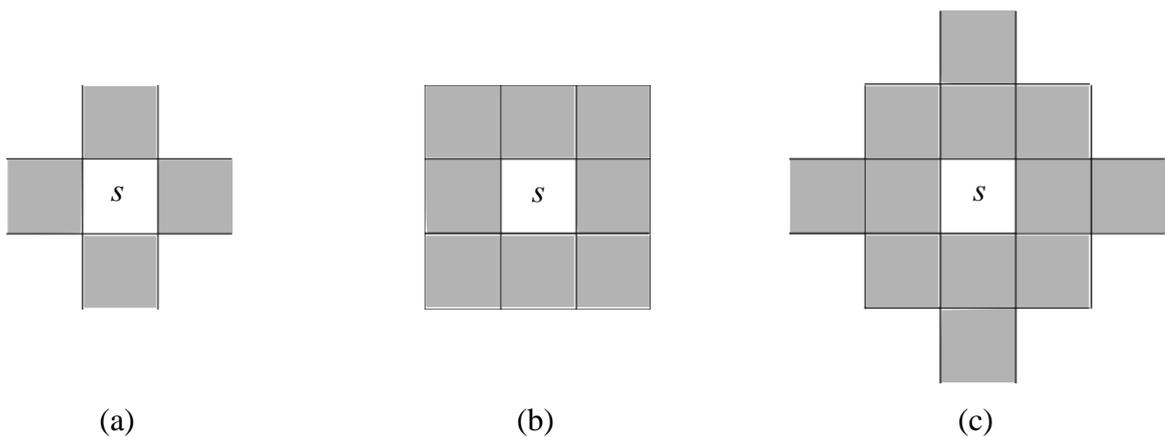
Assim, um Campo Aleatório consiste em um conjunto de variáveis aleatórias  $X = \{X_s\}$ , onde  $X_s$  é uma variável aleatória de índice  $s$  de um total de  $M$  variáveis aleatórias. Além disso, temos que uma realização  $x_s$  de  $X_s$  assume valores dentro de um alfabeto  $A_{X_s}$ , tal que o campo pode ser caracterizado por uma distribuição de probabilidade conjunta  $P_X$ . Ainda, podemos definir o Produto Cartesiano  $A_X = \prod_{s \in M} A_{X_s}$ , como o conjunto das possíveis realizações de  $X$ , ou seja, qualquer realização  $x$  de  $X$  estará contida em  $A_X$ .

Deste modo, temos que uma imagem pode ser modelada por um Campo Aleatório  $X = \{X_s | s \in \Omega\}$ , onde  $\Omega = \{(i, j) | 0 \leq i \leq N_1 - 1, 0 \leq j \leq N_2 - 1\}$  é o conjunto de índices de locais (*site*) em um reticulado 2-D inteiro retangular de  $N_1 \times N_2$  pontos ou pixels. Em geral, em imagens assumimos que o alfabeto  $A_{X_s} = \{0, 1, \dots, 255\}$  é discreto, representando 256 tons de cinza, para qualquer  $s \in \Omega$ .

Dado um Campo Aleatório, podemos definir um sistema de vizinhança sobre ele. Um sistema de vizinhança  $\eta$  com relação a um local  $s$  pode ser definido como um subconjunto de  $\Omega$  como  $\eta = \{\eta_s | s \in \Omega\}$  e  $\eta_s \subset \Omega$ , onde cada local  $\eta_s$  será denominado um vizinho de  $s$ , des-

de que satisfaça as seguintes condições: 1)  $s$  não pertence ao conjunto dos seus vizinhos ( $s \notin \eta_s$ ) e 2) se  $s$  é vizinho de  $t$ , então  $t$  é um de seus vizinhos (reciprocidade), ou seja,  $s \in \eta_t \rightarrow t \in \eta_s$ . Além disso, um sistema de vizinhança apresenta as seguintes propriedades: 1) simetria circular e 2) mesma estrutura para todo  $s \in \Omega$ , exceto nas bordas.

Com base nesta ideia, em geral, na solução dos problemas, uma ordem pode ser dada pelo número de vizinhos que atendem às propriedades e condições para ser um sistema de vizinhança. Desta maneira, temos que a primeira ordem corresponde a quatro vizinhos, a segunda ordem a oito vizinhos, a terceira ordem a doze vizinhos, e assim por diante. As primeiras três ordens são ilustradas na Figura 4.1, já que são as mais utilizadas. A escolha da ordem a ser utilizada é importante, pois interfere na força da suavização da solução, como também no custo computacional.



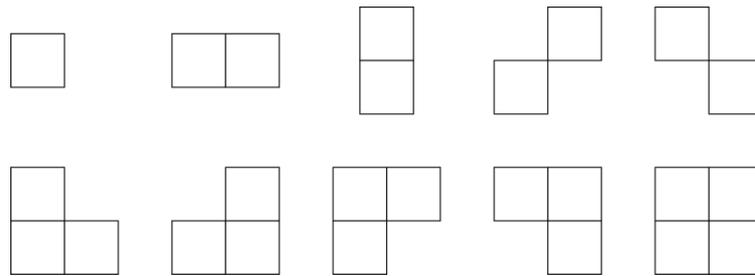
**Figura 4.1.** Ordem de Sistemas de Vizinhança: a) primeira ordem (4 vizinhos), b) segunda ordem (8 vizinhos) e c) terceira ordem (12 vizinhos). Adaptado de (Won e Gray, 2004).

Considerando os conceitos de campo aleatório e sistema de vizinhança apresentados anteriormente, podemos especificar o conceito de Campos Aleatórios Markovianos e Campos Aleatórios de Gibbs.

Um Campo Aleatório  $X$  sobre  $\Omega$  e um sistema de vizinhança  $\eta$  é dito Markoviano se ele satisfaz duas condições: 1) Markovianidade:  $P(X_s = x_s | X_t = x_t, \forall t \in \Omega, t \neq s) = P(X_s = x_s | X_t = x_t, \forall t \in \eta_s)$  para  $\forall s \in \Omega$  e 2) Positividade:  $P(x) > 0$  para  $\forall x \in A_X$ . Markovianidade nos diz que a probabilidade condicional de uma variável aleatória  $X_s \in X$  dado todas as outras variáveis aleatórias em  $X$  depende apenas dos seus vizinhos. Já a positividade

nos diz que toda realização de  $X$  terá probabilidade conjunta maior que zero. Assim, podemos dizer que  $X$  é determinado apenas por suas probabilidades condicionais locais (Won e Gray, 2004; Li, 2009).

Antes de conceituarmos um Campo Aleatório de Gibbs, primeiramente, necessitamos entender o conceito de um clique. Na Teoria de Grafos, um clique  $c$  consiste em um subgrafo completo de um grafo  $G$ , ou seja, todos os vértices (pixels de uma imagem) de  $c$  terão uma aresta a cada outro. Assim, para cada sistema de vizinhança teremos um conjunto  $\mathcal{C}$  de cliques. Além disso, a cada clique  $c$  podemos ter associado um potencial de clique  $V_c(x)$ , que corresponde a uma função das variáveis aleatórias do campo. A Figura 4.2 ilustra os cliques definidos para um sistema de vizinhança de segunda ordem.



**Figura 4.2.** Cliques para um sistema de vizinhança de segunda ordem. Baseada em (Won e Gray, 2004).

Portanto, temos que um dado Campo Aleatório  $X$  sobre  $\Omega$ , um sistema de vizinhança  $\eta$  e seu conjunto de cliques  $\mathcal{C}$  é dito de Gibbs se sua distribuição conjunta é definida por uma distribuição de Gibbs (Won e Gray, 2004; Li, 2009)

$$P(x) = \frac{1}{Z} e^{-U(x)}, \quad (4.1)$$

onde  $Z$  é denominada função de partição, caracterizando uma constante de normalização, dada pelo somatório de  $e^{-U(x)}$  para todas as possíveis realizações  $x \in A_X$ . Como o número de realizações pode ser gigantesco, avaliar  $Z$  torna-se intratável.

Por sua vez,  $U(x)$  é chamada função de energia e pode ser definida por meio de potenciais  $V_c(x)$  dos cliques  $c \in \mathcal{C}$ , ficando como

$$U(x) = \sum_{c \in C} V_c(x). \quad (4.2)$$

Assim, temos que o conhecimento *a priori*, tal como restrições de suavidade podem ser definidas através dos cliques e seus potenciais (Won e Gray, 2004). Por exemplo, um potencial mínimo poderia ser definido se os pixels naquele clique tivessem o mesmo nível de cinza.

Por fim, o resultado mais importante para as aplicações é fornecido pelo Teorema de Hammerley-Clifford. Ele estabelece uma equivalência entre MRF (local) e GRF (global), ao provar que um Campo Aleatório  $X$  sobre  $\Omega$ , um sistema de vizinhança  $\eta$  e seu conjunto de cliques  $C$  é um MRF se e somente se a sua probabilidade conjunta  $P(x)$  segue uma distribuição de Gibbs, ou seja, podemos obter distribuição conjunta das probabilidades condicionais locais (e o contrário), implicando que esta última pode ser dada em termos de potenciais de clique (Won e Gray, 2004). Para isto existem modelos de Campos Aleatórios Markovianos, sendo alguns deles apresentados na próxima Seção.

## 4.2 Modelos de Campos Aleatórios Markovianos

Diversos modelos Markovianos que consideram a informação contextual foram propostos na literatura. Estes modelos são adequados, principalmente, para representar o conhecimento *a priori* por meio de distribuições de probabilidade. Os modelos apresentados só consideram a interação por pares, ou seja, entre o pixel central e cada um de seus vizinhos. A ideia de se considerar estes modelos consiste em definir restrições de suavidade (maiores detalhes na Seção 4.4), especialmente, devido a termos uma correlação alta entre pixels de uma região homogênea (Levada, 2010).

Um dos modelos mais utilizados é chamado de modelo de Potts (ou Potts-Strauss) (Geman e Geman, 1984). Este é um modelo Markoviano discreto, ou seja, o alfabeto  $A_{X_s}$  é um valor inteiro. Este modelo pode ser definido através das probabilidades condicionais locais como

$$p(x_s = m | \{x_t, t \in \eta_s\}, \beta) = \frac{\exp\{\beta U_s(m)\}}{\sum_l^M \exp\{\beta U_s(l)\}} \quad (4.3)$$

onde  $m$  representa um valor de pixel entre  $M$  possíveis (para o nosso caso de filtragem  $M=256$ ),  $U_s(m)$  representa uma função de energia, que neste modelo é o número de vizinhos

que possuem o mesmo valor  $m$  e  $\beta$  é um parâmetro que representa o peso dado à função de energia e que deverá ser estimado, sendo que neste trabalho isto será realizado por meio de estimação de Máxima Pseudo-Verossimilhança (Besag, 1975) (ver a próxima Seção).

Uma extensão do modelo de Potts, que considera uma contribuição contínua dos pixels vizinhos é o modelo *Generalized Isotropic Multi-Level Logistic* (GIMLL), modificando apenas a definição da função de energia  $U_s(m)$  para

$$U_s(m) = \sum_{x_t, t \in \eta_s} [1 - 2e^{-(m-x_t)^2}]. \quad (4.4)$$

Se observarmos esta função de energia, vemos que a contribuição é dada por uma norma L2. Assim, podemos definir outra versão do GIMLL, considerando uma norma L1, que denominaremos de GIMLL-L1, ficando como

$$U_s(m) = \sum_{x_t, t \in \eta_s} [1 - 2e^{-|m-x_t|}]. \quad (4.5)$$

Por fim, outro modelo muito utilizado é o MRF Gaussiano (GMRF), também chamado de modelo auto-normal, cujas probabilidades condicionais locais são dadas por (Li, 2009)

$$\begin{aligned} p(x_s = m | \{x_t, t \in \eta_s\}, \beta, \mu_s, \sigma_s^2) \\ = \frac{1}{\sqrt{2\pi\sigma_s^2}} e^{-\frac{1}{2\sigma_s^2}[m-\mu_s-\beta \sum_{x_t, t \in \eta_s}(x_t-\mu_s)]^2}, \end{aligned} \quad (4.6)$$

onde  $\mu_s$  e  $\sigma_s^2$  correspondem a média e variância locais estimados em uma janela ao redor de  $s$ .

Para se estimar o parâmetro  $\beta$  no GMRF, existe uma fórmula fechada para o estimador de Máxima Pseudo-Verossimilhança, que é definida por

$$\hat{\beta}_{MPL} = \frac{\sum_s [(x_s - \mu) \sum_{x_t, t \in \eta_s} (x_t - \mu)]}{\sum_s [\sum_{x_t, t \in \eta_s} (x_t - \mu)]^2}, \quad (4.7)$$

Onde  $\mu$  é a média global do campo.

Vale ressaltar que não há expressão fechada para o estimador de Máxima Pseudo-Verossimilhança para o parâmetro  $\beta$  nos modelos de Potts e GIMLL. Ele será estimado numericamente, pelo processo definido na próxima seção.

### 4.3 Estimação de Parâmetros por Máxima Pseudo-Verossimilhança para Potts, GIMLL e GIMLL-L1

Os modelos Potts, GIMLL e GIMLL-L1 definidos na Seção anterior, possuem um parâmetro que precisa ser estimado:  $\beta$ . Existem diversos métodos para estimar este parâmetro, sendo que talvez a escolha inicial fosse o método da Máxima Verossimilhança para a distribuição de Gibbs. Porém, como observado anteriormente, a função de partição é intratável (Won e Gray, 2004) e isto “inviabiliza a definição da função de verossimilhança” (Levada, 2010).

Desta forma, uma boa alternativa é o uso do método de estimação da Máxima Pseudo-Verossimilhança (MPV) sobre as funções de densidade de probabilidade locais, que para os modelos de Potts, GIMLL e GIMLL-L1 é dada por (Martins, Levada *et al.*, 2009; Levada, 2010)

$$\frac{\partial}{\partial \beta} \log PL(\beta) = \sum_{s \in \Omega} U_s(m_s) - \sum_{s \in \Omega} \left[ \frac{\sum_l^M U_s(l) \exp\{\beta U_s(l)\}}{\sum_l^M \exp\{\beta U_s(l)\}} \right] = 0, \quad (4.8)$$

onde  $U_s(m)$  é função de energia do modelo e  $M$  é o número de valores de pixel possíveis.

No caso do modelo de Potts há uma simplificação para a estimativa MPV implementada na tese de doutorado de Alexandre L. M. Levada (Levada, 2010), que para o caso de sistemas de vizinhança de segunda ordem é dada por

$$\begin{aligned} \frac{\partial}{\partial \beta} \log PL(\beta) = & \sum_{s \in \Omega} U_s(m_s) - \frac{8e^{8\hat{\beta}}}{e^{8\hat{\beta}+M-1}} K_1 - \frac{7e^{7\hat{\beta}+e\hat{\beta}}}{e^{7\hat{\beta}+e\hat{\beta}+M-2}} K_2 \\ & - \frac{6e^{6\hat{\beta}+2e^2\hat{\beta}}}{e^{6\hat{\beta}+e^2\hat{\beta}+M-2}} K_3 - \frac{6e^{6\hat{\beta}+2e\hat{\beta}}}{e^{6\hat{\beta}+2e\hat{\beta}+M-3}} K_4 - \frac{5e^{5\hat{\beta}+3e^3\hat{\beta}}}{e^{5\hat{\beta}+e^3\hat{\beta}+M-2}} K_5 \\ & - \frac{5e^{5\hat{\beta}+2e^2\hat{\beta}+e\hat{\beta}}}{e^{5\hat{\beta}+e^2\hat{\beta}+e\hat{\beta}+M-3}} K_6 - \frac{5e^{5\hat{\beta}+3e\hat{\beta}}}{e^{5\hat{\beta}+3e\hat{\beta}+M-4}} K_7 - \frac{8e^{4\hat{\beta}}}{2e^{4\hat{\beta}+M-2}} K_8 \\ & - \frac{4e^{4\hat{\beta}+3e^3\hat{\beta}+e\hat{\beta}}}{e^{4\hat{\beta}+e^3\hat{\beta}+e\hat{\beta}+M-3}} K_9 - \frac{4e^{4\hat{\beta}+4e^2\hat{\beta}}}{e^{4\hat{\beta}+2e^2\hat{\beta}+M-3}} K_{10} - \frac{4e^{4\hat{\beta}+2e^2\hat{\beta}+2e\hat{\beta}}}{e^{4\hat{\beta}+e^2\hat{\beta}+2e\hat{\beta}+M-4}} K_{11} \\ & - \frac{4e^{4\hat{\beta}+4e\hat{\beta}}}{e^{4\hat{\beta}+4e^2\hat{\beta}+M-5}} K_{12} - \frac{6e^{3\hat{\beta}+2e^2\hat{\beta}}}{2e^{3\hat{\beta}+e^2\hat{\beta}+M-3}} K_{13} - \frac{6e^{3\hat{\beta}+2e\hat{\beta}}}{2e^{3\hat{\beta}+2e\hat{\beta}+M-4}} K_{14} \\ & - \frac{3e^{3\hat{\beta}+4e^2\hat{\beta}+e\hat{\beta}}}{e^{3\hat{\beta}+2e^2\hat{\beta}+e\hat{\beta}+M-4}} K_{15} - \frac{3e^{3\hat{\beta}+2e^2\hat{\beta}+3e\hat{\beta}}}{e^{3\hat{\beta}+e^2\hat{\beta}+3e\hat{\beta}+M-5}} K_{16} - \frac{3e^{3\hat{\beta}+5e\hat{\beta}}}{e^{3\hat{\beta}+5e\hat{\beta}+M-6}} K_{17} \\ & - \frac{8e^{2\hat{\beta}}}{4e^{2\hat{\beta}+M-4}} K_{18} - \frac{6e^{2\hat{\beta}+2e\hat{\beta}}}{3e^{2\hat{\beta}+2e\hat{\beta}+M-5}} K_{19} - \frac{4e^{2\hat{\beta}+4e\hat{\beta}}}{2e^{2\hat{\beta}+4e\hat{\beta}+M-6}} K_{20} \\ & - \frac{2e^{2\hat{\beta}+6e\hat{\beta}}}{e^{2\hat{\beta}+6e\hat{\beta}+M-7}} K_{21} - \frac{8e^{\hat{\beta}}}{8e^{\hat{\beta}+M-8}} K_{22} = 0, \quad (4.9) \end{aligned}$$

onde  $U_s(m)$  é a função de energia do modelo de Potts,  $M$  é o número de valores de pixel possíveis e para cada termo teremos uma fração correspondendo ao peso do número de ocorrên-

cias  $K_i$  de um determinado padrão de realização espacial no campo. É importante destacar que esta equação é válida para um número arbitrário de valores de pixel possíveis  $M$ , porém o custo computacional da estimação está diretamente relacionado ao seu valor (Levada, 2010).

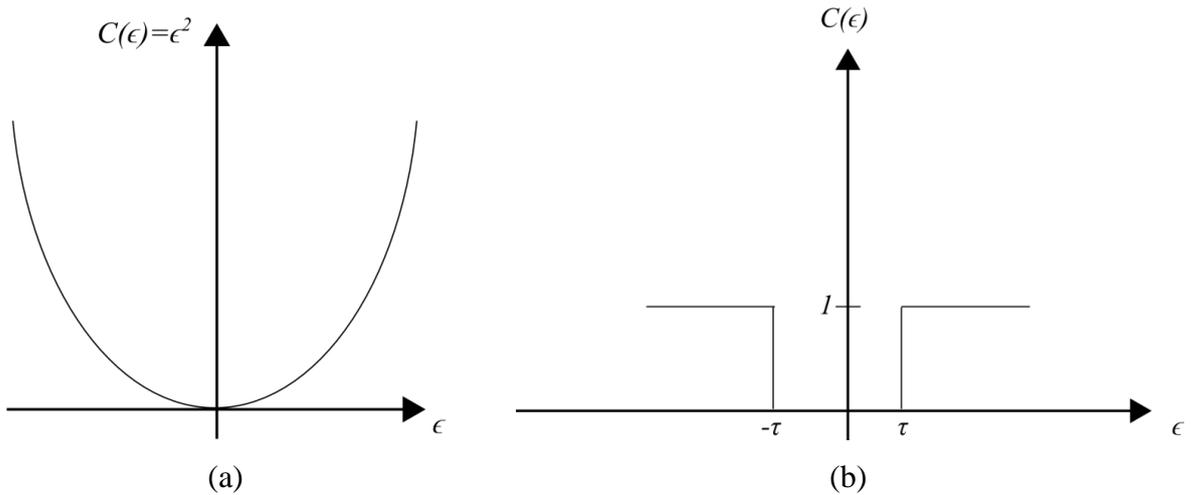
Vale ressaltar ainda que a solução MPV para ambos os modelos é determinada numericamente. Em (Levada, 2010) e (Martins, Levada *et al.*, 2009) isto foi realizado pelo algoritmo de Brent (Brent, 1973). Além disso, neste trabalho se utilizaram somente sistemas de vizinhança de segunda ordem para os modelos propostos acima. Desta forma, com a estimação do parâmetro para  $\beta$ , os modelos Markovianos estão completamente especificados, bastando para isso serem incluídos em algum método que os considere. Aqui, isto será feito via Estimação Bayesiana.

#### 4.4 Estimação Bayesiana

A teoria de estimação Bayesiana estabelece que a estimativa  $\hat{x} = \hat{x}(y)$  a ser escolhida é aquela que minimiza o risco de Bayes ou valor esperado de uma função de custo  $E[C(X, \hat{x}(Y))]$ , onde  $C(x, \hat{x}) \geq 0$  é o custo de se estimar pelo valor  $\hat{x}$  a partir do valor observado  $y$ , quando  $x$  é o valor verdadeiro. Dentre as funções de custo mais utilizadas, podemos citar a função de custo quadrático (Figura 4.3a), a função de custo uniforme (Figura 4.3b), a função de custo de valor absoluto do erro e a distância de Hamming, onde  $\epsilon = x - \hat{x}$  é o erro de estimação.

A função de custo quadrático tem por característica penalizar fortemente erros grandes e pode ser definida como  $C(x, \hat{x}) = (x - \hat{x})^2$ . Deste modo, temos que minimizar o risco de Bayes corresponde a minimizar o Erro Médio Quadrático pelo valor esperado condicional *a posteriori*  $E[x|y]$ , definindo o estimador Mínimo Erro Médio Quadrático (MMSE) (Kay, 1993; Won e Gray, 2004).

Por sua vez, a função de custo absoluto do erro, definida como  $C(x, \hat{x}) = |x - \hat{x}|$ , pondera menos os erros grandes e leva ao estimador de Mediana a Posteriori (Kay, 1993).



**Figura 4.3.** Exemplos de funções de custo: a) quadrática e b) uniforme. Baseada em (Kay, 1993).

Já a função de custo uniforme tem a característica principal de penalizar os erros igualmente ( $C(x, \hat{x}) = 1$ ). Um erro de estimação é realmente considerado “erro”, quando  $|\epsilon| \geq \tau$ , sendo  $\tau > 0$ . Assim, são considerados “acertos” ( $C(x, \hat{x}) = 0$ ) pequenos erros de estimação  $|\epsilon| < \tau$ . Ela pode ser representada pela equação (Won e Gray, 2004)

$$C(x, \hat{x}) = 1 - \delta[x - \hat{x}] = \begin{cases} 1, & \text{se } x \neq \hat{x} \\ 0, & \text{se } x = \hat{x}. \end{cases} \quad (4.10)$$

Por fim, a distância de Hamming define uma função de custo que equivale proporcionalmente ao número de erros, sendo definida como (Won e Gray, 2004)

$$C(x, \hat{x}) = \sum_{s \in \Omega} [1 - \delta[x_s - \hat{x}_s]], \quad (4.11)$$

onde  $\Omega = \{(i, j) | 0 \leq i \leq N_1 - 1, 0 \leq j \leq N_2 - 1\}$  é o conjunto de índices de uma imagem de tamanho  $N_1 \times N_2$  pixels.

A partir disto, podemos definir as estimativas ótimas de Bayes considerando estas funções de custo, especialmente uniforme e distância de Hamming. Como mencionado anteriormente, a estimativa de Bayes é definida pela minimização do valor esperado da função de custo, podendo ser simplificado como (Won e Gray, 2004; Levada, 2010)

$$\begin{aligned}
E[C(X, \hat{x}(Y))] &= \sum_x \sum_y C(x, \hat{x}(y))P(x, y) \\
&= \sum_x \sum_y C(x, \hat{x}(y))P(x|y)P(y) \\
&= \sum_y E[C(X, \hat{x}(Y))|Y = y]P(y),
\end{aligned} \tag{4.12}$$

onde  $X = \{x_s | s \in \Omega\}$  e  $Y = \{y_s | s \in \Omega\}$  são a imagem verdadeira e a observada, respectivamente. Assim, como  $P(y)$  não é função de  $x$ , temos que a estimativa ótima de Bayes  $\hat{x}$ , será a função que minimiza o valor esperado condicional do custo  $E[C(X, \hat{x}(Y))|Y = y]$ , para qualquer  $y$ .

Com isso, o estimador ótimo para a função de custo quadrático é obtido da seguinte forma (Kay, 1993), em termos discretos

$$\begin{aligned}
\frac{\partial}{\partial \hat{x}(y)} \sum_x C(x, \hat{x}(y))P(x|y) &= 0 \\
-2 \sum_x [(x - \hat{x}(y))P(x|y)] &= 0 \\
\hat{x}(y) \sum_x P(x|y) &= \sum_x xP(x|y).
\end{aligned} \tag{4.13}$$

Como  $\sum_x P(x|y) = 1$ , temos que

$$\hat{x}(y) = \sum_x xP(x|y). \tag{4.14}$$

Assim, lembrando que  $\sum_x xP(x|y) = E[x|y]$ , temos que minimizar o risco de Bayes para a função de custo quadrático equivale a obter o valor esperado *a posteriori*. Podemos resumir este processo, como

$$\hat{x}_{MMSE} = E[x|y]. \tag{4.15}$$

Por sua vez, o estimador ótimo para a função de custo uniforme é definido por (Won e Gray, 2004)

$$\begin{aligned}
E[C(X, \hat{x}(Y))|Y = y] &= \sum_x C(x, \hat{x}(y))P(x|y) \\
&= \sum_x [(1 - \delta[x - \hat{x}(y)])P(x|y)] \\
&= 1 - P(\hat{x}(y)|Y = y).
\end{aligned} \tag{4.16}$$

Deste modo, minimizar o risco de Bayes para a função de custo uniforme equivale a encontrar o  $\hat{x}(y)$  que maximiza a probabilidade *a posteriori*  $P(\hat{x}(y)|Y = y)$ . Devido a isto, temos a conhecida estimação MAP (*Maximum a Posteriori*), sendo considerada muito conservadora (Marroquin, Mitter *et al.*, 1987). Ainda, de acordo com o Teorema de Bayes, temos que maximizar  $P(x|y)$  equivale a maximizar  $P(y|x)P(x)$ , onde  $P(y|x)$  representa o processo de formação da imagem e  $P(x)$  conhecimento *a priori* sobre  $x$ . Podemos resumir todo este processo para o MAP como a equação (Levada, 2010)

$$\begin{aligned}
\hat{x}_{MAP} &= \arg \max_x P(x|y) \\
&= \arg \max_x P(y|x)P(x) = \arg \max_x [\log P(y|x) + \log P(x)].
\end{aligned} \tag{4.17}$$

Para a função de custo dada pela distância de Hamming, o estimador ótimo é dado por (Won e Gray, 2004)

$$\begin{aligned}
E[C(X, \hat{x}(Y))|Y = y] &= \sum_x C(x, \hat{x}(y))P(x|y) \\
&= \sum_x \sum_{s \in \Omega} [(1 - \delta[x_s - \hat{x}_s])P(x|y)] \\
&= N_1 N_2 - \sum_{s \in \Omega} \left[ \sum_x \delta[x_s - \hat{x}_s] P(x|y) \right] \\
&= N_1 N_2 - \sum_{s \in \Omega} \left[ \sum_{x_{s-}} \sum_{x_s} \delta[x_s - \hat{x}_s] P(x|y) \right] \\
&= N_1 N_2 - \sum_{s \in \Omega} \left[ \sum_{x_{s-}} P(x_s = \hat{x}_s, x_{s-}|y) \right],
\end{aligned} \tag{4.18}$$

onde  $x_{s-} = \{x_t | t \in \Omega, t \neq s\}$  consiste no conjunto de todos os pixels da imagem, exceto o pixel atual  $x_s$  e  $\sum_{x_{s-}} P(x_s = \hat{x}_s, x_{s-}|y)$  é a probabilidade *a posteriori* marginal de  $P(x|y)$

para  $x_{s-}$  com  $x_s = \hat{x}_s$ . Ou seja, para esta função de custo, minimizar o Risco de Bayes equivale a maximizar as probabilidades *a posteriori* marginais para todo pixel da imagem. Devido a isto, este estimador é denominado *Maximizer of the Posterior Marginal* (MPM), cujo processo pode ser resumido pela igualdade (Won e Gray, 2004)

$$\hat{x}_s(y) = \arg \max_{\hat{x}_s} \left[ \sum_{x_{s-}} P(x_s = \hat{x}_s, x_{s-} | y) \right] = \arg \max_{x_s} P(x_s | y),$$

$$\forall s \in \Omega. \quad (4.19)$$

Como para se computar as probabilidades *a posteriori* marginais exige um somatório sobre praticamente todos os pixels para se determinar cada estimativa  $\hat{x}_s(y)$ , o custo computacional deste método é enorme. Assim, uma abordagem é resolver este problema usando o processo de amostragem de Markov Chain Monte Carlo (MCMC). Deste modo, na próxima seção veremos os algoritmos de otimização para se encontrar a solução para esses estimadores.

## 4.5 Algoritmos de Otimização Combinatória

Na comunidade científica de análise de imagens estatística é conhecido que existe um método chamado de *Simulated Annealing* (Li, 2009) que pode obter a solução mínima global para a estimação MAP. Porém, este método é extremamente lento. Assim, existem alguns outros algoritmos iterativos subótimos (atingem um mínimo local) para a Estimação Bayesiana, sendo abordado aqui, o *Iterated Conditional Modes* (ICM), *Game Strategy Approach* (GSA) e *Maximizer of Posterior Marginals* (MPM).

### 4.5.1 Iterated Conditional Modes (ICM)

O algoritmo *Iterated Conditional Modes* (ICM) foi proposto por (Besag, 1986) e tem como principal característica ser determinístico. A ideia central aqui é estimar a solução MAP de  $X$  localmente, ou seja, para cada pixel individualmente  $X_s$ . Para isso, a cada iteração escolha-se (Won e Gray, 2004)

$$x_s^* = \arg \max_{x_s} P(x_s | x_{s-}, y), \quad (4.20)$$

onde  $x_s$  é a estimativa livre de ruído corrente do pixel atual,  $x_{s-}$  são todos os outros pixels da estimativa corrente imagem livre de ruído e  $y$  é o valor observado (pixel ruidoso). Com base nisso e observando que  $P(x|y) = P(x_s|x_{s-}, y)P(x_{s-}|y)$ , temos que, ao maximizar a probabilidade *a posteriori* localmente estamos maximizando também o critério MAP  $P(x|y)$ , sendo dependente da inicialização. Em geral, esta inicialização é dada pela estimativa de Máxima Verossimilhança  $\hat{x}_s = \arg \max_{x_s} P(Y_s = y_s | X_s = x_s)$  para todo pixel  $s$  na imagem. Este é considerado um método muito rápido, especialmente se comparado ao *Simulated Annealing*, convergindo em poucas iterações (menos de 10, geralmente). O Algoritmo 4.1 representa o ICM para a filtragem.

Vale ressaltar que na etapa (1), esta inicialização pode ser feita também por algum método de suavização como o filtro da média ou outra pré-filtragem. Por fim, temos também que podemos considerar como condição de parada (etapa (3)) além do número de iterações outra como um número mínimo de pixels alterados de uma iteração para outra a ser atingido (o que vier primeiro).

**Algoritmo 4.1.** Pseudocódigo do método *Iterated Conditional Modes* (ICM) para filtragem contextual. Baseado em (Dubes e Jain, 1993; Levada, 2010).

---

**Entradas:** Uma imagem ruidosa  $Y$  com  $M = N_1 \times N_2$  pixels

O número máximo de iterações  $N_{iter}$

O modelo Markoviano *a priori*  $P_X$

A função de densidade de probabilidade da verossimilhança  $P_{Y|X}$

**Saída:** Uma estimativa MAP da imagem livre de ruído  $X$

---

- (1) Inicializar a estimativa corrente  $\hat{x}$  que maximiza para cada pixel  $\hat{x}_s$  a verossimilhança  $P(Y_s = y_s | X_s = x_s)$
  - (2)  $n = 0$
  - (3) **Enquanto**  $n \leq N_{iter}$
  - (4)     Estimar o parâmetro  $\beta$  dos modelos por MPV
  - (5)     **Para** todo pixel  $s = 1, \dots, M$  **fazer**
  - (6)         Atualizar  $\hat{x}_s$  com o valor de  $x_s$  que maximiza (com base em  $P_{Y|X}$  e  $P_X$ )
 
$$P(X_s = x_s | x_{s-}, y) \propto P(Y_s = y_s | X_s = x_s)P(X_s = x_s | X_s = x_{s-})$$
  - (7)     **Fim-Para**
  - (8) **Fim-Enquanto**
-

#### 4.5.2 Game Strategy Approach (GSA)

O algoritmo *Game Strategy Approach* (GSA) foi proposto por (Yu e Berthod, 1995) fazendo uma analogia com a teoria de jogos não cooperativos de  $n$ -jogadores, também com a finalidade de se encontrar uma estimativa MAP de forma não determinística, ou seja, neste caso depende menos da inicialização (ou estimativa inicial) do que o ICM.

Seja um jogo (reticulado/imagem) de  $n$ -jogadores (pixels), cujo conjunto de jogadores pode ser definido por  $I = \{1, 2, \dots, n\}$ . Cada jogador  $i$  possui um conjunto  $S_i$  de estratégias puras (valores de pixel possíveis). Neste tipo de jogo, cada jogador deve selecionar uma estratégia  $s_i \in S_i$ , definindo uma jogada (realização do campo)  $s = (s_1, \dots, s_n)$ , sendo que cada jogador atinge um ganho (função de energia)  $H_i(s)$ . Além disso, é suposto que cada jogador conhece todas as possíveis estratégias e o ganho sobre cada jogada (Yu e Berthod, 1995). Assim, pode-se definir uma estratégia mista (funções de densidade condicionais locais) como uma distribuição de probabilidade sobre o conjunto de estratégias puras, tal que neste caso o ganho  $H_i(s)$  de um jogador é definido somente em função da sua própria estratégia e a de seus vizinhos (Levada, 2010).

Neste tipo de jogo, cada jogador deve procurar maximizar o seu ganho unilateralmente com base nas suas próprias estratégias como definido em (Yu e Berthod, 1995)

$$H_i(s^*) = \max_{s_i \in S_i} H_i(s^* || s_i), \quad \forall i \in I, \quad (4.21)$$

onde  $s^* || s_i$  representa a jogada obtida substituindo  $s_i^*$  por  $s_i$ . Sendo que a solução para este jogo, que sempre existe, é dada quando nenhum jogador consegue elevar o seu ganho unilateralmente, atingindo um ponto de equilíbrio, que corresponde ao equilíbrio de Nash (Nash, 1950), denotado aqui por  $s^* = (s_1^*, \dots, s_n^*)$  (Yu e Berthod, 1995).

Assim, temos que os pontos de máximo (MAP) correspondem ao equilíbrio de Nash. E a cada iteração do GSA, temos que a solução se aproxima do equilíbrio de Nash, tal como mostram dois teoremas apresentados em (Yu e Berthod, 1995).

O Algoritmo 4.2 representa o GSA para a filtragem. Este algoritmo difere do ICM, por ser não determinístico. Seu processo básico consiste em, partindo de uma inicialização, cada jogador define uma nova estratégia que maximize o seu ganho. Se o seu ganho for menor do que o ganho da jogada anterior, ele continua com a mesma estratégia, caso contrário, ele deverá aceitá-la com probabilidade  $\alpha$  ou manter a anterior com probabilidade  $1 - \alpha$ , sendo

$\alpha = (0,1)$ . Isto é feito até que o Equilíbrio de Nash ou o número de iterações seja atingido. Se  $\alpha = 1$  (ou seja, sempre aceita), pode equivaler ao ICM.

**Algoritmo 4.2.** Pseudocódigo do método *Game Strategy Approach* (GSA) para filtragem contextual. Baseado em (Berthod, Kato *et al.*, 1996; Levada, 2010).

---

**Entradas:** Uma imagem ruidosa  $Y$  com  $M = N_1 \times N_2$  pixels

O número máximo de iterações  $N_{iter}$

A probabilidade de aceitação de novas estratégias (valores para o pixel)  $\alpha$

O modelo Markoviano *a priori*  $P_X$

A função de densidade de probabilidade da verossimilhança  $P_{Y|X}$

**Saída:** Uma estimativa MAP da imagem livre de ruído  $X$

---

(1) Inicializar a estimativa inicial da imagem livre de ruído  $\hat{x}^{(0)} = (\hat{x}_1^{(0)}, \dots, \hat{x}_M^{(0)})$

(2)  $n = 0$

(3) **Enquanto**  $n \leq N_{iter}$

(4) Estimar o parâmetro  $\beta$  dos modelos por MPV

(5) **Para** todo pixel (jogador)  $i = 1, \dots, M$  **fazer**

(6) Escolher um valor de pixel (estratégia) diferente do atual  $\hat{x}'_i \neq \hat{x}_i^{(n)}$ , que maximize o ganho deste jogador localmente (com base em  $P_{Y|X}$  e  $P_X$ )

$$H_i(\hat{x}_i^{(n)} || \hat{x}'_i) = \max_{\hat{x}_i} [H_i(\hat{x}_i^{(n)} || \hat{x}_i)]$$

(7) **Se**  $H_i(\hat{x}_i^{(n)} || \hat{x}'_i) \leq H_i(\hat{x}_i^{(n)} || \hat{x}_i^{(n)})$  **Então** mantém a estratégia  $\hat{x}_i^{(n+1)} = \hat{x}_i^{(n)}$

(8) **Senão**

(9) Aceitar a nova estratégia  $\hat{x}'_i$  com probabilidade  $\alpha$ , ou seja,

(10)  $\hat{x}_i^{(n+1)} = \hat{x}'_i$  com probabilidade  $\alpha$  ou,

(11)  $\hat{x}_i^{(n+1)} = \hat{x}_i^{(n)}$  com probabilidade  $1 - \alpha$ .

(12) **Fim-Se**

(13)  $\hat{x}^{(n+1)} = (\hat{x}_1^{(n+1)}, \dots, \hat{x}_M^{(n+1)})$

(14) **Se**  $\hat{x}^{(n+1)}$  é o Equilíbrio de Nash **Então** pare

(15) **Senão**

(16)  $n = n + 1$

(17) **Fim-Se**

(18) **Fim-Para**

(19) **Fim-Enquanto**

---

### 4.5.3 Maximizer of Posterior Marginals (MPM)

O algoritmo *Maximizer of Posterior Marginals* (MPM), ao contrário dos dois anteriores não segue uma estimativa MAP, mas uma estimativa de mesmo nome (definida na Seção 4.5), derivada da Estimação Bayesiana considerando a função de custo dada por distância de Hamming.

A obtenção das probabilidades marginais, geralmente é feita via simulação de cadeias de Markov sobre um conjunto de  $G^M$  estados, representando todas as realizações possíveis de um campo aleatório, tal como métodos de Markov Chain Monte Carlo (MCMC). Esta forma de amostrar as probabilidades marginais para o MPM foi proposta em (Marroquin, Mitter *et al.*, 1987).

O resultado mais importante para o algoritmo MPM, dado pelos métodos MCMC, ocorre quando uma cadeia de Markov atinge o seu estado de equilíbrio. Neste caso temos que as realizações após este ponto, correspondem a amostras das distribuições *a posteriori*. Assim, temos que as distribuições marginais *a posteriori* podem ser definidas pela média amostral (Dubes e Jain, 1993)

$$P(X_s = g|Y = y) = \frac{1}{n - k} \sum_{i=k+1}^n \delta(x_s^{(i)} - g), \quad (4.22)$$

onde  $x_s^{(i)}$  é o valor do pixel  $x_s$  na realização (iteração)  $i$ ,  $g$  é um dos valores que o pixel pode assumir do conjunto  $G$ ,  $k$  é o número de iterações para a Cadeia de Markov atingir o equilíbrio,  $n$  é o número de iterações para se obter a estimativa MPM e  $\delta$  assume valor 1 se ocorreu um acerto ( $x_s^{(i)} = g$ ). Geralmente,  $k$  e  $n$  são determinados empiricamente, sendo que este último costuma ser muito grande, mas deve manter um compromisso entre custo computacional e precisão. Desta forma, podemos dizer que o MPM é uma alternativa intermediária entre o ICM e o *Simulated Annealing*. Por fim, o Algoritmo 4.3 obtém a estimativa MPM para a filtragem.

**Algoritmo 4.3.** Pseudocódigo do método *Maximizer of Posterior Marginals* (MPM) para filtragem contextual. Baseado em (Dubes e Jain, 1993; Levada, 2010).

---

<b>Entradas:</b>	<p>Uma imagem ruidosa <math>Y</math> com <math>M = N_1 \times N_2</math> pixels</p> <p>O número de iterações da simulação MCMC <math>N_{iter}</math></p> <p>O número de iterações para se atingir o equilíbrio da Cadeia de Markov <math>K</math></p> <p>O modelo Markoviano <i>a priori</i> <math>P_X</math></p> <p>A função de densidade de probabilidade da verossimilhança <math>P_{Y X}</math></p>
<b>Saída:</b>	<p>Uma estimativa MPM da imagem livre de ruído <math>X</math></p>

---

- (1) Inicializar a estimativa corrente para cada pixel  $\hat{x}_s$  como o  $g \in G$  que maximiza a verossimilhança  $P(Y_s = y_s | X_s = g)$
- (2)  $n = 0$
- (3) Estimar o parâmetro  $\beta$  dos modelos por MPV
- (4) **Enquanto**  $n \leq N_{iter}$
- (5) **Para** todo pixel  $s = 1, \dots, M$  **fazer**
- (6) Escolher  $g \in G$  aleatoriamente, definir  $z_s = g$  e  $z_r = x_s$  para todo  $r \neq s$
- (7) Seja  $p = \min \left\{ 1, \frac{P(X=z|Y=y)}{P(X=x|Y=y)} \right\}$ , com base em  $P_{Y|X}$  e  $P_X$
- (8) Substituir  $x$  por  $z$  com probabilidade  $p$
- (9) **Fim-Para**
- (10) **Se**  $n > K$  (atingiu o equilíbrio) **então**
- (11) Armazena a realização atual  $x^{(n)}$
- (12) **Fim-Se**
- (13) **Fim-Enquanto**
- (14) Construir  $P(X_s = g | Y = y)$  para todo  $g \in G$ , como em
 
$$P(X_s = g | Y = y) = \frac{1}{n - k} \sum_{i=k+1}^n \delta(x_s^{(i)} - g)$$
- (15) **Para** todo pixel  $s = 1, \dots, M$  **fazer**
- (16) Definir a estimativa final  $\hat{x}_s$  como o  $g \in G$  que maximiza a probabilidade *a posteriori* marginal  $P(X_s = \hat{x}_s | Y = y) > P(X_s = g | Y = y)$
- (17) **Fim-Para**

---

## 4.6 Considerações Finais

Neste capítulo vimos os princípios de Campos Aleatórios Markovianos que consistem em uma formulação adequada para se inserir o contexto no problema de filtragem e como utilizá-lo a fim de se estimar o valor verdadeiro de um pixel ruidoso.

Finalmente, temos que os métodos de otimização combinatória apresentados aqui, correspondem a uma abordagem das utilizadas neste trabalho. No próximo capítulo será examinada outra abordagem para a filtragem contextual, baseada em filtros de Wiener.

## 5 FILTRO DE WIENER

Os métodos para filtragem apresentados até agora, consideram algoritmos iterativos a fim de se obter a estimativa Bayesiana, seja por critério MAP ou MPM, dos pixels originais (estimativa da imagem original livre de ruído). Porém estes métodos iterativos podem ser custosos computacionalmente.

Um dos métodos mais clássicos para a filtragem de imagens consiste no Filtro de Wiener. O filtro ótimo no sentido de Wiener é definido como a estimativa LMMSE (Linear de Erro Médio Quadrático Mínimo) de um sinal desejado dado o sinal ruidoso, sendo o processo definido por

$$g(x, y) = f(x, y) + v(x, y), \quad (5.1)$$

onde  $g(x, y)$  é o sinal ruidoso e observado,  $f(x, y)$  é o sinal original livre de ruído e que deseja ser estimado e  $v(x, y)$  é um ruído. Ele é o filtro ótimo para o caso de sinal e ruído conjuntamente Gaussianos ou quando se impõe uma operação linear para a filtragem ou quando se dispõe apenas de informação de momentos até segunda ordem. No nosso caso, o sinal corresponde a uma imagem 2-D.

Matematicamente, temos que a estimativa MMSE  $\hat{f}_{MMSE}$  é aquela que minimiza o valor esperado do quadrado do erro de estimação, ou seja,  $\hat{f}_{MMSE} = \min_{\hat{f}} E[(f - \hat{f})^2]$ .

Existem diversas abordagens para o filtro de Wiener, definidas com base no modelo de formação do sinal (imagem). Entretanto, em várias delas nenhuma informação contextual é considerada. Assim, neste capítulo veremos o filtro de Wiener Pontual (Seção 5.1) e três abordagens de filtros de Wiener contextuais, sendo eles o Wiener com MRF Separável, o Wiener com MRF Isotrópico (Seção 5.2) e o Wiener Generalizado (com Informação de Fisher) (Seção 5.3) e finalmente, na Seção 5.4 algumas considerações finais.

### 5.1 Filtro de Wiener Pontual

O Filtro de Wiener Pontual corresponde a uma estimativa LLMSE (MSE Linear Local), que é dada por (Kuan, Sawchuk *et al.*, 1985)

$$\hat{f}_{LLMSE} = E[f] + C_{fg}C_g^{-1}(g - E[g]), \quad (5.2)$$

onde  $C_{fg}$  é a matriz de covariância cruzada entre  $f$  e  $g$  e  $C_g$  é a matriz de covariância de  $g$ .

A versão pontual deste filtro proposta por (Kuan, Sawchuk *et al.*, 1985) para ruído aditivo é apresentada na seguinte equação

$$\hat{f}(i, j) = \bar{f}(i, j) + \frac{\sigma_f^2(i, j)}{\sigma_f^2(i, j) + \sigma_v^2(i, j)} (g(i, j) - \bar{g}(i, j)), \quad (5.3)$$

onde  $\bar{f}(i, j)$  e  $\bar{g}(i, j)$  são estimados por médias locais da imagem original e observada, respectivamente,  $\sigma_f^2(i, j)$  e  $\sigma_v^2(i, j)$  são estimados por variâncias locais da imagem original e do ruído, nesta ordem. Estas estimativas locais para a média e variância podem ser realizadas em uma janela de tamanho  $W \times W$ .

Porém, em geral, temos apenas a imagem ruidosa e alguma informação sobre o ruído e não a imagem original. Assim, antes de obter as estatísticas para a imagem livre de ruído, precisamos possuir ao menos uma estimativa da mesma, que pode ser feita sobre uma versão suavizada da imagem ruidosa, aplicando o filtro da média, por exemplo.

Outra abordagem para se definir a média e variância da imagem original é fazer como o proposto por (Kuan, Sawchuk *et al.*, 1985). Eles definem que  $\bar{f}(i, j) = \bar{g}(i, j)$  pois supõem média nula e  $\sigma_f^2(i, j) = \sigma_g^2(i, j) - \sigma_v^2(i, j)$ , onde  $\sigma_g^2(i, j)$  é a variância local da imagem observada. Porém, isto não é adequado já que podemos ter valores negativos para  $\sigma_f^2(i, j)$  em regiões suaves da imagem

Além disso, vale ressaltar que este método serve tanto para ruídos aditivos independentes do sinal considerando variância única para toda a imagem ( $\sigma_v^2(i, j) = \sigma_v^2$ ), quanto para ruídos não estacionários e dependentes do sinal ( $\sigma_v^2(i, j)$  pode mudar a cada ponto).

## 5.2 Filtros de Wiener com MRF Separável e MRF Isotrópico

Nesta seção, apresentaremos duas versões do filtro de Wiener que embutem Campos Aleatórios Markovianos, na derivação da estimação LMMSE.

Suponha uma imagem em notação lexicográfica. Seja a estimativa  $\hat{f}$  de uma janela da imagem original de  $N$  pixels definida como uma combinação linear de  $g$ , dada por

$$\hat{f} = \sum_{n=0}^{N-1} a_n g[n]. \quad (5.4)$$

Considerando a Equação 5.4 na regra da estimativa MMSE, como temos os valores de  $g$ , precisamos apenas encontrar os valores dos pesos  $a_n$  que minimizam  $\epsilon = f - \hat{f}$ . Observando a Figura 5.1, temos que isto equivale a minimizar o valor esperado da norma  $\|\epsilon\|^2$ , tal que  $\epsilon \perp g[0], \dots, g[N-1]$ . Esta ideia é denominada de Princípio da Ortogonalidade. Ela estabelece que “na estimação da realização de uma variável aleatória por uma combinação linear das amostras dos dados, o estimador ótimo é obtido quando o erro é ortogonal a cada amostra de dados” (Kay, 1993).

Assim, usando o princípio da ortogonalidade, temos a seguinte derivação

$$\begin{aligned} E[(f - \hat{f})g[m]] &= 0, \\ E\left[\left(f - \sum_{n=0}^{N-1} a_n g[n]\right)g[m]\right] &= 0, \\ \sum_{n=0}^{N-1} a_n E[g[n]g[m]] &= E[fg[m]] \end{aligned} \quad (5.5)$$

onde  $m = 0, \dots, N-1$ . Com isso, obtemos um sistema de  $N$  equações e  $N$  incógnitas, que admite uma solução única.

Considerando o modelo aditivo e que não há correlação entre ruído e imagem, temos que  $R_{gg} = E[g[n]g[m]]$  é a matriz de autocorrelação da saída ( $g$ ),  $R_{fg} = E[fg[m]] = R_{ff}$  é a matriz de autocorrelação da entrada ( $f$ ) e  $a = (a_1, \dots, a_n)$ , podemos reescrever este sistema em forma matricial como

$$R_{gg}a = R_{fg}. \quad (5.6)$$

Assim, a solução para este sistema é dada por

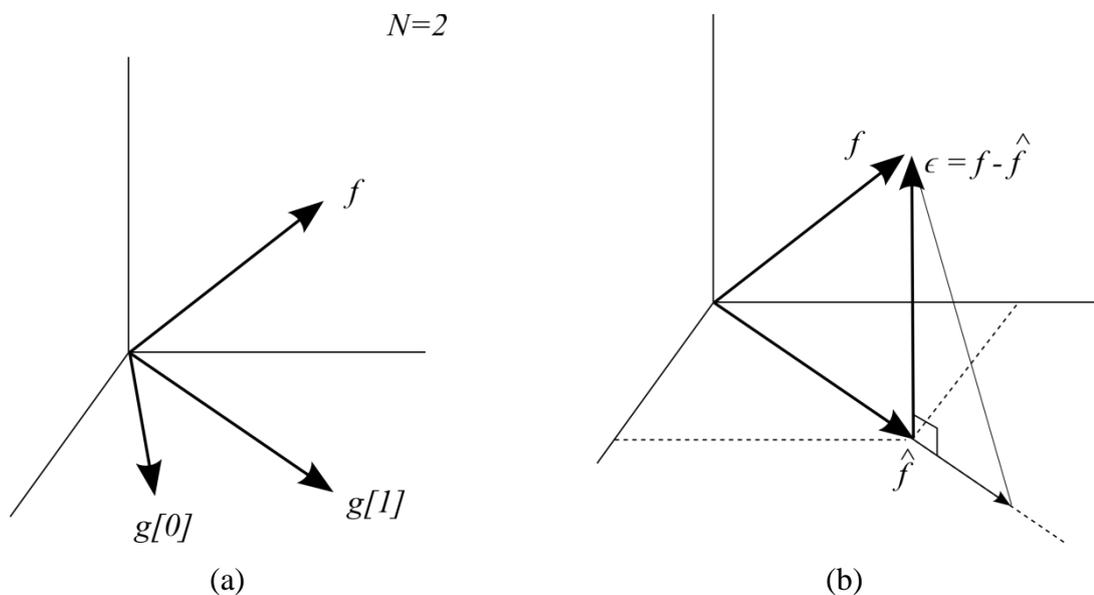
$$a = R_{gg}^{-1}R_{fg}. \quad (5.7)$$

Com os pesos  $a$  obtidos na Equação 5.7, podemos substituí-los na Equação 5.4 e desta forma, chegar à estimativa de  $\hat{f}$ , sendo isto para cada pixel na imagem.

Além disso, vale ressaltar que cada linha de  $R_{gg}$  representa a autocorrelação de pixels de  $g$  entre cada ponto e todos os outros de uma janela, enquanto  $R_{fg}$  é um vetor que representa a autocorrelação de pixels de  $f$  entre o ponto central (corrente) e todos os outros valores observados da janela. Assim, se considerarmos uma janela de tamanho  $N = W \times W$ ,  $R_{gg}$  será uma matriz quadrada  $N \times N$  e  $R_{fg}$  será um vetor coluna  $N \times 1$ .

Para facilitar o entendimento das versões abaixo, a Equação matricial 5.6 (Kay, 1993) equivale a

$$\begin{bmatrix} E[g^2[0]] & E[g[0]g[1]] & \cdots & E[g[0]g[N-1]] \\ E[g[1]g[0]] & E[g^2[1]] & \cdots & E[g[1]g[N-1]] \\ \vdots & \vdots & \ddots & \vdots \\ E[g[N-1]g[0]] & E[g[N-1]g[1]] & \cdots & E[g^2[N-1]] \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \\ \vdots \\ a_{N-1} \end{bmatrix} = \begin{bmatrix} E[fg[0]] \\ E[fg[1]] \\ \vdots \\ E[fg[N-1]] \end{bmatrix}. \quad (5.8)$$



**Figura 5.1.** Princípio da Ortogonalidade: a) Situação Inicial e b) Projeção . Baseada em (Kay, 1993).

Com base neste processo, tanto a definição, quanto a diferença entre as abordagens de Wiener contextual com MRF Separável e Isotrópico está na definição das matrizes de autocorrelação. A ideia é defini-las com base em um modelo de decaimento exponencial (Mascarenhas, Banon *et al.*, 1996; Zaniboni e Mascarenhas, 1998; Zhang, Nosratinia *et al.*, 2000; Wang, Fu-Cheng *et al.*, 2005).

Para a versão de Wiener com MRF Separável temos que para cada pixel central  $(i, j)$  em uma janela de tamanho  $W \times W$  na imagem, as matrizes de autocorrelação de  $g$  e  $f$  são definidas, respectivamente, como

$$R_{gg} = \begin{cases} \sigma_f^2(i, j) + \sigma_v^2(i, j), & \text{na diagonal principal} \\ \sigma_f^2(i, j) \rho_V^{|i'-i''|} \rho_H^{|j'-j''|}, & \text{fora da diagonal principal,} \end{cases} \quad (5.9)$$

$$R_{ff} = \left( \sigma_f^2(i, j) \rho_V^{|i'-i|} \rho_H^{|j'-j|} \right), \quad (5.10)$$

onde  $\rho_V$  e  $\rho_H$  são coeficientes de correlação verticais e horizontais que usualmente recebem o mesmo valor  $\rho_V = \rho_H = 0.95$ , por exemplo, para imagens consideradas típicas e  $(i', j')$  e  $(i'', j'')$  correspondem a posições dos pixels em uma janela.

Finalmente na versão de Wiener com MRF Isotrópico, estas autocorrelações são definidas como

$$R_{gg} = \begin{cases} \sigma_f^2(i, j) + \sigma_v^2(i, j), & \text{na diagonal principal} \\ \sigma_f^2(i, j) \rho^{\sqrt{(i'-i'')^2 + (j'-j'')^2}}, & \text{fora da diagonal principal,} \end{cases} \quad (5.11)$$

$$R_{ff} = \left( \sigma_f^2(i, j) \rho^{\sqrt{(i'-i)^2 + (j'-j)^2}} \right), \quad (5.12)$$

onde  $\rho$  é um coeficiente de correlação, geralmente definido como 0.95. Neste caso, temos que a influência da variância do pixel central decai circularmente ao seu redor.

### 5.3 Filtro de Wiener Generalizado (com Informação de Fisher)

O filtro de Wiener com Informação de Fisher ou Generalizado foi desenvolvido por (Levada e Mascarenhas, 2010). A Informação de Fisher representa a quantidade de informação que determinada variável aleatória observada possui sobre o parâmetro a ser estimado, sendo que a Informação de Fisher observada pode ser estimada sobre um Campo Aleatório

Markoviano Gaussiano (GMRF), considerando uma determinada vizinhança (Levada e Mascarenhas, 2010). Neste caso em particular o parâmetro de interesse é o parâmetro de dependência espacial  $\beta$ , que controla a estrutura de dependência espacial de um GMRF.

Levada e Mascarenhas (Levada e Mascarenhas, 2010), ao observarem a estimativa da Informação de Fisher notaram uma semelhança com o Filtro de Wiener Pontual, sendo este um caso particular do método proposto, que foi denominado de Filtro de Wiener Generalizado. As estimativas dos pixels livres de ruído deste método são definidas como (Levada e Mascarenhas, 2010)

$$\begin{aligned} \hat{f}(i, j) = & \bar{f}(i, j) \\ & + \frac{\sigma_f^2(i, j)}{\sigma_f^2(i, j) + \sigma_v^2(i, j)} \left[ \alpha (g(i, j) - \bar{g}(i, j)) \right. \\ & \left. + (1 - \alpha) \sum_{g(k, l) \in \eta(i, j)} (g(k, l) - \bar{g}(i, j)) \right], \end{aligned} \quad (5.13)$$

onde  $\alpha \in [0, 1]$  representa um compromisso entre a filtragem pontual ( $\alpha = 1$ ) e a filtragem contextual ( $\alpha = 0$ ) ou entre o MMSE e a minimização da Informação de Fisher observada (Levada e Mascarenhas, 2010).

#### 5.4 Considerações Finais

Neste capítulo vimos o método de filtragem por Wiener e seus princípios, tendo sido apresentadas quatro versões do método, sendo que uma aplica uma filtragem pontual e as restantes filtragens contextuais. No primeiro caso, temos o filtro de Wiener Pontual. Já no segundo caso, destacamos as versões com MRF Separável, com MRF Isotrópico e com Informação de Fisher. Em todos estes métodos podemos utilizar um modelo dependente do sinal para o ruído.

Vale ressaltar que o filtro de Wiener consiste em um método direto, enquanto a abordagem por métodos de Otimização Combinatória propostos no Capítulo 4 são iterativos.

Desta forma, concluímos aqui as teorias que norteiam a nossa proposta para a filtragem contextual em imagens de CT, que será apresentada no próximo Capítulo, permitindo

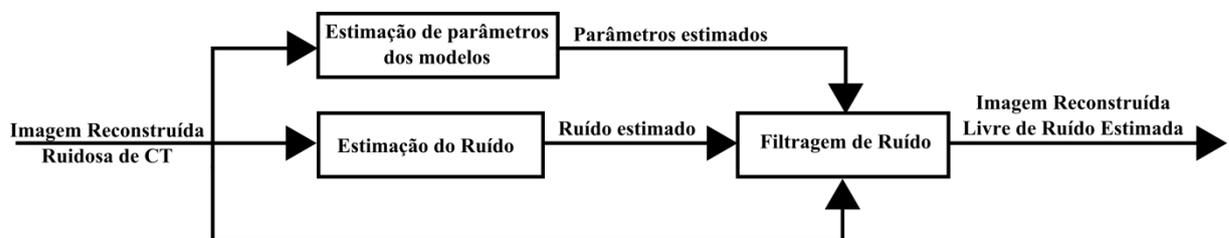
inclusive considerar um método para se estimar a variância do ruído dependente do sinal (em cada pixel).

## 6 FILTRAGEM DE RUÍDO EM CT NO DOMÍNIO DA IMAGEM UTILIZANDO UMA ABORDAGEM BAYESIANA CONTEXTUAL

O presente trabalho propõe a filtragem contextual em imagens ruidosas de CT, adquiridas com baixa taxa de contagem e reconstruídas por POCS e FBP. O ruído na imagem reconstruída é considerado como Gaussiano, aditivo e dependente do sinal. Ele deverá ser estimado segundo um dos três métodos apresentados neste capítulo. Além disso, o contexto será dado por considerar o uso de Campos Aleatórios Markovianos para a modelagem de informação *a priori*. Um diagrama de blocos resumindo o processo geral é apresentado na Figura 6.1.

Basicamente, teremos duas abordagens para a filtragem contextual Bayesiana. A primeira utiliza algoritmos de otimização iterativos, sendo eles ICM, GSA e MPM. Já a segunda abordagem considera variantes de Wiener, caso do Wiener com MRF Separável, Wiener com MRF Isotrópico e Wiener Generalizado (com Informação de Fisher).

Neste capítulo, iniciaremos apresentando a modelagem do ruído, o método de filtragem Non Local Means e os métodos proposto para estimar o ruído dependente do sinal na Seção 6.1. Em seguida, na Seção 6.2, veremos em maiores detalhes a metodologia utilizada. Por fim, nas Seções 6.3 e 6.4, os métodos de avaliação dos resultados e os resultados esperados nesta proposta são apresentados.



**Figura 6.1.** Diagrama de blocos representando a metodologia para filtragem utilizada nesta tese.

## 6.1 Modelagem e Método de Estimação do Ruído Dependente do Sinal

Para a solução dos problemas de filtragem, restrições sobre o processo de aquisição do sinal, os ruídos presentes no sinal obtido e mesmo informações sobre o conhecimento a priori da imagem são de grande importância para restringir o espaço de soluções possíveis e assim, obtermos um melhor desempenho no processo inverso de filtragem.

Neste trabalho, além de restrição de suavidade dada pela consideração de contexto via MRF, consideramos um modelo para o ruído presente nas imagens reconstruídas de CT. Como apontado na Seção 2.4 e Capítulo 3, podemos modelar este ruído como Gaussiano, aditivo, não estacionário, dependente do sinal e com média zero. Este modelo já foi descrito pela Equação 3.2.

Assim, temos que para cada pixel  $g(i, j)$  da imagem observada, o ruído  $v(i, j)$  neste ponto segue uma distribuição normal com média zero e variância  $\sigma_v^2(i, j)$ , representado por

$$v(i, j) \sim N(0, \sigma_v^2(i, j)). \quad (6.1)$$

Deste modo, sua função de densidade de probabilidade para cada ponto, pode ser definida como

$$p(v(i, j), 0, \sigma_v^2(i, j)) = \frac{1}{\sqrt{2\pi\sigma_v^2(i, j)}} e^{-\frac{(v(i, j))^2}{2\sigma_v^2(i, j)}}. \quad (6.2)$$

É importante notar que temos apenas a imagem observada, cujas estatísticas de média  $\mu_g(i, j)$  e variância  $\sigma_g^2(i, j)$  podem ser calculadas usando média e variância amostrais dentro de uma janela de tamanho  $W \times W$ .

Para a variância do ruído  $\sigma_v^2(i, j)$  (lembre-se que estamos assumindo média nula), um processo empírico, que normalmente é realizado, consiste em selecionar áreas homogêneas e calcular a variância amostral considerando os pixels nesta área. Isto se baseia no fato de que se o objeto sendo imageado contém áreas homogêneas, os pixels em cada uma destas áreas devem apresentar a mesma tonalidade ou muito próxima. Assim, a variância calculada em cada área é considerada dada pelo ruído, já que em áreas realmente homogêneas (ou seja, onde todos os pixels originais são aproximadamente iguais) a variância é aproximadamente nula.

Para a imagem original, em muitos métodos a sua média  $\mu_f(i, j)$  é assumida como sendo igual a da imagem observada (média do ruído nula) e portanto,  $\mu_f(i, j) = \mu_g(i, j)$ . Já a

variância  $\sigma_f^2(i, j)$ , considerando que o modelo é aditivo, muitas vezes é determinada por  $\sigma_f^2(i, j) = \sigma_g^2(i, j) - \sigma_v^2(i, j)$ . Porém, isto pode levar a inconsistências, já que podemos obter valores negativos para a variância em regiões homogêneas.

Assim, neste trabalho optamos por estimar a variância  $\sigma_f^2(i, j)$  aplicando o mesmo processo da imagem observada, porém sobre uma versão suavizada desta. Isto pode ser feito por meio de um filtro da média ou *Non Local Means* (Buades, Coll *et al.*, 2005) sobre  $g$ .

Com base nisto e por considerar que o processo de obtenção das variâncias do ruído muitas vezes é realizado manualmente, pela cálculo das variâncias em áreas homogêneas selecionadas, foram propostos novos métodos para a estimação do ruído dependente do sinal. Estes métodos tentam tornar a estimação das variâncias do ruído automática e também mais robusta. Eles serão apresentados em mais detalhes a seguir.

### 6.1.1 Non Local Means

O método de filtragem Non Local Means foi proposto por (Buades, Coll *et al.*, 2005), baseado principalmente na redundância de patches nas imagens. Neste método, o valor estimado livre de ruído de um pixel é basicamente definido como uma média ponderada dos pixels em uma certa região. Estes pesos são calculados usando uma distância Euclideana para medir a similaridade entre um patch central e patches vizinhos em uma área de busca, onde o pixel central de ambos patch central e janela de busca correspondem ao pixel atual a ser estimado. Como o método clássico é baseado na distância Euclideana, ele é adequado para ruído Gaussiano Branco Aditivo. Este método pode ser representado pela seguinte equação

$$\hat{u}_s \triangleq \frac{\sum_{t \in W} \omega(s, t) v_t}{\sum_{t \in W} \omega(s, t)}, \quad (6.3)$$

onde  $\hat{u}_s$  é a estimativa livre de ruído atual de um pixel da imagem,  $v_t$  é um pixel ruidoso pertencente a uma janela de busca  $W$  e  $\omega(s, t)$  são os pesos entre os patches centralizados em  $s$  e  $t$  e definidos por (Deledalle, 2011)

$$\omega(s, t) \triangleq \exp\left(-\frac{1}{h} \sum_{k \in P} |v_{s,k} - v_{t,k}|^2\right), \quad (6.4)$$

onde  $h$  controla o decaimento exponencial (incrementando este parâmetro, a imagem tende a ser mais suavizada),  $P$  são os índices de patch,  $v_{s,k}$  e  $v_{t,k}$  são os  $k$ -ésimos pixels nos patches  $s$  e  $t$  da imagem ruidosa  $v$ , respectivamente.

A fim de aplicar esta ideia simples a outros modelos de ruído e para melhorar os resultados, um framework foi proposto por (Deledalle, 2011) para gerar e refinar iterativamente os pesos baseado na estimação de Máxima Verossimilhança Ponderada. Este método é representado pela seguinte equação em um framework Bayesiano (Deledalle, 2011)

$$\omega_{(s,t)}^{(i)} \triangleq \frac{p(\mathcal{H}_0 | v_s, v_t, \hat{\theta}^{(i-1)})}{p(\mathcal{H}_1 | v_s, v_t, \hat{\theta}^{(i-1)})} = \underbrace{\frac{p(v_s, v_t | \mathcal{H}_0)}{p(v_s, v_t | \mathcal{H}_1)}}_{\text{verossimilhança}} \times \underbrace{\frac{p(\mathcal{H}_0 | \hat{\theta}^{(i-1)})}{p(\mathcal{H}_1 | \hat{\theta}^{(i-1)})}}_{\text{a priori}}, \quad (6.5)$$

onde  $\mathcal{H}_0: u_1 = u_2 \equiv u_{12}$  é a hipótese nula,  $\mathcal{H}_1: u_1 \neq u_2$  é a hipótese alternativa,  $v_s$  e  $v_t$  são os patches ruidosos,  $u_1$  e  $u_2$  são os patches livres de ruído,  $u_{12}$  é um parâmetro comum e  $\hat{\theta}^{(i-1)}$  é uma imagem estimada livre de ruído na iteração anterior.

Considerando que os pixels dentro de um patch são independentes entre si, a probabilidade de similaridade na Equação 6.5 pode ser definida pelo produto das probabilidades como (Deledalle, 2011)

$$\prod_k \frac{p(\theta_{s,k}^* = \theta_{t,k}^* | v_{s,k}, v_{t,k}, \hat{\theta}^{(i-1)})}{p(\theta_{s,k}^* \neq \theta_{t,k}^* | v_{s,k}, v_{t,k}, \hat{\theta}^{(i-1)})}, \quad (6.6)$$

tal que cada probabilidade pode ser descrita por (Deledalle, 2011)

$$\frac{p(\theta_{s,k}^* = \theta_{t,k}^* | v_{s,k}, v_{t,k}, \hat{\theta}^{(i-1)})}{p(\theta_{s,k}^* \neq \theta_{t,k}^* | v_{s,k}, v_{t,k}, \hat{\theta}^{(i-1)})} \propto \underbrace{\frac{p(v_{s,k}, v_{t,k} | \theta_{s,k}^* = \theta_{t,k}^*)}{p(v_{s,k}, v_{t,k} | \theta_{s,k}^* \neq \theta_{t,k}^*)}}_{\text{verossimilhança}} \times \underbrace{\frac{p(\theta_{s,k}^* = \theta_{t,k}^* | \hat{\theta}^{(i-1)})}{p(\theta_{s,k}^* \neq \theta_{t,k}^* | \hat{\theta}^{(i-1)})}}_{\text{a priori}}, \quad (6.7)$$

onde  $\theta_{s,k}^*$  e  $\theta_{t,k}^*$  são os  $k$ -ésimos pixels nos patches livres de ruído  $u_s$  e  $u_t$ , respectivamente.

Além disso, da verossimilhança e da informação a priori, duas medidas de similaridade foram derivadas diretamente: a Razão de Verossimilhança Generalizada (GLR) e a Divergência Simétrica de Kullback-Leibler (SKLD), respectivamente.

A GLR é definida pela equação (Deledalle, 2011)

$$\mathcal{L}_G(v_1, v_2) = \frac{\sup_t p(v_1, v_2 | u_{12} = t, \mathcal{H}_0)}{\sup_{t_1, t_2} p(v_1, v_2 | u_1 = t_1, u_2 = t_2, \mathcal{H}_1)}. \quad (6.8)$$

Por sua vez, a SKLD é definida por (Deledalle, 2011)

$$\mathcal{D}_{KL}(u_1, u_2) = \int (p(v|u_1) - p(v|u_2)) \log \frac{p(v|u_1)}{p(v|u_2)} dv. \quad (6.9)$$

Finalmente, a medida de similaridade conjunta pode ser definida por (Deledalle, 2011)

$$\omega(s, t)^{(i)} = \varphi \left( -\frac{-\log \mathcal{L}_G(v(Ps), v(Pt))}{\alpha} - \frac{\mathcal{D}_{KL}(v(Ps), v(Pt))}{\beta} \right), \quad (6.10)$$

onde  $\varphi$  é um kernel (normalmente definido como um kernel exponencial ou trapezoidal),  $P$  define um patch e  $\alpha$  e  $\beta$  são parâmetros de confiança na quantidade de filtragem e na imagem pré-estimada, respectivamente (apresentam o mesmo efeito de  $h$  na Equação 6.4, ou seja, tendo o seu valor incrementado maior será a suavização). É importante notar que a imagem pré-estimada na primeira iteração pode ser definida como uma matriz de valores constantes igual a 1 e o primeiro  $\beta$  também igual a 1. Esta condição inicial corresponde ao Non Local Means não iterativo. Além disso, se o ruído é Gaussiano, eles correspondem ao Non Local Means clássico.

Ainda, é importante reforçar que considerando o ruído não correlacionado como suposto por (Deledalle, 2011), a similaridade entre os patches corresponde a um produto da similaridade entre seus pixels. Assim, considerando que um logaritmo é aplicado neste produto, a Equação 6.10 pode ser reescrita como

$$\omega(s, t)^{(i)} = \varphi \left[ -\sum_k \left( \frac{-\log \mathcal{L}_G(v_{s,k}, v_{t,k})}{\alpha} - \frac{\mathcal{D}_{KL}(v_{s,k}, v_{t,k})}{\beta} \right) \right]. \quad (6.11)$$

Para a distribuição Gaussiana, temos que GLR e SKLD são definidos como  $e^{-(v_1 - v_2)^2}$ , onde  $v_1$  e  $v_2$  correspondem ao valor de dois patches ruidosos. Maiores detalhes podem ser encontrados em (Deledalle, 2011).

Finalmente, o procedimento básico (já com alguma otimização de desempenho que reduzem o efeito raro de patch) proposto por (Deledalle, 2011) é apresentado no Algoritmo 6.1.

**Algoritmo 6.1.** 2D-FFT NL-Means, onde  $\varphi$  é um kernel,  $S$  é a forma do patch (por exemplo, retangular, circular), FFT é a Transformada Rápida de Fourier e  $\overline{\mathcal{F}(S)}$  corresponde ao complexo conjugado de  $\mathcal{F}(S)$ . Adaptado de (Deledalle, 2011) (maiores detalhes podem ser encontrados nesta referência).

---

**Entradas:** - imagem ruidosa  $V$

- imagem pré-estimada  $U'$

- FFT 2D da forma  $\mathcal{F}(S)$

- janela de busca  $W$

- contribuição da similaridade na imagem ruidosa  $\alpha$

- contribuição da similaridade sobre a imagem pré-estimada  $\beta$

**Saída:** - imagem livre de ruído estimada  $\hat{U}$

---

(1) Inicializar os acumuladores de imagens  $A$  e  $B$  para zero

(2) **Para todos** os deslocamentos  $\delta$  em  $W$

(3) Computar  $\Delta_{V,\delta}(s) = -\log \mathcal{L}_G(V(s), V(s + \delta))$  para todos os pixels  $s$  em  $V$

(4) Computar  $\Delta_{U',\delta}(s) = \mathcal{D}_{KL}(U'(s), U'(s + \delta))$  para todos os pixels  $s$  em  $U'$

(5) Computar a FFT 2-D  $\mathcal{F}(\Delta_{V,\delta}(s))$  e  $\mathcal{F}(\Delta_{U',\delta}(s))$

(6) Executar a convolução de  $\Delta_{V,\delta}$  e  $\Delta_{U',\delta}$  pela forma  $S$

(7)  $d_V(\dots + \delta) = \mathcal{F}^{-1}(\overline{\mathcal{F}(S)}\mathcal{F}(\Delta_{V,\delta}))(\dots)$

(8)  $d_{U'}(\dots + \delta) = \mathcal{F}^{-1}(\overline{\mathcal{F}(S)}\mathcal{F}(\Delta_{U',\delta}))(\dots)$

(9) **Para todos** os pixels  $s$

(10) Computar os pesos

$$\omega(s, s + \delta) = \varphi\left(-\left(\frac{d_V(s, s + \delta)}{\alpha} + \frac{d_{U'}(s, s + \delta)}{\beta}\right)\right)$$

(11) Atualizar os acumuladores

(12)  $A(s) = A(s) + \omega(s, s + \delta)V(s)$  de acordo com a coluna NLM na Tabela I

(13)  $B(s) = B(s) + \omega(s, s + \delta)$

(14) **Final para**

(15) **Final para**

(16)  $\hat{U}(s) = \frac{A(s)}{B(s)}$  para todos os pixels  $s$

---

Vale ressaltar ainda que neste trabalho utilizaremos apenas uma única iteração deste algoritmo, sendo que este algoritmo foi selecionado por ser uma implementação otimizada do Non Local Means. Reforça-se que usar o algoritmo proposto por Deledalle com apenas uma iteração e medida de similaridade dada pela distância Euclideana corresponde ao Non Local Me-

ans clássico, sendo este um caso especial daquele. Portanto, a opção pelo algoritmo de Deledalle nesta tese foi devido especialmente ao seu maior desempenho computacional, mas também pela redução de artefatos.

### ***6.1.2 Métodos para Estimação de Ruído Dependente de Sinal***

Nesta Seção são apresentados três métodos propostos para a estimação do ruído dependente do sinal. Os dois primeiros métodos, denominados Preliminar e Final, foram baseados nos métodos propostos em (Gravel, Beaudoin *et al.*, 2004) e (Mencattini, Salmeri *et al.*, 2007; Salmeri, Mencattini *et al.*, 2008).

O processo básico destes métodos consiste nas seguintes etapas: 1) Suavização da imagem ruidosa, 2) Geração de máscara binária dos componentes de baixa frequência (áreas homogêneas), desconsiderando bordas, 3) Criação de um histograma relacionando tom de cinza do pixel (nas abscissas) a uma variância (nas ordenadas), 4) Ajuste dos dados.

As modificações propostas por nossos métodos tentam traduzir a forma empírica manual para a estimação do ruído dentro do algoritmo. Nas próximas Subseções, os três métodos propostos aqui são apresentados, sendo que a versão preliminar foi proposta nesta tese e utilizada na dissertação de mestrado de Rafael J. Geraldo (Geraldo, 2011). Resultados comparando os três métodos propostos e os dois em que eles se basearam são apresentados no Apêndice C e discussões sobre a escolha dos parâmetros dos métodos Preliminar e Final são apresentados no Apêndice E.

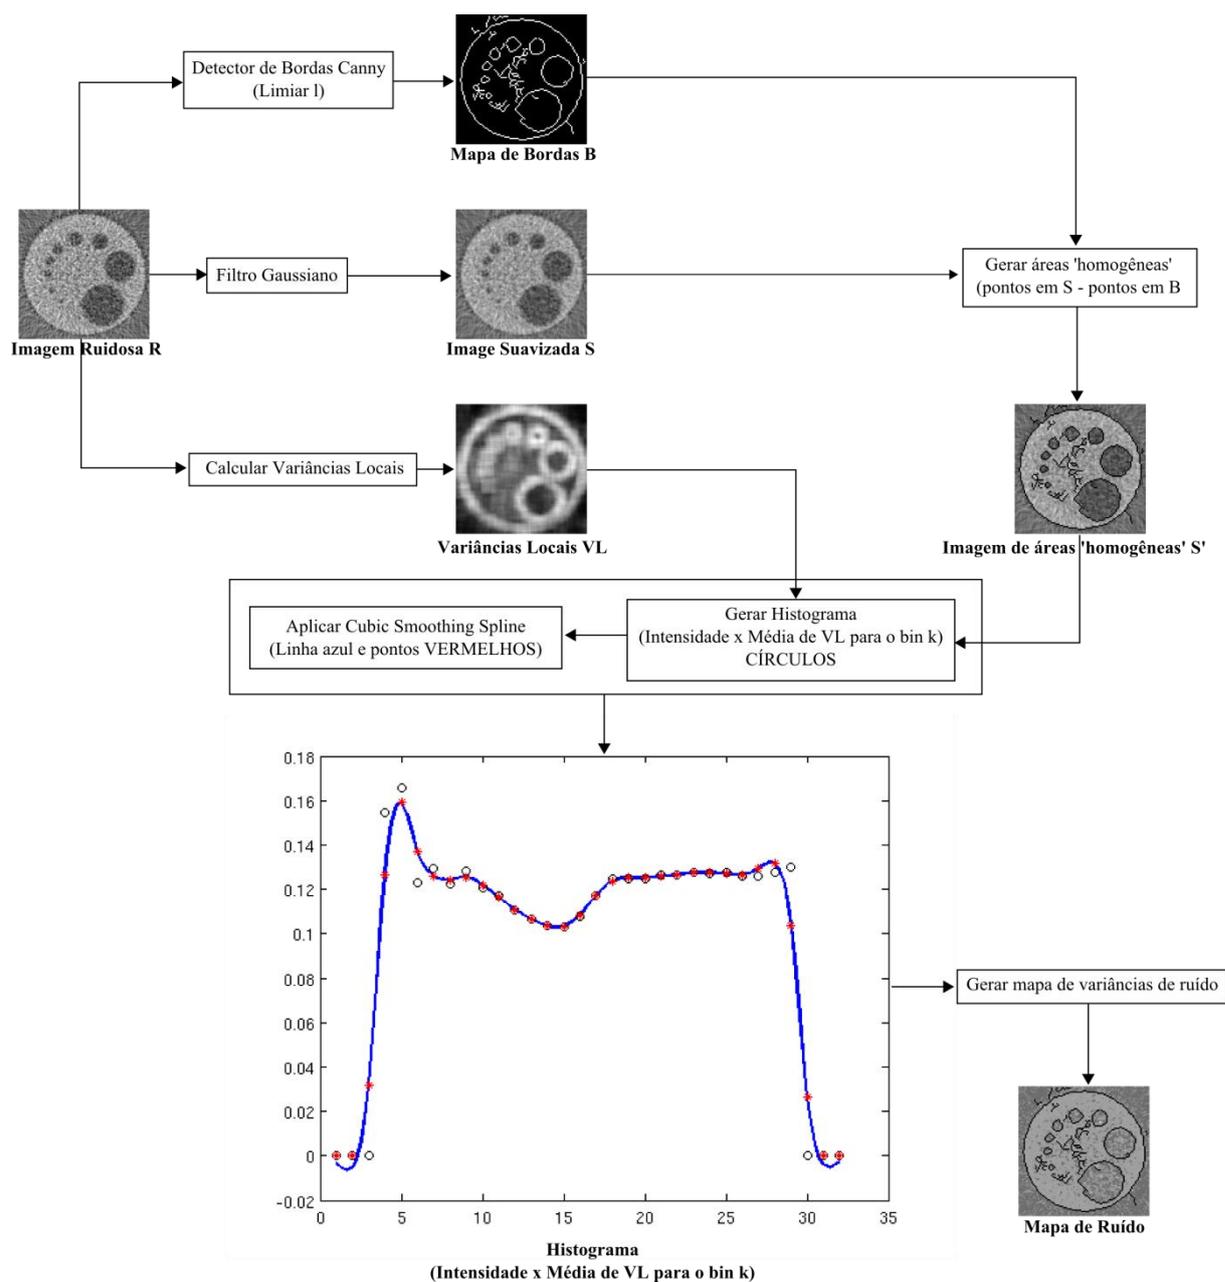
#### ***6.1.2.1 Método Preliminar***

O método para estimação de ruído dependente do sinal proposto inicialmente nesta tese está representado no diagrama de blocos na Figura 6.2 e é descrito a seguir.

Para o primeiro passo, consideramos o uso de filtro Gaussiano passa baixas para a suavização como foi feito em (Salmeri, Mencattini *et al.*, 2008).

No segundo passo, foi utilizado um detector de bordas de Canny (Canny, 1986). Esta escolha foi motivada após alguns testes com outros detectores de borda, especialmente Sobel e Prewitt (Gonzalez e Woods, 2002). Foi verificado que ele possuía uma maior capacidade

para detectar bordas em imagens ruidosas. A máscara binária final consiste em todos os pixels da imagem, exceto as bordas definidas de acordo com um valor de limiar. No caso de reconstrução por POCS, foram desconsiderados também os pixels fora do objeto que são definidos como valor nulo. Para isso, consideraram-se os pixels maiores que zero e depois um método para preencher os buracos dos pixels zero dentro do objeto.



**Figura 6.2.** Versão preliminar do método proposto de estimação de ruído dependente de sinal.

Por sua vez, no terceiro passo foi onde ocorreu a principal modificação. Primeiramente, foram calculadas sobre a imagem ruidosa as variâncias locais para cada pixel. Um número de bins  $K$  é considerado para a construção de um histograma, onde cada bin contém  $\left\lceil \frac{256}{K} \right\rceil$  tons, sendo que o bin  $K_i$  contém os tons  $\left\{ (i-1) \left\lceil \frac{256}{K} \right\rceil, \dots, i \left\lceil \frac{256}{K} \right\rceil - 1 \right\}$ , onde  $i = 1, \dots, K$ . Em seguida, dentre os pixels que foram definidos na máscara binária, para cada bin  $K_i$  foram selecionados os pixels para cada tom da imagem suavizada, e calculado a média das variâncias locais destes pixels. Desta forma, pode ser produzido um histograma com  $K$  bins, relacionando a intensidade média no bin e a média de suas variâncias locais dos pixels que compõe o bin.

E para o último passo, uma curva ajustando os dados foi definida pelo método de análise de regressão *Cubic Smoothing Spline* como em (Salmeri, Mencattini *et al.*, 2008). Este passo é importante para se evitar *outliers*. Vale ressaltar que o uso da *Spline* pode alterar a PSF (Função de Espalhamento Pontual) no filtro. Portanto, temos um balanço entre perda de informação e ganhos com uma melhor estimativa do ruído. Entretanto, notou-se que a remoção desta etapa de ajuste de dados pode levar ao aparecimento de artefatos nas bordas após a filtragem de ruído, o que justifica o seu uso.

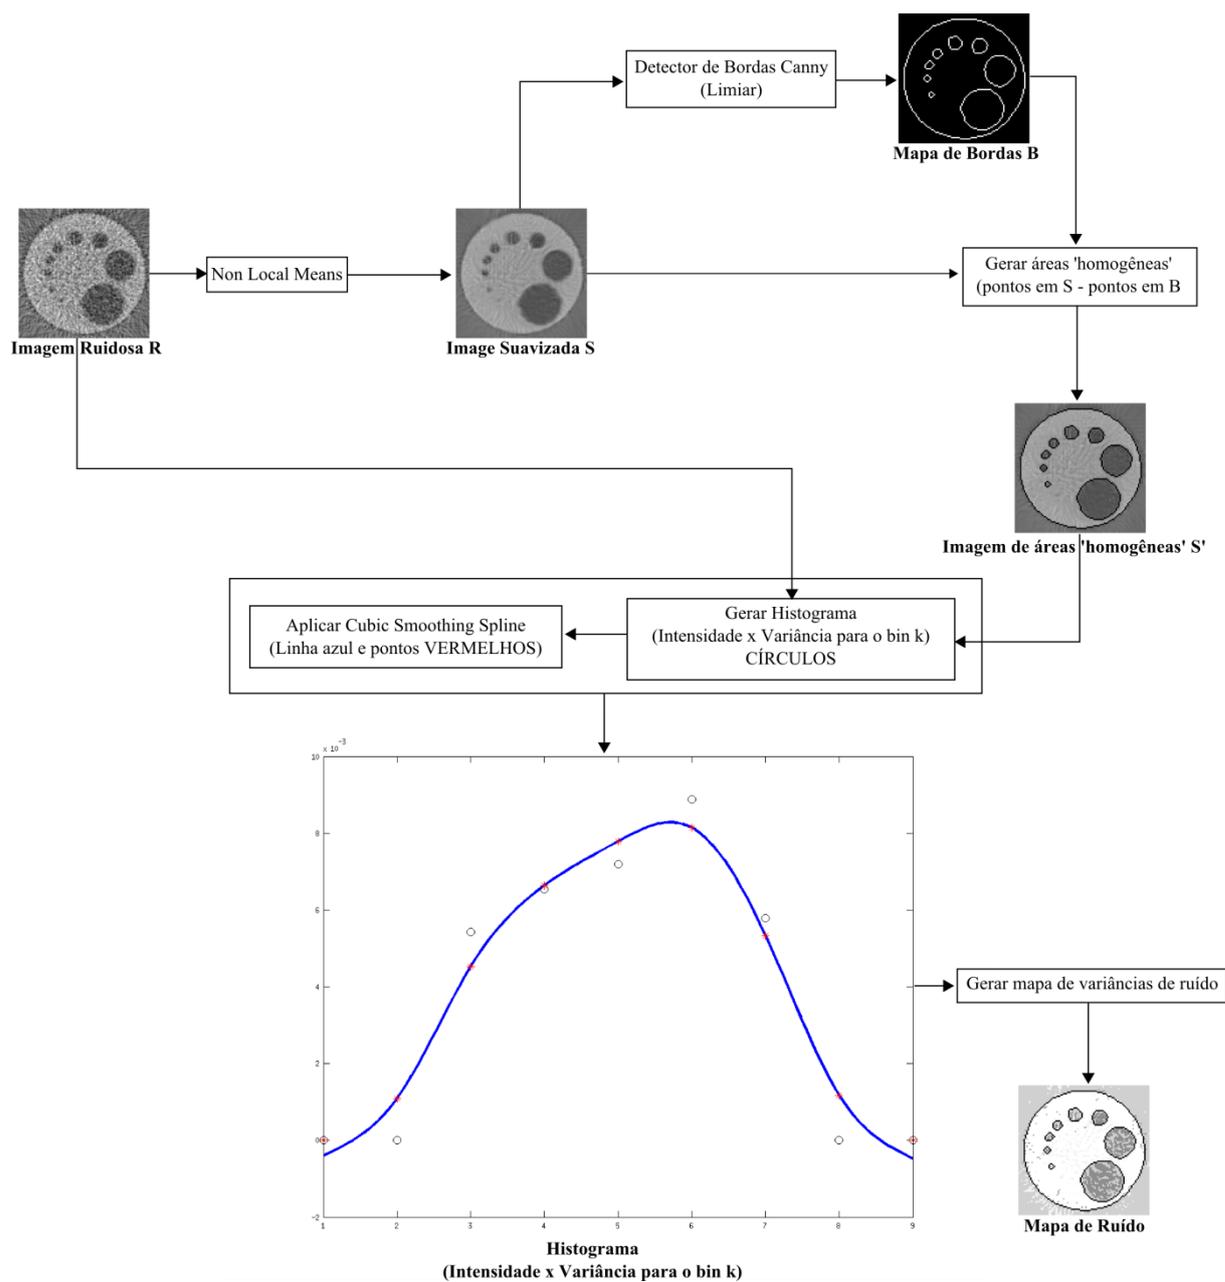
Desta forma, podemos gerar um mapa das variâncias do ruído, considerando as médias das variâncias locais dada pela curva da etapa anterior no lugar da intensidade. Vale ressaltar que nas bordas o ruído é considerado nulo.

É importante notar também, que no caso de número de bins  $K = 1$ , temos que o ruído é independente do sinal. Caso contrário, ele é considerado dependente do sinal.

Os valores tanto para o limiar do detector de bordas, quanto para o número de bins do histograma são definidos empiricamente. Basicamente, escolheu-se um número de  $K$  próximo ao número de segmentos da imagem e o limiar como o máximo possível antes de se obter uma quantidade visível de falsos positivos (ruído detectado como borda). Entretanto, uma análise mais detalhada para a escolha dos parâmetros é apontado no Apêndice E.

### 6.1.2.2 Método Final

Baseado no método de estimação de ruído dependente de sinal proposto preliminarmente (na Subseção anterior), algumas mudanças foram propostas a fim de tornar a estimação mais precisa. Este método está representado no diagrama de blocos da Figura 6.3.



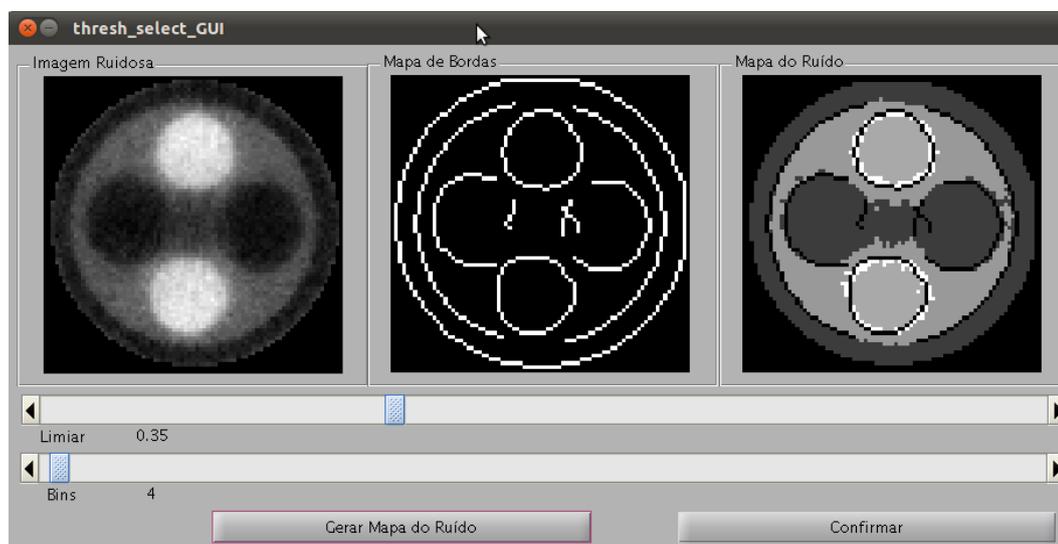
**Figura 6.3.** Versão final do método proposto de estimação de ruído dependente de sinal.

A primeira mudança consistiu em utilizar o método de Non Local Means para obter a imagem pré-estimada, pois este método é mais preciso do que o filtro da média para este tipo de ruído.

A segunda modificação foi obter o mapa de bordas da imagem suavizada pelo Non Local Means, por ser mais preciso do que obter da imagem ruidosa.

E por último, a variância para cada bin não é mais determinada pela média das variâncias locais, mas é dada pela variância dos pixels ruidosos pertencentes ao bin. Lembrando que os pixels pertencentes a cada bin são definidos a partir da imagem suavizada (excluídos os pixels de borda).

Por fim, para realizar a escolha dos parâmetros de ambos os métodos foi desenvolvida uma ferramenta simples, na qual podemos ir ajustando os valores de bin e limiar e verificar o mapa de bordas gerado. A Figura 6.4 apresenta a tela desta ferramenta.



**Figura 6.4.** Tela da ferramenta para a escolha do número de bins do histograma e limiar do detector de bordas para o método de estimação do ruído dependente do sinal.

### 6.1.2.3 Método Formal

Nesta seção, um método analítico e automático para a estimação do ruído dependente do sinal é proposto. Para isto, inspirado no modelo definido em (Foi, 2009), vamos considerar o seguinte modelo aditivo, equivalente à Equação 3.2

$$y_i = x_i + \eta_i(x_i), \quad (6.12)$$

onde  $y_i$  é o pixel ruidoso,  $x_i$  é o pixel livre de ruído a ser estimado e  $\eta_i(x_i)$  é um ruído Gaussiano, dependente do sinal (função de  $x_i$ ) e de média zero, tal que  $\eta_i \sim N(0, \sigma_{\eta_i}^2)$ , onde a variância do ruído é  $\sigma_{\eta_i}^2 = \sigma^2 x_i$ .

Seja a função de densidade de probabilidade da verossimilhança dada por  $N(y_i|x_i; \sigma_{\eta_i}^2)$

$$f(y_i|x_i; \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2 x_i}} \exp\left\{-\frac{1}{2} \frac{(y_i - x_i)^2}{\sigma^2 x_i}\right\}, \quad (6.13)$$

Onde  $\mu = x_i$  e  $\sigma_{\eta_i}^2 = \sigma^2 x_i$  são os parâmetros.

Definido este modelo, vamos estimar o valor de  $\sigma^2$  por Máxima Verossimilhança. Assim, sejam a verossimilhança conjunta  $f(y_1, y_2, \dots, y_N|x_1, x_2, \dots, x_N; \sigma^2)$  e o seu o logaritmo

$$f(y_1, y_2, \dots, y_N|x_1, x_2, \dots, x_N; \sigma^2) = \prod_{i=1}^N f(y_i|x_i; \sigma^2) \quad (6.14)$$

e

$$\begin{aligned} L &= \ln f(y_1, y_2, \dots, y_N|x_1, x_2, \dots, x_N; \sigma^2) \\ &= \sum_{i=1}^N \ln f(y_i|x_i; \sigma^2) \\ &= \sum_{i=1}^N \left[ -\ln \sqrt{2\pi\sigma^2 x_i} - \frac{1}{2} \frac{(y_i - x_i)^2}{\sigma^2 x_i} \right] \\ &= -N \ln \sqrt{2\pi} - N \ln \sigma - \sum_{i=1}^N \ln \sqrt{x_i} - \frac{1}{2\sigma^2} \sum_{i=1}^N \frac{y_i^2}{x_i} + \frac{1}{\sigma^2} \sum_{i=1}^N y_i - \frac{1}{2\sigma^2} \sum_{i=1}^N x_i. \end{aligned} \quad (6.15)$$

Aplicando a derivação com relação a  $\sigma$  e igualando a zero, temos

$$\frac{dL}{d\sigma} = -\frac{N}{\sigma} + \frac{1}{\sigma^3} \sum_{i=1}^N \frac{y_i^2}{x_i} - \frac{2}{\sigma^3} \sum_{i=1}^N y_i + \frac{1}{\sigma^3} \sum_{i=1}^N x_i = 0, \quad (6.16)$$

onde o termo a ser estimado  $\sigma^2$  é, portanto,

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N \frac{y_i^2}{x_i} - \frac{2}{N} \sum_{i=1}^N y_i + \frac{1}{N} \sum_{i=1}^N x_i = \frac{1}{N} \sum_{i=1}^N \frac{y_i^2}{x_i} - 2\bar{y} + \bar{x}, \quad (6.17)$$

onde  $\bar{y}$  e  $\bar{x}$  correspondem às médias globais das imagens ruidosa e livre de ruído, respectivamente, sendo que a última pode ser estimada sobre uma imagem pré-suavizada pelo método Non Local Means, por exemplo.

Desta forma, temos que a variância final do ruído pode ser definida como

$$\sigma_{\eta_i}^2 = \left( \frac{1}{N} \sum_{i=1}^N \frac{y_i^2}{x_i} - 2\bar{y} + \bar{x} \right) x_i. \quad (6.18)$$

## 6.2 Metodologia

A metodologia proposta consiste em utilizar Campos Aleatórios Markovianos utilizando um modelo *a priori* contextual para a filtragem de imagens tomográficas. Para isso é necessário inicialmente efetuar a estimação de parâmetros de Campo Aleatório Markoviano *a priori*.

Em (Mascarenhas e Frery, 1994) foi derivada a Equação de Máxima Pseudo Verossimilhança para a estimação do parâmetro beta do modelo de Potts para o caso de vizinhança de primeira ordem, enquanto que em (Levada, 2010) foi derivada para segunda e terceira ordens. Em ambos os trabalhos, esta equação foi resolvida por métodos numéricos. Em nosso caso, adotamos o modelo de Potts com até 256 tons de cinza, representando a imagem original (sem ruído), estimando o parâmetro beta pelas Equações de Máxima Pseudo Verossimilhança.

Por outro lado, no Modelo de Potts, a contribuição de um pixel vizinho ao pixel central da vizinhança é não nula apenas quando o pixel da vizinhança é igual ao pixel central. Para obter um modelo mais contínuo, Li (Li, 2009) propôs o chamado *Generalized Isotropic Multi-Level Logistic Markov Random Field Model* (GIMLL), onde a contribuição do pixel vizinho é contínua, dependendo da diferença entre o pixel vizinho e o pixel central. Como uma alternativa ao Modelo de Potts adotamos também o Modelo GIMLL.

Neste modelo, é utilizada a norma L2 sobre a diferença entre o pixel vizinho e o central. Desta forma também propomos o uso da norma L1, definindo o modelo que chamamos aqui de GIMLL-L1. Também para o GIMLL, não é possível obter-se uma forma fechada para

a estimação do parâmetro beta, sendo ele obtido por método numérico (Martins, Levada *et al.*, 2009). E ainda, podemos utilizar diferentes vizinhanças.

Além destes modelos foi utilizado também o modelo GMRF. Este último foi utilizado também para modelar a verossimilhança, que geralmente foi modelada por Gaussiana. Portanto, ao todo temos oito combinações verossimilhança-priori, escolhendo-se um modelo para a verossimilhança entre Gaussiana e GMRF e um modelo para *a priori* entre Potts, GIMLL, GIMLL-L1 e GMRF.

Estes modelos foram utilizados em conjunto com diversos algoritmos de otimização estatística como o ICM, GSA e MPM. Para esta abordagem ver o Capítulo 4. Vale ressaltar ainda que para considerar o ruído dependente do sinal nos métodos iterativos, foi proposto substituir o valor da variância da verossimilhança (observação) em cada ponto  $\sigma_{y_i}^2$  pela soma das variâncias  $\sigma_{x_i}^2 + \sigma_{\eta_i}^2$ , onde a primeira vem da estimativa da imagem livre de ruído dada pelo filtro da Média e a segunda dos métodos de estimação do ruído.

Além de comparar os resultados com esses diferentes algoritmos, os resultados foram comparados também às filtragens de Wiener Pontual, Wiener com MRF Separável, Wiener com MRF Isotrópico e Wiener Generalizado (veja o Capítulo 5) e do método estado da arte para filtragem de ruído Gaussiano denominado Non Local Means. E mais, foram comparados os resultados para ruído dependente do sinal e independente do sinal.

O desenvolvimento do trabalho contemplou a implementação dos estimadores dos parâmetros dos modelos contextuais, dos algoritmos ICM, GSA, MPM, dos métodos baseados em Wiener (Pontual, MRF Separável, MRF Isotrópico, Informação de Fisher), dos métodos de estimação de ruído dependente do sinal e de outros métodos da literatura que foram utilizados para a comparação de desempenho. Para isso, o software Matlab foi utilizado para sua implementação que ao final do processo produziu os resultados que foram analisados e discutidos no trabalho proposto.

Vale ressaltar que foram estendidas as implementações feitas em (Levada, 2010) dos métodos de otimização ICM, GSA, MPM e dos estimadores dos parâmetros dos modelos contextuais. Além disso, o algoritmo de reconstrução POCS paralelo utilizado foi o de (Salina, 2007).

Diversas medidas quantitativas para avaliação de qualidade de imagens foram utilizadas na comparação entre os diferentes métodos, dentre as quais *Mean Square Error* (MSE),

*Peak Signal-To-Noise Ratio (PSNR)*, *Improvement in Signal-To-Noise Ratio (ISNR)*, *Universal Image Quality Index (UIQ)* e *Structural Similarity Index (SSIM)* (Wang e Bovik, 2009). Estas medidas de avaliação serão apresentadas na Seção 6.3.

Para fazer estes testes e avaliar o desempenho dos métodos, dispomos de dados de projeção das imagens CT do CNPDIA da Embrapa (fornecidas em parceria), com baixa (3s de exposição por ponto de projeção) ou alta (20s de exposição por ponto de projeção) taxa de contagem. No primeiro caso, consideramos que a imagem é ruidosa, enquanto que no segundo caso a imagem foi considerada sem ruído permitindo assim comparação com outros métodos já propostos anteriormente. E também foram implementadas as filtragens de imagens clássicas na área de Tomografia, como a do phantom de Shepp-Logan (Shepp e Logan, 1974), corrompida por ruído gaussiano (gerado por ruído Poisson nas projeções). Vale ressaltar que filtraremos imagens que foram reconstruídas por Retroprojeção Filtrada (FBP) ou por POCS. Além disso, foi gerado um conjunto de imagens simuladas, cujo processo está descrito no Apêndice A. Estas imagens também foram utilizadas para a avaliação dos métodos de filtragem de ruído. Por fim, estudos dos parâmetros dos métodos de estimação do ruído e de filtragem também foram realizados e encontram-se nos Apêndices D a F.

### 6.3 Avaliação dos Resultados

Para comparar os diversos métodos, medidas quantitativas como *Mean Square Error (MSE)*, *Peak Signal-To-Noise Ratio (PSNR)*, *Improvement in Signal-To-Noise Ratio (ISNR)*, *Universal Image Quality Index (UIQ)* e *Structural Similarity Index (SSIM)* foram obtidas para a avaliação dos resultados.

O MSE entre dois sinais, sendo neste caso a imagem original (20s)  $x$  e a filtrada  $y$ , é definido pela seguinte equação

$$MSE(x, y) = \frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2. \quad (1.1)$$

Para esta medida, quanto menor o valor melhor o resultado.

O PSNR é definido em termos do MSE, sendo dado por

$$PSNR = 10 \log_{10} \frac{L^2}{MSE}, \quad (1.2)$$

onde  $L$  corresponde a faixa dinâmica das intensidades permitidas. Por exemplo, no caso de uma imagem de 8 bits em tons de cinza,  $L = 2^8 - 1 = 255$ . Além disso, quanto maior o valor de PSNR melhor. A unidade de medida dada é em decibéis (dB).

A medida ISNR (Salina, 2007) tem a diferença entre as outras que ela considera a imagem ruidosa no seu cálculo. Ela é dada pela seguinte equação

$$ISNR = 10 \log_{10} \frac{\sum_j (f_j - g_j)^2}{\sum_j (f_j - \hat{f}_j)^2}, \quad (1.3)$$

onde  $f_j$ ,  $g_j$  e  $\hat{f}_j$  correspondem à imagem original (20s), imagem ruidosa (3s) e imagem filtrada, respectivamente. Para esta medida quanto maior o seu valor, melhor.

Por sua vez, o UIQ pode ser definido como (Wang e Bovik, 2002)

$$Q(x, y) = \frac{4\sigma_{xy}\bar{x}\bar{y}}{(\sigma_x^2 + \sigma_y^2)[(\bar{x})^2 + (\bar{y})^2]}, \quad (1.4)$$

onde  $\bar{x}$  e  $\bar{y}$  são as médias amostrais dos sinais original  $x$  e filtrado  $y$ , respectivamente,  $\sigma_x^2$  e  $\sigma_y^2$  as variâncias destes sinais nesta ordem e  $\sigma_{xy}$  é a correlação cruzada entre estes sinais. Esta medida tem seus valores definidos entre  $[-1, 1]$ , sendo 1 o melhor valor.

Por fim, o SSIM é considerado uma das melhores medidas, por ter alta fidelidade à avaliação visual qualitativa. Ele é definido por

$$\begin{aligned} S(x, y) &= l(x, y)c(x, y)s(x, y) \\ &= \left( \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \right) \left( \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \right) \left( \frac{2\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3} \right), \end{aligned} \quad (1.5)$$

onde  $l(x, y)$ ,  $c(x, y)$  e  $s(x, y)$  são as similaridades da luminância, contraste e estruturas, nesta ordem,  $\mu_x$  e  $\mu_y$  correspondem às médias amostrais locais dos sinais original  $x$  e filtrado  $y$ , respectivamente,  $\sigma_x$  e  $\sigma_y$  são os desvios padrão locais destes sinais, respectivamente,  $\sigma_{xy}$  é a correlação cruzada local entre estes sinais centralizados no zero (médias removidas) e  $C_1$ ,  $C_2$  e  $C_3$  são constantes positivas pequenas para estabilização. Esta medida gera valores entre  $[-1, 1]$ , sendo que quanto maior o valor desta medida, melhor.

#### **6.4 Resultados Esperados e considerações finais**

Com a utilização do contexto via MRF e com a modelagem do ruído dependente do sinal na filtragem de imagens de CT, espera-se uma maior redução no nível de ruído em termos de MSE, PSNR, ISNR, UIQ e SSIM e, principalmente, visualmente.

Baseado nas teorias descritas nos capítulos anteriores, na metodologia e nas propostas apresentadas neste capítulo, os resultados produzidos são apresentados e discutidos nos Apêndices C a E, e especialmente, no capítulo a seguir.

## 7 RESULTADOS PRINCIPAIS DE FILTRAGEM DE RUÍDO EM IMAGENS DE CT

Neste capítulo, são apresentados alguns resultados gerados considerando tanto a abordagem por algoritmos iterativos de otimização combinatória, quanto métodos diretos baseados no Wiener. Além disso, tanto resultados usando dependência quanto independência de sinal foram obtidos. Os resultados apresentados aqui foram aplicados especialmente nas imagens reais de CT.

Ou seja, foram gerados resultados para as seguintes combinações de parâmetros para cada método:

- 1) **ICM:** Número de Iterações {1, 3, 8} e modelos para verossimilhança (Gaussiana, GMRF) e a priori (Potts, GIMLL, GIMLL-L1, GMRF);
- 2) **GSA:** Taxa de Aceitação {0.6, 0.7, 0.8, 0.9}, Número de Iterações {1, 3, 8} e modelos para verossimilhança (Gaussiana, GMRF) e a priori (Potts, GIMLL, GIMLL-L1, GMRF);
- 3) **MPM:** Número de Iterações 2000 com número de Iterações para o Equilíbrio 1000, e modelos para verossimilhança (Gaussiana, GMRF) e a priori (Potts, GIMLL, GIMLL-L1, GMRF);
- 4) **Non Local Means:** Largura da área de busca, largura do patch, número de iterações, e parâmetros de confiança na quantidade de filtragem  $\alpha$  e na imagem pré-estimada  $\beta$  foram 10, 3, 1, 0.03 e 0.03, respectivamente;
- 5) **Wiener Pontual:** Largura da Janela para estimar parâmetros (W) {3, 5, 7, 9} e estimativa da imagem livre de ruído obtida ou por Non Local Means ou por filtro da média com Largura da Janela ( $w_{\text{pré}}$ ) {3, 5, 7, 9};
- 6) **Wiener com Informação de Fisher (Generalizado):** Taxa de Compromisso  $\alpha$  {0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1} e Largura da Janela para Estimação dos parâmetros {3, 5, 7, 9}. Também, foram considerados os Sistemas de Vizinhança de Primeira Ordem ( $viz = 4$ ) e Segunda Ordem ( $viz = 8$ ), além da estimativa da imagem livre de ruído obtida ou por Non Local Means ou por filtro da média com Largura da Janela ( $w_{\text{pré}}$ ) {3, 5, 7, 9};

- 7) **Wiener com MRF Isotrópico:** Largura da Janela para Estimação dos parâmetros  $\{3, 5, 7, 9\}$  e estimativa da imagem livre de ruído obtida ou por Non Local Means ou por filtro da média com Largura da Janela ( $w_{\text{pré}}$ )  $\{3, 5, 7, 9\}$ ;
- 8) **Wiener com MRF Separável:** Largura da Janela para Estimação dos parâmetros  $\{3, 5, 7, 9\}$  e estimativa da imagem livre de ruído obtida ou por Non Local Means ou por filtro da média com Largura da Janela ( $w_{\text{pré}}$ )  $\{3, 5, 7, 9\}$ .

Além disso, foram considerados em cada método de filtragem os três métodos propostos nesta tese para a estimação do ruído dependente do sinal: Preliminar, Final e Formal. Nos métodos Preliminar e Final, foram definidos para cada imagem um limiar que gerasse o mapa de borda mais preciso visualmente, com um mínimo visual de falsos positivos. Além disso, para o número de bins ( $K$ ), além de  $K = 256$ , também foi selecionado um  $K$  que visualmente melhor ajustasse o mapa de segmentos da imagem. Lembrando que a principal diferença entre os métodos Preliminar e Final, é que este utiliza o Non Local Means e aquele o filtro da Média.

Já para o ruído independente do sinal, temos dois casos diferentes para os métodos diretos e os métodos iterativos. Para o primeiro, além da estimativa manual da variância em área homogênea, foi considerado o número de bins  $K = 1$  para os métodos propostos Preliminar e Final, com os mesmos limiares definidos para o ruído dependente. Já para último, apenas a estimativa manual foi utilizada.

Ainda, uma técnica simples de melhora de contraste aplicada após a filtragem, também foi testada, devido ao baixo contraste exibido pelas imagens ruidosas e filtradas, especialmente nas reconstruídas por FBP. Esta técnica consistiu em um mapeamento linear do histograma para o intervalo  $[0,1]$ , onde o menor valor foi levado para zero e o maior para 1.

Estes métodos foram aplicados em várias imagens reais de CT que foram reconstruídas tanto por FBP com Filtro de Ram-Lak quanto por POCS paralelo. Os melhores resultados para cada uma das imagens e cada método de reconstrução, de acordo com MSE, PSNR, ISNR, UIQ e SSIM, serão apresentados nas próximas Seções em formas de tabelas e pela exibição das imagens filtradas resultantes, como também haverá uma discussão sobre eles.

Vale ressaltar também que os tempos da estimativa da imagem livre de ruído estão adicionados aos tempos apresentados para cada método nas tabelas de resultados. E também, algumas representações foram usadas nas tabelas, onde NLM e MÉD definem a técnica de

pré-estimação da imagem livre do ruído utilizada, Non Local Means e filtro da Média, respectivamente, e MAN, PRELIM, FINAL e FORM representam o método de estimação de ruído utilizado sendo, respectivamente, Manual (independente do sinal), Preliminar, Final e Formal.

Além disso, é importante informar que todas as medidas foram arredondadas para apenas duas casas decimais, sendo que valores 0,00 não correspondem ao valor 0, mas valores menores ou iguais a 0,005, que ao serem arredondados para apenas duas casas decimais tornaram-se 0,00. Ainda, para facilitar a análise destes resultados podemos considerar apenas as medidas de ISNR e SSIM, já que em geral, a primeira medida apresenta resultados equivalentes a MSE e PSNR e a segunda, ao UIQ.

Às seguintes imagens os métodos foram aplicados:

- 1) ***Phantom de Shepp-Logan***: Esta é uma imagem simulada, por adicionar ruído Poisson nas projeções. Seus resultados estão na Seção 7.1;
- 2) ***Phantom Homogêneo***: Seção 7.2;
- 3) ***Phantom Simétrico***: Seção 7.3;
- 4) ***Phantom Assimétrico***: Seção 7.4;
- 5) **Madeira 1**: Seção 7.5;
- 6) **Madeira 2**: Seção 7.6.

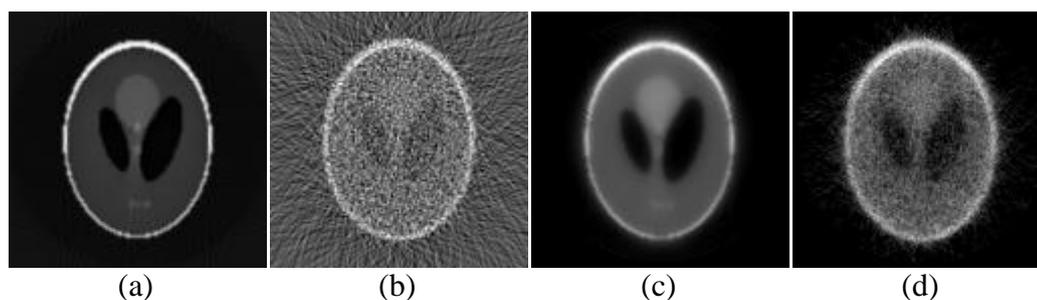
Finalizando o texto deste documento, na Seção 7.7 são apresentadas algumas considerações finais.

## **7.1 Imagem Simulada: *Phantom de Shepp-Logan***

O *phantom* de Shepp-Logan (Shepp e Logan, 1974) foi proposto a fim de se simular a aquisição de imagem de cabeça. Ele possui áreas homogêneas de diferentes tonalidades (dadas por materiais de densidades diferentes), tamanhos e formas. Este foi um experimento simulado já que foi adicionado ruído Poisson nas projeções. As imagens continham dimensões de 128 x 128 pixels. Na Figura 7.1 são exibidas as imagens original e ruidosa para FBP e POCS e na Tabela 7.1 as medidas da imagem ruidosa comparada com a original. Nas Seções 7.1.1 e 7.1.2 são apresentados e discutidos os resultados de filtragem obtidos em imagens reconstruídas por FBP e POCS, respectivamente.

**Tabela 7.1.** Resultados das medidas de avaliação da imagem ruidosa comparada com a imagem original para o *phantom* de Shepp-Logan, reconstruídas tanto por FBP quanto por POCS.

Métodos de Reconstrução	MSE	PSNR	UIQ	SSIM	Tempo de Reconstrução (s)
<b>FBP</b>	0,07	11,29	0,11	0,13	0,02
<b>POCS</b>	0,00	24,02	0,44	0,55	120,15



**Figura 7.1.** Imagens do *phantom* de Shepp-Logan: a) original reconstruída por FBP, b) ruidosa reconstruída por FBP, c) original reconstruída por POCS e d) ruidosa reconstruída por POCS.

### 7.1.1 FBP

Nesta Seção, temos os resultados da aplicação dos métodos sobre a imagem do *phantom* de Shepp-Logan reconstruída por FBP. Os melhores resultados para cada método são exibidos na Tabela 7.2, e suas respectivas imagens filtradas na Figura 7.2. Ainda na Figura 7.3 temos os mapas de borda obtidos para  $K = 256$  e  $K = 1$ , e os números de bins considerados os mais adequados para esta imagem,  $K = 5$  e  $K = 8$ , para os métodos Preliminar e Final, respectivamente. Nos mapas de borda, quanto maior a intensidade do ponto, maior é a variância do ruído.

Para esta imagem, temos que o melhor resultado obtido foi exibido pelo Wiener com MRF Separável com Largura de Janela 5, pré-estimativa da imagem livre de ruído dado por Non Local Means, estimativa do ruído definido manualmente (independência do sinal) e contraste melhorado, aumentando cerca de 10,16 dB do PSNR da imagem ruidosa, melhorando muito o contraste e a suavização. Comparando com o Wiener Pontual e Non Local Means, esse resultado chegou a ser cerca de 4,19 dB e 2,9 dB superior, respectivamente.

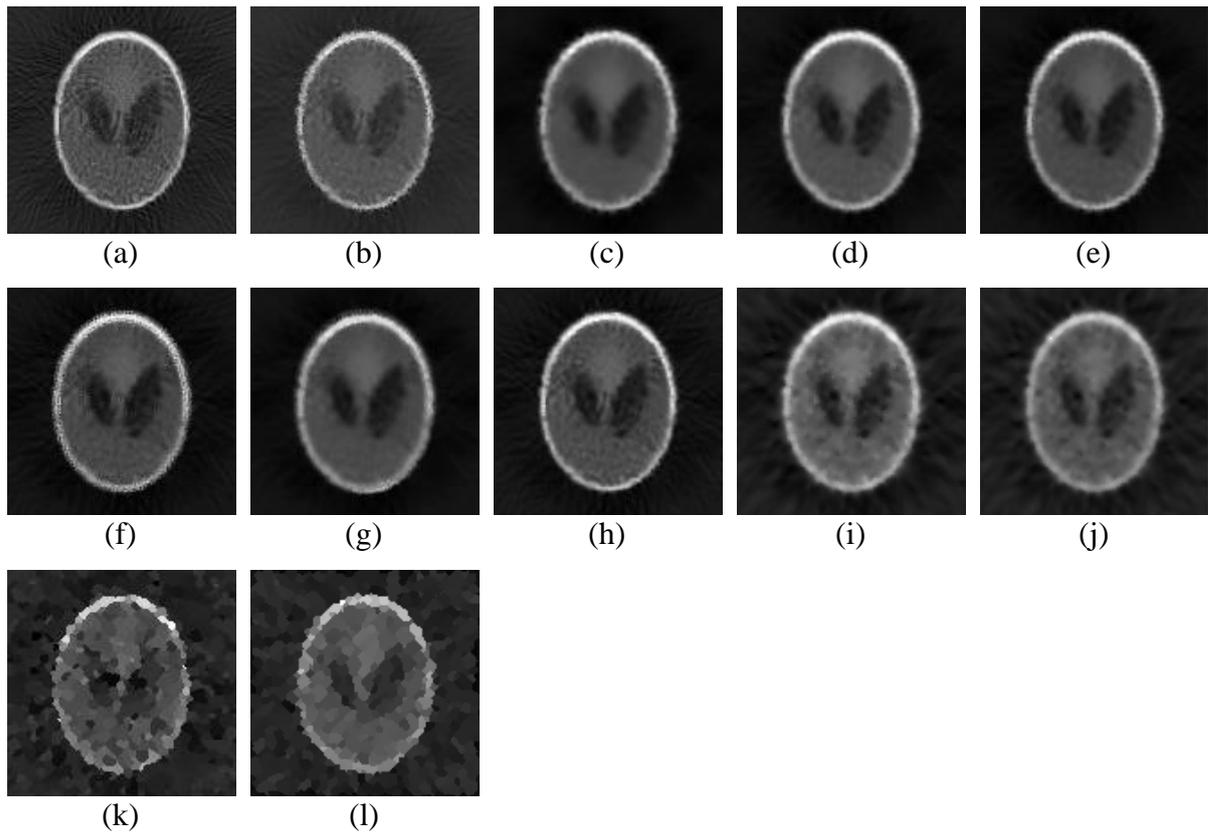
Visualmente, além do melhor resultado apontado no parágrafo anterior (Figura 7.2e), podemos destacar também o resultado do Wiener com MRF Isotrópico \* ( $w = 5 \times 5$ , NLM, MAN) e do Wiener Generalizado \* ( $\alpha = 0,6$ ,  $w = 5 \times 5$ ,  $viz = 4$ , NLM, MAN) nos itens (d) e (g) da Figura 7.2, respectivamente.

Tabela 7.2. Melhores resultados para o *phantom* de Shepp-Logan reconstruído por FBP, onde \* representa o uso de técnica de realce de contraste.

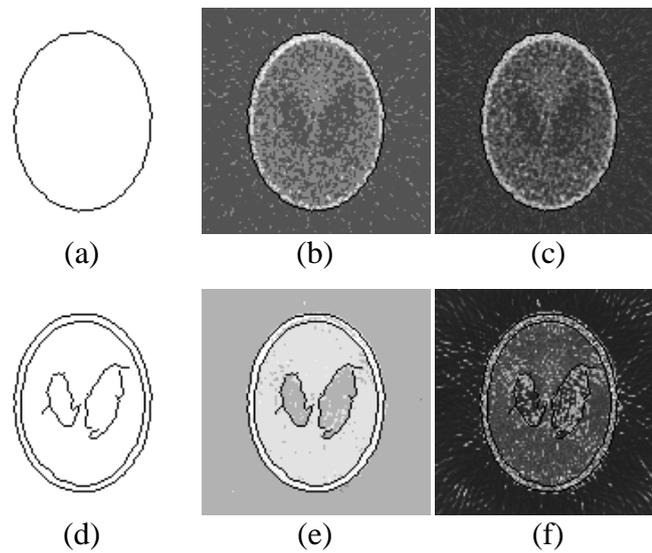
Ord.	Métodos de Filtragem	MSE	PSNR	ISNR	UIQ	SSIM	Tempo (s)
(a)	Non Local Means *	<b>0,01</b>	18,55	7,26	0,21	0,43	0,71
(b)	Wiener Pontual * (w = 3x3, NLM, MAN)	0,02	17,26	5,97	0,21	0,50	0,71
	Wiener Pontual * (w = 3x3, w_pre = 5x5, MÉD, FINAL, bins = 8)	0,03	15,14	3,85	0,15	0,39	<b>0,01</b>
	Wiener Pontual * (w = 5x5, NLM, FINAL, bins = 1)	0,03	15,03	3,74	0,16	0,44	0,72
	Wiener Pontual * (w = 3x3, NLM, FINAL, bins = 8)	0,03	15,11	3,82	0,18	0,43	0,72
	Wiener Pontual * (w = 3x3, NLM, PRELIM, bins = 1)	0,03	15,22	3,93	0,19	0,44	0,72
	Wiener Pontual * (w = 5x5, NLM, PRELIM, bins = 1)	0,03	15,13	3,84	0,19	0,45	0,72
	Wiener Pontual * (w = 3x3, NLM, FORM)	0,03	15,07	3,78	0,19	0,42	0,71
(c)	Wiener com MRF Isotrópico * (w = 7x7, NLM, MAN)	<b>0,01</b>	20,91	9,61	0,25	0,72	3,66
(d)	Wiener com MRF Isotrópico * (w = 5x5, NLM, MAN)	<b>0,01</b>	20,30	9,01	<b>0,26</b>	0,72	2,65
	Wiener com MRF Isotrópico * (w = 9x9, NLM, FINAL, bins = 8)	0,03	15,48	4,19	0,14	0,44	5,58
	Wiener com MRF Isotrópico * (w = 3x3, NLM, FINAL, bins = 256)	0,03	14,66	3,37	0,17	0,43	2,27
	Wiener com MRF Isotrópico * (w = 3x3, NLM, PRELIM, bins = 256)	0,03	15,43	4,14	0,20	0,46	2,05
	Wiener com MRF Isotrópico * (w = 3x3, NLM, FORM)	<b>0,01</b>	20,61	9,32	<b>0,26</b>	0,67	2,07
	Wiener com MRF Isotrópico * (w = 5x5, NLM, FORM)	<b>0,01</b>	19,77	8,48	0,25	0,71	2,43
(e)	Wiener com MRF Separável * (w = 5x5, NLM, MAN)	<b>0,01</b>	<b>21,45</b>	<b>10,16</b>	<b>0,26</b>	<b>0,74</b>	2,63
	Wiener com MRF Separável * (w = 9x9, NLM, FINAL, bins = 8)	0,03	15,48	4,19	0,14	0,44	5,52
	Wiener com MRF Separável * (w = 3x3, NLM, FINAL, bins = 256)	0,03	14,67	3,37	0,17	0,43	2,27
	Wiener com MRF Separável * (w = 3x3, NLM, PRELIM, bins = 256)	0,03	15,44	4,15	0,20	0,46	2,05
	Wiener com MRF Separável * (w = 3x3, NLM, FORM)	<b>0,01</b>	20,63	9,34	<b>0,26</b>	0,67	2,05
(f)	Wiener Generalizado * ( $\alpha = 0$ , w = 3x3, viz = 8, NLM, MAN)	<b>0,01</b>	21,07	9,78	0,24	0,68	0,72
(g)	Wiener Generalizado * ( $\alpha = 0,6$ , w = 5x5, viz = 4, NLM, MAN)	<b>0,01</b>	20,71	9,42	0,25	0,72	0,72
(h)	Wiener Generalizado * ( $\alpha = 0,6$ , w = 3x3, viz = 4, NLM, MAN)	<b>0,01</b>	20,76	9,47	<b>0,26</b>	0,67	0,72
	Wiener Generalizado * ( $\alpha = 0,3$ , w = 3x3, viz = 8, NLM, FINAL, bins = 8)	<b>0,01</b>	20,77	9,47	0,24	0,67	0,72
	Wiener Generalizado * ( $\alpha = 0,3$ , w = 3x3, viz = 8, NLM, FINAL, bins = 1)	<b>0,01</b>	20,73	9,44	0,25	0,67	0,72
	Wiener Generalizado * ( $\alpha = 0,3$ , w = 3x3, viz = 8, NLM, PRELIM, bins = 1)	<b>0,01</b>	20,88	9,59	0,25	0,68	0,72
	Wiener Generalizado * ( $\alpha = 0,3$ , w = 3x3, viz = 8, NLM, PRELIM, bins = 1)	<b>0,01</b>	20,78	9,49	0,25	0,67	0,72

	FORM)						
	ICM * (Modelo = GMRF+GIMLL-L1, iter = 8, MAN)	0,02	16,99	5,70	0,18	0,40	156,65
	ICM * (Modelo = Gaussiana+GMRF, iter = 8, MAN)	0,03	15,19	3,89	0,19	0,42	1,41
	ICM * (Modelo = Gaussiana+GMRF, iter = 3, MAN)	0,03	15,53	4,24	0,20	0,40	0,53
(i)	ICM * (Modelo = GMRF+GMRF, iter = 8, FINAL, bins = 8)	0,02	17,35	6,06	0,21	0,53	1,16
	ICM * (Modelo = GMRF+GIMLL-L1, iter = 8, PRELIM, bins = 256)	0,02	16,89	5,60	0,17	0,39	146,05
	ICM * (Modelo = GMRF+GMRF, iter = 8, PRELIM, bins = 5)	0,03	15,85	4,56	0,20	0,49	1,53
	ICM * (Modelo = GMRF+GIMLL-L1, iter = 8, FORM)	0,02	16,87	5,58	0,18	0,39	147,17
	ICM * (Modelo = GMRF+GMRF, iter = 8, FORM)	0,02	16,13	4,83	0,20	0,46	1,32
	GSA * (Modelo = GMRF+GIMLL-L1, iter = 8, $\alpha = 0,7$ , MAN)	0,02	17,17	5,87	0,18	0,38	159,48
	GSA * (Modelo = Gaussiana+GMRF, iter = 8, $\alpha = 0,7$ , MAN)	0,03	15,53	4,24	0,19	0,42	3,03
	GSA * (Modelo = GMRF+GMRF, iter = 3, $\alpha = 0,7$ , FINAL, bins = 8)	<b>0,01</b>	18,29	7,00	0,21	0,46	1,52
	GSA * (Modelo = GMRF+GMRF, iter = 8, $\alpha = 0,9$ , FINAL, bins = 8)	0,02	17,36	6,07	0,21	0,53	3,18
(j)	GSA * (Modelo = GMRF+GMRF, iter = 8, $\alpha = 0,7$ , PRELIM, bins = 5)	<b>0,01</b>	18,40	7,10	0,21	0,53	3,70
	GSA * (Modelo = GMRF+GMRF, iter = 3, $\alpha = 0,8$ , FORM)	0,02	17,57	6,28	0,21	0,44	1,44
	GSA * (Modelo = GMRF+GMRF, iter = 8, $\alpha = 0,8$ , FORM)	0,02	16,66	5,37	0,21	0,47	3,45
(k)	MPM * (Modelo = GMRF+GIMLL, MAN)	0,02	17,79	6,50	0,15	0,38	1294,06
(l)	MPM * (Modelo = Gaussiana+ GIMLL-L1, FINAL, bins=8)	0,02	17,35	6,06	0,16	0,42	1620,28
	MPM * (Modelo = GMRF+Potts, PRELIM, bins=5)	0,02	17,15	5,86	0,13	0,32	275,75
	MPM * (Modelo = GMRF+GIMLL-L1, PRELIM, bins=5)	0,02	16,35	5,06	0,14	0,37	1629,41
	MPM * (Modelo = GMRF+Potts, FORM)	0,02	16,49	5,20	0,16	0,33	274,60
	MPM * (Modelo = GMRF+GIMLL-L1, FORM)	0,03	15,78	4,49	0,15	0,35	1608,68

Foi observado também que os métodos baseados nos algoritmos de otimização melhoraram o resultado menos dos que os métodos baseados em Wiener, tendo o GSA obtido os melhores resultados. Além disso, notou-se que os melhores resultados obtidos pelo MPM, que usam modelos a priori GIMLL e GIMLL-L1 (itens (k) e (l) da Figura 7.2, respectivamente), parecem tender a segmentação da imagem.



**Figura 7.2.** Resultados de Filtragem para a Imagem do *phantom* de Shepp-Logan reconstruído por FBP. As imagens exibidas estão na ordem da Tabela 7.2.



**Figura 7.3.** Mapas do Ruído para o *phantom* de Shepp-Logan reconstruído por FBP do método Preliminar (limiar = 0,85 e número de bins: (a)  $K = 1$ , (b)  $K = 5$  e (c)  $K = 256$ ) e do Final (limiar = 0,22 e número de bins: (d)  $K = 1$ , (e)  $K = 8$  e (f)  $K = 256$ ).

Por fim, temos que em geral os melhores resultados para esta imagem utilizaram técnica de melhora de contraste e pré-estimativa da imagem livre de ruído dada por Non Local Means, e que a estimativa do ruído manual foi comumente superior aos outros métodos.

### 7.1.2 POCS

Nesta Seção, temos os resultados da aplicação dos métodos sobre a imagem do *phantom* de Shepp-Logan reconstruída por POCS. Os melhores resultados para cada método são exibidos na Tabela 7.3, e suas respectivas imagens filtradas na Figura 7.4. Ainda na Figura 7.5 temos os mapas de borda obtidos para  $K = 256$  e  $K = 1$ , e os números de bins considerados os mais adequados para esta imagem,  $K = 5$  para ambos os métodos Preliminar e Final.

**Tabela 7.3.** Melhores resultados para o *phantom* de Shepp-Logan reconstruído por POCS, onde \* representa o uso de técnica de realce de contraste.

Ord.	Métodos de Filtragem	MSE	PSNR	ISNR	UIQ	SSIM	Tempo (s)
(a)	Non Local Means	0,00	26,60	2,58	0,47	0,77	0,71
(b)	Non Local Means *	0,00	24,20	0,19	0,50	0,75	0,71
	Wiener Pontual ( $w = 3 \times 3$ , NLM, MAN)	0,00	26,16	2,14	0,46	0,76	0,71
	Wiener Pontual * ( $w = 5 \times 5$ , $w_{pre} = 3 \times 3$ , MÉD, MAN)	0,00	24,20	0,19	0,51	0,70	0,01
	Wiener Pontual ( $w = 3 \times 3$ , NLM, FINAL, bins = 1)	0,00	26,28	2,27	0,55	0,79	0,71
(c)	Wiener Pontual ( $w = 3 \times 3$ , NLM, PRELIM, bins = 256)	0,00	26,37	2,35	0,56	0,80	0,71
	Wiener Pontual ( $w = 3 \times 3$ , NLM, FORM)	0,00	26,32	2,30	0,47	0,76	0,71
	Wiener Pontual ( $w = 3 \times 3$ , $w_{pre} = 3 \times 3$ , MÉD, FORM)	0,00	25,70	1,68	0,51	0,71	0,01
	Wiener com MRF Isotrópico ( $w = 3 \times 3$ , NLM, MAN)	0,00	26,52	2,50	0,47	0,77	2,15
	Wiener com MRF Isotrópico ( $w = 5 \times 5$ , $w_{pre} = 3 \times 3$ , MÉD, MAN)	0,00	25,76	1,74	0,51	0,72	0,91
	Wiener com MRF Isotrópico ( $w = 3 \times 3$ , NLM, FINAL, bins = 256)	0,00	26,40	2,39	0,45	0,78	2,14
	Wiener com MRF Isotrópico ( $w = 3 \times 3$ , $w_{pre} = 3 \times 3$ , MÉD, FINAL, bins = 256)	0,00	25,68	1,66	0,50	0,73	1,24
(d)	Wiener com MRF Isotrópico ( $w = 3 \times 3$ , NLM, PRELIM, bins = 5)	0,00	26,48	2,47	0,45	0,78	1,94
	Wiener com MRF Isotrópico ( $w = 3 \times 3$ , $w_{pre} = 3 \times 3$ , MÉD, PRELIM, bins = 5)	0,00	25,74	1,72	0,50	0,74	1,06
(e)	Wiener com MRF Isotrópico ( $w = 3 \times 3$ , NLM, FORM)	0,00	26,53	2,51	0,47	0,77	2,12
(f)	Wiener com MRF Isotrópico ( $w = 3 \times 3$ , pré_est = 3x3, MÉD, FORM)	0,00	25,77	1,75	0,51	0,72	0,90

	Wiener com MRF Separável ( $w = 3 \times 3$ , NLM, MAN)	0,00	26,52	2,50	0,47	0,77	2,13
	Wiener com MRF Separável ( $w = 3 \times 3$ , $w_{pre} = 3 \times 3$ , MÉD, MAN)	0,00	25,76	1,74	0,51	0,72	1,26
	Wiener com MRF Separável ( $w = 3 \times 3$ , NLM, FINAL, bins = 256)	0,00	26,40	2,38	0,45	0,78	2,14
	Wiener com MRF Separável ( $w = 3 \times 3$ , $w_{pre} = 3 \times 3$ , MÉD, FINAL, bins = 256)	0,00	25,68	1,66	0,50	0,73	1,24
(g)	Wiener com MRF Separável ( $w = 3 \times 3$ , NLM, PRELIM, bins = 5)	0,00	26,48	2,47	0,45	0,78	1,95
	Wiener com MRF Separável ( $w = 3 \times 3$ , $w_{pre} = 3 \times 3$ , MÉD, PRELIM, bins = 5)	0,00	25,74	1,73	0,50	0,74	1,08
(h)	Wiener com MRF Separável ( $w = 3 \times 3$ , NLM, FORM)	0,00	26,54	2,52	0,47	0,77	2,12
(i)	Wiener com MRF Separável ( $w = 3 \times 3$ , $w_{pre} = 3 \times 3$ , MÉD, FORM)	0,00	25,77	1,76	0,51	0,72	1,23
	Wiener Generalizado ( $\alpha = 0,5$ , $w = 3 \times 3$ , viz = 8, NLM, MAN)	0,00	26,45	2,43	0,47	0,77	0,72
	Wiener Generalizado ( $\alpha = 0,5$ , $w = 3 \times 3$ , viz = 8, $w_{pré} = 3 \times 3$ , MÉD, MAN)	0,00	25,78	1,76	0,51	0,72	0,01
	Wiener Generalizado ( $\alpha = 0,6$ , $w = 3 \times 3$ , viz = 8, NLM, FINAL, bins = 1)	0,00	26,48	2,46	0,47	0,78	0,72
	Wiener Generalizado ( $\alpha = 1$ , $w = 3 \times 3$ , viz = 4, NLM, FINAL, bins = 1)	0,00	26,30	2,29	0,55	0,79	0,71
(j)	Wiener Generalizado ( $\alpha = 0,7$ , $w = 3 \times 3$ , viz = 4, NLM, PRELIM, bins = 256)	0,00	26,50	2,48	0,46	0,79	0,71
(k)	Wiener Generalizado ( $\alpha = 1$ , $w = 3 \times 3$ , viz = 4, NLM, PRELIM, bins = 5)	0,00	26,43	2,41	0,56	0,80	0,71
(l)	Wiener Generalizado ( $\alpha = 0,6$ , $w = 3 \times 3$ , viz = 4, NLM, FORM)	0,00	26,50	2,48	0,47	0,77	0,71
	Wiener Generalizado ( $\alpha = 0,8$ , $w = 3 \times 3$ , viz = 4, $w_{pré} = 3 \times 3$ , MÉD, FORM)	0,00	25,79	1,77	0,51	0,72	0,00
(m)	ICM (Modelo = Gaussiana+GMRF, iter = 1, MAN)	0,00	25,79	1,77	0,53	0,73	0,37
(n)	ICM (Modelo = Gaussiana+GMRF, iter = 3, MAN)	0,00	25,69	1,67	0,54	0,74	0,56
	ICM (Modelo = GMRF+GMRF, iter = 1, FINAL, bins = 256)	0,00	25,77	1,75	0,53	0,72	0,28
	ICM (Modelo = GMRF+GMRF, iter = 3, FINAL, bins = 256)	0,00	25,64	1,63	0,53	0,73	0,77
	ICM (Modelo = GMRF+GMRF, iter = 1, PRELIM, bins = 5)	0,00	25,74	1,73	0,53	0,72	0,35
	ICM (Modelo = Gaussiana+GMRF, iter = 1, PRELIM, bins = 5)	0,00	25,59	1,58	0,53	0,73	0,29
	ICM (Modelo = GMRF+GMRF, iter = 1, FORM)	0,00	25,74	1,73	0,53	0,72	0,26
	ICM (Modelo = Gaussiana+GMRF, iter = 1, FORM)	0,00	25,60	1,58	0,53	0,73	0,27
(o)	GSA (Modelo = Gaussiana+GMRF, iter = 1, $\alpha = 0,8$ , MAN)	0,00	25,78	1,76	0,53	0,72	0,49
(p)	GSA (Modelo = Gaussiana+GMRF, iter = 3, $\alpha = 0,9$ , MAN)	0,00	25,70	1,68	0,54	0,74	1,34

	<b>GSA (Modelo = GMRF+GMRF, iter = 1, <math>\alpha = 0,9</math>, FINAL, bins = 256)</b>	<b>0,00</b>	25,75	1,74	0,53	0,72	0,52
	<b>GSA (Modelo = GMRF+GMRF, iter = 3, <math>\alpha = 0,9</math>, FINAL, bins = 256)</b>	<b>0,00</b>	25,67	1,65	0,53	0,73	1,42
	<b>GSA (Modelo = GMRF+GMRF, iter = 1, <math>\alpha = 0,8</math>, PRELIM, bins = 256)</b>	<b>0,00</b>	25,73	1,72	0,53	0,72	0,70
	<b>GSA (Modelo = Gaussiana+GMRF, iter = 1, <math>\alpha = 0,9</math>, PRELIM, bins = 256)</b>	<b>0,00</b>	25,61	1,59	0,53	0,73	0,53
	<b>GSA (Modelo = GMRF+GMRF, iter = 1, <math>\alpha = 0,9</math>, FORM)</b>	<b>0,00</b>	25,74	1,72	0,52	0,72	0,63
	<b>GSA (Modelo = Gaussiana+GMRF, iter = 1, <math>\alpha = 0,7</math>, FORM)</b>	<b>0,00</b>	25,64	1,63	0,53	0,73	0,60
	<b>MPM (Modelo = Gaussiana+GIMLL-L1, MAN)</b>	0,07	11,62	-12,40	0,32	0,40	1611,34
	<b>MPM (Modelo = GMRF+GMRF, MAN)</b>	0,08	10,78	-13,24	0,34	0,41	361,32
	<b>MPM (Modelo = GMRF+GIMLL-L1, FINAL, bins=256)</b>	0,06	12,29	-11,73	0,33	0,47	1629,00
	<b>MPM (Modelo = Gaussiana+GIMLL, FINAL, bins=256)</b>	0,06	12,27	-11,74	0,34	0,46	1283,50
	<b>MPM (Modelo = GMRF+Potts, PRELIM, bins=256)</b>	0,06	12,27	-11,75	0,31	0,43	276,38
	<b>MPM (Modelo = Gaussiana+GIMLL-L1, PRELIM, bins=256)</b>	0,06	12,07	-11,95	0,33	0,45	1616,18
<b>(q)</b>	<b>MPM (Modelo = Gaussiana+GIMLL-L1, FORM)</b>	0,03	15,57	-8,45	0,36	0,59	1635,58

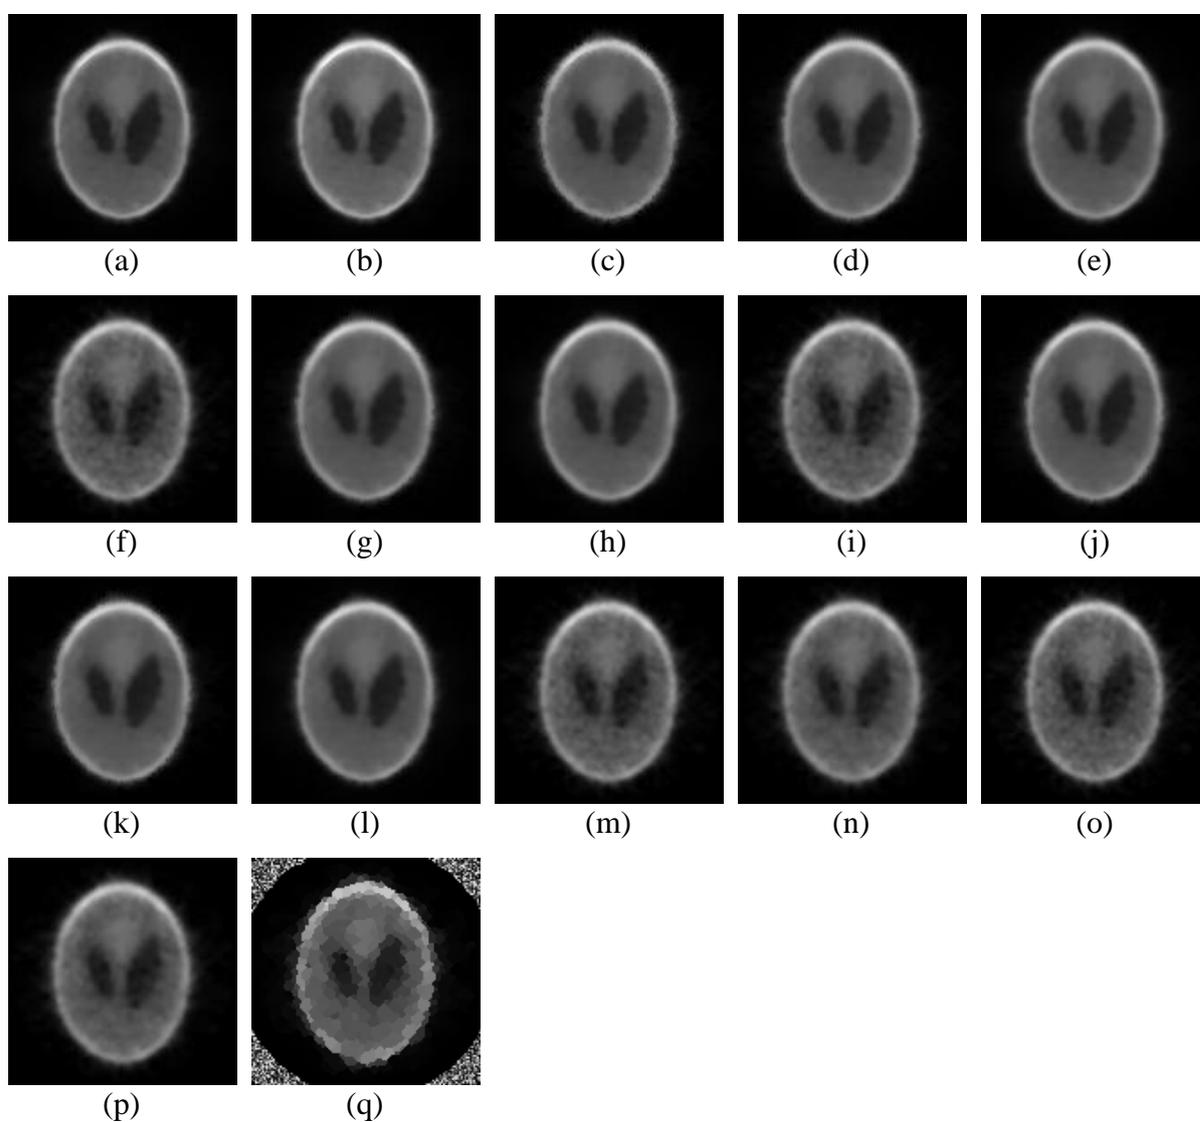
Para esta imagem, temos que o melhor resultado em termos de PSNR foi obtido pelo Non Local Means, aumentando em mais de 2,58 dB do PSNR da imagem ruidosa. Entretanto, este resultado é equivalente ao do Wiener com MRF Isotrópico ( $w = 3 \times 3$ , NLM, FORM), o melhor método contextual em termos de PSNR. Este último, comparado com o melhor resultado do Wiener Pontual e imagem ruidosa foi cerca de 0,16 dB e 2,51 dB superior, respectivamente.

Entretanto, em termos de SSIM e UIQ, o melhor resultado foi o Wiener Generalizado ( $\alpha = 1$ ,  $w = 3 \times 3$ , viz = 4, NLM, PRELIM, bins = 5), que corresponde ao Wiener Pontual. Este resultado foi um pouco superior ao desempenho dos métodos contextuais, dentre os quais destacamos o Wiener Generalizado ( $\alpha = 0,7$ ,  $w = 3 \times 3$ , viz = 4, NLM, PRELIM, bins = 256) com o melhor SSIM e o GSA (Gaussiana+GMRF, iter = 3,  $\alpha = 0,9$ , MAN) com o melhor UIQ.

Visualmente, os melhores resultados foram obtidos pelo Non Local Means e métodos diretos que apresentaram resultados bastante semelhantes, excetuando-se entre estes os itens

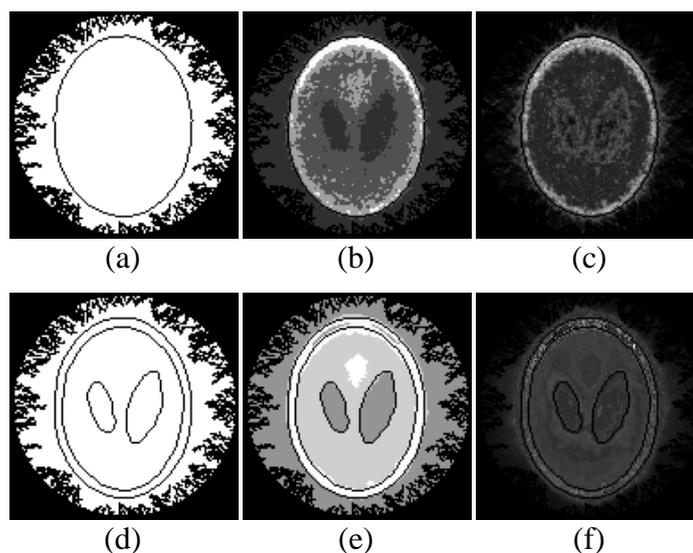
(f) e (i) da Figura 7.4, que utilizaram a pré-estimativa da imagem livre de ruído dada pelo filtro da média.

Aqui, também foi observado que o ICM e o GSA apresentaram resultados semelhantes. Além disso, acredita-se que um maior número de iterações para o MPM seja necessário, pois os resultados foram muito inferiores. Notou-se também aqui uma tendência do melhor resultado para o MPM, que usa modelo a priori GIMLL-L1 (itens (p) e (l) da Figura 7.4), de segmentar a imagem.



**Figura 7.4.** Resultados de Filtragem para a Imagem do *phantom* de Shepp-Logan reconstruído por POCS. As imagens exibidas estão na ordem da Tabela 7.3.

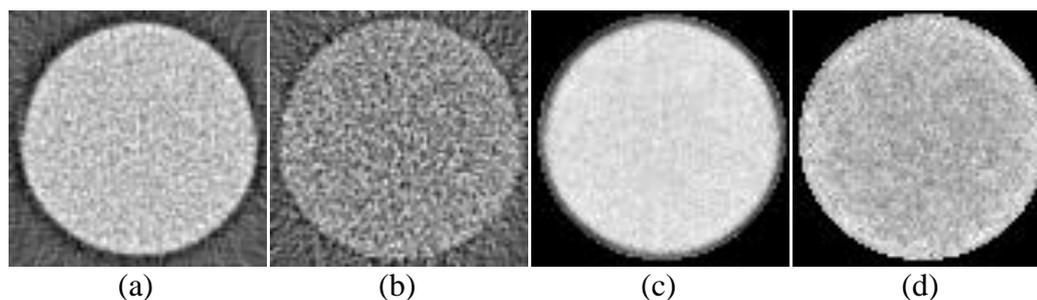
Finalmente, temos que em geral os melhores resultados para esta imagem não utilizaram técnica de melhora de contraste, a pré-estimativa da imagem livre de ruído foi dada por Non Local Means. Ainda, em geral, os melhores resultados não pareceram ter sofrido grande interferência dos métodos de estimação do ruído, mas podemos destacar uma leve superioridade do método Formal para o MPM e do Preliminar para os métodos diretos.



**Figura 7.5.** Mapas do Ruído para o *phantom* de Shepp-Logan reconstruído por POCS do método Preliminar (limiar = 0,61 e número de bins: (a)  $K = 1$ , (b)  $K = 5$  e (c)  $K = 256$ ) e do Final (limiar = 0,24 e número de bins: (d)  $K = 1$ , (e)  $K = 5$  e (f)  $K = 256$ ).

## 7.2 *Phantom* Homogêneo

As projeções do *phantom* Homogêneo foram fornecidas pelo CNPDIA-EMBRAPA. Este *phantom* é composto de uma estrutura cilíndrica de plexiglass envolvendo água. A imagem reconstruída possui basicamente uma área homogênea grande dada pela água e uma área em forma de anel definida pelo plexiglass. As imagens continham dimensões de  $79 \times 79$  pixels. Na Figura 7.6 são exibidas as imagens original e ruidosa para FBP e POCS e na Tabela 7.4 as medidas da imagem ruidosa comparada com a original. Nas Seções 7.2.1 e 7.2.2 são apresentados e discutidos os resultados de filtragem obtidos em imagens reconstruídas por FBP e POCS, respectivamente.



**Figura 7.6.** Imagens do *phantom* Homogêneo: a) original reconstruída por FBP, b) ruidosa reconstruída por FBP, c) original reconstruída por POCS e d) ruidosa reconstruída por POCS.

**Tabela 7.4.** Resultados das medidas de avaliação da imagem ruidosa comparada com a imagem original para o *phantom* Homogêneo, reconstruídas tanto por FBP quanto por POCS.

Métodos de Reconstrução	MSE	PSNR	UIQ	SSIM	Tempo de Reconstrução (s)
<b>FBP</b>	0,04	13,56	0,10	0,09	0,01
<b>POCS</b>	0,03	15,47	0,25	0,28	34,47

### 7.2.1 FBP

Nesta Seção, temos os resultados da aplicação dos métodos sobre a imagem do *phantom* Homogêneo reconstruída por FBP. Os melhores resultados para cada método são exibidos na Tabela 7.5, e suas respectivas imagens filtradas na Figura 7.7. Ainda na Figura 7.8 temos os mapas de borda obtidos para  $K = 256$  e  $K = 1$ , e os números de bins considerados os mais adequados para esta imagem,  $K = 2$  para ambos os métodos Preliminar e Final.

Para esta imagem, temos que o melhor resultado em termos de PSNR foi obtido pelo Wiener Generalizado ( $\alpha = 0$ ,  $w = 9 \times 9$ ,  $viz = 8$ , NLM, FINAL, bins = 1), aumentando cerca de 6,28 dB do PSNR da imagem ruidosa e 2,84 dB do melhor resultado obtido por Non Local Means. Comparando com o Wiener Pontual este resultado foi aproximadamente 1,69 dB superior. Entretanto, este método apresentou ISNR negativo, redução de UIQ e não houve um grande aumento no SSIM se comparado com outros resultados. Isso se deve principalmente ao contraste não ser o mais adequado e a uma suavização excessiva, que é causada pela estimativa da imagem livre de ruído dada por Non Local Means e também por considerar apenas a informação contextual (definida por  $\alpha = 0$ ).

**Tabela 7.5.** Melhores resultados para o *phantom* Homogêneo reconstruído por FBP, onde \* representa o uso de técnica de realce de contraste.

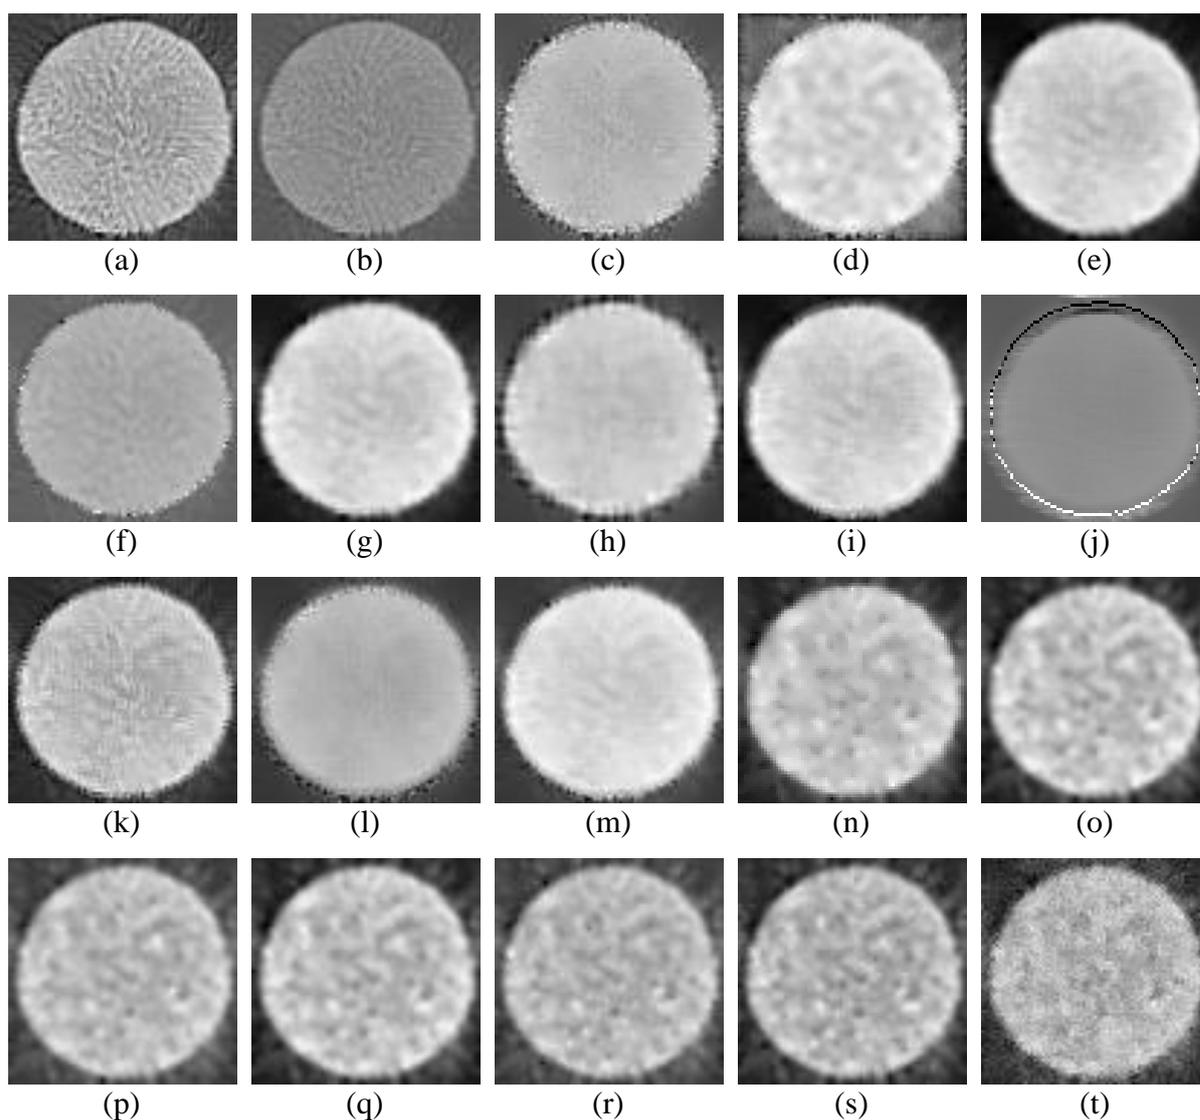
Ord.	Métodos de Filtragem	MSE	PSNR	ISNR	UIQ	SSIM	Tempo (s)
(a)	Non Local Means *	0,02	17,00	3,44	0,16	0,17	1,48
(b)	Non Local Means	0,03	14,74	1,18	0,11	0,18	1,48
(c)	Wiener Pontual * (w = 7x7, NLM, MAN)	0,02	18,15	4,59	0,16	0,22	1,49
	Wiener Pontual * (w = 3x3, w_pre = 5x5, MÉD, MAN)	0,03	14,90	1,34	0,19	0,25	<b>0,00</b>
	Wiener Pontual * (w = 3x3, w_pre = 5x5, MÉD, FINAL, bins = 1)	0,02	16,66	3,10	0,13	0,22	<b>0,00</b>
	Wiener Pontual * (w = 3x3, w_pre = 3x3, MÉD, FINAL, bins = 1)	0,02	16,58	3,02	0,15	0,21	<b>0,00</b>
	Wiener Pontual * (w = 3x3, NLM, PRELIM, bins = 1)	0,03	15,10	1,54	0,14	0,21	1,49
	Wiener Pontual * (w = 3x3, w_pre = 5x5, MÉD, PRELIM, bins = 256)	0,03	14,91	1,35	0,15	0,22	<b>0,00</b>
	Wiener Pontual * (w = 3x3, w_pre = 3x3, MÉD, PRELIM, bins = 256)	0,03	14,89	1,33	0,16	0,21	0,01
	Wiener Pontual * (w = 7x7, w_pre = 7x7, MÉD, FORM)	0,02	17,70	4,14	0,14	0,21	0,01
(d)	Wiener Pontual * (w = 3x3, w_pre = 5x5, MÉD, FORM)	0,03	15,24	1,68	0,19	0,25	<b>0,00</b>
	Wiener com MRF Isotrópico * (w = 3x3, w_pre = 3x3, MÉD, MAN)	0,02	16,73	3,17	0,21	0,24	0,61
(e)	Wiener com MRF Isotrópico * (w = 5x5, NLM, MAN)	0,03	15,33	1,77	<b>0,24</b>	<b>0,29</b>	2,22
(f)	Wiener com MRF Isotrópico * (w = 3x3, NLM, FINAL, bins = 2)	0,02	17,28	3,72	0,15	0,23	3,08
	Wiener com MRF Isotrópico * (w = 3x3, w_pre = 5x5, MÉD, FINAL, bins = 256)	0,02	17,19	3,63	0,16	0,23	0,60
	Wiener com MRF Isotrópico * (w = 3x3, w_pre = 9x9, MÉD, PRELIM, bins = 256)	0,02	17,11	3,55	0,10	0,19	0,51
	Wiener com MRF Isotrópico * (w = 3x3, w_pre = 5x5, MÉD, PRELIM, bins = 256)	0,02	16,41	2,85	0,16	0,23	0,51
	Wiener com MRF Isotrópico * (w = 3x3, w_pre = 3x3, MÉD, PRELIM, bins = 2)	0,03	15,28	1,72	0,17	0,22	0,51
	Wiener com MRF Isotrópico * (w = 9x9, w_pre = 3x3, MÉD, FORM)	0,02	17,09	3,53	0,20	0,26	1,77
	Wiener com MRF Isotrópico * (w = 5x5, NLM, FORM)	0,02	16,18	2,62	0,22	0,28	2,15
	Wiener com MRF Separável * (w = 9x9, w_pre = 3x3, MÉD, MAN)	0,02	17,41	3,85	0,20	0,25	1,86
(g)	Wiener com MRF Separável * (w = 5x5, NLM, MAN)	0,03	15,68	2,12	0,23	0,28	2,22
	Wiener com MRF Separável * (w = 3x3, NLM, FINAL, bins = 1)	0,02	17,28	3,72	0,15	0,23	2,08
	Wiener com MRF Separável * (w = 3x3, w_pre = 5x5, MÉD, FINAL, bins = 2)	0,02	17,27	3,71	0,16	0,23	0,61
	Wiener com MRF Separável * (w = 3x3, w_pre = 9x9, MÉD, PRELIM, bins = 1)	0,02	17,11	3,55	0,10	0,19	0,52
	Wiener com MRF Separável * (w = 3x3, w_pre = 5x5,	0,02	16,41	2,86	0,16	0,23	0,52

	MÉD, PRELIM, bins = 256)						
	Wiener com MRF Separável * (w = 3x3, w_pré = 3x3, MÉD, PRELIM, bins = 2)	0,03	15,28	1,72	0,17	0,22	0,52
(h)	Wiener com MRF Separável * (w = 9x9, NLM, FORM)	0,02	17,93	4,37	0,21	0,27	3,25
	Wiener Generalizado * ( $\alpha = 0,7$ , w = 5x5, viz = 8, NLM, MAN)	0,02	17,95	4,39	0,19	0,26	1,49
(i)	Wiener Generalizado * ( $\alpha = 0,7$ , w = 5x5, viz = 4, NLM, MAN)	0,03	15,51	1,95	0,23	0,28	1,49
(j)	Wiener Generalizado ( $\alpha = 0$ , w = 9x9, viz = 8, NLM, FINAL, bins = 1)	0,06	<b>19,84</b>	-1,42	0,01	0,13	1,49
(k)	Wiener Generalizado * ( $\alpha = 0,3$ , w = 3x3, viz = 8, NLM, FINAL, bins = 256)	0,02	17,71	4,15	0,23	0,27	1,49
	Wiener Generalizado * ( $\alpha = 0,7$ , w = 3x3, viz = 8, NLM, FINAL, bins = 1)	<b>0,01</b>	18,32	4,76	0,19	0,24	1,49
	Wiener Generalizado ( $\alpha = 0$ , w = 9x9, viz = 8, w_pré = 7x7, MÉD, PRELIM, bins = 256)	0,06	19,68	-1,45	0,01	0,13	0,01
	Wiener Generalizado * ( $\alpha = 0,1$ , w = 3x3, viz = 8, NLM, PRELIM, bins = 2)	0,02	17,75	4,20	0,22	0,27	1,49
	Wiener Generalizado * ( $\alpha = 0,2$ , w = 3x3, viz = 4, NLM, PRELIM, bins = 256)	0,02	18,21	4,65	0,19	0,25	1,49
(l)	Wiener Generalizado * ( $\alpha = 1$ , w = 7x7, viz = 8, NLM, FORM)	<b>0,01</b>	18,53	<b>4,97</b>	0,18	0,25	1,49
(m)	Wiener Generalizado * ( $\alpha = 0,8$ , w = 5x5, viz = 4, NLM, FORM)	0,02	16,08	2,52	0,22	0,28	1,49
	Wiener Generalizado * ( $\alpha = 0,3$ , w = 3x3, viz = 8, NLM, FORM)	0,02	17,24	3,68	0,23	0,27	1,49
(n)	ICM * (Modelo = Gaussiana+GMRF, iter = 8, MAN)	0,02	17,68	4,12	0,21	0,26	0,57
(o)	ICM * (Modelo = GMRF+GMRF, iter = 3, MAN)	0,02	17,39	3,83	0,23	0,26	0,32
	ICM * (Modelo = GMRF+GMRF, iter = 3, FINAL, bins = 256)	0,02	17,24	3,68	0,23	0,26	0,25
	ICM * (Modelo = GMRF+GMRF, iter = 1, PRELIM, bins = 256)	0,02	17,16	3,60	0,23	0,24	0,14
	ICM * (Modelo = GMRF+GMRF, iter = 3, PRELIM, bins = 256)	0,02	16,40	2,84	0,23	0,26	0,23
	ICM * (Modelo = GMRF+GMRF, iter = 1, FORM)	0,02	17,23	3,68	0,23	0,24	0,18
	ICM * (Modelo = GMRF+GMRF, iter = 3, FORM)	0,02	16,89	3,33	0,23	0,26	0,29
(p)	GSA * (Modelo = GMRF+GMRF, iter = 3, $\alpha = 0,8$ , MAN)	<b>0,01</b>	18,28	4,72	0,22	0,25	0,42
(q)	GSA * (Modelo = GMRF+GMRF, iter = 3, $\alpha = 0,9$ , MAN)	0,02	17,55	3,99	0,23	0,26	0,45
	GSA * (Modelo = GMRF+GMRF, iter = 3, $\alpha = 0,7$ , FINAL, bins = 256)	0,02	18,07	4,51	0,22	0,25	0,47
	GSA * (Modelo = GMRF+GMRF, iter = 3, $\alpha = 0,9$ , FINAL, bins = 2)	0,02	16,75	3,19	0,23	0,26	0,49
(r)	GSA * (Modelo = GMRF+GMRF, iter = 3, $\alpha = 0,6$ , PRELIM, bins = 256)	<b>0,01</b>	18,28	4,72	0,22	0,25	0,56

	<b>GSA * (Modelo = GMRF+GMRF, iter = 3, <math>\alpha = 0,8</math>, PRELIM, bins = 2)</b>	0,02	17,25	3,69	0,23	0,26	0,44
(s)	<b>GSA * (Modelo = GMRF+GMRF, iter = 3, <math>\alpha = 0,6</math>, FORM)</b>	0,02	17,81	4,25	0,23	0,25	0,55
	<b>GSA * (Modelo = GMRF+GMRF, iter = 3, <math>\alpha = 0,9</math>, FORM)</b>	0,02	16,95	3,39	0,23	0,26	0,54
	<b>MPM * (Modelo = Gaussiana+GMRF, MAN)</b>	0,02	17,41	3,86	0,18	0,20	118,72
	<b>MPM (Modelo = Gaussiana+GIMLL-L1, MAN)</b>	0,03	14,69	1,13	0,13	0,21	798,16
(t)	<b>MPM * (Modelo = GMRF+GMRF, FINAL, bins=256)</b>	0,02	17,52	3,97	0,20	0,22	122,61
	<b>MPM * (Modelo = GMRF+GMRF, PRELIM, bins=2)</b>	0,02	17,24	3,68	0,16	0,18	120,52
	<b>MPM * (Modelo = Gaussiana+GIMLL-L1, PRELIM, bins=256)</b>	0,03	15,95	2,40	0,16	0,21	796,94
	<b>MPM * (Modelo = Gaussiana+Potts, PRELIM, bins=2)</b>	0,02	16,14	2,58	0,17	0,20	78,21
	<b>MPM * (Modelo = GMRF+GMRF, FORM)</b>	0,02	17,45	3,89	0,18	0,19	116,89
	<b>MPM * (Modelo = Gaussiana+GIMLL, FORM)</b>	0,03	15,43	1,87	0,17	0,22	529,02

Em termos de SSIM e UIQ, por sua vez, o melhor resultado foi obtido pelo Wiener com MRF Isotrópico \* ( $w = 5 \times 5$ , NLM, MAN). Enquanto isto, o melhor resultado em termos de ISNR foi atingido pelo Wiener Generalizado \* ( $\alpha = 1$ ,  $w = 7 \times 7$ , viz = 8, NLM, FORM), que corresponde ao Wiener Pontual. O melhor resultado contextual obtido em termos de ISNR foi apresentado pelo Wiener Generalizado \* ( $\alpha = 0,7$ ,  $w = 3 \times 3$ , viz = 8, NLM, FINAL, bins = 1), cerca de 0,2 dB inferior ao melhor em termos de ISNR.

Visualmente, os melhores resultados foram atingidos pelo Wiener com MRF Isotrópico \* ( $w = 5 \times 5$ , NLM, MAN) (que foi o melhor em termos de SSIM e UIQ), Wiener com MRF Separável \* ( $w = 5 \times 5$ , NLM, MAN), Wiener Generalizado \* ( $\alpha = 0,7$ ,  $w = 5 \times 5$ , viz = 4, NLM, MAN), Wiener Generalizado \* ( $\alpha = 0,3$ ,  $w = 3 \times 3$ , viz = 8, NLM, FINAL, bins = 1) e Wiener Generalizado \* ( $\alpha = 0,8$ ,  $w = 5 \times 5$ , viz = 4, NLM, FORM) que correspondem aos itens (e), (g), (i), (k) e (m) da Figura 7.7, respectivamente. Vale notar também que nas imagens cujo ruído foi estimado pelo método Formal, há alguns pequenos artefatos próximo as bordas. Acredita-se que isto pode ser causado por *outliers* na estimação do ruído e que um método para ajustá-los poderia ser necessário. Esta afirmação foi inspirada devido a alguns testes realizados quando do desenvolvimento do método Final, que quando não se utilizava o Cubic Smoothing Spline para ajustar os dados, artefatos semelhantes ao que está ocorrendo com o método Formal surgiam. É algo a se verificar nos trabalhos futuros.

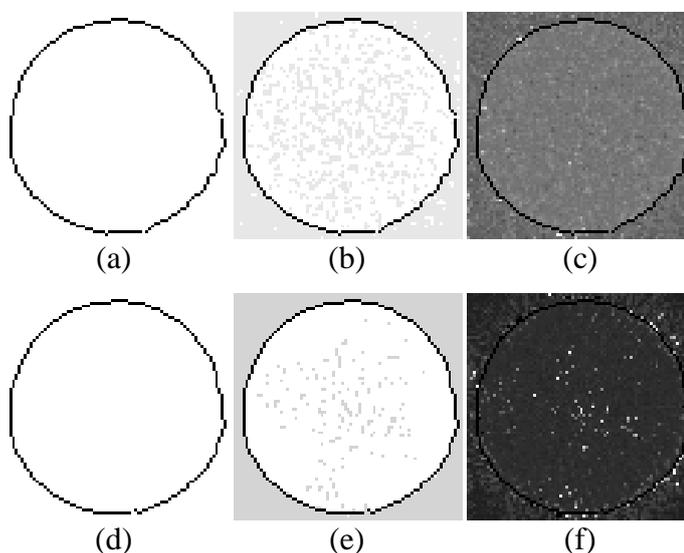


**Figura 7.7.** Resultados de Filtragem para a Imagem do *phantom* Homogêneo reconstruído por FBP. As imagens exibidas estão na ordem da Tabela 7.5.

Foi observado também que resultados dos métodos baseados nos algoritmos de otimização ICM e GSA foram muito parecidos, e apesar, de melhorarem em termos quantitativos, visualmente, os seus resultados são bastante inferiores. Acredita-se que isto ocorre principalmente devido ao uso de uma estimativa inferior da imagem livre de ruído, que para estes métodos foi dada pelo filtro da Média. Isto pode ser entendido ao analisar que os melhores resultados dos métodos diretos utilizarem a pré-estimativa dada pelo Non Local Means, que é superior.

Por fim, temos também que, geralmente, os melhores resultados para esta imagem utilizaram técnica de melhora de contraste. Ainda, notou-se que, exceto o método Preliminar de

estimação do ruído, os outros métodos apresentaram resultados bastante semelhantes, sendo o método Manual levemente superior.



**Figura 7.8.** Mapas do Ruído para o *phantom* Homogêneo reconstruído por FBP do método Preliminar (limiar = 0,56 e número de bins: (a)  $K = 1$ , (b)  $K = 2$  e (c)  $K = 256$ ) e do Final (limiar = 0,99 e número de bins: (d)  $K = 1$ , (e)  $K = 2$  e (f)  $K = 256$ ).

### 7.2.2 POCS

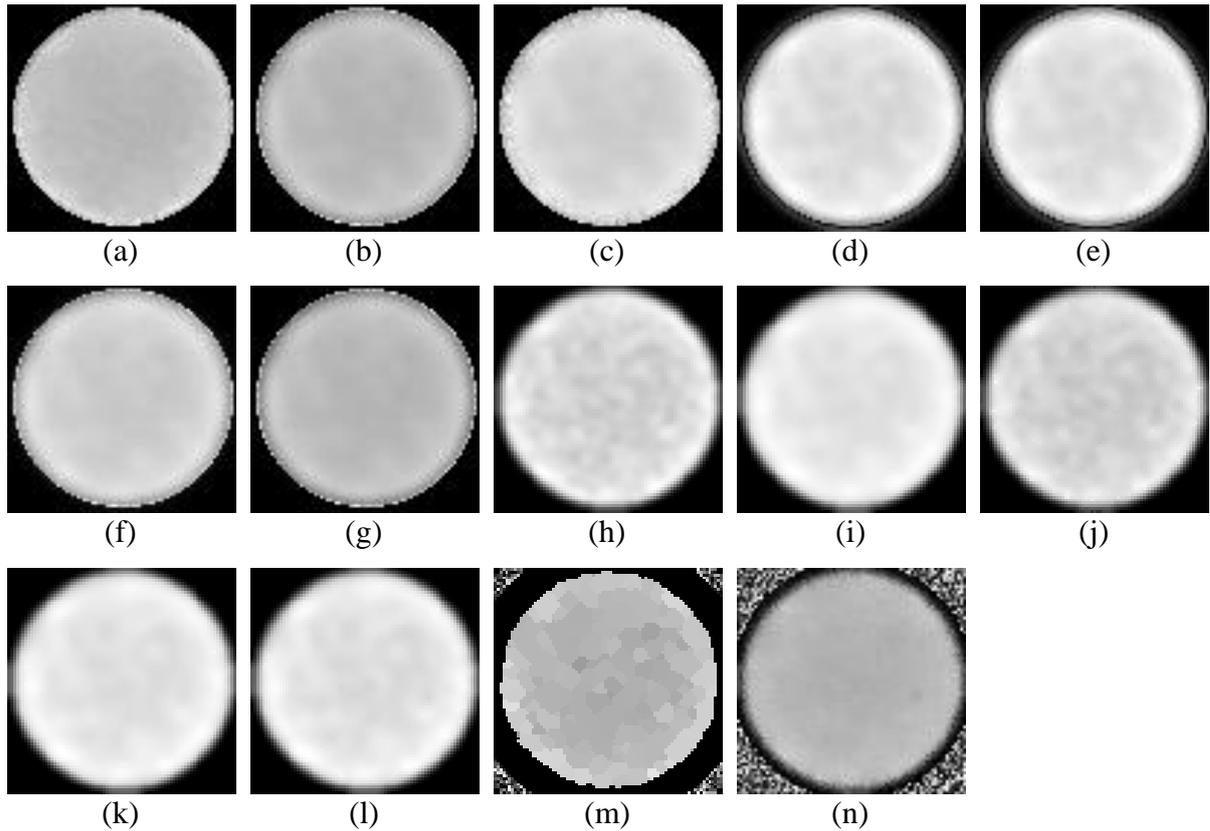
Nesta Seção, temos os resultados da aplicação dos métodos sobre a imagem do *phantom* Homogêneo reconstruída por POCS. Os melhores resultados para cada método são exibidos na Tabela 7.6, e suas respectivas imagens filtradas na Figura 7.9. Ainda na Figura 7.10 temos os mapas de borda obtidos para  $K = 256$  e  $K = 1$ , e para o número de bins considerados os mais adequados para esta imagem,  $K = 2$  no método Final.

Para esta imagem, temos que o melhor resultado em termos de PSNR foi obtido pelo Wiener Generalizado \* ( $\alpha = 0,9$ ,  $w = 3 \times 3$ ,  $viz = 8$ ,  $w_{pré} = 9 \times 9$ , MÉD, PRELIM, bins = 256), aumentando aproximadamente 4,13 dB do PSNR da imagem ruidosa e 3,11 dB do Non Local Means. Comparando com o melhor resultado do Wiener Pontual foi cerca de 1,37 dB superior.

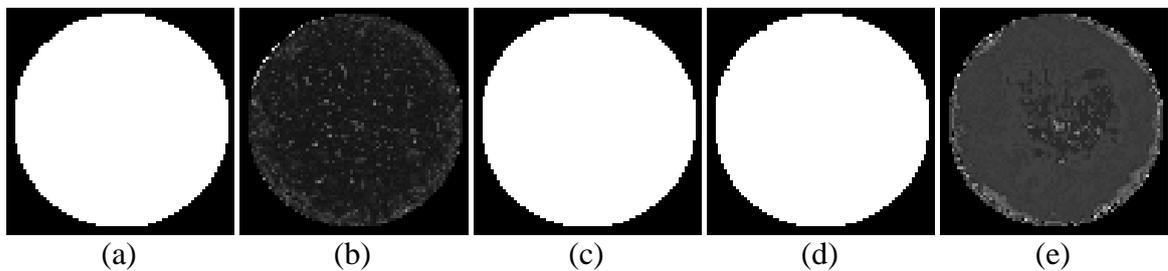
Tabela 7.6. Melhores resultados para o *phantom* Homogêneo reconstruído por POCS, onde \* representa o uso de técnica de realce de contraste.

Ord.	Métodos de Filtragem	MSE	PSNR	ISNR	UIQ	SSIM	Tempo (s)
(a)	Non Local Means *	0,02	16,49	1,02	0,24	0,46	1,48
	Wiener Pontual * (w = 3x3, w_pré = 7x7, MÉD, MAN)	0,02	17,87	2,40	0,23	0,48	<b>0,00</b>
	Wiener Pontual * (w = 3x3, w_pre = 9x9, MÉD, MAN)	0,02	17,64	2,17	0,24	0,48	<b>0,00</b>
	Wiener Pontual * (w = 3x3, w_pre = 9x9, MÉD, FINAL, bins = 1)	0,02	17,51	2,04	0,30	0,52	<b>0,00</b>
	Wiener Pontual (w = 3x3, w_pré = 9x9, MÉD, FINAL, bins = 1)	0,02	16,60	1,13	0,31	0,52	<b>0,00</b>
(b)	Wiener Pontual * (w = 3x3, w_pré = 9x9, MÉD, PRELIM, bins = 256)	0,02	17,86	2,40	0,33	0,55	0,01
(c)	Wiener Pontual * (w=3x3, w_pré=9x9, MÉD, FORM)	0,02	18,23	2,76	0,29	0,51	<b>0,00</b>
	Wiener com MRF Isotrópico * (w = 3x3, w_pre = 5x5, MÉD, MAN)	0,02	17,97	2,51	0,27	0,50	0,54
	Wiener com MRF Isotrópico * (w = 3x3, w_pre = 7x7, MÉD, MAN)	0,02	17,71	2,24	0,29	0,52	0,54
	Wiener com MRF Isotrópico * (w = 3x3, w_pre = 7x7, MÉD, FINAL, bins = 1)	<b>0,01</b>	18,85	3,39	0,29	0,53	0,53
	Wiener com MRF Isotrópico * (w = 3x3, w_pre = 7x7, MÉD, PRELIM, bins = 256)	<b>0,01</b>	18,89	3,42	0,29	0,53	0,47
(d)	Wiener com MRF Isotrópico * (w = 3x3, pré_est = 7x7, MÉD, FORM)	<b>0,01</b>	19,03	3,57	0,30	0,53	0,53
	Wiener com MRF Separável * (w = 3x3, w_pre = 5x5, MÉD, MAN)	0,02	17,94	2,47	0,27	0,50	0,53
	Wiener com MRF Separável * (w = 3x3, w_pre = 7x7, MÉD, MAN)	0,02	17,72	2,25	0,29	0,52	0,54
	Wiener com MRF Separável * (w = 3x3, w_pre = 7x7, MÉD, FINAL, bins = 1)	<b>0,01</b>	18,81	3,34	0,29	0,53	0,54
	Wiener com MRF Separável * (w = 3x3, w_pre = 7x7, MÉD, PRELIM, bins = 256)	<b>0,01</b>	18,86	3,39	0,29	0,53	0,46
(e)	Wiener com MRF Separável * (w = 3x3, w_pre = 7x7, MÉD, FORM)	<b>0,01</b>	18,88	3,41	0,30	0,53	0,55
	Wiener Generalizado * ( $\alpha = 1$ , w = 9x9, viz = 4, NLM, MAN)	<b>0,01</b>	18,26	2,79	0,25	0,50	1,48
	Wiener Generalizado * ( $\alpha = 0,6$ , w = 3x3, viz = 4, w_pré = 9x9, MÉD, MAN)	0,02	17,26	1,79	0,28	0,51	0,01
	Wiener Generalizado * ( $\alpha = 0,8$ , w = 3x3, viz = 4, w_pré = 9x9, MÉD, FINAL, bins = 1)	<b>0,01</b>	19,22	3,75	0,28	0,50	0,01
	Wiener Generalizado * ( $\alpha = 1$ , w = 3x3, viz = 4, w_pré = 9x9, MÉD, FINAL, bins = 1)	0,02	17,94	2,47	0,34	0,55	0,01
(f)	Wiener Generalizado * ( $\alpha = 0,9$ , w = 3x3, viz = 8, w_pré = 9x9, MÉD, PRELIM, bins = 256)	<b>0,01</b>	<b>19,60</b>	<b>4,13</b>	0,29	0,54	<b>0,00</b>
(g)	Wiener Generalizado * ( $\alpha = 1$ , w = 3x3, viz = 4, w_pré = 9x9, MÉD, PRELIM, bins = 256)	0,02	18,11	2,65	<b>0,35</b>	<b>0,56</b>	<b>0,00</b>

	Wiener Generalizado * ( $\alpha = 1$ , $w = 9 \times 9$ , $viz = 4$ , $w_{pré} = 5 \times 5$ . MÉD, FORM)	0,01	18,81	3,35	0,31	0,52	0,01
	Wiener Generalizado ( $\alpha = 1$ , $w = 3 \times 3$ , $viz = 4$ , $w_{pré} = 9 \times 9$ . MÉD, FORM)	0,02	17,21	1,75	0,32	0,55	0,01
	Wiener Generalizado * ( $\alpha = 1$ , $w = 3 \times 3$ , $viz = 4$ , $w_{pré} = 9 \times 9$ . MÉD, FORM)	0,02	18,21	2,74	0,33	0,54	0,01
	ICM * (Modelo = GMRF+GMRF, iter = 8, MAN)	0,02	17,70	2,23	0,26	0,48	0,58
	ICM (Modelo = Gaussiana+GMRF, iter = 8, MAN)	0,02	16,52	1,05	0,27	0,48	0,60
	ICM * (Modelo = Gaussiana+GMRF, iter = 1, FINAL, bins = 2)	0,02	17,80	2,33	0,26	0,47	0,16
	ICM * (Modelo = Gaussiana+GMRF, iter = 8, FINAL, bins = 2)	0,02	17,09	1,62	0,27	0,51	0,56
(h)	ICM * (Modelo = Gaussiana+GMRF, iter = 1, PRELIM, bins = 256)	0,02	17,85	2,38	0,26	0,48	0,19
(i)	ICM * (Modelo = Gaussiana+GMRF, iter = 8, PRELIM, bins = 256)	0,02	17,02	1,55	0,29	0,52	0,58
	ICM * (Modelo = Gaussiana+GMRF, iter = 1, FORM)	0,02	17,77	2,31	0,26	0,47	0,13
	ICM * (Modelo = Gaussiana+GMRF, iter = 8, FORM)	0,02	17,19	1,72	0,27	0,51	0,70
	GSA * (Modelo = Gaussiana+GMRF, iter = 3, $\alpha = 0,7$ , MAN)	0,02	17,80	2,34	0,26	0,46	0,48
	GSA (Modelo = Gaussiana+GMRF, iter = 8, $\alpha = 0,9$ , MAN)	0,02	16,51	1,05	0,27	0,48	1,09
	GSA * (Modelo = Gaussiana+GMRF, iter = 3, $\alpha = 0,7$ , FINAL, bins = 256)	0,02	18,14	2,67	0,26	0,49	0,43
	GSA * (Modelo = Gaussiana+GMRF, iter = 8, $\alpha = 0,8$ , FINAL, bins = 2)	0,02	17,16	1,69	0,28	0,51	1,05
(j)	GSA * (Modelo = Gaussiana+GMRF, iter = 3, $\alpha = 0,6$ , PRELIM, bins = 256)	0,02	18,18	2,71	0,27	0,49	0,53
(k)	GSA * (Modelo = Gaussiana+GMRF, iter = 8, $\alpha = 0,9$ , PRELIM, bins = 256)	0,02	17,11	1,65	0,28	0,52	1,07
(l)	GSA * (Modelo = Gaussiana+GMRF, iter = 8, $\alpha = 0,7$ , PRELIM, bins = 256)	0,02	17,26	1,80	0,29	0,51	1,14
	GSA * (Modelo = Gaussiana+GMRF, iter = 1, $\alpha = 0,7$ , FORM)	0,02	17,97	2,50	0,26	0,47	0,22
	GSA * (Modelo = Gaussiana+GMRF, iter = 8, $\alpha = 0,9$ , FORM)	0,02	17,26	1,80	0,27	0,50	1,42
	MPM (Modelo = GMRF+GMRF, MAN)	0,09	10,67	-4,80	0,15	0,39	128,04
	MPM (Modelo = Gaussiana+GMRF, FINAL, bins=256)	0,07	11,67	-3,79	0,21	0,44	122,59
	MPM (Modelo = GMRF+GMRF, PRELIM, bins=256)	0,07	11,69	-3,78	0,18	0,41	127,29
	MPM * (Modelo = Gaussiana+GMRF, PRELIM, bins=1)	0,07	11,45	-4,01	0,17	0,42	122,68
(m)	MPM * (Modelo = GMRF+GIMLL, FORM)	0,04	14,34	-1,13	0,19	0,41	525,15
(n)	MPM * (Modelo = Gaussiana+GMRF, FORM)	0,06	12,11	-3,36	0,21	0,45	117,46



**Figura 7.9.** Resultados de Filtragem para a Imagem do *phantom* Homogêneo reconstruído por POCS. As imagens exibidas estão na ordem da Tabela 7.6.



**Figura 7.10.** Mapas do Ruído para o *phantom* Homogêneo reconstruído por POCS do método Preliminar (limiar = 0,56 e número de bins: (a)  $K = 1$  e (b)  $K = 256$ ) e do Final (limiar = 0,99 e número de bins: (c)  $K = 1$ , (d)  $K = 2$  e (e)  $K = 256$ ).

Entretanto, em termos de SSIM e UIQ, temos que o melhor resultado foi obtido pelo Wiener Generalizado \* ( $\alpha = 1$ ,  $w = 3 \times 3$ ,  $viz = 4$ ,  $w_{pré} = 9 \times 9$ , MÉD, PRELIM, bins = 256), sendo um pouco superior ao melhor resultado contextual obtido para estas medidas, que também foi obtido pelo método de melhor PSNR apontado no parágrafo anterior.

Visualmente, a filtragem é muito boa e adequada para praticamente todos os métodos, exceto para os resultados de MPM, que apresentaram alguns artefatos fora da área do objeto,

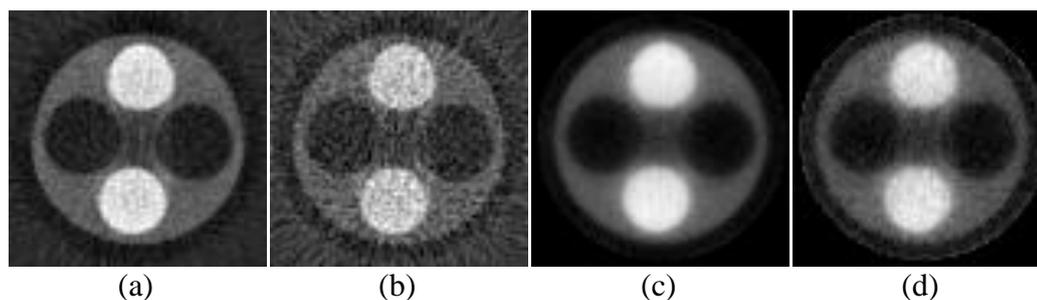
apesar da excelente redução do ruído na área do objeto. Possivelmente, estes artefatos são os principais causadores do baixo desempenho em termos quantitativos deste método. Porém, não foi possível identificar o que causou estes artefatos. Entretanto, podemos destacar que nos itens (e), (d), (i), (k) e (l) da Figura 7.9, o contraste é mais próximo do esperado. Aqui, também foi observado que o ICM e o GSA apresentaram resultados semelhantes.

Finalmente, temos que em geral os melhores resultados para esta imagem utilizaram técnica de melhora de contraste e a pré-estimativa da imagem livre de ruído foi dada pelo filtro da Média. Como estamos trabalhando com uma imagem praticamente binária, já que este *phantom* não apresenta muitos detalhes (componentes de alta frequência), esse último pode ser entendido devido a uma suavização superior dada por este filtro, já que ele tende a suavizar mais do que o Non Local Means. Além disso, vale observar que estes resultados em geral usavam também tamanhos grandes de janela, o que suaviza mais. Além do mais, notou-se que geralmente o uso dos métodos automáticos para a estimação do ruído nos métodos baseados em Wiener aumentou o seu desempenho em termos de SSIM. Ainda, em geral, notou-se uma superioridade do método Formal para o MPM, e dos métodos Formal e Preliminar para os métodos diretos. Entretanto, para o ICM e GSA, os resultados foram bastante semelhantes.

### 7.3 *Phantom* Simétrico

As projeções do *phantom* Simétrico também foram fornecidas pelo CNPDIA-EMBRAPA. Este *phantom* é composto de uma estrutura cilíndrica de plexiglass com quatro furos, sendo dois de alumínio e dois de ar dispostos simetricamente. A imagem reconstruída possui basicamente uma área homogênea maior dada pelo plexiglass, dois furos simétricos de tom mais escuro e outros dois, também simétricos de tons mais claros que o plexiglass. As imagens continham dimensões de 79 x 79 pixels. Na Figura 7.11 são exibidas as imagens original e ruidosa para FBP e POCS e na

Tabela 7.7 as medidas da imagem ruidosa comparada com a original. Nas Seções 7.3.1 e 7.3.2 são apresentados e discutidos os resultados de filtragem de imagens reconstruídas por FBP e POCS, respectivamente.



**Figura 7.11.** Imagens do *phantom* Simétrico: a) original reconstruída por FBP, b) ruidosa reconstruída por FBP, c) original reconstruída por POCS e d) ruidosa reconstruída por POCS.

**Tabela 7.7.** Resultados das medidas de avaliação da imagem ruidosa comparada com a imagem original para o *phantom* Simétrico, reconstruídas tanto por FBP quanto por POCS.

Métodos de Reconstrução	MSE	PSNR	UIQ	SSIM	Tempo de Reconstrução (s)
<b>FBP</b>	0,01	20,75	0,51	0,51	0,01
<b>POCS</b>	0,00	27,51	0,80	0,81	34,44

### 7.3.1 FBP

Nesta Seção, temos os resultados da aplicação dos métodos sobre a imagem do *phantom* Simétrico reconstruída por FBP. Os melhores resultados para cada método são exibidos na Tabela 7.8 e suas respectivas imagens filtradas na Figura 7.12. Ainda na Figura 7.13 temos os mapas de borda obtidos para  $K = 256$  e  $K = 1$ , e os números de bins considerados os mais adequados para esta imagem,  $K = 3$  e  $K = 9$ , para os métodos Preliminar e Final, respectivamente.

Para esta imagem, temos que o melhor resultado em termos de PSNR foi obtido pelo Wiener Pontual \* ( $w = 3 \times 3$ , NLM, FORM), aumentando aproximadamente 6,3 dB do PSNR da imagem ruidosa e 0,28 dB do melhor método contextual de acordo com esta medida, que foi o Wiener Generalizado \* ( $\alpha = 0,8$ ,  $w = 3 \times 3$ ,  $viz = 8$ , NLM, PRELIM, bins = 1). Por sua vez, este é cerca de 6,02 dB e 4,35 dB da imagem ruidosa e do melhor resultado obtido por Non Local Means, respectivamente.

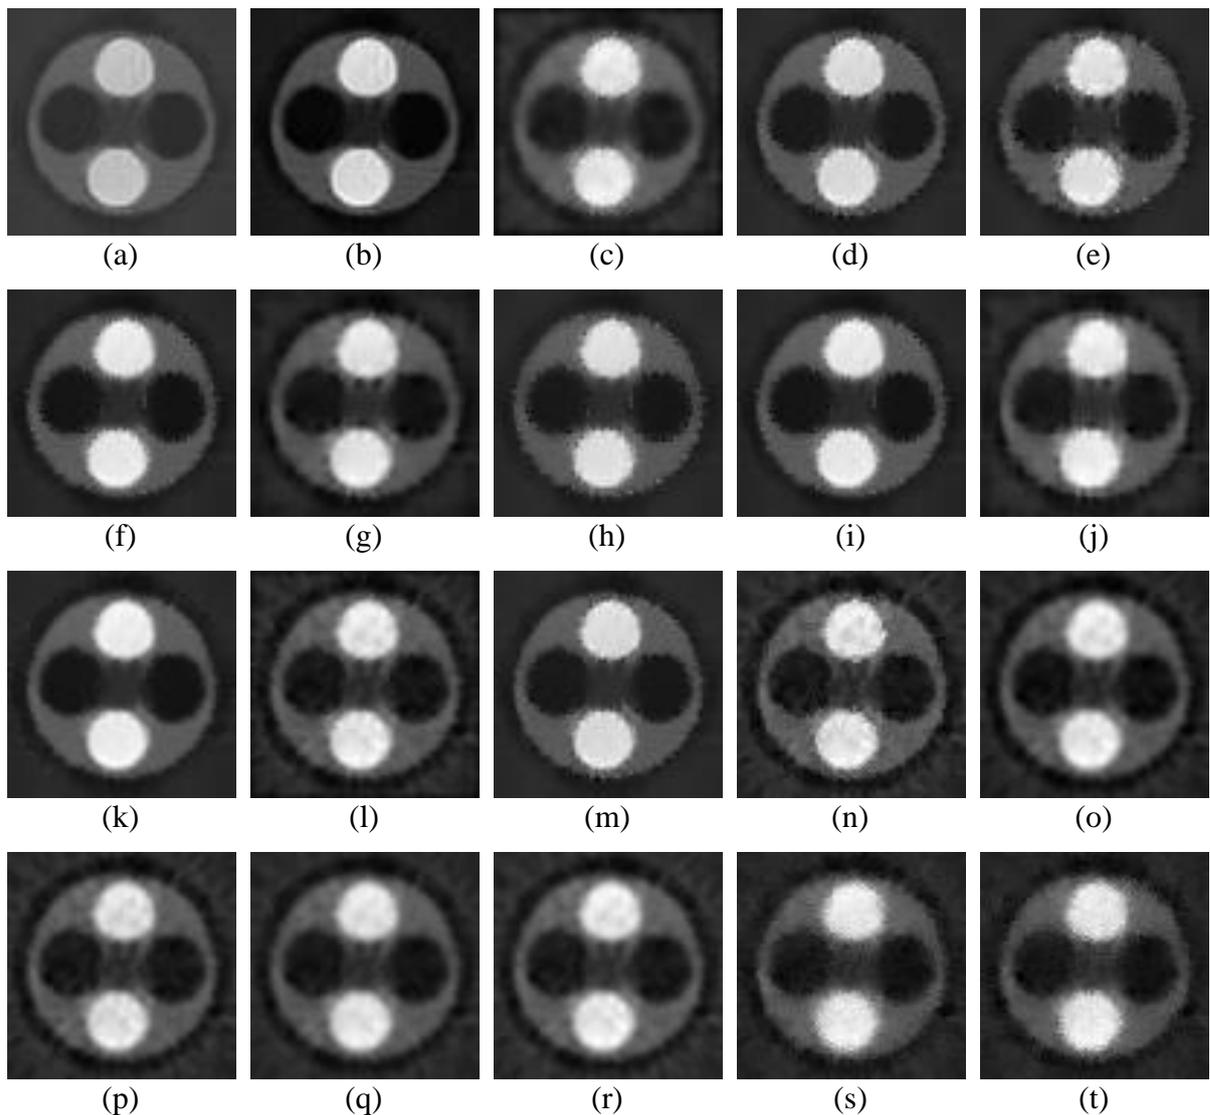
Em termos de SSIM, o melhor resultado foi obtido pelo Wiener Generalizado \* ( $\alpha = 0,7$ ,  $w = 3 \times 3$ ,  $viz = 8$ , NLM, PRELIM, bins = 3). Em termos de UIQ, por sua vez, podemos destacar o resultado obtido pelo GSA \* (Modelo = GMRF+GMRF, iter = 1,  $\alpha = 0,9$ , FORM).

Tabela 7.8. Melhores resultados para o *phantom* Simétrico reconstruído por FBP, onde \* representa o uso de técnica de realce de contraste.

Ord.	Métodos de Filtragem	MSE	PSNR	ISNR	UIQ	SSIM	Tempo (s)
(a)	Non Local Means	0,01	22,42	1,67	0,58	0,68	1,50
(b)	Non Local Means *	0,01	22,35	1,60	0,61	0,67	1,50
(c)	Wiener Pontual * (w = 3x3, w_pré = 5x5, MÉD, MAN)	<b>0,00</b>	25,61	4,86	0,64	0,71	0,01
	Wiener Pontual * (w = 3x3, NLM, FINAL, bins = 1)	<b>0,00</b>	26,32	5,57	0,62	0,71	0,50
	Wiener Pontual * (w = 3x3, w_pre = 3x3, MÉD, FINAL, bins = 1)	<b>0,00</b>	25,22	4,47	0,64	0,69	0,01
	Wiener Pontual * (w = 5x5, w_pre = 3x3, MÉD, PRELIM, bins = 1)	<b>0,00</b>	24,99	4,24	0,61	0,67	0,01
	Wiener Pontual * (w = 3x3, NLM, PRELIM, bins = 1)	<b>0,00</b>	24,98	4,23	0,60	0,69	1,50
	Wiener Pontual * (w = 3x3, w_pre = 3x3, MÉD, PRELIM, bins = 1)	<b>0,00</b>	24,48	3,74	0,62	0,68	0,01
(d)	Wiener Pontual * (w = 3x3, NLM, FORM)	<b>0,00</b>	<b>27,05</b>	<b>6,30</b>	0,63	0,72	1,50
	Wiener Pontual * (w = 3x3, w_pre = 5x5, MÉD, FORM)	<b>0,00</b>	25,53	4,79	0,64	0,71	0,01
	Wiener com MRF Isotrópico * (w = 3x3, w_pré = 3x3, MÉD, MAN)	<b>0,00</b>	25,13	4,38	0,65	0,70	0,61
(e)	Wiener com MRF Isotrópico * (w = 9x9, NLM, FINAL, bins = 256)	<b>0,00</b>	26,21	5,46	0,61	0,69	3,37
(f)	Wiener com MRF Isotrópico * (w = 3x3, NLM, FINAL, bins = 9)	<b>0,00</b>	26,10	5,35	0,63	0,71	2,10
	Wiener com MRF Isotrópico * (w = 3x3, w_pré = 3x3, MÉD, FINAL, bins = 9)	<b>0,00</b>	24,75	4,00	0,64	0,69	0,61
	Wiener com MRF Isotrópico * (w = 3x3, NLM, PRELIM, bins = 1)	<b>0,00</b>	24,97	4,22	0,61	0,69	2,01
	Wiener com MRF Isotrópico * (w = 3x3, w_pré = 3x3, MÉD, PRELIM, bins = 1)	<b>0,00</b>	23,59	2,84	0,62	0,67	0,52
(g)	Wiener com MRF Isotrópico * (w = 9x9, w_pré = 3x3, MÉD, FORM)	<b>0,00</b>	25,78	5,03	0,65	0,71	1,83
	Wiener com MRF Separável * (w = 3x3, w_pré = 3x3, MÉD, MAN)	<b>0,00</b>	25,14	4,39	0,65	0,70	0,60
(h)	Wiener com MRF Separável * (w = 5x5, NLM, FINAL, bins = 9)	<b>0,00</b>	26,21	5,46	0,60	0,69	2,24
(i)	Wiener com MRF Separável * (w = 3x3, NLM, FINAL, bins = 9)	<b>0,00</b>	26,13	5,38	0,63	0,71	2,09
	Wiener com MRF Separável * (w = 5x5, w_pré = 3x3, MÉD, FINAL, bins = 9)	<b>0,00</b>	26,01	5,26	0,64	0,70	0,74
	Wiener com MRF Separável * (w = 3x3, NLM, PRELIM, bins = 1)	<b>0,00</b>	24,99	4,24	0,61	0,69	2,02
	Wiener com MRF Separável * (w = 3x3, w_pré = 3x3, MÉD, PRELIM, bins = 1)	<b>0,00</b>	23,62	2,87	0,62	0,67	0,52
(j)	Wiener com MRF Separável * (w = 7x7, w_pré = 3x3, MÉD, FORM)	<b>0,00</b>	25,83	5,08	0,65	0,71	1,08

	Wiener Generalizado * ( $\alpha = 1$ , $w = 3 \times 3$ , $viz = 8$ , $w\_pré = 5 \times 5$ , MÉD, MAN)	0,00	25,55	4,80	0,64	0,71	0,00
	Wiener Generalizado * ( $\alpha = 0,7$ , $w = 3 \times 3$ , $viz = 4$ , $w\_pré = 3 \times 3$ , MÉD, MAN)	0,00	25,02	4,27	0,65	0,70	0,00
	Wiener Generalizado * ( $\alpha = 1$ , $w = 3 \times 3$ , $viz = 8$ , NLM, FINAL, bins = 1)	0,00	26,32	5,57	0,62	0,71	1,50
	Wiener Generalizado * ( $\alpha = 0,6$ , $w = 3 \times 3$ , $viz = 8$ , $w\_pré = 3 \times 3$ , MÉD, FINAL, bins = 9)	0,00	24,96	4,21	0,65	0,70	0,01
	Wiener Generalizado * ( $\alpha = 0,8$ , $w = 3 \times 3$ , $viz = 8$ , NLM, PRELIM, bins = 1)	0,00	26,77	6,02	0,63	0,72	1,50
(k)	Wiener Generalizado * ( $\alpha = 0,7$ , $w = 3 \times 3$ , $viz = 8$ , NLM, PRELIM, bins = 3)	0,00	26,35	5,60	0,64	0,73	1,50
(l)	Wiener Generalizado * ( $\alpha = 0,7$ , $w = 3 \times 3$ , $viz = 8$ , $w\_pré = 3 \times 3$ , MÉD, PRELIM, bins = 1)	0,00	25,81	5,06	0,65	0,71	0,01
(m)	Wiener Generalizado * ( $\alpha = 1$ , $w = 3 \times 3$ , $viz = 8$ , NLM, FORM)	0,00	27,03	6,28	0,63	0,72	1,50
	Wiener Generalizado * ( $\alpha = 0,8$ , $w = 3 \times 3$ , $viz = 8$ , $w\_pré = 3 \times 3$ , MÉD, FORM)	0,00	25,57	4,82	0,65	0,70	0,01
(n)	ICM * (Modelo = Gaussiana+Potss, iter = 1, MAN)	0,00	25,46	4,71	0,63	0,67	1,84
	ICM * (Modelo = GMRF+GMRF, iter = 3, MAN)	0,00	24,88	4,13	0,65	0,70	0,27
(o)	ICM * (Modelo = GMRF+GMRF, iter = 1, FINAL, bins = 256)	0,00	25,40	4,65	0,65	0,70	0,13
	ICM * (Modelo = GMRF+GMRF, iter = 1, PRELIM, bins = 3)	0,00	25,37	4,62	0,65	0,70	0,20
	ICM * (Modelo = GMRF+GMRF, iter = 1, FORM)	0,00	25,39	4,64	0,65	0,70	0,17
(p)	GSA * (Modelo = Gaussiana+GMRF, iter = 1, $\alpha = 0,8$ , MAN)	0,00	26,49	5,74	0,65	0,70	0,18
	GSA * (Modelo = Gaussiana+GMRF, iter = 3, $\alpha = 0,7$ , MAN)	0,00	26,19	5,44	0,66	0,71	0,43
	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,8$ , FINAL, bins = 256)	0,00	26,39	5,64	0,65	0,70	0,19
	GSA * (Modelo = GMRF+GMRF, iter = 3, $\alpha = 0,8$ , FINAL, bins = 9)	0,00	25,91	5,16	0,66	0,71	0,45
	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,7$ , PRELIM, bins = 256)	0,00	26,29	5,54	0,65	0,70	0,22
(q)	GSA * (Modelo = GMRF+GMRF, iter = 3, $\alpha = 0,6$ , FORM)	0,00	26,29	5,54	0,65	0,71	0,55
(r)	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,9$ , FORM)	0,00	26,20	5,45	0,66	0,71	0,23
(s)	MPM * (Modelo = GMRF+GMRF, MAN)	0,00	24,75	4,00	0,60	0,64	119,50
(t)	MPM * (Modelo = Gaussiana+GMRF, MAN)	0,00	24,73	3,98	0,60	0,65	118,40
	MPM * (Modelo = GMRF+GMRF, FINAL, bins=9)	0,00	24,15	3,40	0,57	0,62	119,04
	MPM * (Modelo = GMRF+GMRF, FINAL, bins=256)	0,00	24,07	3,32	0,59	0,63	121,35
	MPM * (Modelo = GMRF+GMRF, PRELIM, bins=256)	0,00	23,56	2,81	0,55	0,60	123,10
	MPM * (Modelo = GMRF+GMRF, FORM)	0,00	23,88	3,13	0,59	0,63	111,38

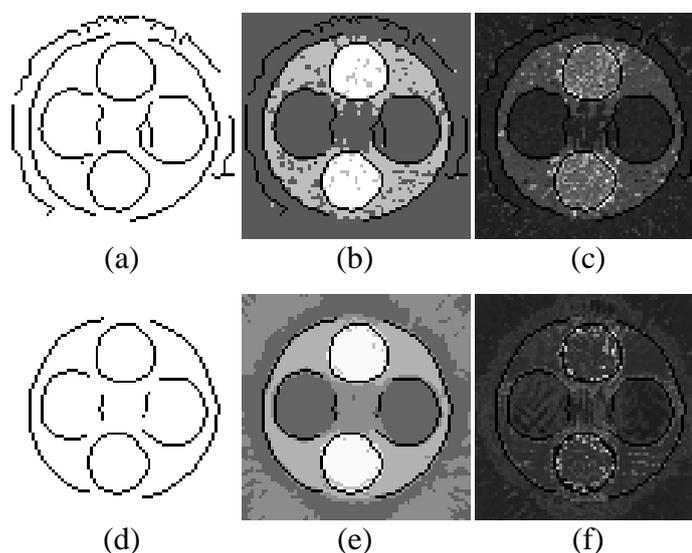
Já visualmente, podemos destacar os resultados do Non Local Means \*, Wiener Pontual \* ( $w = 3 \times 3$ ,  $w_{\text{pré}} = 5 \times 5$ , MÉD, MAN), Wiener Pontual \* ( $w = 3 \times 3$ , NLM, FORM), Wiener com MRF Isotrópico \* ( $w = 3 \times 3$ , NLM, FINAL, bins = 9), Wiener com MRF Separável \* ( $3 \times 3$ , NLM, FINAL, bins = 9), ( $\alpha = 0,7$ ,  $w = 3 \times 3$ , viz = 8, NLM, PRELIM, bins = 3) e Wiener Generalizado \* ( $\alpha = 1$ ,  $w = 3 \times 3$ , viz = 8, NLM, FORM) apresentados nos itens (b)-(d), (f), (i), (k) e (m) da Figura 7.12, respectivamente.



**Figura 7.12.** Resultados de Filtragem para a Imagem do *phantom* Simétrico reconstruído por FBP. As imagens exibidas estão na ordem da Tabela 7.8.

Foi observado também que os métodos baseados nos algoritmos de otimização melhoraram bastante o resultado. Entretanto, acredita-se que com a utilização de imagem pré-estimada obtida do Non Local Means, estes resultados seriam ainda mais competitivos.

Por fim, temos também que, geralmente, os melhores resultados para esta imagem utilizaram técnica de melhora de contraste e Non Local Means para realizar a pré-estimção da imagem livre de ruído. Ainda, notou-se que para os métodos diretos houve uma certa predominância de desempenho quando utilizado métodos de estimação do ruído considerando dependência do sinal ( $K > 1$  e uso do método Formal). Enquanto que para os métodos iterativos, o desempenho entre eles foi muito próximo.



**Figura 7.13.** Mapas do Ruído para o *phantom* Simétrico reconstruído por FBP do método Preliminar (limiar = 0,24 e número de bins: (a)  $K = 1$ , (b)  $K = 3$  e (c)  $K = 256$ ) e do Final (limiar = 0,09 e número de bins: (d)  $K = 1$ , (e)  $K = 9$  e (f)  $K = 256$ ).

### 7.3.2 POCS

Nesta Seção, temos os resultados da aplicação dos métodos sobre a imagem do *phantom* Simétrico reconstruída por POCS. Os melhores resultados para cada método são exibidos na Tabela 7.9 e suas respectivas imagens filtradas na Figura 7.14. Ainda na Figura 7.15 temos os mapas de borda obtidos para  $K = 256$  e  $K = 1$ , e os números de bins considerados os mais adequados para esta imagem,  $K = 3$  e  $K = 9$ , para os métodos Preliminar e Final, respectivamente.

**Tabela 7.9.** Melhores resultados para o *phantom* Simétrico reconstruído por POCS, onde \* representa o uso de técnica de realce de contraste.

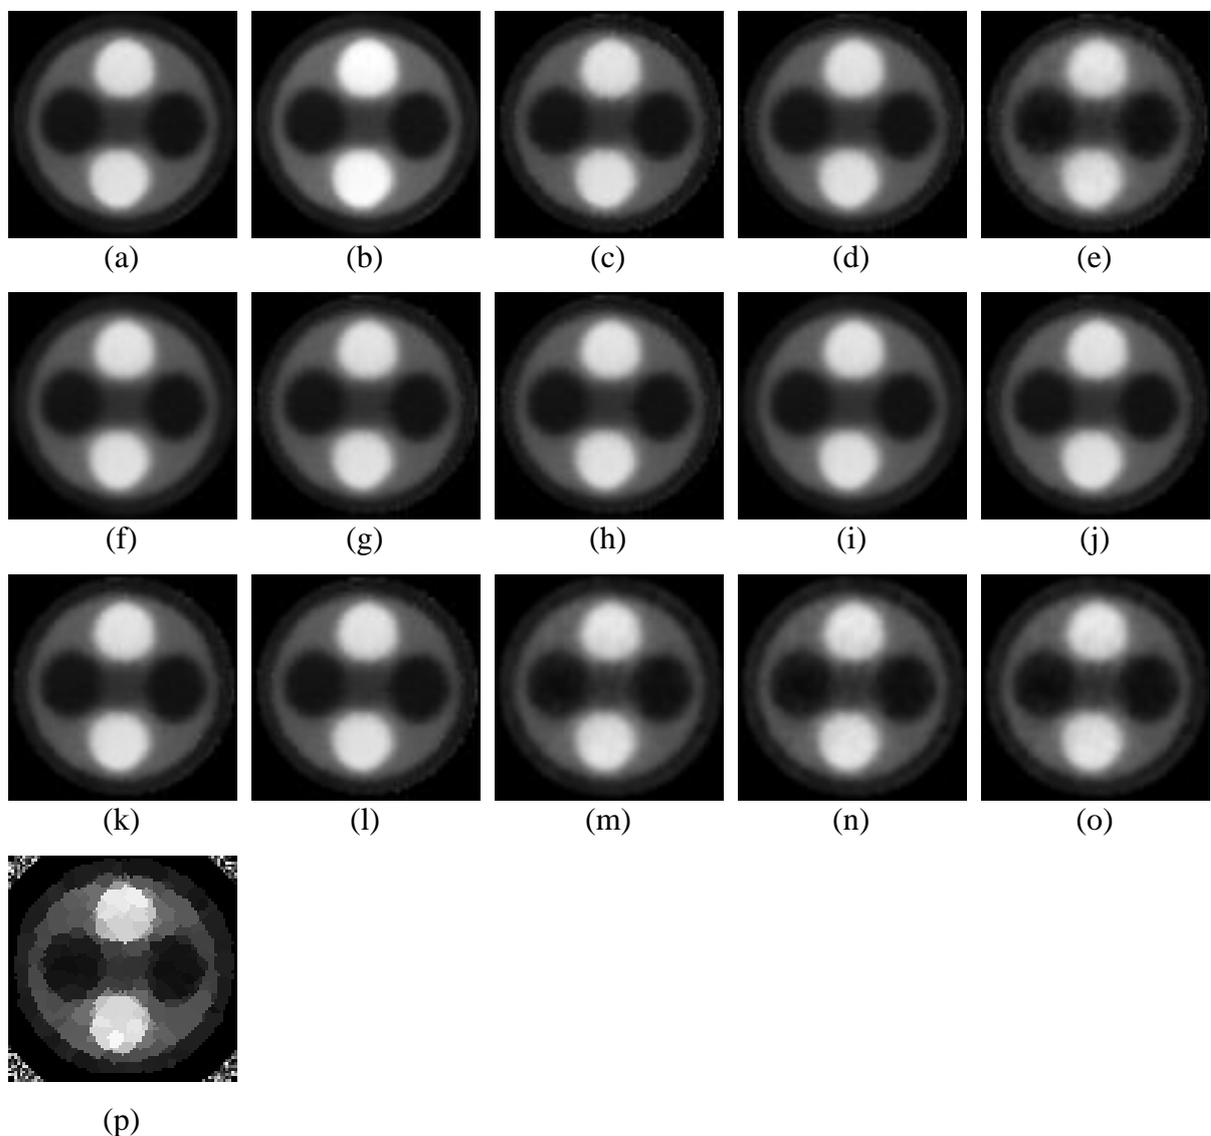
Ord.	Métodos de Filtragem	MSE	PSNR	ISNR	UIQ	SSIM	Tempo (s)
(a)	Non Local Means	0,00	30,10	2,59	0,81	0,89	1,48
(b)	Non Local Means *	0,00	26,60	-0,91	0,82	0,88	1,48
	Wiener Pontual (w = 3x3, NLM, MAN)	0,00	29,76	2,25	0,81	0,89	1,49
	Wiener Pontual (w = 3x3, w_pre = 3x3, MÉD, MAN)	0,00	28,92	1,41	0,82	0,87	0,01
	Wiener Pontual (w = 3x3, NLM, FINAL, bins = 1)	0,00	29,31	1,80	0,86	0,89	1,49
(c)	Wiener Pontual (w = 3x3, NLM, PRELIM, bins = 256)	0,00	29,76	2,25	0,87	0,89	1,49
	Wiener Pontual (w = 3x3, NLM, FORM)	0,00	29,58	2,07	0,81	0,89	1,49
	Wiener Pontual * (w = 3x3, w_pre = 3x3, MÉD, FORM)	0,00	27,03	-0,48	0,83	0,87	0,01
	Wiener com MRF Isotrópico (w = 3x3, NLM, MAN)	0,00	29,47	1,96	0,80	0,87	2,06
	Wiener com MRF Isotrópico (w = 3x3, w_pre = 3x3, MÉD, MAN)	0,00	28,43	0,93	0,81	0,86	0,53
	Wiener com MRF Isotrópico (w = 3x3, NLM, FINAL, bins = 256)	0,00	29,44	1,93	0,81	0,89	2,07
	Wiener com MRF Isotrópico (w = 3x3, w_pre = 3x3, MÉD, FINAL, bins = 256)	0,00	28,40	0,89	0,83	0,87	0,50
(d)	Wiener com MRF Isotrópico (w = 3x3, NLM, PRELIM, bins = 1)	0,00	29,56	2,05	0,81	0,89	1,98
(e)	Wiener com MRF Isotrópico (w = 3x3, w_pre = 3x3, MÉD, PRELIM, bins = 3)	0,00	28,52	1,01	0,83	0,87	0,44
(f)	Wiener com MRF Isotrópico (w = 3x3, NLM, FORM)	0,00	29,59	2,08	0,81	0,88	2,06
	Wiener com MRF Isotrópico (w = 3x3, w_pre = 3x3, MÉD, FORM)	0,00	28,55	1,04	0,82	0,86	0,49
	Wiener com MRF Separável (w = 3x3, NLM, MAN)	0,00	29,50	2,00	0,80	0,87	2,06
	Wiener com MRF Separável (w = 3x3, w_pre = 3x3, MÉD, MAN)	0,00	28,46	0,96	0,81	0,86	0,50
	Wiener com MRF Separável (w = 3x3, NLM, FINAL, bins = 256)	0,00	29,47	1,96	0,81	0,89	2,07
	Wiener com MRF Separável (w = 3x3, w_pre = 3x3, MÉD, FINAL, bins = 256)	0,00	28,43	0,92	0,83	0,87	0,50
(g)	Wiener com MRF Separável (w = 3x3, NLM, PRELIM, bins = 1)	0,00	29,58	2,07	0,81	0,89	1,98
(h)	Wiener com MRF Separável (w = 3x3, w_pre = 3x3, MÉD, PRELIM, bins = 3)	0,00	28,53	1,03	0,83	0,87	0,43
(i)	Wiener com MRF Separável (w = 3x3, NLM, FORM)	0,00	29,60	2,09	0,80	0,88	2,06
	Wiener com MRF Separável (w = 3x3, w_pre = 3x3, MÉD, FORM)	0,00	28,54	1,04	0,82	0,86	0,49
	Wiener Generalizado ( $\alpha = 0,9$ , w = 3x3, viz = 8, NLM, MAN)	0,00	29,77	2,26	0,81	0,89	1,49
	Wiener Generalizado ( $\alpha = 1$ , w = 3x3, viz = 8, w_pre = 3x3, MÉD, MAN)	0,00	28,92	1,42	0,83	0,87	0,01

	Wiener Generalizado ( $\alpha = 0,7$ , $w = 3 \times 3$ , $viz = 8$ , NLM, FINAL, bins = 9)	0,00	29,79	2,28	0,81	0,89	1,49
	Wiener Generalizado ( $\alpha = 1$ , $w = 3 \times 3$ , $viz = 4$ , NLM, FINAL, bins = 9)	0,00	29,42	1,92	0,86	0,89	1,49
(i)	Wiener Generalizado ( $\alpha = 0,8$ , $w = 3 \times 3$ , $viz = 8$ , NLM, PRELIM, bins = 256)	0,00	29,91	2,40	0,82	0,89	1,49
(j)	Wiener Generalizado ( $\alpha = 0,9$ , $w = 3 \times 3$ , $viz = 8$ , NLM, PRELIM, bins = 256)	0,00	29,89	2,38	0,82	0,90	1,49
(k)	Wiener Generalizado ( $\alpha = 1$ , $w = 3 \times 3$ , $viz = 4$ , NLM, PRELIM, bins = 3)	0,00	29,67	2,16	0,87	0,89	1,49
	Wiener Generalizado ( $\alpha = 0,9$ , $w = 3 \times 3$ , $viz = 4$ , NLM, FORM)	0,00	29,88	2,37	0,81	0,89	1,43
	Wiener Generalizado ( $\alpha = 1$ , $w = 3 \times 3$ , $viz = 4$ , $w_{pré} = 3 \times 3$ . MÉD, FORM)	0,00	28,91	1,41	0,83	0,88	0,01
(l)	ICM (Modelo = Gaussiana+GMRF, iter = 1, MAN)	0,00	28,59	1,08	0,83	0,86	0,11
	ICM (Modelo = GMRF+GMRF, iter = 1, FINAL, bins = 256)	0,00	28,41	0,90	0,82	0,86	0,19
	ICM (Modelo = GMRF+GMRF, iter = 1, PRELIM, bins = 3)	0,00	28,36	0,85	0,82	0,86	0,19
	ICM (Modelo = GMRF+GMRF, iter = 1, FORM)	0,00	28,36	0,85	0,81	0,86	0,16
	ICM (Modelo = GMRF+Potts, iter = 1, FORM)	0,00	28,14	0,63	0,82	0,84	1,78
(m)	GSA (Modelo = Gaussiana+GMRF, iter = 1, $\alpha = 0,6$ , MAN)	0,00	28,61	1,10	0,83	0,86	0,18
(n)	GSA (Modelo = Gaussiana+GMRF, iter = 1, $\alpha = 0,7$ , MAN)	0,00	28,61	1,10	0,83	0,86	0,18
	GSA (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,9$ , FINAL, bins = 256)	0,00	28,41	0,91	0,82	0,86	0,18
	GSA (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,8$ , PRELIM, bins = 3)	0,00	28,38	0,87	0,82	0,85	0,23
	GSA (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,7$ , FORM)	0,00	28,38	0,87	0,82	0,85	0,25
	MPM (Modelo = Gaussiana+GIMLL, MAN)	0,06	12,26	-15,24	0,58	0,63	559,33
	MPM (Modelo = Gaussiana+GMRF, MAN)	0,06	11,91	-15,60	0,62	0,69	126,14
	MPM (Modelo = Gaussiana+GIMLL, FINAL, bins=9)	0,04	13,57	-13,94	0,61	0,64	553,61
	MPM (Modelo = GMRF+GMRF, FINAL, bins=256)	0,05	13,04	-14,47	0,67	0,72	129,40
	MPM (Modelo = Gaussiana+Potts, PRELIM, bins=3)	0,05	13,44	-14,07	0,59	0,62	86,63
	MPM (Modelo = GMRF+GMRF, PRELIM, bins=256)	0,05	13,24	-14,27	0,64	0,68	138,30
(o)	MPM (Modelo = GMRF+Potts, FORM)	0,01	19,18	-8,33	0,71	0,73	87,03

Para esta imagem, temos que o melhor resultado em termos de PSNR foi obtido pelo método de Non Local Means, que foi aproximadamente 2,59 dB superior à imagem ruidosa e 0,19 dB ao melhor resultado obtido para esta medida por um método contextual, atingido pelo Wiener Generalizado \* ( $\alpha = 0,8$ ,  $w = 3 \times 3$ ,  $viz = 8$ , NLM, PRELIM, bins = 256). Por sua vez,

este método foi o que apresentou o melhor desempenho em termos de SSIM, além de melhorar aproximadamente 2,4 dB e 0,15 dB da imagem ruidosa e do melhor resultado com Wiener Pontual, respectivamente.

O melhor resultado apontado para o Wiener Pontual em termos de PSNR, Wiener Pontual ( $w = 3 \times 3$ , NLM, PRELIM, bins = 256), foi o que apresentou o melhor resultado em termos de UIQ. Neste critério, os melhores resultados obtidos por métodos contextuais foi atingido pelo Wiener com MRF Separável ( $w = 3 \times 3$ ,  $w_{\text{pré}} = 3 \times 3$ , MÉD, PRELIM, bins = 3), sendo superior ao Non Local Means.



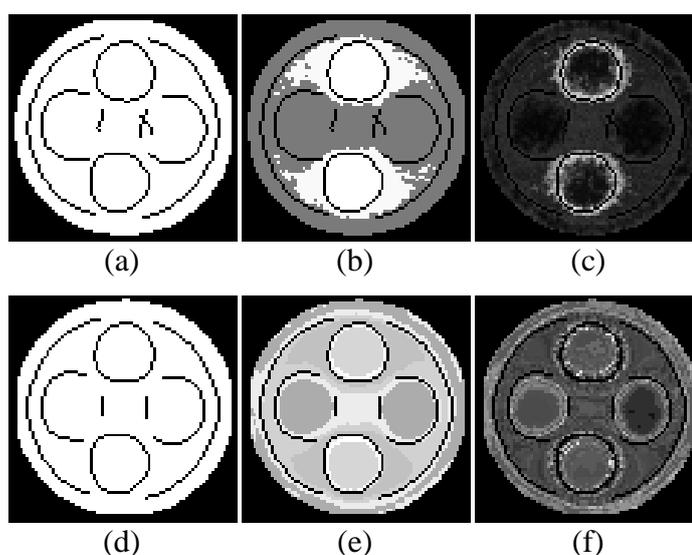
**Figura 7.14.** Resultados de Filtragem para a Imagem do *phantom* Simétrico reconstruído por POCS. As imagens exibidas estão na ordem da Tabela 7.9.

Já os métodos iterativos ICM e GSA apresentaram resultados quantitativos muito próximos para as suas diferentes configurações.

Visualmente, os resultados foram muito parecidos para praticamente todos os métodos, apresentado boa redução de ruído e preservação dos detalhes. A exceção foi o MPM, que possivelmente necessitaria de mais iterações, além de termos novamente um caso onde artefactos fora da área do objeto surgiram, além do que o uso do modelo de Potts como o modelo a priori, parece também tender a segmentar a imagem.

Vale ressaltar ainda que alguns resultados apresentaram ISNR negativo, como foi o caso do Non Local Means \* e do Wiener Pontual \* ( $w = 3 \times 3$ ,  $w_{\text{pré}} = 3 \times 3$ , MÉD, FORM), apesar da melhora em termos de UIQ e SSIM. Isto foi gerado devido, especialmente, ao uso de método de modificação de contraste.

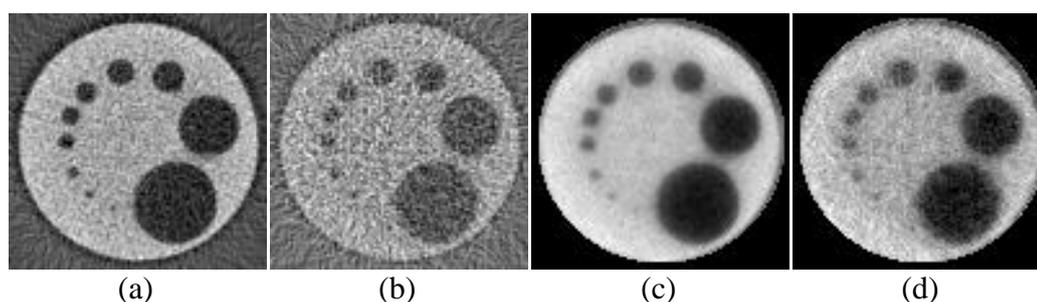
Finalmente, em geral, temos que os melhores resultados para esta imagem não utilizaram técnica de melhora de contraste e a pré-estimativa da imagem livre de ruído foi dada por Non Local Means. Ainda, notou-se que geralmente o uso dos métodos automáticos para a estimação do ruído nos métodos baseados em Wiener, aumentou o desempenho em termos de SSIM. Para o ICM e GSA, não parece ter havido interferência do método de estimação do ruído. Entretanto, é notável para o MPM, que o uso do método Formal foi bastante superior, especialmente em termos de PSNR.



**Figura 7.15.** Mapas do Ruído para o *phantom* Simétrico reconstruído por FBP do método Preliminar (limiar = 0,35 e número de bins: (a)  $K = 1$ , (b)  $K = 3$  e (c)  $K = 256$ ) e do Final (limiar = 0,19 e número de bins: (d)  $K = 1$ , (e)  $K = 9$  e (f)  $K = 256$ ).

### 7.4 Phantom Assimétrico

As projeções do *phantom* Assimétrico foram fornecidas pelo CNPDIA-EMBRAPA. Este *phantom* é composto também de uma estrutura cilíndrica de plexiglass, mas com dez furos cheios de ar, cujos diâmetros variam. A ideia ao se utilizar este *phantom* é verificar a resolução do método, já que pixels muito pequenos podem não estar visíveis após a filtragem, no caso de haver suavização excessiva. A imagem reconstruída possui basicamente uma área homogênea base dada pelo plexiglass, dez furos espalhados espiralmente com diâmetro sendo reduzido a cada furo (tons mais escuros). As imagens continham dimensões de 100 x 100 pixels. Na Figura 7.16 são exibidas as imagens original e ruidosa para FBP e POCS e na Tabela 7.10 as medidas da imagem ruidosa comparada com a original. Nas Seções 7.4.1 e 7.4.2 são apresentados e discutidos os resultados de filtragem obtidos em imagens reconstruídas por FBP e POCS, respectivamente.



**Figura 7.16.** Imagens do *phantom* Assimétrico: a) original reconstruída por FBP, b) ruidosa reconstruída por FBP, c) original reconstruída por POCS e d) ruidosa reconstruída por POCS.

**Tabela 7.10.** Resultados das medidas de avaliação da imagem ruidosa comparada com a imagem original para o *phantom* Assimétrico, reconstruídas tanto por FBP quanto por POCS.

Métodos de Reconstrução	MSE	PSNR	UIQ	SSIM	Tempo de Reconstrução (s)
FBP	0,02	16,32	0,32	0,28	0,01
POCS	0,01	22,17	0,68	0,64	61,58

#### 7.4.1 FBP

Nesta Seção, temos os resultados da aplicação dos métodos sobre a imagem do *phantom* Assimétrico reconstruída por FBP. Os melhores resultados para cada método são exibidos na Tabela 7.8 e suas respectivas imagens filtradas na Figura 7.17. Ainda na Figura 7.18 temos

os mapas de borda obtidos para  $K = 256$  e  $K = 1$ , e os números de bins considerados os mais adequados para esta imagem,  $K = 2$  para ambos os métodos Preliminar e Final.

Para esta imagem, os melhores resultados em termos de PSNR foram obtidos pelo Wiener com MRF Separável \* ( $w = 3 \times 3$ , NLM, PRELIM, bins = 2), aumentando em quase 5 dB do PSNR da imagem ruidosa. Comparando-o com os melhores resultados para o Wiener Pontual e o Non Local Means, ele foi cerca de 0,85 dB e 3,43 dB superior, respectivamente.

Em termos de SSIM e UIQ, o melhor resultado foi obtido também por um método contextual: Wiener Generalizado \* ( $\alpha = 0,7$ ,  $w = 3 \times 3$ , viz = 8, NLM, MAN). Ele apresentou desempenho consideravelmente superior comparado à imagem ruidosa.

Apesar de os métodos iterativos apresentarem desempenho semelhante quantitativamente aos métodos diretos, seu resultado visual é inferior. Acredita-se que isto ocorra devido a uma estimativa inferior da imagem livre de ruído dada pelo filtro da Média, o que poderia ser melhorado com o uso da estimação por Non Local Means.

Visualmente, os melhores resultados foram obtidos pelo Wiener com MRF Isotrópico \* ( $w = 3 \times 3$ , NLM, MAN), Wiener com MRF Isotrópico \* ( $w = 3 \times 3$ , NLM, FORM), Wiener com MRF Separável \* ( $w = 3 \times 3$ , NLM, MAN), Wiener com MRF Separável \* ( $w = 3 \times 3$ , NLM, FORM) e Wiener Generalizado \* ( $\alpha = 0,7$ ,  $w = 3 \times 3$ , viz = 8, NLM, MAN) correspondendo aos itens (f), (h), (i), (k) e (l) da Figura 7.17, respectivamente. Além disso, nota-se também a necessidade de maior número de iterações para o MPM, além do que aqui temos mais um exemplo de que o uso de priori GIMLL-L1 tende a segmentar a imagem, como apontado por um dos melhores resultados do MPM (item (r) da Figura 7.17).

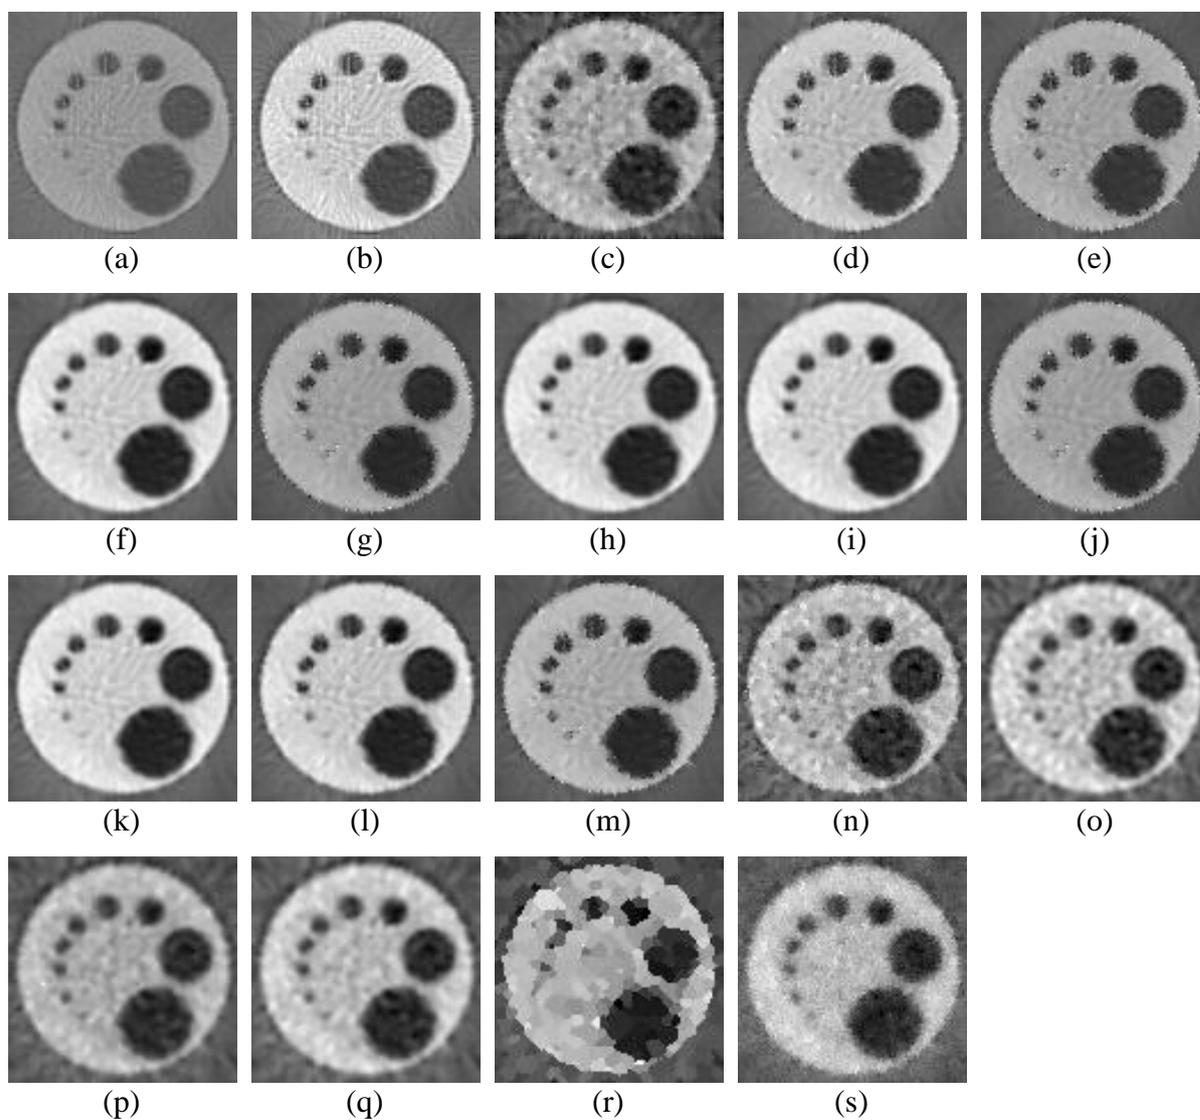
Por fim, temos também que, geralmente, os melhores resultados para esta imagem utilizaram técnica de melhora de contraste e Non Local Means para realizar a pré-estimação da imagem livre de ruído. Ainda, notou-se que para os métodos diretos, os melhores resultados foram obtidos pelos métodos de estimação do ruído Manual e Formal.

Tabela 7.11. Melhores resultados para o *phantom* Assimétrico reconstruído por FBP, onde \* representa o uso de técnica de realce de contraste.

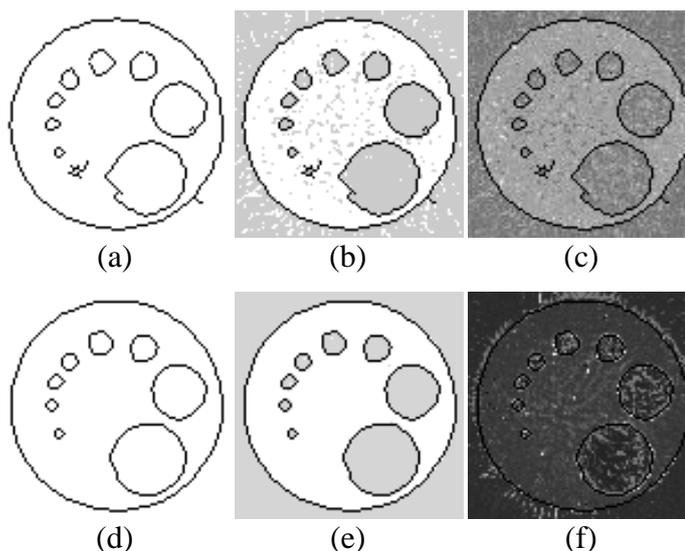
Ord.	Métodos de Filtragem	MSE	PSNR	ISNR	UIQ	SSIM	Tempo (s)
(a)	Non Local Means	0,02	17,86	1,54	0,36	0,38	0,82
(b)	Non Local Means *	0,03	15,48	-0,84	0,44	0,43	0,82
(c)	Wiener Pontual * ( $w = 3 \times 3$ , $w_{pré} = 3 \times 3$ , MÉD, MAN)	<b>0,01</b>	20,35	4,03	0,46	0,43	0,01
(d)	Wiener Pontual * ( $w = 3 \times 3$ , NLM, MAN)	<b>0,01</b>	18,31	1,99	0,46	0,45	0,82
	Wiener Pontual * ( $w = 3 \times 3$ , $w_{pre} = 3 \times 3$ , MÉD, FINAL, bins = 1)	0,02	17,80	1,48	0,41	0,40	0,01
	Wiener Pontual * ( $w = 3 \times 3$ , NLM, FINAL, bins = 2)	0,02	17,72	1,40	0,41	0,42	0,82
(e)	Wiener Pontual * ( $w = 3 \times 3$ , NLM, PRELIM, bins = 2)	<b>0,01</b>	20,44	4,12	0,43	0,44	0,82
	Wiener Pontual * ( $w = 3 \times 3$ , $w_{pre} = 3 \times 3$ , MÉD, FORM)	<b>0,01</b>	18,79	2,47	0,44	0,42	0,01
	Wiener Pontual * ( $w = 3 \times 3$ , $w_{pre} = 5 \times 5$ , MÉD, FORM)	0,03	14,87	-1,45	0,44	0,43	<b>0,00</b>
	Wiener com MRF Isotrópico ( $w = 3 \times 3$ , $w_{pré} = 3 \times 3$ , MÉD, MAN)	0,02	17,77	1,46	0,34	0,36	0,97
(f)	Wiener com MRF Isotrópico * ( $w = 3 \times 3$ , NLM, MAN)	0,02	16,21	-0,11	0,47	<b>0,47</b>	1,78
	Wiener com MRF Isotrópico * ( $w = 3 \times 3$ , NLM, FINAL, bins = 2)	<b>0,01</b>	19,64	3,33	0,43	0,43	1,78
(g)	Wiener com MRF Isotrópico * ( $w = 3 \times 3$ , NLM, PRELIM, bins = 2)	<b>0,01</b>	21,27	4,96	0,44	0,45	1,64
	Wiener com MRF Isotrópico ( $w = 3 \times 3$ , $w_{pré} = 3 \times 3$ , MÉD, FORM)	0,02	17,78	1,46	0,34	0,36	0,83
(h)	Wiener com MRF Isotrópico * ( $w = 3 \times 3$ , NLM, FORM)	0,02	16,21	-0,11	0,47	<b>0,47</b>	1,63
	Wiener com MRF Separável * ( $w = 9 \times 9$ , $w_{pré} = 3 \times 3$ , MÉD, MAN)	<b>0,01</b>	18,28	1,96	0,44	0,43	2,97
(i)	Wiener com MRF Separável * ( $w = 3 \times 3$ , NLM, MAN)	0,02	16,21	-0,11	<b>0,48</b>	<b>0,47</b>	1,77
	Wiener com MRF Separável * ( $w = 3 \times 3$ , NLM, FINAL, bins = 2)	<b>0,01</b>	19,65	3,34	0,43	0,43	1,77
(j)	Wiener com MRF Separável * ( $w = 3 \times 3$ , NLM, PRELIM, bins = 2)	<b>0,01</b>	<b>21,29</b>	<b>4,97</b>	0,44	0,45	1,63
	Wiener com MRF Separável ( $w = 3 \times 3$ , $w_{pré} = 3 \times 3$ , MÉD, FORM)	0,02	17,79	1,47	0,35	0,36	0,81
(k)	Wiener com MRF Separável * ( $w = 3 \times 3$ , NLM, FORM)	0,02	16,21	-0,11	<b>0,48</b>	<b>0,47</b>	1,63
	Wiener Generalizado * ( $\alpha = 1$ , $w = 3 \times 3$ , viz = 8, $w_{pré} = 3 \times 3$ , MÉD, MAN)	<b>0,01</b>	20,35	4,03	0,46	0,44	0,01
(l)	Wiener Generalizado * ( $\alpha = 0,7$ , $w = 3 \times 3$ , viz = 8, NLM, MAN)	0,02	17,41	1,09	<b>0,48</b>	<b>0,47</b>	0,82
	Wiener Generalizado * ( $\alpha = 0,8$ , $w = 3 \times 3$ , viz = 4, NLM, FINAL, bins = 2)	<b>0,01</b>	19,55	3,24	0,45	0,45	0,82
	Wiener Generalizado * ( $\alpha = 0,5$ , $w = 3 \times 3$ , viz = 8, NLM, FINAL, bins = 256)	0,02	16,55	0,23	<b>0,48</b>	<b>0,47</b>	0,83
(m)	Wiener Generalizado * ( $\alpha = 0,9$ , $w = 3 \times 3$ , viz = 8, NLM, PRELIM, bins = 256)	<b>0,01</b>	21,00	4,69	0,46	0,46	0,83

	Wiener Generalizado * ( $\alpha = 0,5$ , $w = 3 \times 3$ , $viz = 8$ , NLM, PRELIM, bins = 2)	0,02	16,38	0,06	<b>0,48</b>	<b>0,47</b>	0,82
	Wiener Generalizado * ( $\alpha = 0,8$ , $w = 3 \times 3$ , $viz = 8$ , $w_{pré} = 3 \times 3$ , MÉD, FORM)	<b>0,01</b>	19,33	3,01	0,46	0,44	0,01
	Wiener Generalizado * ( $\alpha = 0,7$ , $w = 3 \times 3$ , $viz = 8$ , NLM, FORM)	0,02	17,27	0,95	<b>0,48</b>	<b>0,47</b>	0,82
(n)	ICM * (Modelo = Gaussiana+Potts, iter = 1, MAN)	<b>0,01</b>	19,37	3,05	0,45	0,42	3,00
(o)	ICM * (Modelo = Gaussiana+GMRF, iter = 1, MAN)	0,02	18,03	1,72	0,47	0,45	0,21
	ICM * (Modelo = GMRF+Potts, iter = 1, FINAL, bins = 2)	<b>0,01</b>	18,57	2,25	0,45	0,41	2,95
	ICM * (Modelo = GMRF+Potts, iter = 1, FINAL, bins = 256)	<b>0,01</b>	18,57	2,25	0,45	0,41	2,95
	ICM * (Modelo = GMRF+GMRF, iter = 1, FINAL, bins = 256)	0,02	17,92	1,60	0,47	0,45	0,24
	ICM * (Modelo = GMRF+Potts, iter = 1, PRELIM, bins = 2)	<b>0,01</b>	18,58	2,26	0,45	0,41	2,83
	ICM * (Modelo = GMRF+Potts, iter = 1, PRELIM, bins = 256)	<b>0,01</b>	18,58	2,26	0,45	0,41	2,83
	ICM * (Modelo = GMRF+GMRF, iter = 3, PRELIM, bins = 2)	0,02	17,05	0,73	0,46	0,45	0,43
	ICM * (Modelo = GMRF+GMRF, iter = 1, PRELIM, bins = 256)	0,02	17,95	1,63	0,47	0,44	0,28
	ICM * (Modelo = GMRF+Potts, iter = 1, FORM)	<b>0,01</b>	18,57	2,25	0,45	0,41	2,88
	ICM * (Modelo = GMRF+GMRF, iter = 3, FORM)	0,02	17,13	0,81	0,47	0,45	0,52
	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,8$ , MAN)	<b>0,01</b>	20,18	3,86	0,46	0,44	0,33
	GSA * (Modelo = Gaussiana+GMRF, iter = 3, $\alpha = 0,8$ , MAN)	0,02	17,99	1,67	0,47	0,45	0,75
(p)	GSA * (Modelo = GMRF+GMRF, iter = 3, $\alpha = 0,6$ , FINAL, bins = 2)	<b>0,01</b>	20,41	4,10	0,46	0,44	0,84
	GSA * (Modelo = GMRF+GMRF, iter = 3, $\alpha = 0,9$ , FINAL, bins = 256)	0,02	17,99	1,68	0,47	0,45	0,80
	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,9$ , PRELIM, bins = 2)	<b>0,01</b>	20,27	3,96	0,46	0,44	0,34
	GSA * (Modelo = GMRF+GMRF, iter = 3, $\alpha = 0,9$ , PRELIM, bins = 2)	0,02	17,34	1,02	0,47	0,45	0,81
	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,6$ , FORM)	<b>0,01</b>	20,06	3,75	0,46	0,43	0,39
(q)	GSA * (Modelo = GMRF+GMRF, iter = 3, $\alpha = 0,7$ , FORM)	<b>0,01</b>	18,72	2,40	0,47	0,45	0,78
	MPM * (Modelo = GMRF+GIMLL, MAN)	0,02	18,03	1,71	0,35	0,33	777,26
	MPM * (Modelo = GMRF+GMRF, MAN)	0,02	17,61	1,29	0,40	0,38	222,05
	MPM * (Modelo = GMRF+GMRF, FINAL, bins=2)	<b>0,01</b>	18,29	1,98	0,37	0,35	212,74
	MPM * (Modelo = GMRF+GMRF, FINAL, bins=256)	0,02	17,78	1,46	0,41	0,38	212,23
	MPM * (Modelo = Gaussiana+GIMLL-L1, PRELIM, bins=2)	<b>0,01</b>	18,26	1,95	0,35	0,34	978,10

	MPM * (Modelo = GMRF+GMRF, PRELIM, bins=256)	0,02	17,17	0,85	0,37	0,35	221,97
(r)	MPM * (Modelo = GMRF+GIMLL-L1, FORM)	<b>0,01</b>	18,40	2,08	0,37	0,35	977,68
(s)	MPM * (Modelo = GMRF+GMRF, FORM)	0,02	18,03	1,71	0,41	0,38	219,85



**Figura 7.17.** Resultados de Filtragem para a Imagem do *phantom* Assimétrico reconstruído por FBP. As imagens exibidas estão na ordem da Tabela 7.11.



**Figura 7.18.** Mapas do Ruído para o *phantom* Assimétrico reconstruído por FBP do método Preliminar (limiar = 0,54 e número de bins: (a)  $K = 1$ , (b)  $K = 2$  e (c)  $K = 256$ ) e do Final (limiar = 0,39 e número de bins: (d)  $K = 1$ , (e)  $K = 2$  e (f)  $K = 256$ ).

#### 7.4.2 POCS

Nesta Seção, temos os resultados da aplicação dos métodos sobre a imagem do *phantom* Assimétrico reconstruída por POCS. Os melhores resultados para cada método são exibidos na Tabela 7.12 e suas respectivas imagens filtradas na Figura 7.19. Ainda na Figura 7.20 temos os mapas de borda obtidos para  $K = 256$  e  $K = 1$ , e os números de bins considerados os mais adequados para esta imagem,  $K = 3$  e  $K = 5$ , para os métodos Preliminar e Final, respectivamente.

Para esta imagem, temos que o melhor resultado em termos de PSNR foi obtido pelo Wiener Generalizado \* ( $\alpha = 0,9$ ,  $w = 3 \times 3$ ,  $viz = 4$ , NLM, MAN), apresentando resultado semelhante ao Non Local Means, aumentando em aproximadamente 5,7 dB e 0,36 dB do PSNR da imagem ruidosa e do melhor resultado obtido pelo Wiener Pontual, respectivamente. Este último é o Wiener Pontual \* ( $w = 3 \times 3$ , NLM, FINAL, bins = 1). Juntamente com o de melhor PSNR e o Wiener Generalizado \* ( $\alpha = 0,9$ ,  $w = 3 \times 3$ ,  $viz = 8$ , NLM, FINAL, bins = 1), eles apresentaram os melhores resultados em termos de SSIM.

Em termos de UIQ, por sua vez, os melhores resultados foram obtidos pelo Wiener Pontual \* ( $w = 3 \times 3$ ,  $w_{pré} = 5 \times 5$ , MÉD, PRELIM, bins = 3) e Wiener Generalizado \* ( $\alpha = 1$ ,  $w = 3 \times 3$ ,  $viz = 8$ ,  $w_{pré} = 5 \times 5$ , MÉD, PRELIM, bins = 3), cujo último corresponde ao caso pontual e portanto, corresponderiam às mesmas configurações. Os resultados obtidos por es-

tes métodos são levemente superiores ao melhor obtido por um filtro contextual, que foi atingido pelo Wiener Generalizado \* ( $\alpha = 0,9$ ,  $w = 3 \times 3$ ,  $viz = 8$ , NLM, FINAL, bins = 1).

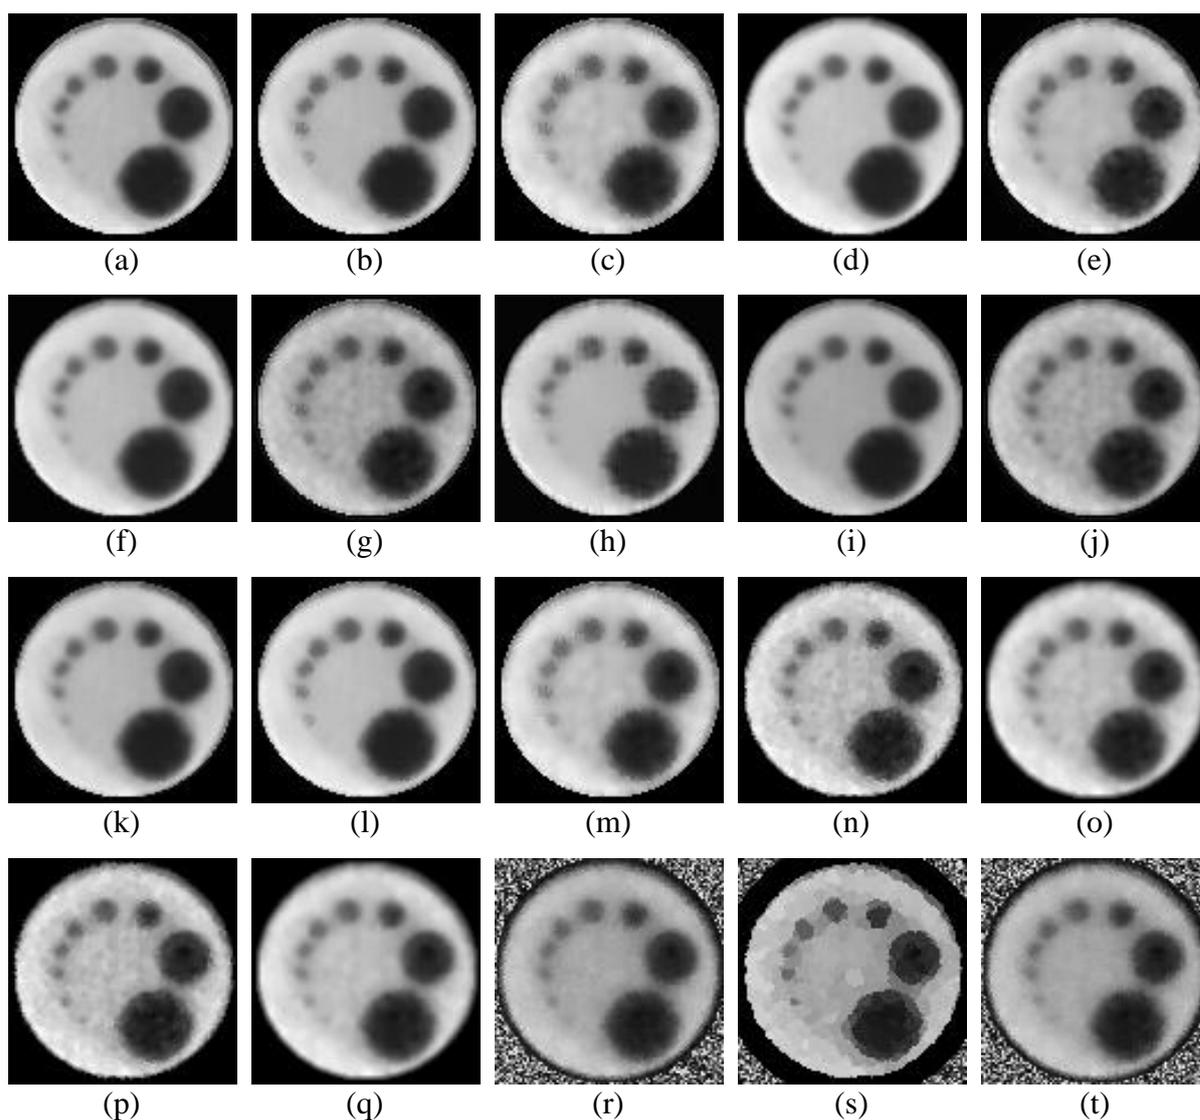
**Tabela 7.12.** Melhores resultados para o *phantom* Assimétrico reconstruído por POCS, onde \* representa o uso de técnica de realce de contraste.

Ord.	Métodos de Filtragem	MSE	PSNR	ISNR	UIQ	SSIM	Tempo (s)
(a)	Non Local Means *	0,00	27,86	5,69	0,77	0,81	0,62
	Wiener Pontual * ( $w = 3 \times 3$ , $w_{pre} = 3 \times 3$ , MÉD, MAN)	0,00	26,72	4,55	0,73	0,79	0,01
	Wiener Pontual * ( $w = 3 \times 3$ , NLM, MAN)	0,00	24,85	2,68	0,74	0,81	0,62
(b)	Wiener Pontual * ( $w = 3 \times 3$ , NLM, FINAL, bins = 1)	0,00	27,51	5,35	0,77	0,82	0,62
	Wiener Pontual * ( $w = 5 \times 5$ , $w_{pre} = 3 \times 3$ , MÉD, FINAL, bins = 1)	0,00	26,64	4,47	0,78	0,81	0,00
	Wiener Pontual * ( $w = 3 \times 3$ , NLM, PRELIM, bins = 256)	0,00	27,24	5,07	0,77	0,81	0,62
(c)	Wiener Pontual * ( $w = 3 \times 3$ , $w_{pre} = 5 \times 5$ , MÉD, PRELIM, bins = 3)	0,00	26,65	4,48	0,78	0,81	0,01
	Wiener Pontual * ( $w = 3 \times 3$ , $w_{pre} = 7 \times 7$ , MÉD, FORM)	0,00	26,86	4,69	0,77	0,80	0,00
	Wiener Pontual * ( $w = 3 \times 3$ , $w_{pre} = 5 \times 5$ , MÉD, FORM)	0,00	26,43	4,27	0,78	0,80	0,00
(d)	Wiener com MRF Isotrópico * ( $w = 5 \times 5$ , NLM, MAN)	0,00	25,72	3,56	0,67	0,75	1,76
	Wiener com MRF Isotrópico * ( $w = 3 \times 3$ , NLM, MAN)	0,00	24,67	2,50	0,75	0,81	1,52
	Wiener com MRF Isotrópico * ( $w = 7 \times 7$ , $w_{pre} = 3 \times 3$ , MÉD, FINAL, bins = 256)	0,00	26,56	4,40	0,69	0,75	1,51
	Wiener com MRF Isotrópico ( $w = 3 \times 3$ , NLM, FINAL, bins = 256)	0,00	23,53	1,36	0,68	0,81	1,53
	Wiener com MRF Isotrópico ( $w = 3 \times 3$ , $w_{pre} = 3 \times 3$ , MÉD, FINAL, bins = 256)	0,01	22,79	0,62	0,73	0,78	0,80
	Wiener com MRF Isotrópico * ( $w = 9 \times 9$ , $w_{pre} = 3 \times 3$ , MÉD, PRELIM, bins = 3)	0,00	26,37	4,21	0,68	0,75	2,50
	Wiener com MRF Isotrópico ( $w = 3 \times 3$ , NLM, PRELIM, bins = 1)	0,00	23,42	1,26	0,67	0,81	1,39
	Wiener com MRF Isotrópico ( $w = 3 \times 3$ , $w_{pre} = 3 \times 3$ , MÉD, PRELIM, bins = 1)	0,01	22,67	0,51	0,73	0,78	0,66
	Wiener com MRF Isotrópico * ( $w = 7 \times 7$ , $w_{pre} = 3 \times 3$ , MÉD, FORM)	0,00	27,39	5,22	0,69	0,77	1,50
	Wiener com MRF Isotrópico ( $w = 3 \times 3$ , NLM, FORM)	0,00	23,64	1,47	0,68	0,81	1,51
(e)	Wiener com MRF Isotrópico ( $w = 3 \times 3$ , $w_{pre} = 3 \times 3$ , MÉD, FORM)	0,01	22,80	0,63	0,73	0,79	0,77
	Wiener com MRF Separável * ( $w = 3 \times 3$ , NLM, MAN)	0,00	26,02	3,86	0,67	0,76	1,52
	Wiener com MRF Separável ( $w = 3 \times 3$ , NLM, MAN)	0,00	23,03	0,86	0,67	0,80	1,52

(f)	Wiener com MRF Separável * (w = 3x3, w_pré = 3x3, MÉD, MAN)	0,00	24,89	2,72	0,73	0,77	0,78
	Wiener com MRF Separável * (w = 9x9, w_pré = 3x3, MÉD, FINAL, bins = 256)	0,00	26,44	4,27	0,68	0,74	2,67
	Wiener com MRF Separável (w = 3x3, NLM, FINAL, bins = 5)	0,00	23,47	1,30	0,67	0,81	1,54
(g)	Wiener com MRF Separável (w = 3x3, w_pré = 3x3, MÉD, FINAL, bins = 256)	0,01	22,79	0,62	0,73	0,78	0,77
	Wiener com MRF Separável * (w = 9x9, w_pré = 3x3, MÉD, PRELIM, bins = 3)	0,00	26,17	4,00	0,68	0,75	2,57
	Wiener com MRF Separável (w = 3x3, NLM, PRELIM, bins = 3)	0,00	23,42	1,25	0,67	0,81	1,39
	Wiener com MRF Separável (w = 3x3, w_pré = 3x3, MÉD, PRELIM, bins = 1)	0,01	22,70	0,53	0,73	0,78	0,65
(h)	Wiener com MRF Separável * (w = 7x7, NLM, FORM)	0,00	26,61	4,44	0,67	0,73	2,32
(i)	Wiener com MRF Separável (w = 3x3, NLM, FORM)	0,00	23,53	1,36	0,68	0,81	1,52
(j)	Wiener com MRF Separável (w = 3x3, w_pré = 3x3, MÉD, FORM)	0,01	22,77	0,60	0,73	0,79	0,76
(k)	Wiener Generalizado * ( $\alpha = 0,9$ , w = 3x3, viz = 4, NLM, MAN)	0,00	27,87	5,71	0,75	0,81	0,62
	Wiener Generalizado * ( $\alpha = 0,8$ , w = 3x3, viz = 8, NLM, FINAL, bins = 5)	0,00	27,62	5,45	0,75	0,81	0,62
(l)	Wiener Generalizado * ( $\alpha = 0,9$ , w = 3x3, viz = 8, NLM, FINAL, bins = 1)	0,00	26,97	4,81	0,76	0,82	0,63
	Wiener Generalizado * ( $\alpha = 1$ , w = 3x3, viz = 4, w_pré = 5x5, MÉD, FINAL, bins = 256)	0,00	26,61	4,44	0,78	0,81	0,01
	Wiener Generalizado * ( $\alpha = 0,9$ , w = 3x3, viz = 8, NLM, PRELIM, bins = 3)	0,00	27,53	5,36	0,75	0,81	0,62
(m)	Wiener Generalizado * ( $\alpha = 1$ , w = 3x3, viz = 8, w_pré = 5x5, MÉD, PRELIM, bins = 3)	0,00	26,65	4,48	0,78	0,81	0,01
	Wiener Generalizado * ( $\alpha = 0,8$ , w = 3x3, viz = 8, NLM, FORM)	0,00	27,57	5,41	0,75	0,81	0,63
	Wiener Generalizado * ( $\alpha = 1$ , w = 3x3, viz = 4, w_pré = 5x5, MÉD, FORM)	0,00	26,30	4,13	0,78	0,81	0,01
(n)	ICM * (Modelo = Gaussiana+Potts, iter = 1, MAN)	0,00	24,25	2,09	0,73	0,74	2,97
(o)	ICM * (Modelo = Gaussiana+GMRF, iter = 3, MAN)	0,00	24,06	1,89	0,75	0,78	0,35
	ICM * (Modelo = GMRF+Potts, iter = 1, FINAL, bins = 5)	0,00	23,98	1,82	0,73	0,76	2,97
	ICM * (Modelo = GMRF+Potts, iter = 1, FINAL, bins = 256)	0,00	23,98	1,82	0,73	0,74	2,98
	ICM * (Modelo = GMRF+GMRF, iter = 3, FINAL, bins = 5)	0,01	22,45	0,28	0,73	0,77	0,48
	ICM * (Modelo = GMRF+Potts, iter = 1, PRELIM, bins = 3)	0,00	23,96	1,79	0,73	0,74	2,86
	ICM * (Modelo = GMRF+Potts, iter = 1, PRELIM, bins = 256)	0,00	23,96	1,79	0,73	0,74	2,88

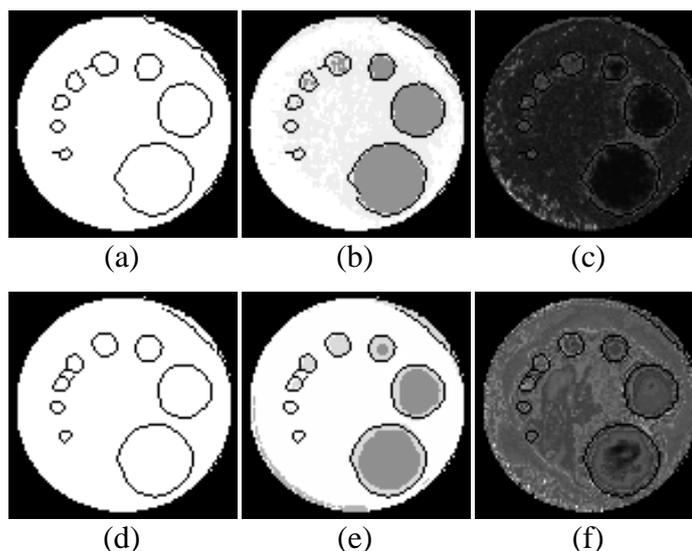
	ICM * (Modelo = GMRF+GMRF, iter = 3, PRELIM, bins = 3)	0,01	22,31	0,14	0,73	0,77	0,45
	ICM * (Modelo = GMRF+Potts, iter = 1, FORM)	<b>0,00</b>	23,98	1,82	0,73	0,74	2,87
	ICM * (Modelo = GMRF+GMRF, iter = 3, FORM)	0,01	22,61	0,45	0,73	0,77	0,39
(p)	GSA * (Modelo = Gaussiana+Potts, iter = 1, $\alpha = 0,7$ , MAN)	<b>0,00</b>	24,41	2,24	0,73	0,74	3,04
(q)	GSA * (Modelo = Gaussiana+GMRF, iter = 8, $\alpha = 0,6$ , MAN)	<b>0,00</b>	24,06	1,89	0,75	0,78	1,72
	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,9$ , FINAL, bins = 5)	<b>0,00</b>	24,06	1,89	0,72	0,77	0,35
	GSA * (Modelo = GMRF+GMRF, iter = 8, $\alpha = 0,9$ , FINAL, bins = 256)	0,01	22,19	0,02	0,73	0,77	1,73
	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,9$ , PRELIM, bins = 256)	<b>0,00</b>	24,07	1,90	0,72	0,76	0,36
	GSA * (Modelo = GMRF+GMRF, iter = 3, $\alpha = 0,9$ , PRELIM, bins = 3)	<b>0,00</b>	23,42	1,25	0,73	0,77	0,78
	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,8$ , FORM)	<b>0,00</b>	24,03	1,87	0,72	0,76	0,39
	GSA * (Modelo = GMRF+GMRF, iter = 8, $\alpha = 0,8$ , FORM)	0,01	22,23	0,06	0,73	0,77	1,65
	MPM (Modelo = Gaussiana+Potts, MAN)	0,07	11,43	-10,74	0,48	0,53	116,83
	MPM (Modelo = Gaussiana+GMRF, MAN)	0,07	11,40	-10,77	0,55	0,61	190,89
	MPM (Modelo = Gaussiana+GIMLL, FINAL, bins=5)	0,06	12,26	-9,91	0,50	0,55	728,20
(r)	MPM (Modelo = GMRF+GMRF, FINAL, bins=256)	0,06	12,06	-10,10	0,58	0,63	189,74
	MPM (Modelo = Gaussiana+Potts, PRELIM, bins=256)	0,06	12,17	-10,00	0,47	0,51	123,10
	MPM (Modelo = GMRF+GMRF, PRELIM, bins=3)	0,07	11,81	-10,36	0,51	0,58	184,22
(s)	MPM (Modelo = GMRF+Potts, FORM)	0,03	15,55	-6,62	0,58	0,62	137,39
(t)	MPM (Modelo = GMRF+GMRF, FORM)	0,06	12,07	-10,10	0,57	0,63	181,82

Comparados aos métodos diretos, temos que os métodos iterativos obtiveram desempenho inferior, especialmente quantitativamente. Qualitativamente, os resultados visuais apresentam-se muito semelhantes, sendo que o MPM novamente sofre com artefatos na região fora do objeto e no caso do uso de modelo a priori Potts, a mesma tendência a segmentar a imagem. Vale ressaltar também que a estimação pelo método Formal para o MPM, apresentou novamente resultados superiores em comparação com os outros métodos de estimação. Entretanto, podemos destacar que os melhores resultados visuais foram obtidos pelos métodos baseados em Wiener com exceção dos itens (c) e (j) da Figura 7.19, que utilizaram o filtro da média para obter a pré-estimativa da imagem livre de ruído.



**Figura 7.19.** Resultados de Filtragem para a Imagem do *phantom* Assimétrico reconstruído por POCS. As imagens exibidas estão na ordem da Tabela 7.12.

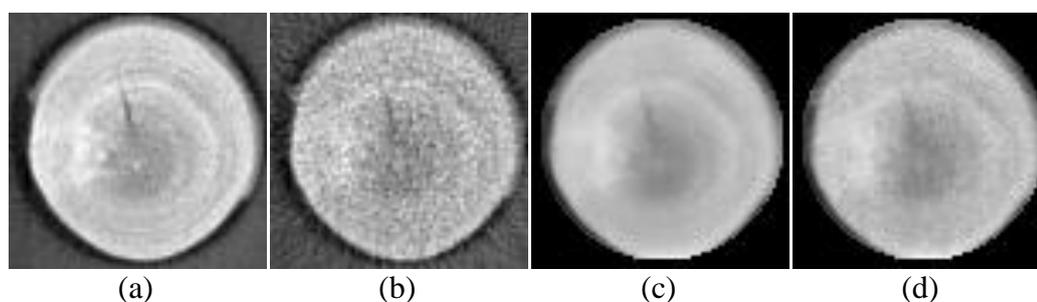
Finalmente, temos também que, geralmente, os melhores resultados para esta imagem utilizaram técnica de melhora de contraste e Non Local Means para realizar a pré-estimação da imagem livre de ruído. Ainda, não foi possível identificar qualquer predominância de um método de um determinado método para todas as medidas, apesar dos ótimos resultados obtidos pelo método Formal.



**Figura 7.20.** Mapas do Ruído para o *phantom* Assimétrico reconstruído por POCS do método Preliminar (limiar = 0,27 e número de bins: (a)  $K = 1$ , (b)  $K = 3$  e (c)  $K = 256$ ) e do Final (limiar = 0,14 e número de bins: (d)  $K = 1$ , (e)  $K = 5$  e (f)  $K = 256$ ).

## 7.5 Madeira 1

Além dos corpos de prova usados anteriormente, o CNPDIA-EMBRAPA forneceu mais as projeções de dois objetos encontrados na natureza. Estes objetos consistem de peças de madeira. A imagem da primeira peça é quase homogênea, mas contém alguma variação de tons circularmente, alguns tons mais escuros no centro e também alguns detalhes. Ela contém dimensão de  $76 \times 76$  pixels. Na Figura 7.21 são exibidas as imagens original e ruidosa para FBP e POCS e na Tabela 7.13 as medidas da imagem ruidosa comparada com a original. Nas Seções 7.5.1 e 7.5.2 são apresentados e discutidos os resultados de filtragem obtidos em imagens reconstruídas por FBP e POCS, respectivamente.



**Figura 7.21.** Imagens de Madeira 1: a) original reconstruída por FBP, b) ruidosa reconstruída por FBP, c) original reconstruída por POCS e d) ruidosa reconstruída por POCS.

**Tabela 7.13.** Resultados das medidas de avaliação da imagem ruidosa comparada com a imagem original para a Madeira 1, reconstruídas tanto por FBP quanto por POCS.

<b>Métodos de Reconstrução</b>	<b>MSE</b>	<b>PSNR</b>	<b>UIQ</b>	<b>SSIM</b>	<b>Tempo de Reconstrução (s)</b>
<b>FBP</b>	0,01	21,50	0,67	0,65	0,01
<b>POCS</b>	0,00	34,06	0,85	0,87	31,14

### 7.5.1 FBP

Nesta Seção, temos os resultados da aplicação dos métodos sobre a imagem de Madeira 1 reconstruída por FBP. Os melhores resultados para cada método são exibidos na Tabela 7.14 e suas respectivas imagens filtradas na Figura 7.22. Ainda na Figura 7.23 temos os mapas de borda obtidos para  $K = 256$  e  $K = 1$ , e os números de bins considerados os mais adequados para esta imagem,  $K = 5$  e  $K = 9$ , para os métodos Preliminar e Final, respectivamente.

Para esta imagem, o melhor resultado em termos de PSNR foi obtido pelo Non Local Means, que foi cerca de 0,28 dB superior ao melhor resultado contextual neste critério que foi atingido pelo Wiener Generalizado \* ( $\alpha = 0,7$ ,  $w = 3 \times 3$ ,  $viz = 4$ , NLM, FINAL, bins = 9). Por sua vez, este é aproximadamente 6,94 dB e 0,03 dB superior ao PSNR da imagem ruidosa e do melhor resultado do Wiener Pontual, respectivamente.

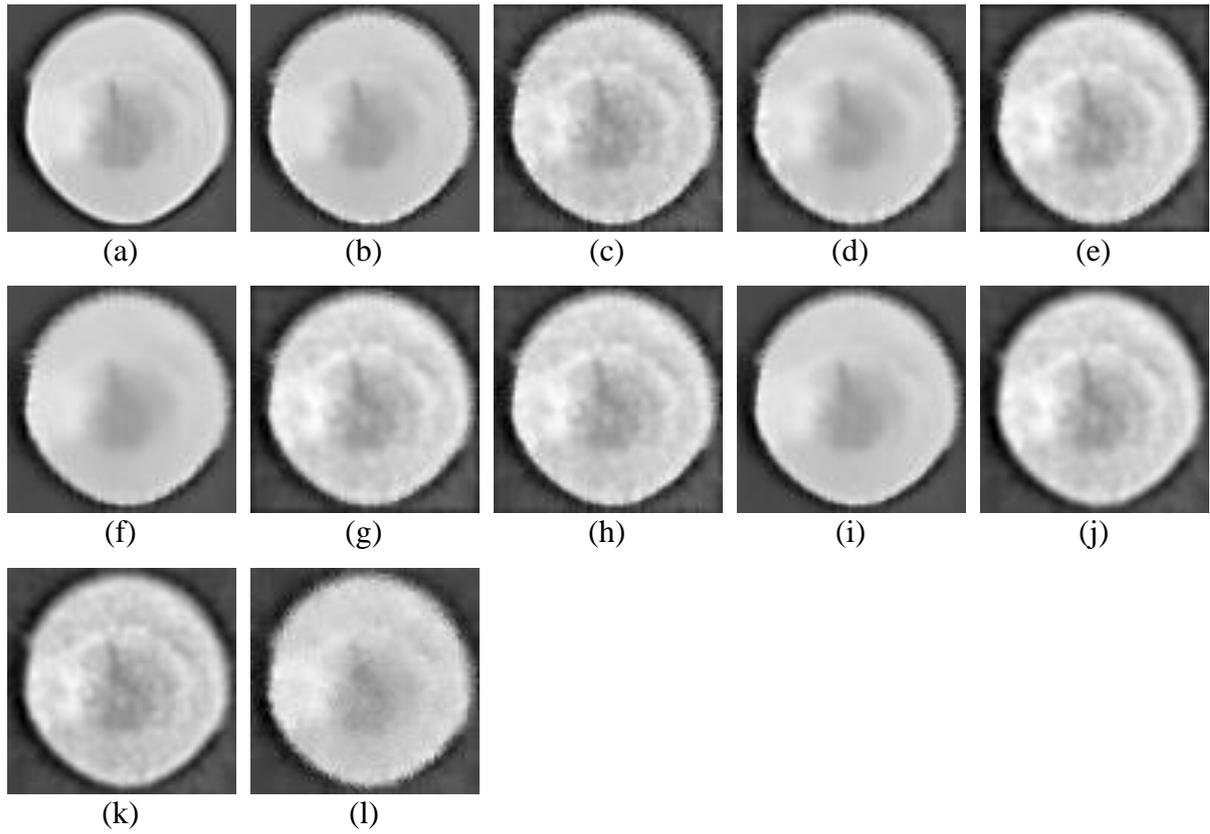
Em termos de SSIM e UIQ, temos vários resultados empatados no topo, sendo que destacamos o Wiener Pontual \* ( $w = 3 \times 3$ ,  $w_{pré} = 3 \times 3$ , MÉD, MAN) e o Wiener Generalizado \* ( $\alpha = 0,9$ ,  $w = 3 \times 3$ ,  $viz = 8$ ,  $w_{pré} = 3 \times 3$ , MÉD, MAN), apesar do primeiro apresentar desempenho superior em termos de PSNR.

Os métodos iterativos apresentam resultados pouco inferiores aos obtidos pelos métodos baseados em Wiener. Entretanto, acredita-se que o MPM necessitaria de maior número de iterações.

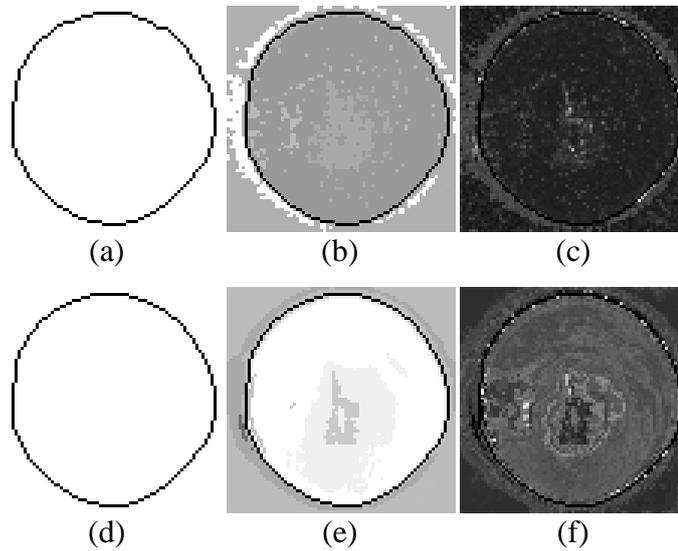
**Tabela 7.14.** Melhores resultados para Madeira 1 reconstruído por FBP, onde \* representa o uso de técnica de realce de contraste.

Ord.	Métodos de Filtragem	MSE	PSNR	ISNR	UIQ	SSIM	Tempo (s)
(a)	Non Local Means *	0,00	28,72	7,22	0,69	0,75	0,92
(b)	Wiener Pontual * (w = 3x3, NLM, MAN)	0,00	28,41	6,91	0,65	0,73	0,92
(c)	Wiener Pontual * (w = 3x3, w_pré = 3x3, MÉD, MAN)	0,00	28,25	6,75	0,77	0,79	0,01
	Wiener Pontual * (w = 3x3, w_pre = 3x3, MÉD, FINAL, bins = 9)	0,00	27,81	6,32	0,76	0,78	0,01
	Wiener Pontual * (w = 3x3, NLM, PRELIM, bins = 1)	0,00	28,20	6,70	0,66	0,73	0,92
	Wiener Pontual * (w = 3x3, w_pré = 3x3, MÉD, PRELIM, bins = 256)	0,00	26,62	5,12	0,77	0,79	0,01
	Wiener Pontual * (w = 5x5, w_pre = 3x3, MÉD, FORM)	0,00	27,16	5,67	0,74	0,77	0,01
	Wiener Pontual * (w = 3x3, w_pre = 3x3, MÉD, FORM)	0,00	26,20	4,70	0,76	0,78	0,01
	Wiener com MRF Isotrópico * (w = 9x9, w_pré = 3x3, MÉD, MAN)	0,00	27,89	6,39	0,68	0,73	1,72
	Wiener com MRF Isotrópico * (w = 3x3, w_pré = 3x3, MÉD, MAN)	0,00	24,75	3,25	0,74	0,77	0,56
(d)	Wiener com MRF Isotrópico * (w = 9x9, w_pré = 3x3, MÉD, FINAL, bins = 9)	0,00	27,95	6,45	0,68	0,73	1,73
(e)	Wiener com MRF Isotrópico * (w = 3x3, w_pré = 3x3, MÉD, FINAL, bins = 256)	0,00	25,25	3,76	0,74	0,77	0,57
	Wiener com MRF Isotrópico * (w = 9x9, NLM, PRELIM, bins = 1)	0,00	26,52	5,03	0,59	0,68	2,55
	Wiener com MRF Isotrópico * (w = 3x3, w_pré = 3x3, MÉD, PRELIM, bins = 1)	0,00	24,62	3,12	0,74	0,76	0,48
	Wiener com MRF Isotrópico * (w = 9x9, w_pré = 3x3, MÉD, FORM)	0,00	27,16	5,67	0,68	0,73	1,64
	Wiener com MRF Isotrópico * (w = 3x3, w_pré = 3x3, MÉD, FORM)	0,00	24,90	3,41	0,74	0,77	0,49
	Wiener com MRF Separável * (w = 5x5, NLM, MAN)	0,00	27,02	5,53	0,61	0,69	1,59
	Wiener com MRF Separável * (w = 3x3, w_pré = 3x3, MÉD, MAN)	0,00	24,87	3,37	0,74	0,77	0,56
(f)	Wiener com MRF Separável * (w = 5x5, NLM, FINAL, bins = 9)	0,00	27,38	5,89	0,61	0,69	1,60
(g)	Wiener com MRF Separável * (w = 3x3, w_pré = 3x3, MÉD, FINAL, bins = 256)	0,00	25,39	3,89	0,75	0,77	0,55
	Wiener com MRF Separável * (w = 7x7, NLM, PRELIM, bins = 1)	0,00	26,23	4,73	0,58	0,67	1,86
	Wiener com MRF Separável * (w = 3x3, w_pré = 3x3, MÉD, PRELIM, bins = 1)	0,00	24,70	3,20	0,74	0,77	0,48
	Wiener com MRF Separável * (w = 9x9, w_pré = 3x3, MÉD, FORM)	0,00	27,03	5,53	0,67	0,72	1,63
	Wiener com MRF Separável * (w = 3x3, w_pré = 3x3, MÉD, FORM)	0,00	25,13	3,63	0,75	0,77	0,47

	Wiener Generalizado * ( $\alpha = 1$ , $w = 3 \times 3$ , $viz = 8$ , NLM, MAN)	0,00	28,41	6,91	0,65	0,72	0,92
(h)	Wiener Generalizado * ( $\alpha = 0,9$ , $w = 3 \times 3$ , $viz = 8$ , $w_{pré} = 3 \times 3$ , MÉD, MAN)	0,00	26,89	5,39	0,77	0,79	0,00
(i)	Wiener Generalizado * ( $\alpha = 0,7$ , $w = 3 \times 3$ , $viz = 4$ , NLM, FINAL, bins = 9)	0,00	28,44	6,94	0,65	0,72	0,92
	Wiener Generalizado * ( $\alpha = 0,8$ , $w = 3 \times 3$ , $viz = 8$ , $w_{pré} = 3 \times 3$ , MÉD, FINAL, bins = 256)	0,00	26,56	5,06	0,77	0,79	0,00
	Wiener Generalizado * ( $\alpha = 1$ , $w = 3 \times 3$ , $viz = 8$ , NLM, PRELIM, bins = 1)	0,00	28,08	6,59	0,66	0,73	0,92
	Wiener Generalizado * ( $\alpha = 1$ , $w = 3 \times 3$ , $viz = 8$ , $w_{pré} = 3 \times 3$ , MÉD, PRELIM, bins = 256)	0,00	26,50	5,00	0,77	0,79	0,01
	Wiener Generalizado * ( $\alpha = 0,5$ , $w = 3 \times 3$ , $viz = 4$ , NLM, FORM)	0,00	27,24	5,75	0,65	0,72	0,92
	Wiener Generalizado * ( $\alpha = 0,9$ , $w = 3 \times 3$ , $viz = 8$ , $w_{pré} = 3 \times 3$ , MÉD, FORM)	0,00	25,84	4,34	0,77	0,79	0,01
(j)	ICM * (Modelo = Gaussiana+GMRF, iter = 1, MAN)	0,00	26,17	4,67	0,75	0,77	0,26
	ICM * (Modelo = GMRF+GMRF, iter = 1, FINAL, bins = 256)	0,00	26,05	4,55	0,75	0,76	0,21
	ICM * (Modelo = GMRF+GMRF, iter = 1, PRELIM, bins = 5)	0,00	25,86	4,36	0,74	0,76	0,24
	ICM * (Modelo = GMRF+GMRF, iter = 1, FORM)	0,00	26,02	4,53	0,74	0,76	0,23
(k)	GSA * (Modelo = Gaussiana+GMRF, iter = 1, $\alpha = 0,6$ , MAN)	0,00	27,34	5,84	0,75	0,76	0,19
	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,9$ , FINAL, bins = 256)	0,00	26,98	5,48	0,73	0,75	0,30
	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,9$ , FINAL, bins = 9)	0,00	25,90	4,40	0,74	0,76	0,32
	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,6$ , PRELIM, bins = 256)	0,00	26,88	5,38	0,73	0,74	0,34
	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,9$ , PRELIM, bins = 5)	0,00	25,94	4,44	0,74	0,75	0,26
	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,6$ , FORM)	0,00	26,91	5,41	0,72	0,74	0,28
	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,9$ , FORM)	0,00	26,51	5,01	0,74	0,75	0,22
(l)	MPM * (Modelo = Gaussiana+GMRF, MAN)	0,00	24,86	3,36	0,61	0,65	142,81
	MPM * (Modelo = GMRF+GMRF, FINAL, bins=9)	0,00	23,33	1,83	0,56	0,62	161,17
	MPM * (Modelo = GMRF+GMRF, FINAL, bins=256)	0,01	22,69	1,19	0,59	0,64	171,17
	MPM * (Modelo = GMRF+GMRF, PRELIM, bins=5)	0,01	21,69	0,19	0,45	0,54	149,70
	MPM (Modelo = Gaussiana+GIMLL-L1, PRELIM, bins=256)	0,01	19,86	-1,64	0,52	0,59	678,94
	MPM * (Modelo = GMRF+GIMLL-L1, PRELIM, bins=5)	0,01	20,67	-0,83	0,53	0,56	685,89
	MPM * (Modelo = GMRF+GMRF, FORM)	0,00	24,18	2,68	0,58	0,63	165,31



**Figura 7.22.** Resultados de Filtragem para a Imagem de Madeira 1 reconstruído por FBP. As imagens exibidas estão na ordem da Tabela 7.14.



**Figura 7.23.** Mapas do Ruído para Madeira 1 reconstruído por FBP do método Preliminar (limiar = 0,26 e número de bins: (a)  $K = 1$ , (b)  $K = 5$  e (c)  $K = 256$ ) e do Final (limiar = 0,99 e número de bins: (d)  $K = 1$ , (e)  $K = 9$  e (f)  $K = 256$ ).

Visualmente, pode-se notar uma suavização excessiva no resultado de Non Local Means e nos métodos que utilizaram Largura de Janela diferente do que 3x3 para fazer a estimação das estatísticas, o que fez com que perdessem detalhes. Assim, os métodos que utilizaram o filtro da Média 3x3 e largura de janela 3x3, apresentaram resultados visualmente superiores. Desta forma, podemos destacar os itens (c), (e), (g), (h) e (j) da Figura 7.22, que correspondem ao Wiener Pontual \* ( $w = 3 \times 3$ ,  $w_{\text{pré}} = 3 \times 3$ , MÉD, MAN), Wiener com MRF Isotrópico \* ( $w = 3 \times 3$ ,  $w_{\text{pré}} = 3 \times 3$ , MÉD, FINAL, bins = 256), Wiener com MRF Separável \* ( $w = 3 \times 3$ ,  $w_{\text{pré}} = 3 \times 3$ , MÉD, FINAL, bins = 256), Wiener Generalizado \* ( $\alpha = 0,9$ ,  $w = 3 \times 3$ , viz = 8,  $w_{\text{pré}} = 3 \times 3$ , MÉD, MAN) e ICM \* (Modelo = Gaussiana + GMRF, iter = 1, MAN), respectivamente.

Finalmente, temos que em geral os melhores resultados para esta imagem utilizaram técnica de melhora de contraste e a pré-estimativa da imagem livre de ruído foi dada pelo filtro da Média. Além disso, não parece haver qualquer predominância de um método de estimação do ruído, apesar de bons resultados terem sido obtidos com o método Manual e Final.

### 7.5.2 POCS

Nesta Seção, temos os resultados da aplicação dos métodos sobre a imagem de Madeira 1 reconstruída por POCS. Os melhores resultados para cada método são exibidos na Tabela 7.15 e suas respectivas imagens filtradas na Figura 7.24. Ainda na Figura 7.25 temos os mapas de borda obtidos para  $K = 256$  e  $K = 1$ , e os números de bins considerados os mais adequados para esta imagem,  $K = 5$  e  $K = 52$ , para os métodos Preliminar e Final, respectivamente.

Para esta imagem, temos que o melhor resultado em termos de PSNR foi obtido pelo método de Wiener Pontual ( $w = 3 \times 3$ ,  $w_{\text{pré}} = 3 \times 3$ , MÉD, FORM) que foi cerca de 0,69 dB superior ao melhor resultado contextual de acordo com este critério, Wiener com MRF Isotrópico ( $w = 9 \times 9$ ,  $w_{\text{pré}} = 3 \times 3$ , MÉD, FINAL, bins = 52). Por sua vez, este foi aproximadamente 1,45 dB e 2,69 dB superior à imagem ruidosa e ao Non Local Means. Entretanto, em termos de SSIM, exceto o MPM, todos os métodos melhoraram. Para o MPM, um número maior de iterações seria necessário também.

Em termos de UIQ e SSIM, os melhores resultados foram obtidos pelos pelo Wiener Pontual ( $w = 3 \times 3$ ,  $w_{\text{pré}} = 3 \times 3$ , MÉD, FINAL, bins = 52). O melhor resultado de um método

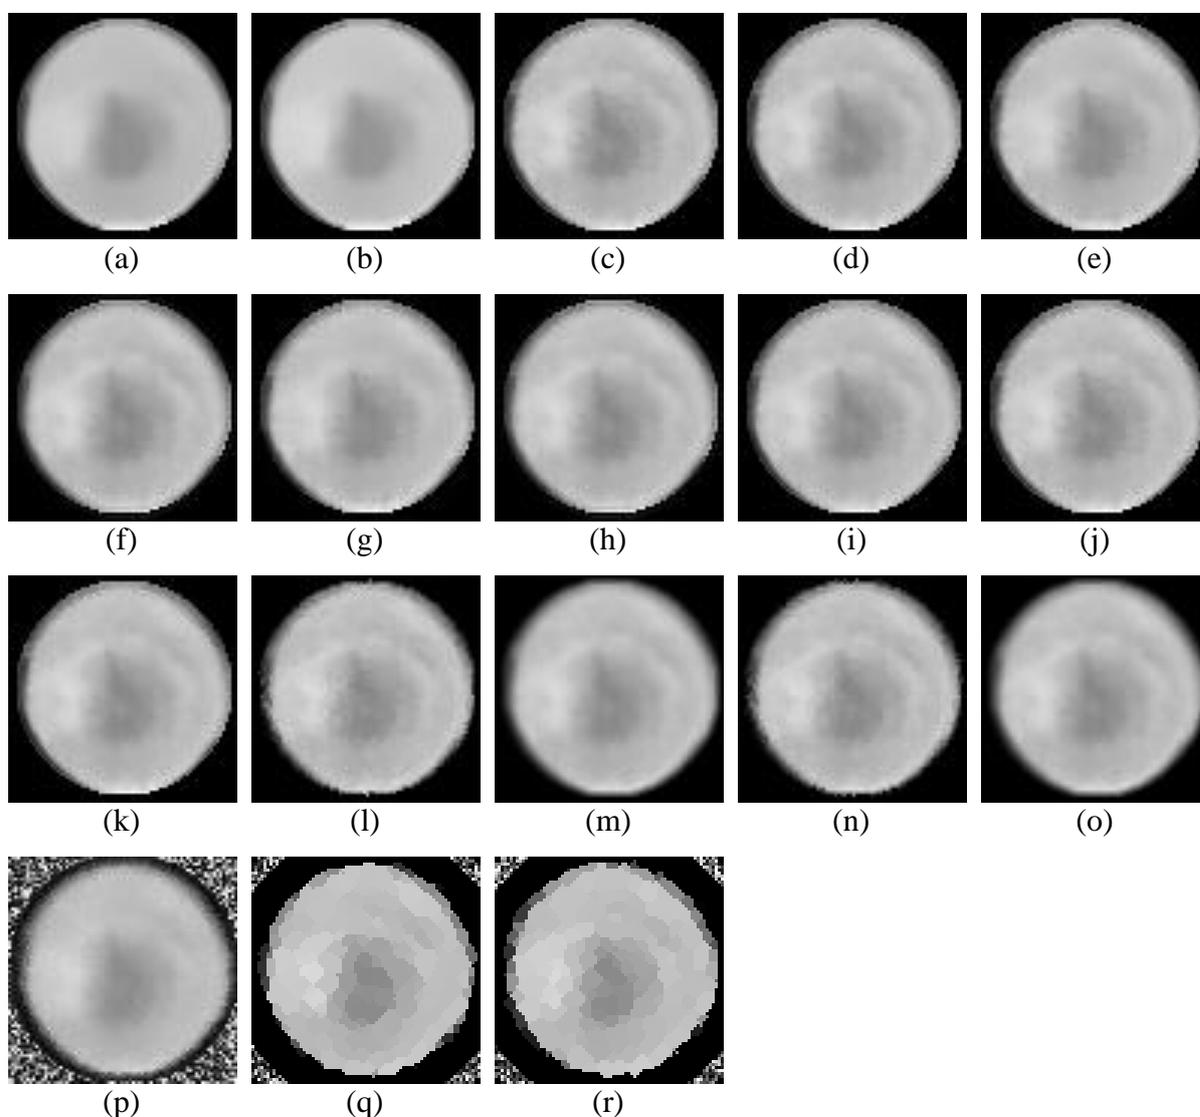
contextual para UIQ e SSIM foi obtido por Wiener com MRF Separável ( $w = 3 \times 3$ ,  $w_{\text{pré}} = 3 \times 3$ , MÉD, FINAL, bins = 52).

**Tabela 7.15.** Melhores resultados para Madeira 1 reconstruído por POCS, onde \* representa o uso de técnica de realce de contraste.

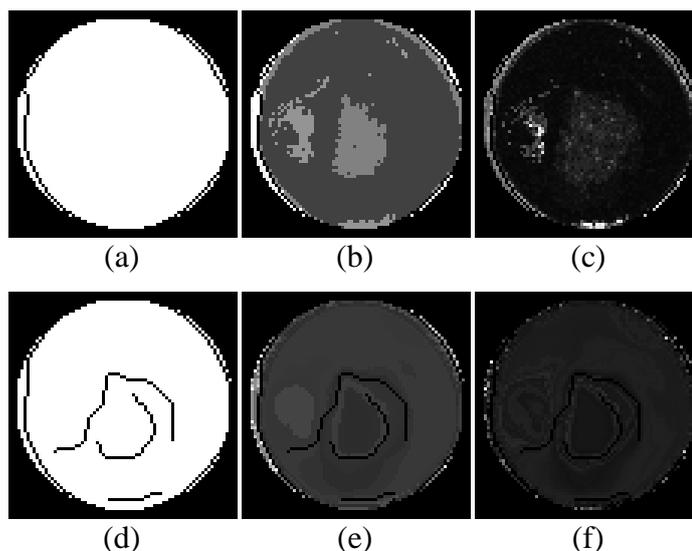
Ord.	Métodos de Filtragem	MSE	PSNR	ISNR	UIQ	SSIM	Tempo (s)
(a)	Non Local Means	0,00	32,82	-1,23	0,70	0,88	0,85
(b)	Non Local Means *	0,00	30,01	-4,04	0,75	0,88	0,85
	Wiener Pontual ( $w = 3 \times 3$ , $w_{\text{pré}} = 3 \times 3$ , MÉD, MAN)	0,00	36,07	2,01	0,84	0,92	0,01
(c)	Wiener Pontual ( $w = 3 \times 3$ , $w_{\text{pré}} = 3 \times 3$ , MÉD, FINAL, bins = 52)	0,00	36,17	2,12	0,88	0,92	0,01
	Wiener Pontual ( $w = 3 \times 3$ , $w_{\text{pré}} = 5 \times 5$ , MÉD, PRE-LIM, bins = 1)	0,00	35,93	1,87	0,87	0,92	0,01
(d)	Wiener Pontual ( $w = 3 \times 3$ , $w_{\text{pré}} = 3 \times 3$ , MÉD, FORM)	0,00	36,20	2,14	0,84	0,92	0,01
	Wiener Pontual * ( $w = 3 \times 3$ , $w_{\text{pré}} = 3 \times 3$ , MÉD, FORM)	0,00	35,34	1,28	0,88	0,92	0,01
	Wiener com MRF Isotrópico ( $w = 9 \times 9$ , NLM, MAN)	0,00	33,45	-0,61	0,70	0,88	2,56
	Wiener com MRF Isotrópico ( $w = 3 \times 3$ , $w_{\text{pré}} = 3 \times 3$ , MÉD, MAN)	0,00	29,68	-4,38	0,81	0,89	0,46
(e)	Wiener com MRF Isotrópico ( $w = 9 \times 9$ , $w_{\text{pré}} = 3 \times 3$ , MÉD, FINAL, bins = 52)	0,00	35,51	1,46	0,78	0,90	1,57
(f)	Wiener com MRF Isotrópico ( $w = 3 \times 3$ , $w_{\text{pré}} = 3 \times 3$ , MÉD, FINAL, bins = 52)	0,00	33,10	-0,96	0,82	0,91	0,46
	Wiener com MRF Isotrópico ( $w = 9 \times 9$ , $w_{\text{pré}} = 3 \times 3$ , MÉD, PRELIM, bins = 1)	0,00	33,23	-0,82	0,72	0,88	1,50
	Wiener com MRF Isotrópico ( $w = 3 \times 3$ , $w_{\text{pré}} = 3 \times 3$ , MÉD, PRELIM, bins = 1)	0,00	31,58	-2,47	0,82	0,90	0,41
	Wiener com MRF Isotrópico ( $w = 9 \times 9$ , $w_{\text{pré}} = 3 \times 3$ , MÉD, FORM)	0,00	35,34	1,28	0,77	0,90	1,55
	Wiener com MRF Isotrópico ( $w = 3 \times 3$ , $w_{\text{pré}} = 3 \times 3$ , MÉD, FORM)	0,00	32,57	-1,49	0,82	0,91	0,47
	Wiener com MRF Separável ( $w = 3 \times 3$ , NLM, MAN)	0,00	31,27	-2,79	0,69	0,87	1,39
	Wiener com MRF Separável ( $w = 3 \times 3$ , $w_{\text{pré}} = 3 \times 3$ , MÉD, MAN)	0,00	29,87	-4,19	0,81	0,89	0,45
(g)	Wiener com MRF Separável ( $w = 9 \times 9$ , $w_{\text{pré}} = 3 \times 3$ , MÉD, FINAL, bins = 256)	0,00	34,71	0,65	0,78	0,89	1,59
(h)	Wiener com MRF Separável ( $w = 3 \times 3$ , $w_{\text{pré}} = 3 \times 3$ , MÉD, FINAL, bins = 52)	0,00	33,11	-0,95	0,82	0,91	0,45
	Wiener com MRF Separável ( $w = 3 \times 3$ , NLM, PRE-LIM, bins = 1)	0,00	33,15	-0,91	0,69	0,88	1,32
	Wiener com MRF Separável ( $w = 3 \times 3$ , $w_{\text{pré}} = 3 \times 3$ , MÉD, PRELIM, bins = 1)	0,00	31,97	-2,09	0,82	0,90	0,38

	Wiener com MRF Separável ( $w = 9 \times 9$ , $w_{pré} = 3 \times 3$ , MÉD, FORM)	0,00	33,11	-0,95	0,77	0,89	1,57
	Wiener com MRF Separável ( $w = 3 \times 3$ , $w_{pré} = 3 \times 3$ , MÉD, FORM)	0,00	31,82	-2,24	0,82	0,90	0,45
	Wiener Generalizado ( $\alpha = 1$ , $w = 3 \times 3$ , viz = 8, $w_{pré} = 3 \times 3$ , MÉD, MAN)	0,00	36,06	2,00	0,84	0,92	0,01
(i)	Wiener Generalizado ( $\alpha = 1$ , $w = 3 \times 3$ , viz = 4, $w_{pré} = 3 \times 3$ , MÉD, FINAL, bins = 52)	0,00	36,17	2,12	0,87	0,92	0,00
(j)	Wiener Generalizado ( $\alpha = 1$ , $w = 3 \times 3$ , viz = 8, $w_{pré} = 3 \times 3$ , MÉD, FINAL, bins = 52)	0,00	36,17	2,11	0,88	0,92	0,00
	Wiener Generalizado ( $\alpha = 1$ , $w = 3 \times 3$ , viz = 8, $w_{pré} = 3 \times 3$ , MÉD, PRELIM, bins = 1)	0,00	35,91	1,86	0,87	0,92	0,01
(k)	Wiener Generalizado ( $\alpha = 1$ , $w = 3 \times 3$ , viz = 8, $w_{pré} = 3 \times 3$ , MÉD, FORM)	0,00	36,19	2,13	0,84	0,92	0,01
	Wiener Generalizado * ( $\alpha = 1$ , $w = 3 \times 3$ , viz = 8, $w_{pré} = 3 \times 3$ , MÉD, FORM)	0,00	35,34	1,28	0,88	0,92	0,01
(l)	ICM (Modelo = Gaussiana+Potts, iter = 1, MAN)	0,00	26,65	-7,41	0,81	0,87	1,81
(m)	ICM (Modelo = Gaussiana+GMRF, iter = 1, MAN)	0,00	26,48	-7,57	0,82	0,89	0,22
	ICM (Modelo = Gaussiana+Potts, iter = 1, FINAL, bins = 52)	0,00	26,34	-7,72	0,78	0,86	1,74
	ICM (Modelo = Gaussiana+Potts, iter = 1, FINAL, bins = 256)	0,00	26,34	-7,72	0,78	0,86	1,75
	ICM (Modelo = GMRF+GMRF, iter = 1, FINAL, bins = 52)	0,00	26,07	-7,99	0,80	0,88	0,16
	ICM (Modelo = Gaussiana+Potts, iter = 1, PRELIM, bins = 5)	0,00	26,32	-7,74	0,78	0,86	1,67
	ICM (Modelo = Gaussiana+Potts, iter = 1, PRELIM, bins = 256)	0,00	26,32	-7,74	0,78	0,86	1,68
	ICM (Modelo = GMRF+GMRF, iter = 1, PRELIM, bins = 256)	0,00	26,06	-7,99	0,81	0,88	0,15
	ICM (Modelo = Gaussiana+Potts, iter = 1, FORM)	0,00	26,32	-7,73	0,78	0,86	1,68
	ICM (Modelo = GMRF+GMRF, iter = 1, FORM)	0,00	26,07	-7,99	0,81	0,88	0,13
(n)	GSA (Modelo = Gaussiana+Potts, iter = 1, $\alpha = 0,7$ , MAN)	0,00	26,79	-7,26	0,81	0,87	1,79
(o)	GSA (Modelo = Gaussiana+GMRF, iter = 1, $\alpha = 0,9$ , MAN)	0,00	26,52	-7,53	0,82	0,89	0,33
	GSA (Modelo = Gaussiana+Potts, iter = 1, $\alpha = 0,6$ , FINAL, bins = 52)	0,00	26,53	-7,53	0,79	0,87	1,76
	GSA (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,9$ , FINAL, bins = 52)	0,00	26,05	-8,00	0,80	0,88	0,27
	GSA (Modelo = Gaussiana+Potts, iter = 1, $\alpha = 0,6$ , PRELIM, bins = 5)	0,00	26,46	-7,60	0,79	0,87	1,70
	GSA (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,9$ , PRELIM, bins = 5)	0,00	26,02	-8,04	0,80	0,88	0,17
	GSA (Modelo = Gaussiana+Potts, iter = 1, $\alpha = 0,9$ , FORM)	0,00	26,35	-7,70	0,79	0,86	1,78

	<b>GSA (Modelo = GMRF+GMRF, iter = 1, <math>\alpha = 0,9</math>, FORM)</b>	<b>0,00</b>	26,05	-8,01	0,80	0,88	0,27
	<b>MPM (Modelo = Gaussiana+GMRF, MAN)</b>	0,07	11,87	-22,19	0,60	0,73	155,26
	<b>MPM (Modelo = Gaussiana+GMRF, FINAL, bins=52)</b>	0,05	12,78	-21,28	0,56	0,73	164,26
<b>(p)</b>	<b>MPM (Modelo = GMRF+GMRF, FINAL, bins=256)</b>	0,05	12,77	-21,29	0,61	0,75	158,78
	<b>MPM (Modelo = GMRF+Potts, PRELIM, bins=5)</b>	0,06	12,47	-21,59	0,43	0,58	81,55
	<b>MPM (Modelo = GMRF+GMRF, PRELIM, bins=256)</b>	0,06	12,37	-21,68	0,47	0,68	159,36
	<b>MPM (Modelo = GMRF+GIMLL-L1, PRELIM, bins=256)</b>	0,06	12,22	-21,84	0,53	0,65	669,41
<b>(q)</b>	<b>MPM (Modelo = Gaussiana+GIMLL-L1, FORM)</b>	0,02	17,78	-16,28	0,61	0,73	673,39
<b>(r)</b>	<b>MPM (Modelo = Gaussiana+GIMLL, FORM)</b>	0,02	17,57	-16,49	0,63	0,74	503,11



**Figura 7.24.** Resultados de Filtragem para a Imagem de Madeira 1 reconstruído por POCS. As imagens exibidas estão na ordem da Tabela 7.15.



**Figura 7.25.** Mapas do Ruído para Madeira 1 reconstruído por POCS do método Preliminar (limiar = 0,15 e número de bins: (a)  $K = 1$ , (b)  $K = 5$  e (c)  $K = 256$ ) e do Final (limiar = 0,09 e número de bins: (d)  $K = 1$ , (e)  $K = 52$  e (f)  $K = 256$ ).

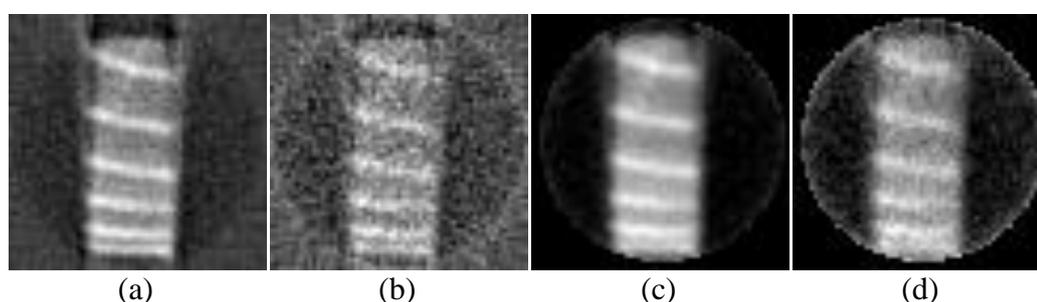
Os métodos iterativos apresentaram resultados muito inferiores aos métodos baseados em Wiener, sendo que para GSA e ICM, os melhores resultados utilizavam apenas uma iteração. Além disso, no caso do MPM há nitidamente uma necessidade maior de iterações. Ainda para este método, o método Formal foi superior aos outros métodos para a estimação do ruído, especialmente em termos de PSNR. E também, mais uma vez, houve o problema de não filtragem fora do objeto e o uso de modelo a priori GIMLL-L1 e GIMLL tendendo a uma segmentação da imagem (itens (r) e (s) da Figura 7.24, respectivamente).

Visualmente, os resultados foram muito semelhantes, com exceção dos obtidos pelo MPM. Além disso, é possível notar uma suavização excessiva do Non Local Means, o que possivelmente levou ao seu desempenho inferior.

Finalmente, em geral, temos que os melhores resultados para esta imagem não utilizaram técnica de melhora de contraste e a pré-estimativa da imagem livre de ruído foi dada pelo filtro da Média. Ainda, notou-se que o método Final foi bastante robusto quando usado com métodos diretos e que não houve grandes diferenças dentre os resultados de ICM e GSA.

## 7.6 Madeira 2

A segunda peça de madeira imageada, também fornecida pelo CNPDIA-EMBRAPA, é bastante heterogênea e em formato retangular. Esta imagem contém dimensão de 61 x 61 pixels. Na Figura 7.26 são exibidas as imagens original e ruidosa para FBP e POCS e na Tabela 7.16 as medidas da imagem ruidosa comparada com a original. Nas Seções 7.6.1 e 7.6.2 são apresentados e discutidos os resultados de filtragem obtidos em imagens reconstruídas por FBP e POCS, respectivamente.



**Figura 7.26.** Imagens de Madeira 2: a) original reconstruída por FBP, b) ruidosa reconstruída por FBP, c) original reconstruída por POCS e d) ruidosa reconstruída por POCS.

**Tabela 7.16.** Resultados das medidas de avaliação da imagem ruidosa comparada com a imagem original para a Madeira 2, reconstruídas tanto por FBP quanto por POCS.

Métodos de Reconstrução	MSE	PSNR	UIQ	SSIM	Tempo de Reconstrução (s)
<b>FBP</b>	0,01	19,01	0,59	0,59	0,01
<b>POCS</b>	0,01	21,66	0,67	0,66	18,53

### 7.6.1 FBP

Nesta Seção, temos os resultados da aplicação dos métodos sobre a imagem de Madeira 2 reconstruída por FBP. Os melhores resultados para cada método são exibidos na Tabela 7.17 e suas respectivas imagens filtradas na Figura 7.27. Ainda na Figura 7.28 temos os mapas de borda obtidos para  $K = 256$  e  $K = 1$ , e os números de bins considerados os mais adequados para esta imagem,  $K = 5$  e  $K = 9$ , para os métodos Preliminar e Final, respectivamente.

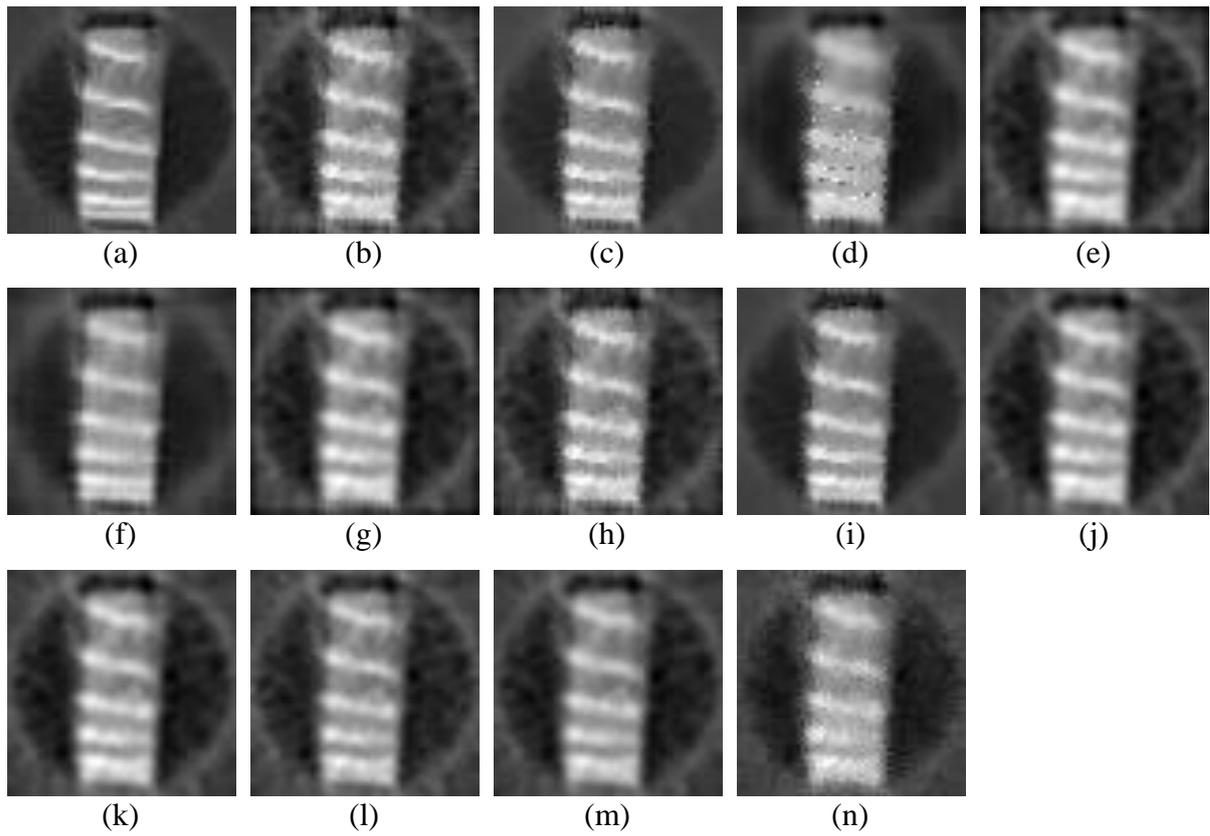
Para esta imagem, o melhor resultado em termos de PSNR foi obtido Wiener Generalizado \* ( $\alpha = 0,9$ ,  $w = 3 \times 3$ ,  $viz = 8$ , NLM, FORM), aumentando cerca de 6,22 dB, 0,09 dB e

0,49 dB do PSNR da imagem ruidosa, do Non Local Means e do melhor resultado para o Wiener Pontual.

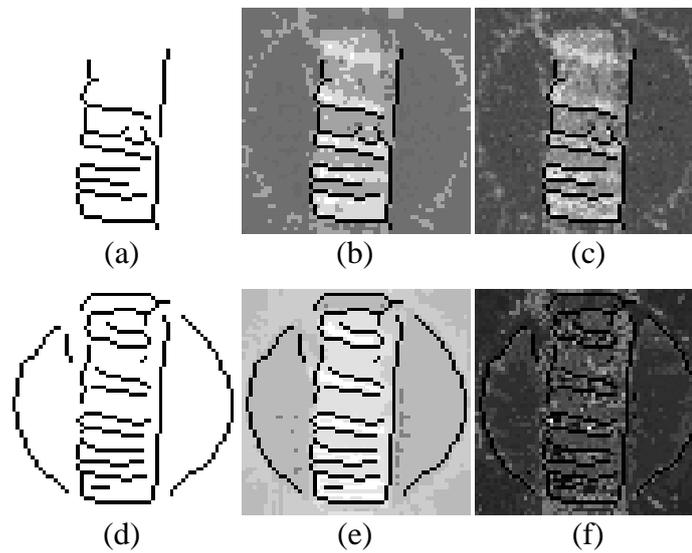
**Tabela 7.17.** Melhores resultados para a Madeira 2 reconstruído por FBP, onde \* representa o uso de técnica de realce de contraste.

Ord.	Métodos de Filtragem	MSE	PSNR	ISNR	UIQ	SSIM	Tempo (s)
(a)	Non Local Means *	<b>0,00</b>	25,14	6,13	<b>0,68</b>	<b>0,74</b>	0,92
	Wiener Pontual * (w = 5x5, w_pré = 3x3, MÉD, MAN)	<b>0,00</b>	24,44	5,43	0,67	0,72	0,01
(b)	Wiener Pontual * (w = 3x3, w_pré = 3x3, MÉD, MAN)	<b>0,00</b>	23,87	4,86	<b>0,68</b>	0,72	<b>0,00</b>
	Wiener Pontual * (w = 5x5, NLM, FINAL, bins = 9)	0,01	20,94	1,93	0,60	0,66	0,92
	Wiener Pontual * (w = 3x3, w_pre = 3x3, MÉD, FINAL, bins = 9)	0,01	19,46	0,45	0,64	0,68	<b>0,00</b>
	Wiener Pontual * (w = 5x5, w_pré = 3x3, MÉD, PRE-LIM, bins = 1)	<b>0,00</b>	24,16	5,15	0,66	0,70	0,01
	Wiener Pontual * (w = 3x3, w_pré = 3x3, MÉD, PRE-LIM, bins = 1)	<b>0,00</b>	23,57	4,56	0,67	0,71	<b>0,00</b>
(c)	Wiener Pontual * (w = 3x3, NLM, FORM)	<b>0,00</b>	24,74	5,73	0,66	0,73	0,92
	Wiener Pontual * (w = 3x3, w_pre = 3x3, MÉD, FORM)	0,01	20,57	1,56	0,67	0,71	0,32
	Wiener com MRF Isotrópico * (w = 9x9, w_pré = 3x3, MÉD, MAN)	<b>0,00</b>	23,30	4,30	0,63	0,68	1,12
	Wiener com MRF Isotrópico * (w = 3x3, w_pré = 3x3, MÉD, MAN)	<b>0,00</b>	23,16	4,15	0,65	0,70	0,37
	Wiener com MRF Isotrópico * (w = 3x3, NLM, FINAL, bins = 256)	0,01	22,69	3,68	0,59	0,67	1,27
	Wiener com MRF Isotrópico * (w = 3x3, w_pré = 3x3, MÉD, FINAL, bins = 256)	0,01	21,50	2,49	0,62	0,67	0,37
(d)	Wiener com MRF Isotrópico * (w = 9x9, w_pré = 3x3, MÉD, PRELIM, bins = 5)	<b>0,00</b>	23,33	4,32	0,59	0,64	1,07
	Wiener com MRF Isotrópico * (w = 3x3, w_pré = 3x3, MÉD, PRELIM, bins = 256)	0,01	22,85	3,84	0,64	0,69	0,31
(e)	Wiener com MRF Isotrópico * (w = 3x3, w_pré = 3x3, MÉD, FORM)	<b>0,00</b>	23,17	4,16	0,66	0,70	0,38
(f)	Wiener com MRF Separável * (w = 9x9, w_pré = 3x3, MÉD, MAN)	<b>0,00</b>	25,02	6,01	0,64	0,70	1,11
	Wiener com MRF Separável * (w = 3x3, w_pré = 3x3, MÉD, MAN)	<b>0,00</b>	23,22	4,21	0,66	0,70	0,36
	Wiener com MRF Separável * (w = 3x3, NLM, FINAL, bins = 256)	0,01	22,74	3,73	0,60	0,67	1,27
	Wiener com MRF Separável * (w = 3x3, w_pré = 3x3, MÉD, FINAL, bins = 256)	0,01	21,53	2,52	0,62	0,67	0,36
	Wiener com MRF Separável * (w = 9x9, w_pré = 3x3, MÉD, PRELIM, bins = 1)	<b>0,00</b>	24,44	5,43	0,63	0,68	1,06

	Wiener com MRF Separável * ( $w = 3 \times 3$ , $w_{\text{pré}} = 3 \times 3$ , MÉD, PRELIM, bins = 1)	0,01	22,90	3,89	0,64	0,69	0,31
	Wiener com MRF Separável * ( $w = 5 \times 5$ , NLM, FORM)	0,00	23,42	4,41	0,63	0,68	1,36
(g)	Wiener com MRF Separável * ( $w = 3 \times 3$ , $w_{\text{pré}} = 3 \times 3$ , MÉD, FORM)	0,00	23,22	4,21	0,66	0,71	0,35
	Wiener Generalizado * ( $\alpha = 0,9$ , $w = 3 \times 3$ , viz = 8, $w_{\text{pré}} = 3 \times 3$ , MÉD, MAN)	0,00	23,93	4,92	0,67	0,72	0,00
(h)	Wiener Generalizado * ( $\alpha = 1$ , $w = 3 \times 3$ , viz = 8, $w_{\text{pré}} = 3 \times 3$ , MÉD, MAN)	0,00	23,78	4,77	0,68	0,72	0,00
	Wiener Generalizado * ( $\alpha = 0,6$ , $w = 3 \times 3$ , viz = 8, NLM, FINAL, bins = 256)	0,00	25,15	6,14	0,66	0,72	0,92
	Wiener Generalizado * ( $\alpha = 0,6$ , $w = 3 \times 3$ , viz = 8, $w_{\text{pré}} = 3 \times 3$ , MÉD, FINAL, bins = 256)	0,00	23,82	4,81	0,67	0,72	0,00
	Wiener Generalizado * ( $\alpha = 0,8$ , $w = 3 \times 3$ , viz = 8, $w_{\text{pré}} = 3 \times 3$ , MÉD, PRELIM, bins = 1)	0,00	23,72	4,71	0,67	0,71	0,01
(i)	Wiener Generalizado * ( $\alpha = 0,9$ , $w = 3 \times 3$ , viz = 8, NLM, FORM)	0,00	25,23	6,22	0,66	0,73	0,92
	Wiener Generalizado * ( $\alpha = 0,8$ , $w = 3 \times 3$ , viz = 8, $w_{\text{pré}} = 3 \times 3$ , MÉD, FORM)	0,01	22,95	3,94	0,68	0,72	0,01
(j)	ICM * (Modelo = Gaussiana+GMRF, iter = 1, MAN)	0,00	23,25	4,24	0,66	0,70	0,10
(k)	ICM * (Modelo = GMRF+GMRF, iter = 1, FINAL, bins = 256)	0,00	23,25	4,24	0,66	0,70	0,10
	ICM * (Modelo = GMRF+GMRF, iter = 1, PRELIM, bins = 5)	0,01	22,81	3,80	0,66	0,69	0,14
	ICM * (Modelo = GMRF+GMRF, iter = 1, FORM)	0,01	22,92	3,91	0,66	0,69	0,10
(l)	GSA * (Modelo = Gaussiana+GMRF, iter = 1, $\alpha = 0,7$ , MAN)	0,00	23,87	4,86	0,66	0,70	0,15
	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,8$ , FINAL, bins = 256)	0,00	23,65	4,64	0,65	0,68	0,14
	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,9$ , FINAL, bins = 9)	0,00	23,29	4,28	0,66	0,70	0,16
	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,8$ , PRELIM, bins = 256)	0,00	23,69	4,68	0,65	0,68	0,14
	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,8$ , PRELIM, bins = 5)	0,00	23,02	4,01	0,65	0,69	0,15
(m)	GSA * (Modelo = GMRF+GMRF, iter = 1, $\alpha = 0,9$ , FORM)	0,00	23,93	4,92	0,65	0,69	0,17
	MPM * (Modelo = Gaussiana+GMRF, MAN)	0,01	22,04	3,03	0,57	0,59	118,94
(n)	MPM * (Modelo = GMRF+GMRF, FINAL, bins=256)	0,01	22,65	3,64	0,58	0,61	119,23
	MPM * (Modelo = GMRF+GMRF, PRELIM, bins=256)	0,01	21,46	2,45	0,50	0,53	116,98
	MPM * (Modelo = GMRF+GMRF, FORM)	0,01	20,70	1,69	0,54	0,57	108,20



**Figura 7.27.** Resultados de Filtragem para a Imagem de Madeira 2 reconstruído por FBP. As imagens exibidas estão na ordem da Tabela 7.17.



**Figura 7.28.** Mapas do Ruído para Madeira 2 reconstruído por FBP do método Preliminar (limiar = 0,8 e número de bins: (a)  $K = 1$ , (b)  $K = 5$  e (c)  $K = 256$ ) e do Final (limiar = 0,22 e número de bins: (d)  $K = 1$ , (e)  $K = 9$  e (f)  $K = 256$ ).

Já em termos de SSIM, o melhor resultado foi obtido pelo Non Local Means, sendo ligeiramente superior ao melhor resultado de métodos contextuais, que foi obtido pelo mesmo método do parágrafo anterior. Além disso, empatado com o Non Local Means em termos de UIQ, temos o resultado obtido pelo Wiener Generalizado \* ( $\alpha = 0,8$ ,  $w = 3 \times 3$ ,  $viz = 8$ ,  $w_{pré} = 3 \times 3$ , MÉD, FORM).

Por sua vez, os algoritmos iterativos apresentaram resultados semelhantes entre si, porém levemente inferiores aos dos métodos baseados em Wiener. Acredita-se que para o MPM, um número maior de iterações também seja necessário.

Visualmente, temos que os melhores resultados foram obtidos por pelo Non Local Means e pelo Wiener Generalizado \* ( $\alpha = 0,9$ ,  $w = 3 \times 3$ ,  $viz = 8$ , NLM, FORM) que estão representados nos itens (a) e (i) da Figura 7.27, respectivamente.

Finalmente, em geral, temos que os melhores resultados para esta imagem utilizaram técnica de melhora de contraste e a pré-estimativa da imagem livre de ruído foi dada pelo Non Local Means, apesar da maioria dos resultados selecionados utilizarem a estimação pelo filtro da Média. Além disso, nota-se que o método Formal junto aos métodos baseados em Wiener teve um desempenho mais robusto.

### 7.6.2 POCS

Nesta Seção, temos os resultados da aplicação dos métodos sobre a imagem de Madeira 2 reconstruída por POCS. Os melhores resultados para cada método são exibidos na Tabela 7.18 e suas respectivas imagens filtradas na Figura 7.29. Ainda na Figura 7.30 temos os mapas de borda obtidos para  $K = 256$  e  $K = 1$ , e os números de bins considerados os mais adequados para esta imagem,  $K = 3$  e  $K = 18$ , para os métodos Preliminar e Final, respectivamente.

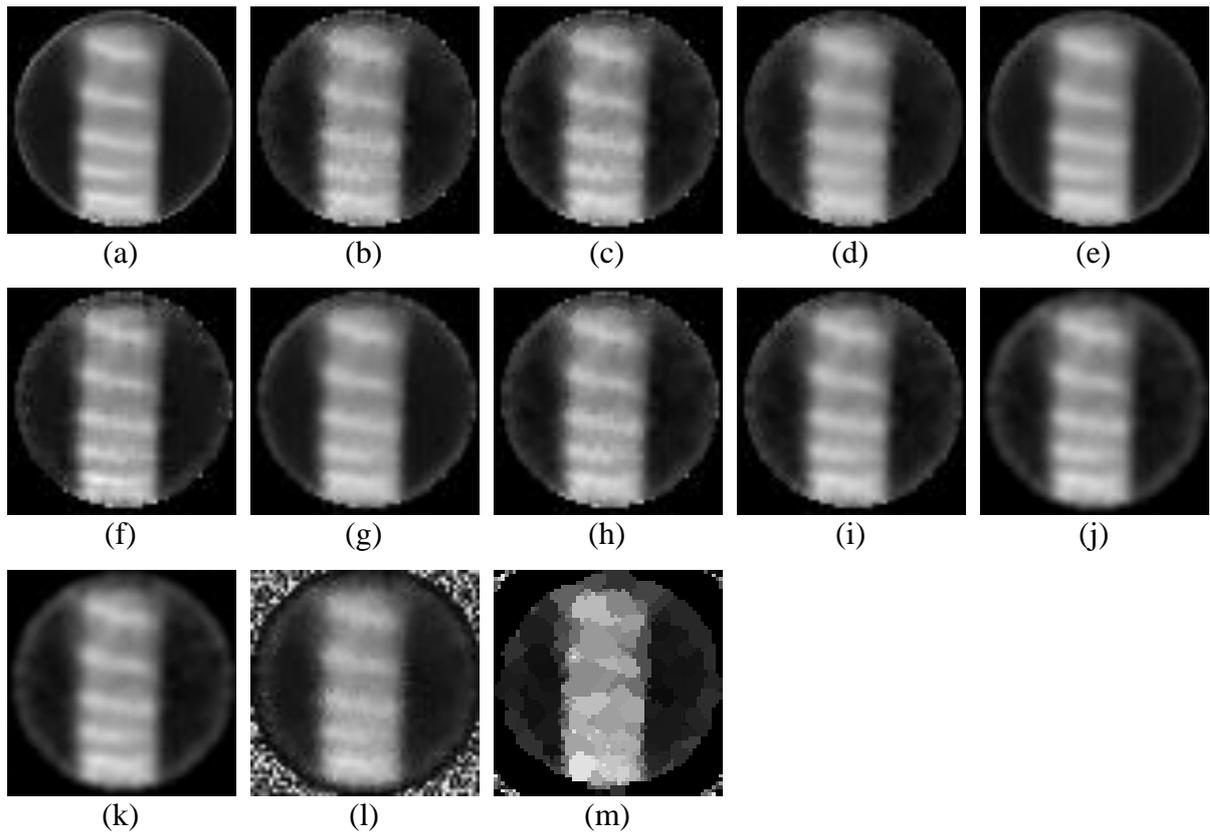
Para esta imagem, temos que o melhor resultado em termos de PSNR foi obtido pelo Wiener com MRF Isotrópico ( $w = 3 \times 3$ , NLM, FORM), que foi aproximadamente 1,67 dB, 0,5 dB e 0,14 dB superior à imagem ruidosa, ao Non Local Means e ao melhor resultado para o Wiener Pontual, respectivamente. Em termos de SSIM, Este método também atinge o máximo valor para o SSIM, o melhor resultado contextual foi obtido por Wiener com MRF Separável ( $w = 9 \times 9$ , NLM, FINAL, bins = 256), igualando a algumas configurações do Wiener

Pontual e sendo ligeiramente superior ao Non Local Means. Além disso, ele é o melhor método contextual também em termos de UIQ, sendo superior ao Non Local Means também neste critério, mas inferior ao Wiener Pontual.

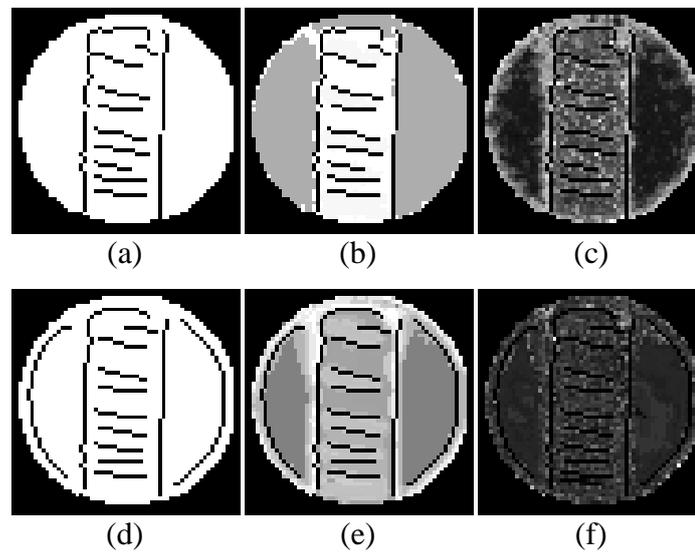
**Tabela 7.18.** Melhores resultados para a Madeira 2 reconstruído por POCS, onde \* representa o uso de técnica de realce de contraste.

Ord.	Métodos de Filtragem	MSE	PSNR	ISNR	UIQ	SSIM	Tempo (s)
(a)	Non Local Means	0,01	22,83	1,17	0,67	0,71	0,90
	Wiener Pontual (w = 3x3, w_pré = 3x3, MÉD, MAN)	0,01	22,91	1,25	0,68	0,71	<b>0,00</b>
	Wiener Pontual (w = 3x3, NLM, MÉD, FINAL, bins=1)	0,01	22,80	1,14	0,69	0,70	0,90
	Wiener Pontual (w = 3x3, w_pré = 3x3, MÉD, FINAL, bins = 18)	0,01	22,61	0,95	0,70	0,71	<b>0,00</b>
(b)	Wiener Pontual (w = 5x5, w_pré = 3x3, MÉD, PRE-LIM, bins = 256)	0,01	22,93	1,27	<b>0,71</b>	0,71	0,01
(c)	Wiener Pontual (w = 3x3, w_pré = 3x3, MÉD, PRE-LIM, bins = 256)	0,01	22,92	1,25	<b>0,71</b>	<b>0,72</b>	0,01
(d)	Wiener Pontual (w = 3x3, w_pre = 5x5, MÉD, FORM)	<b>0,00</b>	23,04	1,38	0,66	0,69	<b>0,00</b>
	Wiener Pontual (w = 3x3, w_pre = 3x3, MÉD, FORM)	0,01	22,91	1,25	0,68	<b>0,72</b>	<b>0,00</b>
	Wiener com MRF Isotrópico (w = 3x3, NLM, MAN)	0,01	22,98	1,32	0,66	0,70	1,25
	Wiener com MRF Isotrópico (w = 9x9, NLM, FINAL, bins = 256)	<b>0,00</b>	23,11	1,45	0,67	0,71	2,01
	Wiener com MRF Isotrópico (w = 3x3, NLM, PRE-LIM, bins = 256)	0,01	22,96	1,29	0,67	0,71	1,20
(e)	Wiener com MRF Isotrópico (w = 3x3, NLM, FORM)	<b>0,00</b>	<b>23,33</b>	<b>1,67</b>	0,67	0,71	1,25
	Wiener com MRF Separável (w = 3x3, NLM, MAN)	0,01	22,97	1,31	0,66	0,70	1,25
(f)	Wiener com MRF Separável (w = 9x9, NLM, FINAL, bins = 256)	<b>0,00</b>	23,29	1,63	0,68	<b>0,72</b>	2,03
	Wiener com MRF Separável (w = 9x9, NLM, PRE-LIM, bins = 256)	<b>0,00</b>	23,05	1,39	0,65	0,69	1,98
	Wiener com MRF Separável (w = 3x3, NLM, PRE-LIM, bins = 256)	0,01	22,96	1,30	0,67	0,71	1,20
	Wiener com MRF Separável (w = 3x3, NLM, FORM)	<b>0,00</b>	23,15	1,49	0,66	0,70	1,24
	Wiener Generalizado ( $\alpha = 0,7$ , w = 3x3, viz = 8, NLM, MAN)	<b>0,00</b>	23,09	1,43	0,67	0,71	0,90
	Wiener Generalizado ( $\alpha = 1$ , w = 3x3, viz = 8, w_pré = 3x3, MÉD, MAN)	0,01	22,91	1,25	0,68	0,71	<b>0,00</b>
	Wiener Generalizado ( $\alpha = 0,8$ , w = 3x3, viz = 8, NLM, FINAL, bins = 1)	<b>0,00</b>	23,13	1,47	0,67	0,71	0,90
	Wiener Generalizado ( $\alpha = 0,8$ , w = 3x3, viz = 8, w_pré = 3x3, MÉD, FINAL, bins = 256)	<b>0,00</b>	23,05	1,38	0,68	<b>0,72</b>	0,01
	Wiener Generalizado ( $\alpha = 1$ , w = 3x3, viz = 4, w_pré =	0,01	22,77	1,10	<b>0,71</b>	0,71	<b>0,00</b>

	<b>3x3, MÉD, FINAL, bins = 18)</b>						
(g)	<b>Wiener Generalizado (<math>\alpha = 0,8</math>, <math>w = 3x3</math>, <math>viz = 8</math>, NLM, PRELIM, bins = 256)</b>	<b>0,00</b>	23,25	1,59	0,68	<b>0,72</b>	0,90
(h)	<b>Wiener Generalizado (<math>\alpha = 1</math>, <math>w = 3x3</math>, <math>viz = 8</math>, <math>w_{pré} = 3x3</math>, MÉD, PRELIM, bins = 256)</b>	0,01	22,92	1,25	<b>0,71</b>	<b>0,72</b>	0,01
(i)	<b>Wiener Generalizado (<math>\alpha = 1</math>, <math>w = 3x3</math>, <math>viz = 4</math>, <math>w_{pré} = 3x3</math>, MÉD, FORM)</b>	<b>0,00</b>	23,19	1,53	0,69	<b>0,72</b>	<b>0,00</b>
(j)	<b>ICM (Modelo = Gaussiana+GMRF, iter = 1, MAN)</b>	0,01	22,61	0,95	0,66	0,68	0,12
	<b>ICM (Modelo = GMRF+GMRF, iter = 1, FINAL, bins = 256)</b>	0,01	22,44	0,78	0,64	0,68	0,13
	<b>ICM (Modelo = GMRF+Potts, iter = 1, FINAL, bins = 18)</b>	0,01	22,31	0,65	0,65	0,65	1,14
	<b>ICM (Modelo = GMRF+Potts, iter = 1, FINAL, bins = 256)</b>	0,01	22,31	0,65	0,65	0,65	1,09
	<b>ICM (Modelo = GMRF+GMRF, iter = 1, PRELIM, bins = 256)</b>	0,01	22,44	0,77	0,64	0,67	0,10
	<b>ICM (Modelo = GMRF+Potts, iter = 1, PRELIM, bins = 3)</b>	0,01	22,32	0,66	0,65	0,65	1,07
	<b>ICM (Modelo = GMRF+Potts, iter = 1, PRELIM, bins = 256)</b>	0,01	22,32	0,66	0,65	0,65	1,06
	<b>ICM (Modelo = GMRF+GMRF, iter = 1, FORM)</b>	0,01	22,41	0,75	0,64	0,67	0,10
	<b>ICM (Modelo = GMRF+Potts, iter = 1, FORM)</b>	0,01	22,32	0,66	0,65	0,65	1,03
(k)	<b>GSA (Modelo = Gaussiana+GMRF, iter = 1, <math>\alpha = 0,9</math>, MAN)</b>	0,01	22,61	0,95	0,66	0,68	0,13
	<b>GSA (Modelo = GMRF+GMRF, iter = 1, <math>\alpha = 0,9</math>, FINAL, bins = 256)</b>	0,01	22,41	0,75	0,64	0,67	0,14
	<b>GSA (Modelo = GMRF+Potts, iter = 1, <math>\alpha = 0,7</math>, FINAL, bins = 256)</b>	0,01	22,30	0,64	0,65	0,66	1,13
	<b>GSA (Modelo = GMRF+GMRF, iter = 1, <math>\alpha = 0,8</math>, PRELIM, bins = 256)</b>	0,01	22,42	0,75	0,64	0,67	0,15
	<b>GSA (Modelo = GMRF+Potts, iter = 1, <math>\alpha = 0,9</math>, PRELIM, bins = 256)</b>	0,01	22,33	0,67	0,65	0,66	1,09
	<b>GSA (Modelo = GMRF+GMRF, iter = 1, <math>\alpha = 0,9</math>, FORM)</b>	0,01	22,39	0,73	0,64	0,67	0,15
	<b>GSA (Modelo = GMRF+Potts, iter = 1, <math>\alpha = 0,7</math>, FORM)</b>	0,01	22,34	0,68	0,65	0,66	1,13
	<b>MPM (Modelo = GMRF+GIMLL-L1, MAN)</b>	0,06	11,88	-9,78	0,45	0,50	508,84
	<b>MPM (Modelo = GMRF+GMRF, MAN)</b>	0,07	11,53	-10,14	0,47	0,53	112,43
	<b>MPM (Modelo = Gaussiana+GIMLL, FINAL, bins=18)</b>	0,05	13,37	-8,30	0,47	0,51	358,69
(l)	<b>MPM (Modelo = GMRF+GMRF, FINAL, bins=256)</b>	0,05	13,09	-8,57	0,53	0,57	111,43
	<b>MPM (Modelo = Gaussiana+GIMLL, PRELIM, bins=3)</b>	0,05	13,27	-8,39	0,45	0,47	357,21
	<b>MPM (Modelo = GMRF+GMRF, PRELIM, bins=256)</b>	0,05	12,83	-8,83	0,46	0,50	100,85
(m)	<b>MPM (Modelo = GMRF+Potts, FORM)</b>	0,01	19,30	-2,36	0,54	0,56	50,77



**Figura 7.29.** Resultados de Filtragem para a Imagem da Madeira 2 reconstruído por POCS. As imagens exibidas estão na ordem da Tabela 7.18.



**Figura 7.30.** Mapas do Ruído para Madeira 2 reconstruído por POCS do método Preliminar (limiar = 0,27 e número de bins: (a)  $K = 1$ , (b)  $K = 3$  e (c)  $K = 256$ ) e do Final (limiar = 0,14 e número de bins: (d)  $K = 1$ , (e)  $K = 18$  e (f)  $K = 256$ ).

Com relação aos métodos iterativos, temos que os resultados são inferiores, especialmente o MPM, que novamente apresentou artefatos na região fora do suporte do objeto. Além disso, temos mais um exemplo de resultado utilizando modelo a priori Potts tendendo à segmentação da imagem. E também, nota-se um melhor desempenho para o MPM, quando utilizado o método Formal para a estimação do ruído, sendo notadamente superior aos outros.

Visualmente, exceto os resultados do MPM, podemos considerar que todos os resultados são satisfatórios.

Por fim, em geral, temos que os melhores resultados para esta imagem não utilizaram técnica de melhora de contraste. Além disso, a pré-estimação por Non Local Means foi a melhor em conjunto com o Wiener com MRF Separável e Isotrópico, enquanto o filtro da Média apresentou a maioria dos resultados para o Wiener Pontual e Generalizado. Quanto aos métodos de estimação de ruído, à exceção já apontada para o MPM, não foi possível identificar nenhum método predominante.

## ***7.7 Considerações Finais***

Neste Capítulo foram apresentados e comparados diversos resultados dos métodos de filtragem propostos aplicados a imagens reais, como também as suas discussões. No Apêndice D isto é feito para imagens simuladas, considerando experimentos de Monte Carlo. Os Apêndices E e F complementam este Capítulo, sendo naquele com o estudo da influência dos parâmetros de limiar e número de bins dos métodos de estimação do ruído Preliminar e Final e neste o estudo de convergência dos métodos iterativos. Por fim, no próximo Capítulo, serão apresentadas as conclusões compiladas baseadas nos resultados apresentados neste Capítulo e nos Apêndices C a F.

## 8 CONCLUSÕES, CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

Nesta tese foi desenvolvido um trabalho de filtragem contextual utilizando Campos Aleatórios Markovianos a fim de se considerar o contexto (contribuição dos vizinhos) e ruído Gaussiano, dependente do sinal e de média zero em imagens de CT reconstruídas por POCS ou Retroprojeção Filtrada (FBP). Ainda, comprovação da dependência do sinal foi apresentada nesta tese.

Para a estimação deste ruído, três novos métodos foram fornecidos: Preliminar e Final que são baseados em métodos existentes na literatura (Gravel, Beaudoin *et al.*, 2004; Salmeri, Mencattini *et al.*, 2008) e um método Formal. Experimentos usando estes métodos nas filtra-gens em imagens simuladas mostraram que o desempenho dos métodos propostos são equiva-lentes. Em geral, isto pode ser notado também nas imagens reais.

Entretanto, apesar de um desempenho inferior do MPM comparado aos demais méto-dos, o método Formal levou a uma convergência mais rápida deste método, potencializando os resultados de filtragem e o destacando entre os demais. Além disso, existe certa dificuldade na definição do parâmetro de número de bins para os métodos Preliminar e Final, sendo que para o primeiro este valor parece bastante instável e para o último parece fornecer um ajuste adequado se selecionados valores de número de bins próximo ao número de segmentos. Po-rém, para o caso de imagens mais complexas a definição deste parâmetro pode ser difícil de determinar mesmo para o método Final. Vale ressaltar que para os métodos Preliminar e Final o número de bins ( $K$ ) mais adequado foi comumente definido como maior do que 1, o que também reforça a existência de ruído dependente do sinal.

Com tudo isto, o método Formal consiste em um método interessante e que pode ser refinado (especialmente para solucionar um problema encontrado nas bordas de alguns resul-tados de filtragem). Vale observar que o uso de método de estimação de ruído dependente do sinal pode também incrementar o desempenho de filtragem.

Para a filtragem contextual foram consideradas duas abordagens: uma utilizando algo-ritmos iterativos de otimização combinatória como ICM, GSA e MPM e a outra utilizando

variações do filtro de Wiener, considerando Informação de Fisher (Generalizado), MRF Separável e MRF Isotrópico.

Para os métodos diretos ou baseados em Wiener, foram utilizados ainda dois métodos de estimação do sinal livre de ruído, filtro da Média e o Non Local Means, sendo o uso do último para este fim uma das principais contribuições deste trabalho. O uso do NLM melhorou sensivelmente o desempenho final da filtragem, sendo que apenas para as imagens Homogêneo e Mandril o desempenho não foi o superior. Entretanto, vale ressaltar que o desempenho do NLM não foi verificado com diferentes valores de parâmetros, o que poderia ou aumentar a suavização (aumentando o valor do parâmetro  $\alpha$  do NLM) e superar o resultado do filtro da Média no phantom Homogêneo ou preservar um pouco mais os detalhes (reduzindo o valor do parâmetro  $\alpha$  do NLM) e também superar o filtro da Média para imagem Mandril. Assim, o uso de NLM para a estimação de imagem livre de ruído é altamente indicado.

Além disso, os resultados para os métodos baseados em Wiener são superiores aos obtidos pelos métodos iterativos. Credita-se esta situação ao não uso do Non Local Means para obter a estimativa da imagem livre de ruído dos métodos iterativos, algo que é uma sugestão de trabalho futuro. Isto reforça ainda mais o uso de Non Local Means para este fim.

É importante ressaltar também que os métodos baseados em Wiener com o resultado de Non Local Means como um de seus parâmetros, é no mínimo equivalente ao desempenho do Non Local Means, com ou sem melhoria de contraste, sendo na maioria das vezes muito superior ao obtido pelo método em estado da arte Non Local Means, com muitas vezes um incremento mínimo em termos de custo computacional. Além disso, considerando os métodos baseados em Wiener, o uso do contexto também melhorou o resultado de filtragem, sendo superior ao caso Pontual na maioria das vezes. Os resultados mostraram que o contexto pode contribuir consideravelmente para a filtragem em CT e, assim, permitir a redução da dose de radiação e de custo.

Dentre os métodos contextuais baseados em Wiener, os resultados obtidos pelo Wiener Separável e Isotrópico podem ser destacados. Por sua vez, dentre os métodos iterativos, o destaque fica para o GSA e até mesmo para o MPM, que exceto para a área fora do objeto no caso de imagens reconstruídas por POCS (e que reduziu o seu desempenho quantitativo), o seu resultado visual foi bastante promissor. Entretanto, vale ressaltar que o uso do MPM é inviável devido ao seu alto custo computacional. Pela própria avaliação do resultado de MPM e dos outros métodos iterativos quando do uso dos métodos de estimação do ruído propostos,

especialmente o método Formal, foi também realizada uma modificação no ICM, GSA e MPM para considerarem ruído dependente do sinal e seus resultados são promissores.

Além disso, devido a uma tendência de segmentar a imagem apresentada pelos resultados que utilizavam modelos a priori Potts, GIMLL e GIMLL-L1 para o ICM, GSA e MPM conforme visto nos resultados, estes modelos mostraram-se inadequados para a filtragem de imagem. Assim, apesar de borramento nas bordas, apenas o uso de GMRF é indicado. Além do mais, vale ressaltar que foi testado o uso do GMRF também para a verossimilhança nos métodos iterativos, obtendo resultados satisfatórios. Isto pode ser uma indicação de que o ruído seria também colorido. Verificações e trabalhos futuros podem decorrer disto.

É importante salientar também que as imagens ruidosas reconstruídas por FBP, em geral, apresentam uma degradação do contraste e necessitam do uso de alguma técnica de realce de contraste. O mesmo não ocorre para as imagens reconstruídas por POCS.

Além disso, notou-se que o custo de reconstrução, especialmente para o POCS, é consideravelmente superior se comparado ao de filtragem (exceto para o MPM). É importante apontar que a Retroprojeção Filtrada apresenta um resultado com melhor definição das bordas, como é possível ser notado no *phantom* Assimétrico, apesar de mais ruidosa e com pior contraste. Assim, utilizar uma combinação de Retroprojeção Filtrada para a reconstrução, o uso de filtragem pós-reconstrução por métodos contextuais com definição de estimava da imagem livre de ruído dada por Non Local Means e estimação do ruído dada pelo método Formal e ainda, o uso de uma técnica de realce de contraste adequada formam uma ferramenta poderosa para a redução de ruído em imagem de CT. Note que mesmo utilizando todo este conjunto de métodos, o seu tempo total ainda será menor do que o tempo somente para a reconstrução por POCS.

Finalizando este trabalho, além das ideias já discutidas de trabalhos futuros como o uso de Non Local Means para se obter a estimativa da imagem livre de ruído para os métodos iterativos, de possíveis refinamentos do método Formal de estimação do ruído dependente do sinal e da verificação do ruído ser colorido (ruído correlacionado), outras sugestões são:

- 1) O uso do algoritmo BM3D (*Block Matching and 3-D Filtering*) (Dabov, Foi *et al.*, 2007) que também é um método de filtragem de ruído em estado da arte, para a comparação e utilização para se obter a estimativa da imagem livre de ruído;

- 2) A seleção ou desenvolvimento de um novo método adequado para a melhora de contraste nos resultados de filtragem da imagem reconstruída por FBP;
- 3) Análise da resolução espacial;
- 4) Verificar o uso de janelamento adaptativo nos métodos de Wiener a fim de que haja uma melhor preservação das bordas;
- 5) Aplicar em imagens médicas de CT e em Tomossíntese de Mama (Niklason, Christian *et al.*, 1997), onde nesta última as imagens são obtidas por definição com baixa dose e número limitado de projeções;
- 6) Comparar os resultados com os obtidos por filtragem pré-reconstrução;
- 7) Como o ICM e GSA correspondem a uma estimativa MAP, era esperado que aumentando o número de iterações, medidas de desempenho fossem incrementadas, porém isto, em geral, não aconteceu. Recomenda-se verificar isto em trabalhos futuros;
- 8) O desenvolvimento de um método de estimação do ruído dependente do sinal considerando uma dependência mais geral do que a linear, como por exemplo, a sua representação por um polinômio;
- 9) Desenvolvimento de uma versão iterativa do método Formal;
- 10) Verificar a aplicação destes métodos sobre o domínio esparso das Wavelets.

### 8.1 Artigos Publicados e Submetidos

Como resultado deste trabalho, até o presente momento teve-se uma publicação apresentada oralmente no SIBRAPI'2012, definida pela seguinte referência "SALVADEO, D. H. P.; MASCARENHAS, N. D. A.; LEVADA, A. L. M. Contextual Filtering of CT Images Using Markovian Wiener Filters With a Non Local Means Approach for Statistical Estimation. In: 25th Conference on Graphics, Patterns and Images (SIBGRAPI), 2012, Ouro Preto. Proceedings of the 25th Conference on Graphics, Patterns and Images (SIBGRAPI), 2012. p. 16-23."

Por fim, esta publicação foi selecionada pelo Comitê Científico do SIBGRAPI'2012 como um dos melhores trabalhos do evento e disto surgiu um convite para o envio de uma versão estendida para um periódico de renome internacional na área, Pattern Recognition Letters, cuja referência submetida e aguardando aprovação é "SALVADEO, D. H. P.; MASCA-

RENHAS, N. D. A.; LEVADA, A. L. M. Noise Modeling, Estimation and Contextual Denoising of CT Reconstructed Images”.

## REFERÊNCIAS

- BARRENO, P. G. Las tecnologías de la imagen en medicina. In: Real Academia de Ciencias Exactas, Físicas y Naturales (Ed.). **Horizontes culturales: las fronteras de la ciencia : 1998**. Madrid: Espasa Calpe, 1998. p.81-101.
- BERTERO, M.; BOCCACCI, P. **Introduction to inverse problems in imaging**. IoP, 1998.
- BERTHOD, M. et al. Bayesian image classification using Markov random fields. **Image and Vision Computing**, v. 14, p. 285-295, 1996.
- BESAG, J. Spatial Interaction and the Statistical Analysis of Lattice Systems. **Journal of the Royal Statistical Society. Series B (Methodological)**, v. 36, n. 2, p. 192-236, 1974.
- \_\_\_\_\_. Statistical Analysis of Non-Lattice Data. **Journal of the Royal Statistical Society. Series D (The Statistician)**, v. 24, n. 3, p. 179-195, 1975.
- \_\_\_\_\_. On The Statistical Analysis Of Dirty Pictures. **Journal of the Royal Statistical Society Series B (Methodological)**, v. 48, n. 3, p. 259-302, 1986.
- BITTENCOURT, M. et al. Iterative reconstruction in image space (IRIS) in cardiac computed tomography: initial experience. **International Journal of Cardiovascular Imaging**, v. 27, n. 7, p. 1081-1087, 2011.
- BORSODORF, A. et al. **Analytic noise propagation for anisotropic denoising of CT images**. 2008 IEEE Nuclear Science Symposium (NSS'08), 2008, Dresden. p.5335-5338.
- \_\_\_\_\_. **Local orientation-dependent noise propagation for anisotropic denoising of CT-images**. 2009 IEEE Nuclear Science Symposium and Medical Imaging Conference (NSS/MIC'09), 2009, Orlando. p.2472-2475.
- BOTEGA, L. C. **Análise de imagens tomográficas da Ciência do Solo em ambiente de realidade virtual**. 2008. 213 f. Dissertação (Mestrado em Ciência da Computação). Departamento de Computação, Universidade Federal de São Carlos, São Carlos.
- BRENT, R. P. **Algorithms for Minimization Without Derivatives**. New York: Prentice Hall, 1973.
- BREVE, F. A. **Classificação de imagens tomográficas de ciência dos solos utilizando redes neurais e combinação de classificadores**. 2006. 57 p. Dissertação (Mestrado em Ciência da Computação). Departamento de Computação, Universidade Federal de São Carlos, São Carlos.
- BRONNIKOV, A. V.; KILLIAN, D. **3D Tomography of Turbine Blades**. International Symposium on Computerized Tomography for Industrial Applications and Image Processing in Radiology, 1999, Berlin. DGZfP. p.173-179.
- BUADES, A.; COLL, B.; MOREL, J. M. A Review of Image Denoising Algorithms, with a New One. **Multiscale Modeling & Simulation**, v. 4, n. 2, p. 490-530, 2005.

BUSHBERG, J. et al. **The Essential Physics of Medical Imaging**. 2nd Edition. Lippincott Williams & Wilkins, 2001.

BUSHONG, S. **Computed Tomography**. McGraw-Hill Medical, 2000.

BUZUG, T. **Computed Tomography From Photon Statistics to Modern Cone-Beam CT**. Springer, 2008.

CANNY, J. A Computational Approach to Edge Detection. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 8, n. 6, p. 679-698, 1986.

CHEN, Y. et al. **Improving low-dose X-ray CT images by Weighted Intensity Averaging over Large-scale Neighborhoods**. 2010 3rd International Congress on Image and Signal Processing (CISP'10), 2010, Yantai. p.727-729.

\_\_\_\_\_. Improving low-dose abdominal CT images by Weighted Intensity Averaging over Large-scale Neighborhoods. **European Journal of Radiology**, v. 80, n. 2, p. E42-E49, 2011.

\_\_\_\_\_. Thoracic low-dose CT image processing using an artifact suppressed large-scale nonlocal means. **Physics in Medicine and Biology**, v. 57, n. 9, 2012.

CIERNIAK, R. **X-Ray Computed Tomography in Biomedical Engineering**. Springer, 2011.

CNPDIA-EMBRAPA. Centro Nacional de Pesquisa e Desenvolvimento de Instrumentação Agropecuária (CNPDIA) da Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA). 2011. Disponível em: <<http://www.cnpdia.embrapa.br/>>. Acesso em: 07 de Julho de 2011.

COMBETTES, P. L. The Foundations of Set Theoretic Estimation. **Proceedings of the IEEE**, v. 81, n. 2, p. 182-208, 1993.

COMBETTES, P. L.; PUH, H. **Parallel projection methods for set theoretic signal reconstruction and restoration**. 1993 IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP'93), 1993, Minneapolis. p.297-300.

CORMACK, A. M. Representation of a Function by Its Line Integrals, With Some Radiological Applications. **Journal of Applied Physics**, v. 34, n. 9, p. 2722-2727, 1963.

CRUVINEL, P. E. **Minitomografo de raio-X e raio-gama computadorizado para aplicações multidisciplinares**. 1987. 349f. Tese (Doutorado). Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas.

DABOV, K. et al. Image denoising by sparse 3-D transform-domain collaborative filtering. **Ieee Transactions on Image Processing**, v. 16, n. 8, p. 2080-2095, 2007.

DE CEZARO, A.; DE CEZARO, F. T. **Problemas Inversos e a Matemática da Tomografia Computadorizada**. V Bienal da Sociedade Brasileira de Matemática (SBM), 2010, João Pessoa. Editora da UFPB.

DELEDALLE, C. A. **Image denoising beyond additive Gaussian noise: patch-based estimators and their application to SAR imagery**. 2011. (PhD). TSI, Télécom ParisTech

DIMOV, I. T. **Monte Carlo Methods for Applied Scientists**. World Scientific, 2008.

DUBES, R. C.; JAIN, A. K. Random field models in image analysis. **Journal of Applied Statistics**, v. 20, n. 5-6, p. 121-154, 1993.

EPSTEIN, C. L. **Introduction to the mathematics of medical imaging**. 2nd Edition. SIAM, 2008.

ERENO, D. **Texturas e Sabores: Da língua eletrônica ao analisador de pó de café, novos equipamentos são licenciados pela Embrapa**. Revista Pesquisa FAPESP: 62-67 p. 2006.

ESCALANTE-RAMIREZ, B.; MARTENS, J.-B. Noise reduction in computerized tomography images by means of polynomial transforms. **Journal of Visual Communication and Image Representation**, v. 3, n. 3, p. 272-285, 1992.

FANG, Y. et al. **De-noising based on wavelet analysis and bayesian estimation for low-dose X-ray CT**. 9th International Conference on Electronic Measurement & Instruments (ICEMI'09), 2009, Beijing. p.2-944-2-947.

FERNANDES, H. C. et al. **Avaliação da Influência de Implementos de Plantio Direto do Milho com Tomografia de Raios Gama**. Boletim de Pesquisa e Desenvolvimento. São Carlos: EMBRAPA - CNPDIA: 21 p. 2005.

FERREIRA, V. C. **Restauração de Imagens Tomográficas de Ciência dos Solos por Métodos Iterativos**. 2000. 90 Dissertação (Mestrado em Ciência da Computação). Departamento de Computação, Universidade Federal de São Carlos, São Carlos.

FESSLER, J. A. Statistical image reconstruction methods for transmission tomography. In: SONKA, M.; SONKA, M., *et al* (Ed.). **Handbook of Medical Imaging: Medical Image Processing and Analysis**. Bellingham: SPIE, v.2, 2000. cap. 1, p.1-70.

FOI, A. Clipped noisy images: Heteroskedastic modeling and practical denoising. **Signal Processing**, v. 89, n. 12, p. 2609-2629, 2009.

FOSBINDER, R. A.; ORTH, D. **Essentials of Radiologic Science**. Wolters Kluwer Health/Lippincott Williams & Wilkins, 2011.

GEMAN, S.; GEMAN, D. Stochastic Relaxation, Gibbs Distributions, and The Bayesian Restoration of Images. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 6, n. 6, p. 721-741, 1984.

GERALDO, R. J. **Filtragem MAP 2-D de Imagens CT Ruidosas**. 2011. 140 f. Dissertação (Mestrado em Ciência da Computação). Departamento de Computação, Universidade Federal de São Carlos, São Carlos.

GERALDO, R. J.; MASCARENHAS, N. D. D. Á. **Noise Reduction Filters Based on Pointwise Map for CT Images**. IEEE International Symposium on Circuits and Systems (ISCAS'2011). Rio de Janeiro 2011.

GIRALDO, J. C. R. et al. **Comparative study of two image space noise reduction methods for computed tomography: Bilateral filter and nonlocal means**. 31st Annual International Conference of the IEEE Engineering in Medicine and Biology Society 2009 (EMBC'2009), 2009. p.3529-3532.

GNU Image Manipulation Program: User Manual. 2012. Disponível em: < <http://docs.gimp.org/2.8/en/> >. Acesso em: 05/02/2013.

GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. 2nd Edition. Prentice Hall, 2002.

GRANATO, L. F. **Algoritmo Adaptativo para a Melhoria em Imagens Tomográficas obtidas em Múltiplas Energias**. 1998. 135 Dissertação (Mestrado em Ciência da Computação). Departamento de Computação, Universidade Federal de São Carlos, São Carlos.

GRAVEL, P.; BEAUDOIN, G.; DE GUISE, J. A. A method for modeling noise in medical images. **IEEE Transactions on Medical Imaging**, v. 23, n. 10, p. 1221-1232, 2004.

GUERRA, A. D. C. **Restauração de Imagens de Minitomógrafo de Análise de Solos por Técnicas de Regularização**. 1998. 80 Dissertação (Mestrado em Ciência da Computação). Departamento de Computação, Universidade Federal de São Carlos, São Carlos.

HALL, E. J. Scientific View of Low-Level Radiation Risks. **Radiographics**, v. 11, n. 3, p. 509-518, 1991.

HAMMERSLEY, J. M.; CLIFFORD, P. **Random Fields on Finite Graphs and Lattices**. Não Publicado. 1971.

HAMMERSLEY, J. M.; HANDSCOMB, D. C. **Monte Carlo Methods**. Methuen, 1964.

HANSON, K. M. Noise and contrast discrimination in Computed Tomography. In: NEWTON, T. H. e POTTS, D. G. (Ed.). **Radiology of the Skull and Brain**. St. Louis: C. V. Mosby, v. Vol. 5: Technical Aspects of Computed Tomography, 1981.

HARA, A. et al. Iterative Reconstruction Technique for Reducing Body Radiation Dose at CT: Feasibility Study. **American Journal of Roentgenology**, v. 193, n. 3, p. 764-771, 2009.

HENDERSON, H. **A sideways look at scanners**. New Scientist. 84: 782-785 p. 1979.

HOFMANN, J.; FLISCH, A.; OBRIST, A. Adaptive CT scanning - mesh based optimisation methods for industrial X-ray computed tomography applications. **NDT & E International**, v. 37, n. 4, p. 271-278, 2004.

HOMEM, M. R. P. **Técnicas de Reconhecimento de Padrões Aplicadas a Imagens Tomográficas Adquiridas com Múltiplas Energias**. 1998. 200 p. Dissertação (Mestre em

Ciência da Computação). Departamento de Computação, Universidade Federal de São Carlos, São Carlos.

HONGBING, L. et al. **Noise properties of low-dose CT projections and noise treatment by scale transformations.** 2001 IEEE Nuclear Science Symposium Conference Record, 2001. p.1662-1666.

HU, S.; LIAO, Z.; CHEN, W. Reducing Noises and Artifacts Simultaneously of Low-Dosed X-Ray Computed Tomography Using Bilateral Filter Weighted by Gaussian Filtered Sinogram. **Mathematical Problems in Engineering**, 2012a.

\_\_\_\_\_. Sinogram Restoration for Low-Dosed X-Ray Computed Tomography Using Fractional-Order Perona-Malik Diffusion. **Mathematical Problems in Engineering**, 2012b.

HU, X. et al. Radiation dose of non-enhanced chest CT can be reduced 40% by using iterative reconstruction in image space. **Clinical Radiology**, v. 66, n. 11, p. 1023-1029, 2011.

HUR, S. et al. 80-kVp CT Using Iterative Reconstruction in Image Space Algorithm for the Detection of Hypervascular Hepatocellular Carcinoma: Phantom and Initial Clinical Experience. **Korean Journal of Radiology**, v. 13, n. 2, p. 152-164, 2012.

ICRP. Recommendations of the International Commission on Radiological Protection. ICRP Publication 26. **Annals of the ICRP**, v. 1, n. 3, p. 1-53, 1977.

JIAO, C. et al. **Multiscale noise reduction on low-dose CT sinogram by stationary wavelet transform.** IEEE Nuclear Science Symposium Conference Record 2008 (NSS'2008), 2008, 19-25 Oct. 2008. p.5339-5344.

KAK, A. C.; SLANEY, M. **Principles of computerized tomographic imaging.** IEEE Press, 1988.

KALENDER, W. X-ray computed tomography. **Physics in Medicine and Biology**, v. 51, n. 13, p. R29-R43, 2006.

KAY, S. **Fundamentals of Statistical Signal Processing, Volume I: Estimation Theory.** Prentice Hall, 1993.

KE, L.; ZHANG, R. **Multiscale Wiener filtering method for low-dose CT images.** 2010 3rd International Conference on Biomedical Engineering and Informatics (BMEI'2010), 2010. p.428-431.

KESELBRENER, L.; SHIMONI, Y.; AKSELROD, S. Nonlinear Filters Applied On Computerized Axial Tomography: Theory and Phantom Images. **Medical Physics**, v. 19, n. 4, p. 1057-1064, 1992.

KUAN, D. T. et al. Adaptive Noise Smoothing Filter for Images With Signal-Dependent Noise. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 7, n. 2, p. 165-177, 1985.

KUMAR, S. R. **Step by Step® Oral Radiology**. New Delhi: Jaypee Brothers Publishers, 2011.

LA RIVIERE, P. J. Penalized-likelihood sinogram smoothing for low-dose CT. **Medical Physics**, v. 32, n. 6, p. 1676-1683, 2005.

LA RIVIERE, P. J.; BILLMIRE, D. M. Reduction of noise-induced streak artifacts in X-ray computed tomography through spline-based penalized-likelihood sinogram smoothing. **IEEE Transactions on Medical Imaging**, v. 24, n. 1, p. 105-111, 2005.

LAIA, M. et al. **A Novel Model for Combining Projection and Image Filtering Using Kalman and Discrete Wavelet Transform in Computerized Tomography**. 11th IEEE International Conference on Computational Science and Engineering (CSE'08), 2008. p.219-226.

LAIA, M. A. D. M. **Filtragem de projeções tomográficas da ciência do solo utilizando Kalman e redes neurais**. 2007. 131 f. Dissertação (Mestrado em Ciência da Computação). Departamento de Computação, Universidade Federal de São Carlos, São Carlos.

LEVADA, A. L. M. **Combinação de modelos de campos aleatórios markovianos para classificação contextual de imagens multiespectrais**. 2010. 146 p. Tese (Doutorado). Instituto de Física de São Carlos, Universidade de São Paulo, São Carlos.

LEVADA, A. L. M.; MASCARENHAS, N. D. A. **Filtragem adaptativa de ruído gaussiano em imagens através da minimização da informação de Fisher observada**. VI Workshop de Visão Computacional (WVC'2010), 2010, Presidente Prudente. p.7-12.

LI, S. Z. **Markov Random Field Modeling in Image Analysis**. 3rd Edition. Springer, 2009.

LI, T. et al. Nonlinear sinogram smoothing for low-dose X-ray CT. **IEEE Transactions on Nuclear Science**, v. 51, n. 5, p. 2505-2513, 2004.

LI, Z. et al. Adaptive non-local means filtering based on local noise level for CT denoising. **Medical Imaging 2012: Physics of Medical Imaging**, v. 8313, 2012.

LJUNGBERG, M.; STRAND, S. E.; KING, M. A. **Monte Carlo Calculations in Nuclear Medicine: Applications in Diagnostic Imaging**. Inst. of Physics Publ., 1998.

LOGAN, B. F.; SHEPP, L. A. Optimal Reconstruction of A Function From Its Projections. **Duke Mathematical Journal**, v. 42, n. 4, p. 645-659, 1975.

MA, J. et al. Image Fusion for Low-Dose Computed Tomography Reconstruction. **2011 Ieee Nuclear Science Symposium and Medical Imaging Conference (Nss/mic)**, p. 4239-4243, 2011.

MACEDO, Á. **Construção e uso de um tomógrafo com resolução micrométrica para aplicações em Ciências do Solo e do Ambiente**. 1997. 129f. Tese (Doutorado em Ciência da Engenharia Ambiental). EESC, Universidade de São Paulo, São Carlos.

MARROQUIN, J.; MITTER, S.; POGGIO, T. Probabilistic Solution of Ill-Posed Problems in Computational Vision. **Journal of the American Statistical Association**, v. 82, n. 397, p. 76-89, 1987.

MARTINS, A. L. D. et al. **MAP-MRF Super-Resolution Image Reconstruction using Maximum Pseudo-Likelihood parameter estimation**. 2009 16th IEEE International Conference on Image Processing (ICIP'2009), 2009. p.1165-1168.

MASCARENHAS, N.; BANON, G.; CANDEIAS, A. Multispectral image data fusion under a Bayesian approach. **International Journal of Remote Sensing**, v. 17, n. 8, p. 1457-1471, 1996.

MASCARENHAS, N. D. A.; FRERY, A. C. **SAR image filtering with the ICM algorithm**. Geoscience and Remote Sensing Symposium, 1994. IGARSS '94. Surface and Atmospheric Remote Sensing: Technologies, Data Analysis and Interpretation., International, 1994, 8-12 Aug 1994. p.2185-2187 vol.4.

MASCARENHAS, N. D. A.; SANTOS, C. A. N.; CRUVINEL, P. E. Transmission tomography under Poisson noise using the Anscombe transformation and Wiener filtering of the projections. **Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment**, v. 423, n. 2-3, p. 265-271, 1999.

MASCARENHAS, N. D. A.; SANTOS, S. S. L.; CRUVINEL, P. E. **The Use of MAP Estimation Techniques in the Tomographic Reconstruction of Poisson Noise Corrupted Images**. IX Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens (SIBGRAPI'96), 1996, Caxambu. SBC/UFMG. p.197-204.

MENCATTINI, A. et al. **Noise estimation in mammographic images for adaptive denoising**. X EFOMP European Conference on Medical Physics (EFOMP'07), 2007, Castelvecchio Pascoli, Italy.

MICHEL-GONZALEZ, E.; CHO, M.; LEE, S. Geometric nonlinear diffusion filter and its application to X-ray imaging. **Biomedical Engineering Online**, v. 10, 2011.

MINATEL, E. R. **Desenvolvimento de Algoritmo para Reconstrução e Visualização Tridimensional de Imagens Tomográficas com uso de Técnicas Freqüenciais e Wavelets**. 1997. 147f. Dissertação (Mestrado em Ciência da Computação). Departamento de Computação, Universidade Federal de São Carlos, São Carlos.

MOSCHETTI, E. et al. On the use of Lee's protocol for speckle-reducing techniques. **Latin American applied research**, v. 36, p. 115-121, 2006.

MUGHAL, M. N.; IKRAM, W. **Early lung cancer detection by classifying chest CT images: a survey**. 8th IEEE International Multitopic Conference (INMIC'2004), 2004. p.67-72.

NAIME, J. D. M. **Projeto e construção de um tomógrafo portátil para estudos de ciência do solo e plantas, em campo**. 1994. 87f Dissertação (Mestrado em Engenharia Elétrica). EESC, Universidade de São Paulo, São Carlos.

\_\_\_\_\_. **Um novo método para estudos dinâmicos, in situ, da infiltração da água na região não-saturada do solo.** 2001. 146p. Tese (Doutorado em Ciência da Engenharia Ambiental). EESC, Universidade de São Paulo, São Carlos.

NASH, J. F. Equilibrium Points in N-Person Games. **Proceedings of the National Academy of Sciences of the United States of America**, v. 36, n. 1, p. 48-49, 1950.

NIKLASON, L. et al. Digital Tomosynthesis in breast imaging. **Radiology**, v. 205, n. 2, p. 399-406, 1997.

PAPOULIS, A. **Probability, random variables, and stochastic processes.** 3rd Ed. McGraw-Hill, 1991.

PEDROTTI, A. et al. Tomografia computadorizada aplicada a estudos de um Planossolo. **Pesquisa Agropecuária Brasileira**, v. 38, p. 819-826, 2003.

PEREIRA, M. F. L. **Algoritmo Paralelo para Reconstrução Tridimensional de Imagens Tomográficas de Amostras Agrícolas em Arquitetura DSP com Técnicas Wavelets.** 2001. 178 Dissertação (Mestrado em Ciência da Computação). Departamento de Computação, Universidade Federal de São Carlos, São Carlos.

\_\_\_\_\_. **Um modelo de reconstrução tomográfica 3D para amostras agrícolas com filtragem de Wiener em processamento paralelo.** 2007. 148 p. (Doutorado). Instituto de Física de São Carlos, Universidade de São Paulo, São Carlos.

PONTI JR, M. P. **Combinação de Múltiplos Classificadores para Identificação de Materiais em Imagens Ruidosas.** 2004. 67 p. Dissertação (Mestrado em Ciência da Computação). Departamento de Computação, Universidade Federal de São Carlos, São Carlos.

RABBANI, H. **Abdominal CT image denoising based on a Laplace distribution with local variance in steerable pyramid domain.** 5th International Conference on Information Technology and Applications in Biomedicine (ITAB'2008), 2008. p.140-143.

RADON, J. Über die Bestimmung von Funktionen durch ihre Integralwerte längs gewisser Mannigfaltigkeiten. **Berichte über die Verhandlungen der Königlich-Sächsischen Akademie der Wissenschaften zu Leipzig**, v. 69, p. 262-277, 1917.

\_\_\_\_\_. On the Determination of Functions from Their Integral Values along Certain Manifolds. **IEEE Transactions on Medical Imaging**, v. 5, n. 4, p. 170-176, 1986.

RAMACHANDRAN, G. N.; LAKSHMINARAYANAN, A. V. Three-Dimensional Reconstruction From Radiographs and Electron Micrographs: Application of Convolutions Instead of Fourier Transforms. **Proceedings of the National Academy of Sciences of the United States of America**, v. 68, n. 9, p. 2236-2240, 1971.

RANGAYYAN, R. M. **Biomedical Image Analysis.** CRC Press, 2005.

RIBEIRO, E. D. S. **Novas propostas em filtragem de projeções tomográficas sob ruído Poisson**. 2010. 149 f. Dissertação (Mestrado em Ciência da Computação). Departamento de Computação, Universidade Federal de São Carlos, São Carlos.

RIBEIRO, G. C. **Desenvolvimento de um Algoritmo para a Reconstrução Tridimensional de Imagens de um Minitomógrafo Baseado no Método de Reconstrução Algébrica Modificado e Interpolação Spline**. 1994. Dissertação (Mestrado em Ciência da Computação). Departamento de Computação, Universidade Federal de São Carlos, São Carlos.

SALINA, F. V. **Reconstrução Tomográfica de Imagens Utilizando Técnicas POCS Sequenciais e Paralelas**. 2001. 111 p. Dissertação (Mestrado em Ciência da Computação). Departamento de Computação, Universidade Federal de São Carlos, São Carlos.

\_\_\_\_\_. **Métodos híbridos para reconstrução tomográfica de imagens usando POCS e teoria da estimação**. 2007. 135 p. Tese (Doutorado). Instituto de Física de São Carlos, Universidade de São Paulo, São Carlos.

SALMERI, M. et al. **Signal-dependent Noise Characterization for Mammographic Images Denoising**. IMEKO TC4 Symposium (IMEKOTC4'08), 2008, Firenze, Italy.

SANTOS, S. S. L. **Reconstrução Tomográfica de Imagens com Ruído Poisson por Estimadores MAP das Projeções utilizando densidades "A Priori" definidas na Semi-reta não negativa**. 1996. 142 Dissertação (Mestrado em Ciência da Computação). Departamento de Computação, Universidade Federal de São Carlos, São Carlos.

SAUER, K.; LIU, B. Nonstationary filtering of transmission tomograms in high photon counting noise. **IEEE Transactions on Medical Imaging**, v. 10, n. 3, p. 445-52, 1991.

SAVAGE, N. Medical imagers lower the dose. **IEEE Spectrum**, v. 47, n. 3, p. 14-16, 2010.

SCHNEBERK, D.; SHASHISHEKHAR, N. High-speed CT imaging for today's industry. **Insight**, v. 50, n. 1, p. 19-21, 2008.

SEZAN, M. I.; STARK, H. Image Restoration by the Method of Convex Projections: Part 2 - Applications and Numerical Results. **IEEE Transactions on Medical Imaging**, v. 1, n. 2, p. 95-101, 1982.

SHEPP, L. A.; LOGAN, B. F. The Fourier Reconstruction of a Head Section. **IEEE Transactions on Nuclear Science**, v. 21, p. 21-43, 1974.

SHTOK, J.; ELAD, M.; ZIBULEVSKY, M. **Sparsity-Based Sinogram Denoising for Low-Dose Computed Tomography**. 2011 International Conference on Acoustics, Speech and Signal Processing (ICASSP). Prague, Czech Republic. 2011.

SILVA, A. et al. Innovations in CT Dose Reduction Strategy: Application of the Adaptive Statistical Iterative Reconstruction Algorithm. **American Journal of Roentgenology**, v. 194, n. 1, p. 191-199, 2010.

TANG, S.; TANG, X. Statistical CT noise reduction with multiscale decomposition and penalized weighted least squares in the projection domain. **Medical Physics**, v. 39, n. 9, p. 5498-5512, 2012.

TAO, Y. et al. Radiation dose reduction in computed tomography (CT) using a new implementation of wavelet denoising in low tube current acquisitions. **Medical Imaging 2011: Physics of Medical Imaging**, v. 7961, 2011.

THIBAULT, J. et al. A three-dimensional statistical approach to improved image quality for multislice helical CT. **Medical Physics**, v. 34, n. 11, p. 4526-4544, 2007.

TIPNIS, S. et al. Iterative Reconstruction in Image Space (IRIS) and lesion detection in abdominal CT. **Medical Imaging 2010: Physics of Medical Imaging**, v. 7622, 2010.

TSUI, M. F. S. **Nasopharyngeal Conditions and Dentofacial Morphology**. 1980. 246 Dissertation (Master of Dental Science). Faculty of Dentistry, University of Sydney, Sydney.

UMISEDO, N. K. **Dose de radiação ionizante decorrente do uso de fertilizantes agrícolas**. 2007. 120 p. (Doutorado em Saúde Ambiental). Faculdade de Saúde Pública, Universidade de São Paulo, São Paulo.

VAL, F. L. **Manual de técnica radiográfica**. Barueri: Manole, 2006.

VAN DE CASTEELE, E. et al. Quantitative evaluation of ASiR image quality: An adaptive statistical iterative reconstruction technique. **Medical Imaging 2012: Physics of Medical Imaging**, v. 8313, 2012.

VAZ, C. M. P. et al. **Avaliação do adensamento de um solo cultivado com cana-de-açúcar usando a tomografia computadorizada**. Boletim de Pesquisa. São Carlos: EMBRAPA - CNPDIA: 15 p. 1996.

\_\_\_\_\_. **Análise da Densidade de Madeira por Tomografia**. Pesquisa em Andamento. São Carlos: EMBRAPA - CNPDIA: 4 p. 1996.

WAGNER JR., H. N. A brief history of positron emission tomography (PET). **Seminars in Nuclear Medicine**, v. 28, n. 3, p. 213-220, 1998.

WANG, J. et al. Penalized weighted least-squares approach to sinogram noise reduction and image reconstruction for low-dose X-ray computed tomography. **IEEE Transactions on Medical Imaging**, v. 25, n. 10, p. 1272-1283, 2006.

\_\_\_\_\_. Multiscale penalized weighted least-squares sinogram restoration for low-dose X-ray computed tomography. **IEEE Transactions on Biomedical Engineering**, v. 55, n. 3, p. 1022-1031, 2008.

WANG, W. et al. **Speckle reduction of SAR image based on modeling autocorrelation function of wavelet coefficients**. 2005 IEEE International Symposium on Microwave, Antenna, Propagation and EMC Technologies for Wireless Communications (MAPE'2005), 2005. p.383-386.

WANG, Z.; BOVIK, A. C. A universal image quality index. **IEEE Signal Processing Letters**, v. 9, n. 3, p. 81-84, 2002.

\_\_\_\_\_. Mean squared error: Love it or leave it? A new look at Signal Fidelity Measures. **IEEE Signal Processing Magazine**, v. 26, n. 1, p. 98-117, 2009.

WON, C. S.; GRAY, R. M. **Stochastic Image Processing (Information Technology: Transmission, Processing, and Storage)**. Kluwer Academic/Plenum Publishers, 2004.

WU, H. et al. Fast CT Image Processing using Parallelized Non-local Means. **Journal of Medical and Biological Engineering**, v. 31, n. 6, p. 437-441, 2011.

YOULA, D. C.; WEBB, H. Image Restoration by the Method of Convex Projections: Part 1 - Theory. **IEEE Transactions on Medical Imaging**, v. 1, n. 2, p. 81-94, 1982.

YU, S.; BERTHOD, M. A Game Strategy Approach for Image Labeling. **Computer Vision and Image Understanding**, v. 61, n. 1, p. 32-37, 1995.

ZANIBONI, G. T.; MASCARENHAS, N. D. A. **Fusão bayesiana de imagens utilizando coeficientes de correlação localmente adaptáveis**. IX Simpósio Brasileiro de Sensoriamento Remoto, 1998, Santos. INPE. p.1003-1014.

ZHANG, H.; NOSRATINIA, A.; WELLS, R. O., JR. **Modeling the autocorrelation of wavelet coefficients for image denoising**. 2000 IEEE International Conference on Image Processing (ICIP'2000), 2000. p.304-307.

ZHANG, Y.; ZHANG, J.; LU, H. Statistical Sinogram Smoothing for Low-Dose CT With Segmentation-Based Adaptive Filtering. **IEEE Transactions on Nuclear Science**, v. 57, n. 5, p. 2587-2598, 2010.

## APÊNDICE A – GERAÇÃO DAS IMAGENS SINTÉTICAS

Seguindo o que fora proposto em (Moschetti, Palacio *et al.*, 2006) para uma melhor avaliação dos métodos propostos, além da aplicação a algumas imagens reais de CT, os métodos propostos também foram aplicados às imagens simuladas por experimentos de Monte Carlo. Esta seção descreve o processo de geração das imagens sintéticas usadas nesta tese.

Os experimentos ou métodos de Monte Carlo consistem em métodos estatísticos, onde uma aproximação da solução desejada de um dado problema em matemática computacional pode ser obtida a partir de processos aleatórios do problema (Dimov, 2008).

Os problemas manipulados por métodos de Monte Carlo são divididos em dois tipos: probabilísticos (simulação) ou determinísticos (algoritmos numéricos) (Hammersley e Handscomb, 1964; Dimov, 2008). Nesta tese estamos interessados no primeiro tipo, onde uma abordagem é “observar números aleatórios, escolhidos de modo que eles simulem diretamente um processo aleatório físico do problema original, e inferir a solução desejada do comportamento destes números aleatórios” (Hammersley e Handscomb, 1964). O processo aleatório físico pode representado por uma função de densidade de probabilidade (fdp) conhecida e a simulação pode ser feita por amostragens aleatórias desta fdp (Ljungberg, Strand *et al.*, 1998).

Assim, para a geração das imagens simuladas de CT, primeiramente foi gerado um conjunto de imagens simuladas de tamanho 512 x 512 pixels pelo algoritmo Metropolis (definido no Algoritmo A.1), que consiste em uma simulação Markov Chain Monte Carlo (MCMC), considerando o modelo Potts como modelo *a priori*, com diferentes valores do seu parâmetro de dependência espacial  $\beta$  e diferentes números de iterações (*num\_iter*) e rótulos/classes (*M*), cujos valores considerados para cada parâmetro foram  $\beta = \{0; 0,5; 1; 2; 5; 10; 50; 1000\}$ ,  $num\_iter = \{50; 250; 1000; 5000; 15000; 30000\}$  e  $M = \{2; 3; 10; 64; 128; 256\}$ , nas mais diversas combinações destes, resultando em  $8 \times 6 \times 6 = 288$  imagens.

**Algoritmo A.1.** Algoritmo Metropolis. Baseado em (Dubes e Jain, 1993; Levada, 2010).

---

<b>Entradas:</b>	Um campo de rótulos $X$ de tamanho $M = N_1 \times N_2$
	O número de iterações $N_{iter}$
	O número de classes $L$
	O modelo Markoviano para o campo de rótulos $P(X)$ , com seus respectivos parâmetros
<b>Saída:</b>	Uma ocorrência do modelo Markoviano definido pela distribuição de Gibbs $P(X)$

---

- (1) Inicializar o campo de rótulos  $X$  aleatoriamente com valores do conjunto  $G = \{1, \dots, L\}$  para cada pixel que definirá a configuração inicial  $x$
- (2) **Para**  $n = 1$  **até**  $N_{iter}$
- (3)     **Para** todo pixel  $s = 1, \dots, M$  **fazer**
- (4)         Escolher aleatoriamente um rótulo  $g \in G$ . Seja  $y_s = g$  e  $y_t = x_t$  para todo  $t \neq s$
- (5)         Seja  $p = \min \left\{ 1, \frac{P(X=y)}{P(X=x)} \right\}$  (com base em  $P_X$ )
- (6)         Substituir  $x$  por  $y$  com probabilidade  $p$
- (7)     **Fim-Para**
- (8) **Fim-Para**

---

Destas imagens geradas pelo Metropolis foi selecionado um subconjunto final de cinco imagens bastante diferentes, que, junto a algumas imagens clássicas em Processamento de Imagens como Lena, Cameraman e Mandril (também de 512 x 512 pixels), formam o conjunto base de oito imagens.

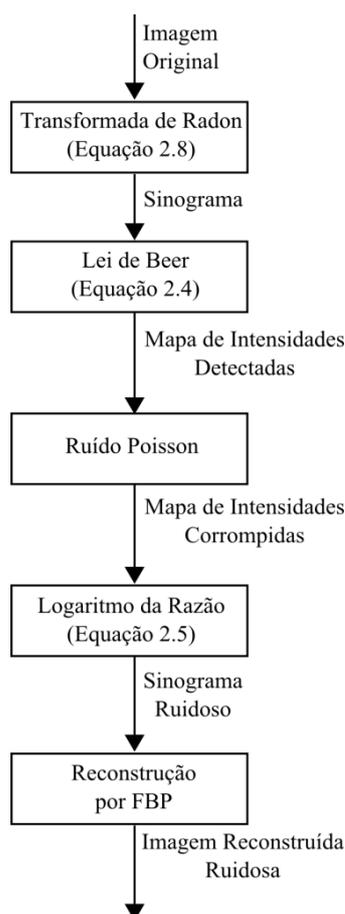
Destas oito imagens foram obtidos os seus respectivos sinogramas por meio da Transformada de Radon definida na Equação 2.8. Em seguida, utilizando a Lei de Beer definida na Equação 2.4 foram determinadas as contagens de fótons  $I$  detectadas a partir dos sinogramas e considerando diferentes valores (definidos empiricamente) para a contagem de fótons incidente  $I_0 = 2000 \times 2^i$  com  $i = 1, \dots, 8$  para simular diferentes níveis de radiação, o que totalizaram  $8 \times 8 = 64$  mapas de intensidade detectadas.

As imagens livres de ruído de referência para os testes quantitativos foram geradas aplicando a Transformada de Radon para obter os respectivos sinogramas das oito imagens base, e em seguida, estes sinogramas foram reconstruídos por Retroprojeção Filtrada.

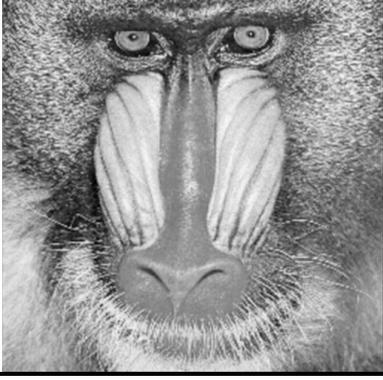
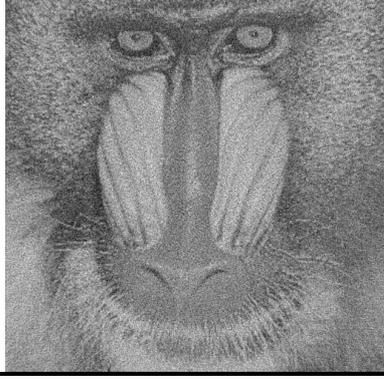
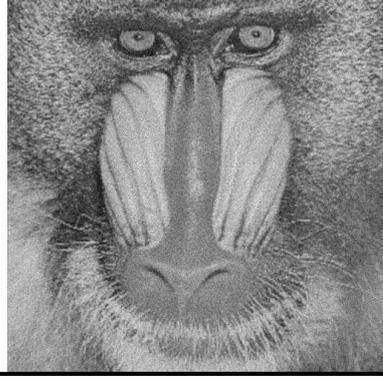
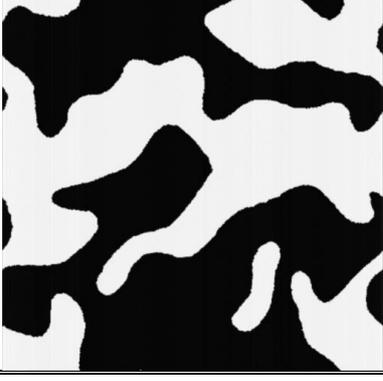
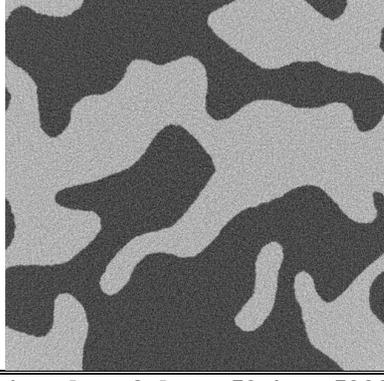
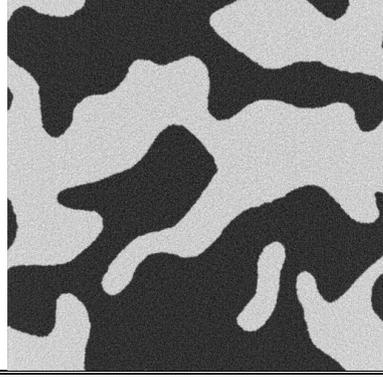
Para simular as imagens ruidosas na imagem reconstruída seguindo o modelo físico em CT, primeiramente, os dados em cada  $I$  foram corrompidos por ruído Poisson, tendo sido considerado 500 sementes do ruído aleatório para cada um dos 64 mapas de intensidades de-

tectadas. Em seguida, os sinogramas ruidosos foram obtidos destes dados corrompidos por aplicar a Equação 2.5. Por último, os sinogramas ruidosos foram reconstruídos por Retroprojeção Filtrada, totalizando  $64 \times 500 = 32000$  imagens reconstruídas ruidosas. Vale ressaltar ainda que os sinogramas não foram reconstruídos por POCS devido ao seu alto custo computacional.

Por fim, devido ao tempo para o processamento destas imagens, um subconjunto delas foi selecionado para a realização dos testes com imagens simuladas. As imagens ruidosas selecionadas foram aquelas geradas considerando os valores de  $I_0 = 8000$  e  $I_0 = 32000$ , totalizando 8000 imagens reconstruídas ruidosas neste conjunto final. O diagrama de blocos da Figura A.1 resume o processo de geração das imagens simuladas. Além disso, na Figura A.2 temos as imagens de referência e algumas de suas respectivas versões ruidosas.



**Figura A.1.** Diagrama de blocos do esquema de geração das imagens simuladas.

Originais	Ruidosas	
	$I_0 = 8000$	$I_0 = 32000$
<b>Camerman</b>		
		
<b>Lena</b>		
		
<b>Mandrill</b>		
		
<b>sim_class_2_beta_5_iter_1000</b>		
		
<b>sim_class_2_beta_50_iter_5000</b>		

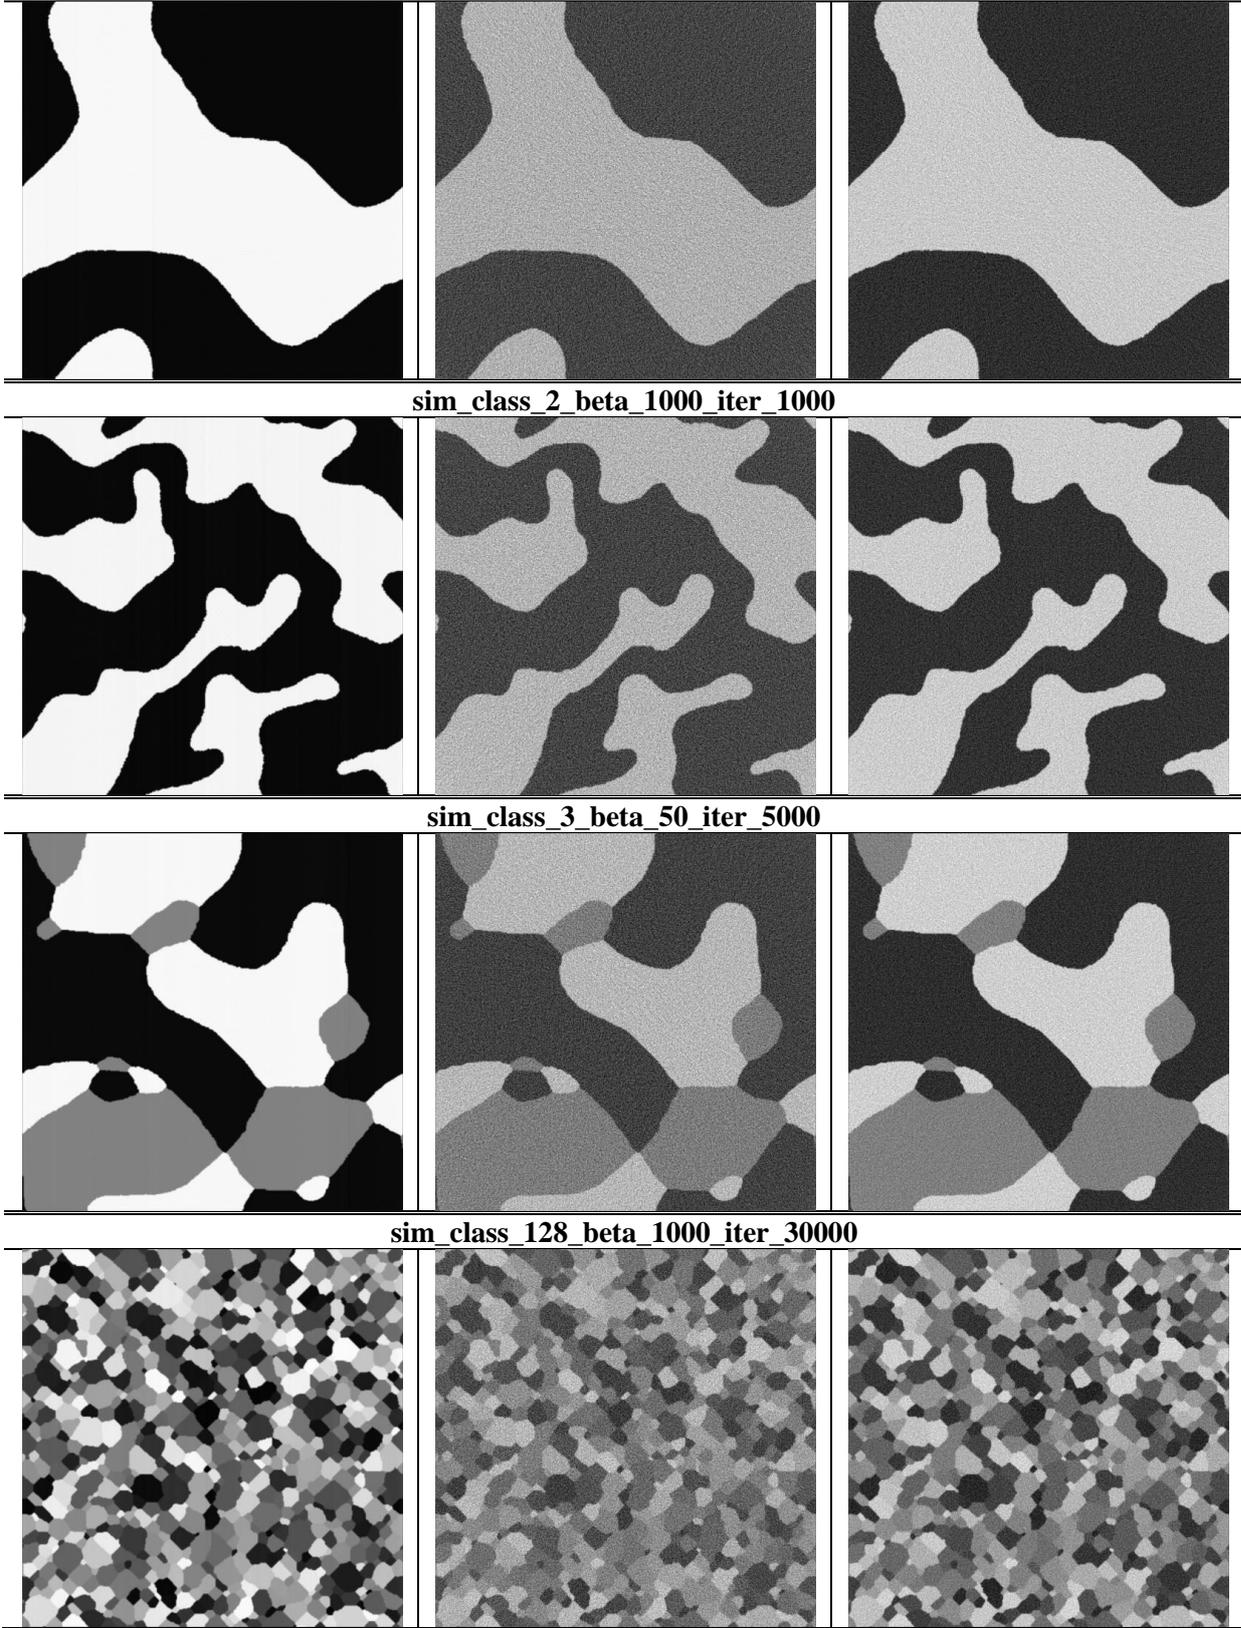


Figura A.2. Exemplos de imagens sintéticas geradas.

## APÊNDICE B – TESTES DE RUÍDO DEPENDENTE DO SINAL

A fim de uma melhor caracterização do ruído presente nas imagens reconstruídas de CT, alguns experimentos foram realizados para verificar se o ruído é dependente ou não do sinal. Para isto, algumas imagens reais e sintéticas foram consideradas.

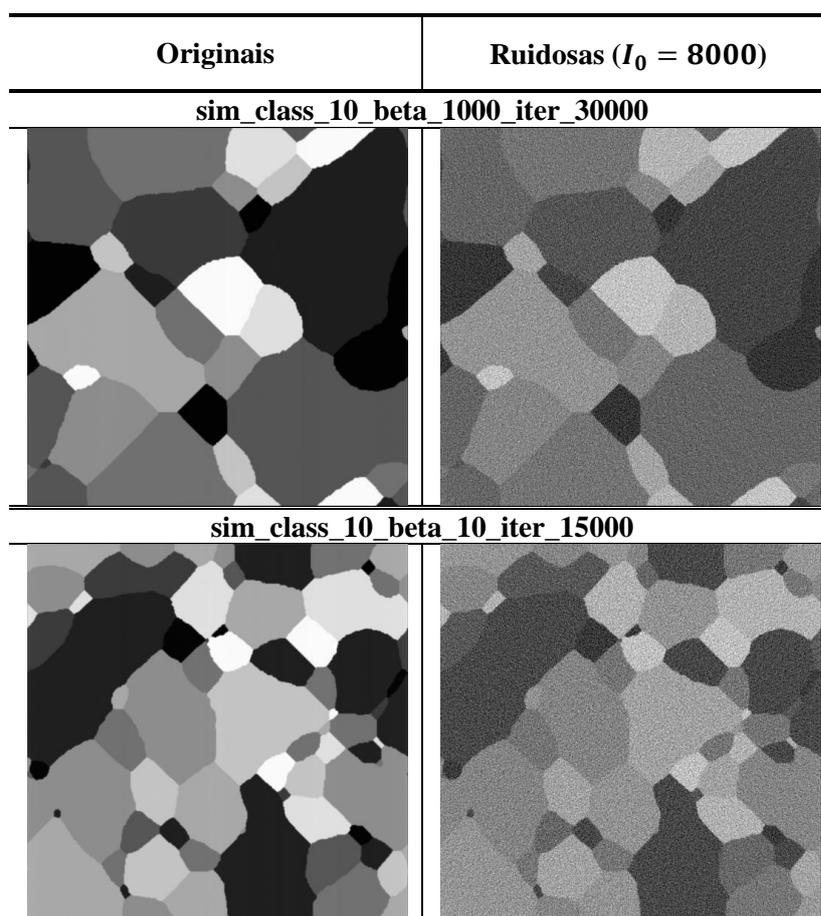
Utilizando o software editor de imagens GIMP (GNU Image Manipulation Program: User Manual, 2012), as áreas homogêneas em cada imagem testada foram selecionadas manualmente das imagens consideradas livres de ruído. Neste software, na ferramenta “Histograma”, além do histograma há também a informação do desvio padrão da região selecionada. É importante ressaltar que uma área homogênea na imagem corresponde a áreas de um mesmo material. Assim, pode-se analisar as variâncias em cada região homogênea da imagem ruidosa. No caso de ruído independente do sinal era esperado que as variâncias possuísem os mesmos valores para todas as regiões homogêneas de uma mesma imagem, não importando se a região tinha um nível médio de cinza mais baixo (área mais escura) ou mais alto (área mais clara). Por sua vez, no caso de ruído dependente do sinal, as variâncias nas áreas homogêneas de uma mesma imagem não são constantes.

Com base nestas considerações serão apresentados e discutidos a seguir os resultados das variâncias para as imagens analisadas. Iniciando pelas imagens sintéticas ruidosas com  $I_0 = 8000$ , cujo processo de geração foi apresentado no Apêndice A, vamos considerar algumas imagens produzidas considerando apenas duas classes (que corresponde a termos dois tipos de materiais) pelo Algoritmo Metropolis.

Na primeira imagem que chamamos de ‘sim\_class\_2\_beta\_50\_iter\_5000’ os valores para as variâncias foram 262,44 e 320,41 para as regiões com média 68,9 e 175,4, respectivamente. Na imagem ‘sim\_class\_2\_beta\_1000\_iter\_1000’, as variâncias foram 285,61 e 316,84 para as regiões com média 69,4 e 179,3, respectivamente. Por sua vez, na imagem ‘sim\_class\_2\_beta\_5\_iter\_1000’, as variâncias foram 243,36 e 268,96 para as regiões com média 74,6 e 176,7, respectivamente.

Em seguida foi considerada uma imagem sintética produzida com três classes (ou três tipos de materiais) pelo Algoritmo Metropolis. Para as regiões com médias 65,4, 124,1 e 182,1 foram encontradas as seguintes variâncias 237,16, 252,81 e 275,56, respectivamente.

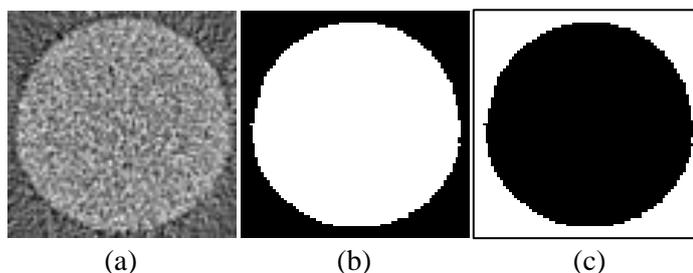
Ainda, foram consideradas duas imagens geradas com dez classes pelo Algoritmo Metropolis, que podem ser vistas na Figura B.1. Na imagem ‘sim\_class\_10\_beta\_1000\_iter\_30000’ foram encontradas as seguintes variâncias (207,36; 213,16; 234,09; 219,04; 228,01; 246,49; 249,64; 237,16; 249,64; 246,49) para as regiões com seguintes médias (53; 68,4; 84; 100,6; 115,8; 131,8; 147,1; 162,8; 179,1; 194,8), respectivamente. E para a última imagem sintética considerada, denominada ‘sim\_class\_10\_beta\_10\_iter\_15000’, foram encontradas as variâncias (295,84; 292,41; 272,25; 306,25; 306,25; 309,76; 306,25; 338,56; 320,41; 334,89) para as regiões com médias crescentes (57,6; 72,1; 87,9; 102,4; 117,3; 132,2; 147,5; 161,3; 176,8; 191,2), respectivamente.



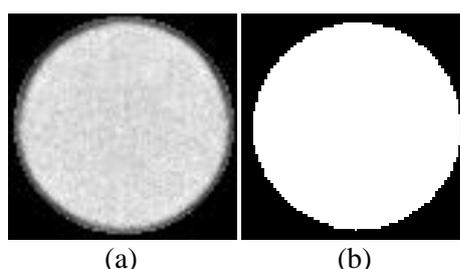
**Figura B.1.** Imagens sintéticas originais e ruidosas com dez classes usadas para a análise de dependência de sinal.

A seguir, as análises para as imagens reais reconstruídas por FBP ou POCS serão apresentadas. Maiores informações sobre as imagens reais podem ser encontradas no Capítulo 7. Vale ressaltar que para o POCS, devido à restrição de suporte finito considerado no algoritmo, os dados fora do objeto são nulos.

Para o phantom Homogêneo reconstruído por FBP, as variâncias foram 882,09 e 998,56 para as regiões dentro e fora do objeto (cujas respectivas médias são 143,7 e 99,2), respectivamente. Para este phantom reconstruído por POCS, tem-se que a área do objeto com média 183,6 apresentou variância 358,64. Maiores detalhes das máscaras selecionadas para cada região podem ser vistas nas Figuras B.2 e B.3 para as versões deste phantom reconstruídas por FBP e POCS, respectivamente.



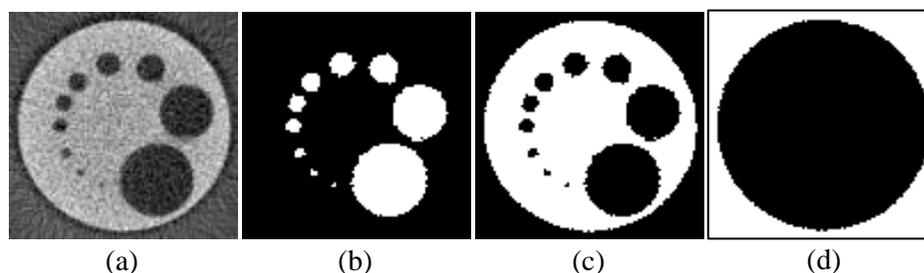
**Figura B.2.** Áreas homogêneas selecionadas para o phantom Homogêneo reconstruído por FBP: (a) imagem ruidosa, (b) região do objeto e (c) região fora do objeto.



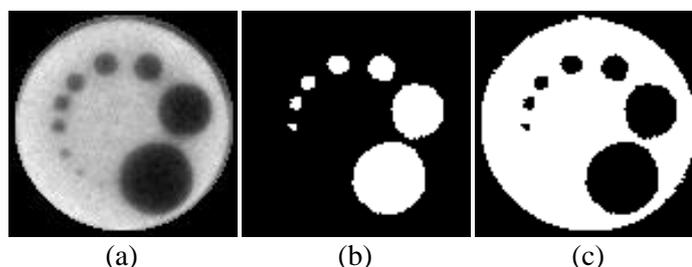
**Figura B.3.** Áreas homogêneas selecionadas para o phantom Homogêneo reconstruído por POCS: (a) imagem ruidosa e (b) região do objeto (borda escura desconsiderada).

Para o phantom Assimétrico reconstruído por FBP, as variâncias para os furos cheios de ar, estrutura de plexiglass e região fora do objeto (cujas respectivas médias são 90,8, 156,2 e 106,6) foram 739,84, 745,29 e 497,29, respectivamente. Por sua vez, este mesmo phantom reconstruído por POCS, apresentou variâncias 789,61 e 729 para a estrutura de plexiglass e furos cheios de ar (cujas respectivas médias são 171 e 54,3), respectivamente. Maiores deta-

lhes das máscaras selecionadas para cada região podem ser vistas nas Figuras B.4 e B.5 para as versões deste phantom reconstruídas por FBP e POCS, respectivamente.



**Figura B.4.** Áreas homogêneas selecionadas para o phantom Assimétrico reconstruído por FBP: (a) imagem ruidosa, (b) furos cheios de ar, (c) estrutura de plexiglass e (d) região fora do objeto.

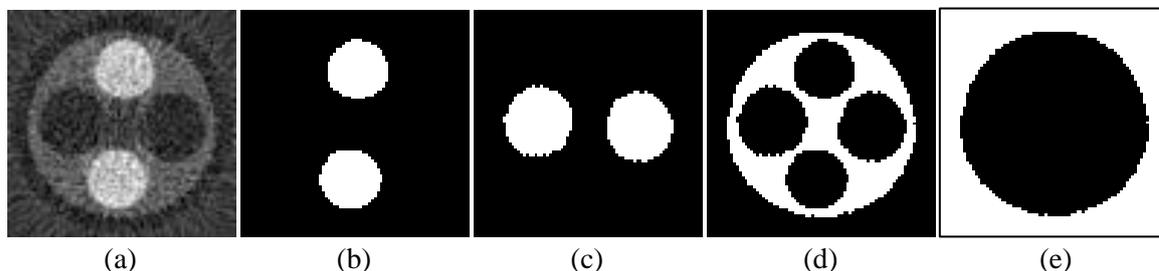


**Figura B.5.** Áreas homogêneas selecionadas para o phantom Assimétrico reconstruído por POCS: (a) imagem ruidosa, (b) furos cheios de ar e (c) estrutura de plexiglass.

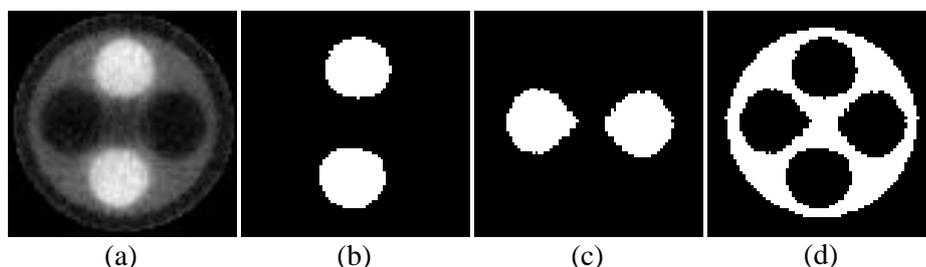
Para o phantom Simétrico reconstruído por FBP, as variâncias foram 630,01, 396,01, 275,56 e 249,64 para as regiões de furos de alumínio, corpo do phantom (plexiglass), furos cheios de ar e fora do objeto (cujas respectivas médias são 188,2, 92,9, 49,4 e 55,2), respectivamente. Para este mesmo phantom reconstruído por POCS, as variâncias foram 1075,84, 388,09 e 123,21 para as regiões de furos de alumínio, corpo do phantom (plexiglass) e furos cheios de ar (cujas respectivas médias são 198,4, 80,3 e 25,1), respectivamente. Maiores detalhes das máscaras selecionadas para cada região podem ser vistas nas Figuras B.6 e B.7 para as versões deste phantom reconstruídas por FBP e POCS, respectivamente.

Para a imagem Madeira 1 reconstruída por FBP, as variâncias foram 320,41, 156,25 e 334,89 para as regiões central, fora do objeto e região interna mais clara (cujas respectivas médias são 144,3, 76,5 e 182,4), respectivamente. Para a sua versão reconstruída por POCS, temos as seguintes variâncias 198,81 e 79,21 para as regiões interna mais clara e central (cujas respectivas médias são 188,6 e 146,5), respectivamente. Maiores detalhes das máscaras sele-

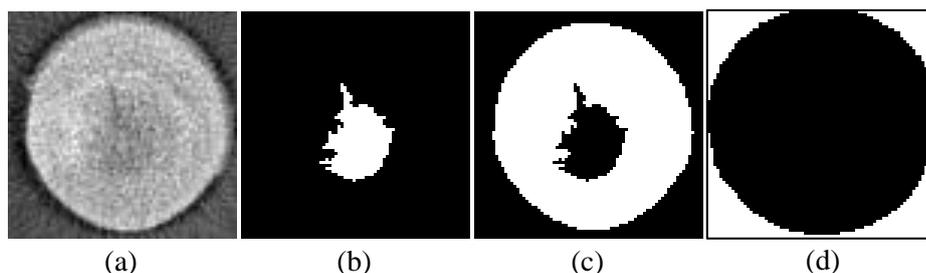
cionadas para cada região podem ser vistas nas Figuras B.8 e B.9 para as versões deste phantom reconstruídas por FBP e POCS, respectivamente.



**Figura B.6.** Áreas homogêneas selecionadas para o phantom Simétrico reconstruído por FBP: (a) imagem ruidosa, (b) furos de alumínio, (c) furos cheios de ar, (d) corpo do phantom (plexiglass) e (e) região fora do objeto.



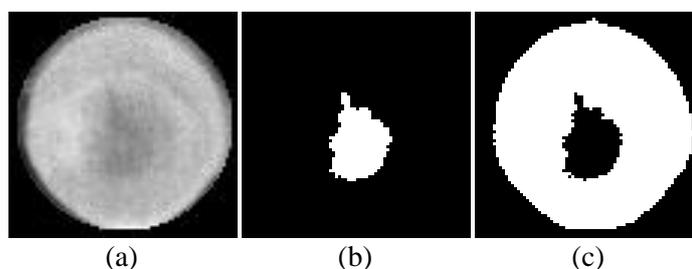
**Figura B.7.** Áreas homogêneas selecionadas para o phantom Simétrico reconstruído por POCS: (a) imagem ruidosa, (b) furos de alumínio, (c) furos cheios de ar e (d) corpo do phantom (plexiglass).



**Figura B.8.** Áreas homogêneas selecionadas para Madeira 1 reconstruída por FBP: (a) imagem ruidosa, (b) região central, (c) região interna mais clara e (d) região fora do objeto.

Por sua vez, para a imagem Madeira 2 reconstruída por FBP, as variâncias para as regiões de estruturas claras, parte escura do objeto, parte escuro do suporte e fora do suporte foram 552,25, 615,04, 533,61 e 292,41 (cujas respectivas médias são 191,3, 134,1, 72,8 e 88), respectivamente. Para a sua versão reconstruída por POCS, temos as seguintes variâncias 309,76, 954,81 e 696,96 para as regiões de estruturas claras, parte escura do objeto e fora do

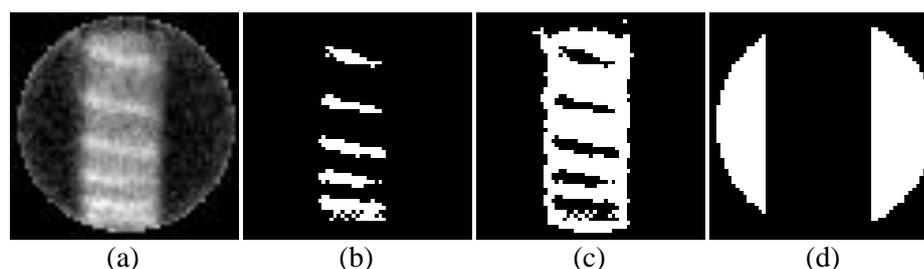
objeto (cujas respectivas médias são 200,2, 140,1 e 37,2), respectivamente. Maiores detalhes das máscaras selecionadas para cada região podem ser vistas nas Figuras B.10 e B.11 para as versões deste phantom reconstruídas por FBP e POCS, respectivamente.



**Figura B.9.** Áreas homogêneas selecionadas para Madeira 1 reconstruída por POCS: (a) imagem ruidosa, (b) região central e (c) região interna mais clara.



**Figura B.10.** Áreas homogêneas selecionadas para Madeira 2 reconstruída por FBP: (a) imagem ruidosa, (b) regiões de estruturas claras, (c) parte escura do objeto, (d) parte escura do suporte e (e) fora do suporte.



**Figura B.11.** Áreas homogêneas selecionadas para Madeira 2 reconstruída por FBP: (a) imagem ruidosa, (b) regiões de estruturas claras, (c) parte escura do objeto e (d) parte escura do suporte.

Por fim, analisando as variâncias obtidas nota-se em geral que elas variam de região para região, portanto, sendo uma função da região ou material. Em alguns casos, tem-se inclusive que as variâncias crescem conforme as médias das regiões aumentam, notadamente nas imagens sintéticas. Assim, podemos concluir que o ruído presente nas imagens reconstruídas tanto por POCS quanto por FBP é dependente do sinal.

## APÊNDICE C – RESULTADOS COMPARATIVOS DOS MÉTODOS DE ESTIMAÇÃO DO RUÍDO DEPENDENTE DO SINAL

Nesta tese foram propostos três novos métodos de estimação do ruído dependente do sinal que são apresentados na Seção 6.1.2: Preliminar, Final e Formal. Assim, neste apêndice, são apresentados resultados comparativos de desempenho destes métodos e também de outros dois propostos na literatura (Gravel, Beaudoin *et al.*, 2004) e (Salmeri, Mencattini *et al.*, 2008), sendo estes indicados nos gráficos dos resultados abaixo por Gravel e Salmeri, respectivamente.

Para se obter uma comparação entre estes cinco métodos, filtragem foi realizada e medidas de PSNR e SSIM foram geradas para as 8000 imagens simuladas (Apêndice A) usando um método de filtragem padrão, que aqui foi definido como sendo o Wiener Generalizado com  $\alpha = 1$  (que corresponde ao Wiener Pontual),  $w = 3 \times 3$ , vizinhança de segunda ordem e com o ruído estimado por cada um dos métodos. Além disso, a fim de se reduzir a influência ou o favorecimento de algum método pelo uso de estimação da imagem livre de ruído dada pelo filtro da Média ou Non Local Means, a própria imagem original foi utilizada para este fim. Ainda, foram considerados resultados com e sem uso de técnica de melhora de contraste após a filtragem, indicados por \*.

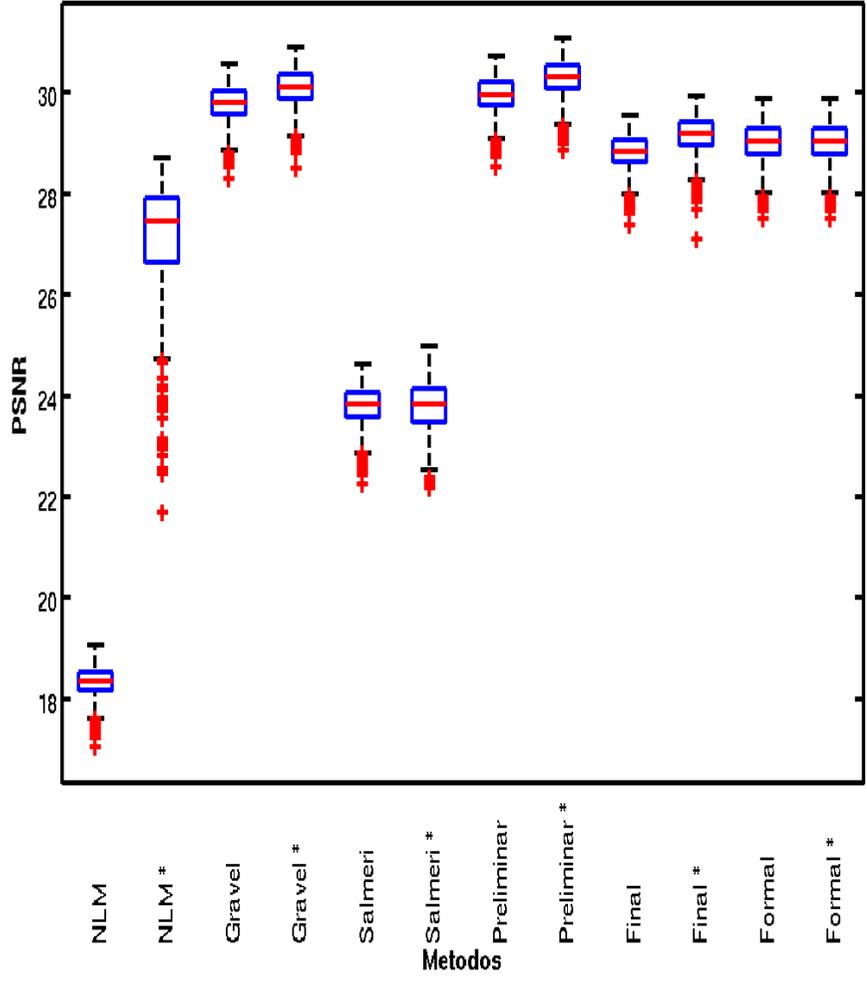
Vale ressaltar também que não foram feitos ajustes a fim de se determinar quais as melhores configurações de parâmetros para cada método, mas foram definidos os mesmos valores para todos (exceto o Formal, cujo parâmetro tem fórmula fechada), sendo o limiar = 0,9 e número de bins = 256.

Com estas definições, nas Figuras C.1 a C.5 são apresentados alguns dos resultados gerados que representam o que foi encontrado nas imagens utilizadas. Aqui, segundo a sugestão do trabalho (Moschetti, Palacio *et al.*, 2006) foi considerado o Método de Monte Carlo e a geração de *boxplots* para comparação.

Por fim, destes resultados podemos concluir que: 1) o método de Salmeri apresentou-se inferior aos outros métodos, 2) todos os outros métodos apresentaram resultados equivalentes e 3) para o caso de imagens geradas por menor número de tons de cinza (Figuras C.4 e

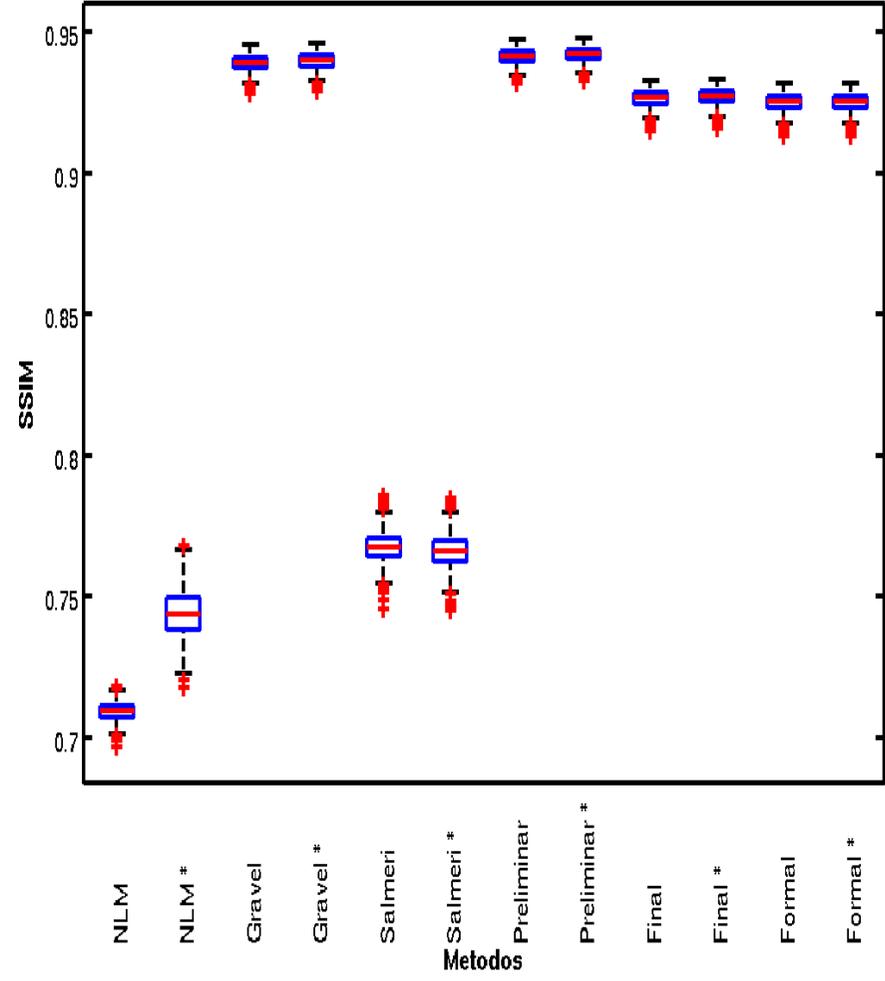
C.5) que utilizaram de técnica de melhoria de contraste, fez com o que desempenho em termos de SSIM fosse inferior. Porém, vale uma ressalva, como aqui apenas um método de filtragem foi considerado, talvez com o uso de outros métodos de filtragem ou mesmo diferentes parâmetros, possa haver alguma variação do desempenho, como apontado por outros resultados gerados no Apêndice D e Capítulo 7. Entretanto, o interesse deste Apêndice foi apenas apresentar uma noção comparativa do desempenho dos diferentes métodos de estimação.

Resultado comparativo dos PSNRs dos metodos de estimacao do ruido para a imagem "lena\_gray\_512" criada com I0 = 8000.



(a)

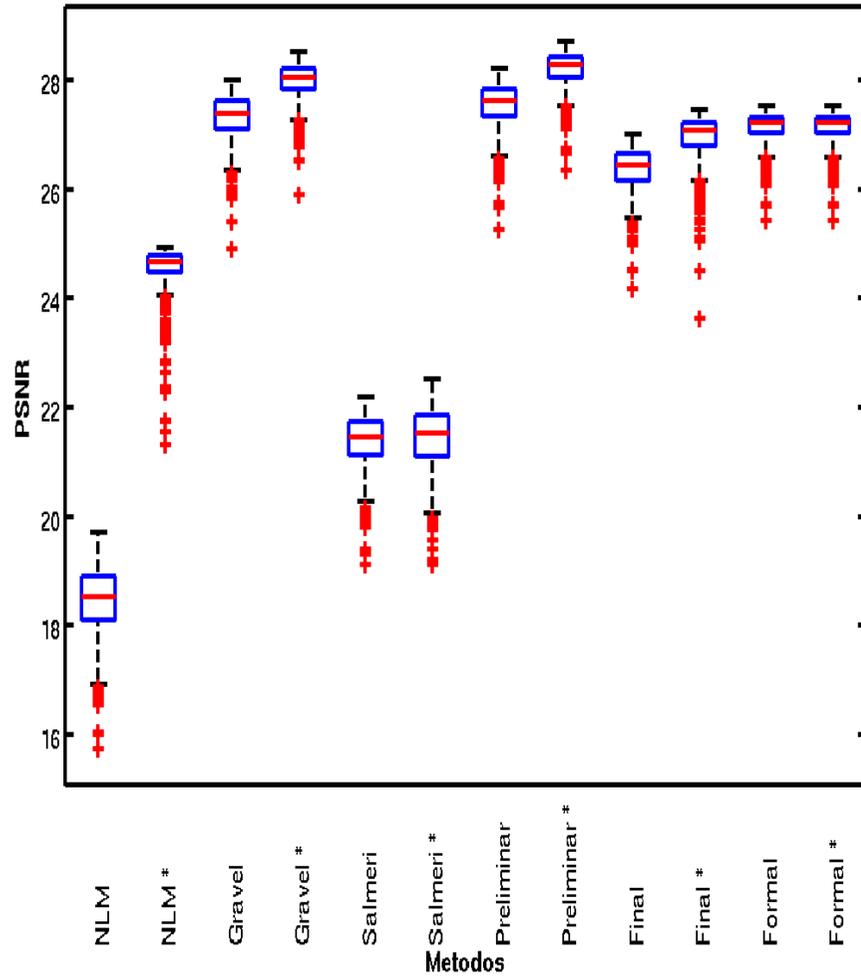
Resultado comparativo dos SSIMs dos metodos de estimacao do ruido para a imagem "lena\_gray\_512" criada com I0 = 8000.



(b)

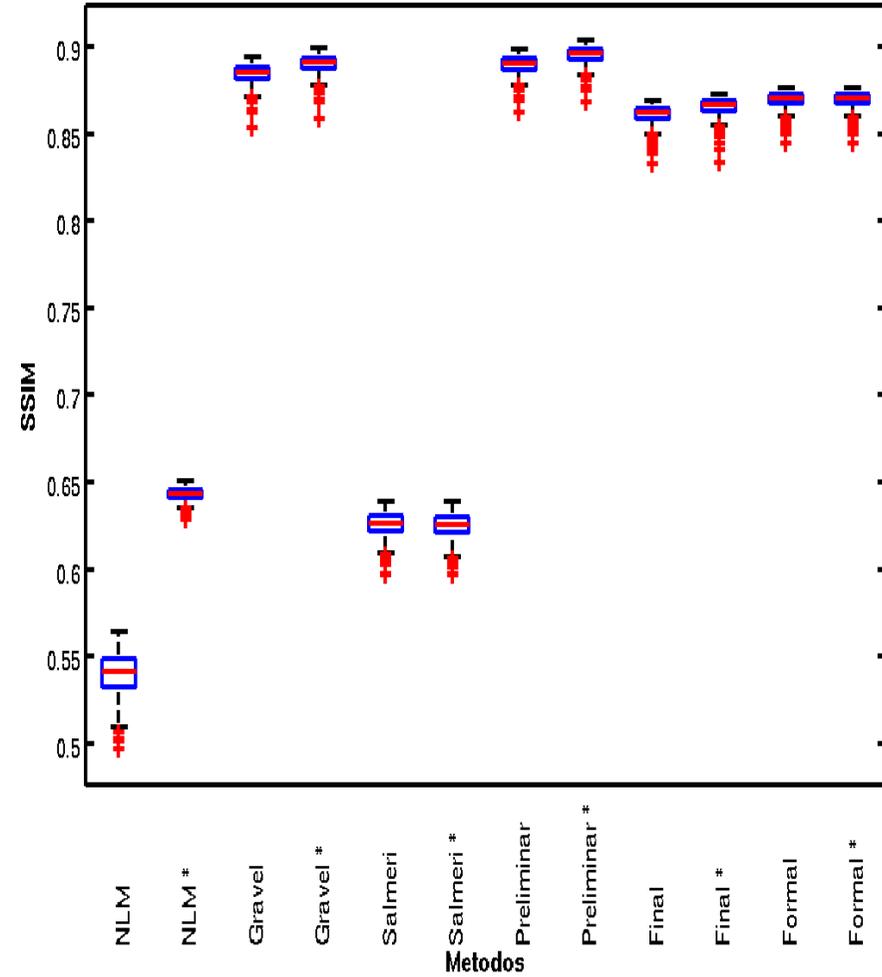
Figura C.1. Resultados comparativos dos métodos de estimação do ruído em termos de (a) PSNR e (b) SSIM para a imagem Lena com I0 = 8000.

Resultado comparativo dos PSNRs dos metodos de estimacao do ruido para a imagem "mandril\_gray" criada com I0 = 8000.



(a)

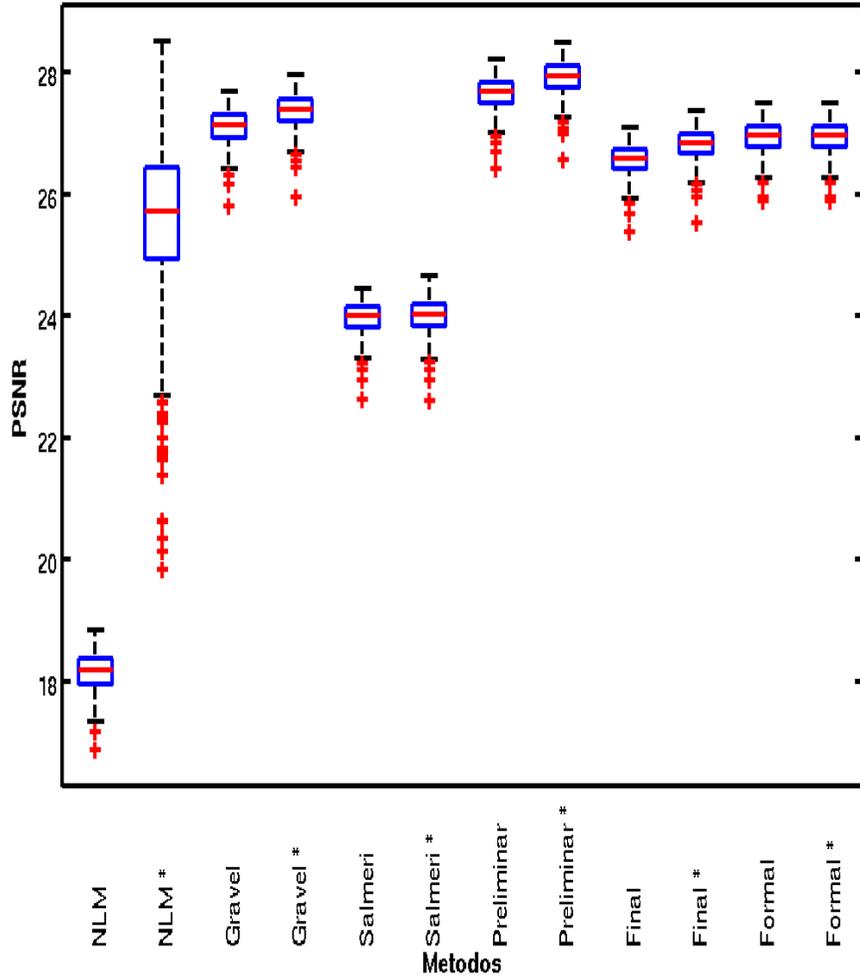
Resultado comparativo dos SSIMs dos metodos de estimacao do ruido para a imagem "mandril\_gray" criada com I0 = 8000.



(b)

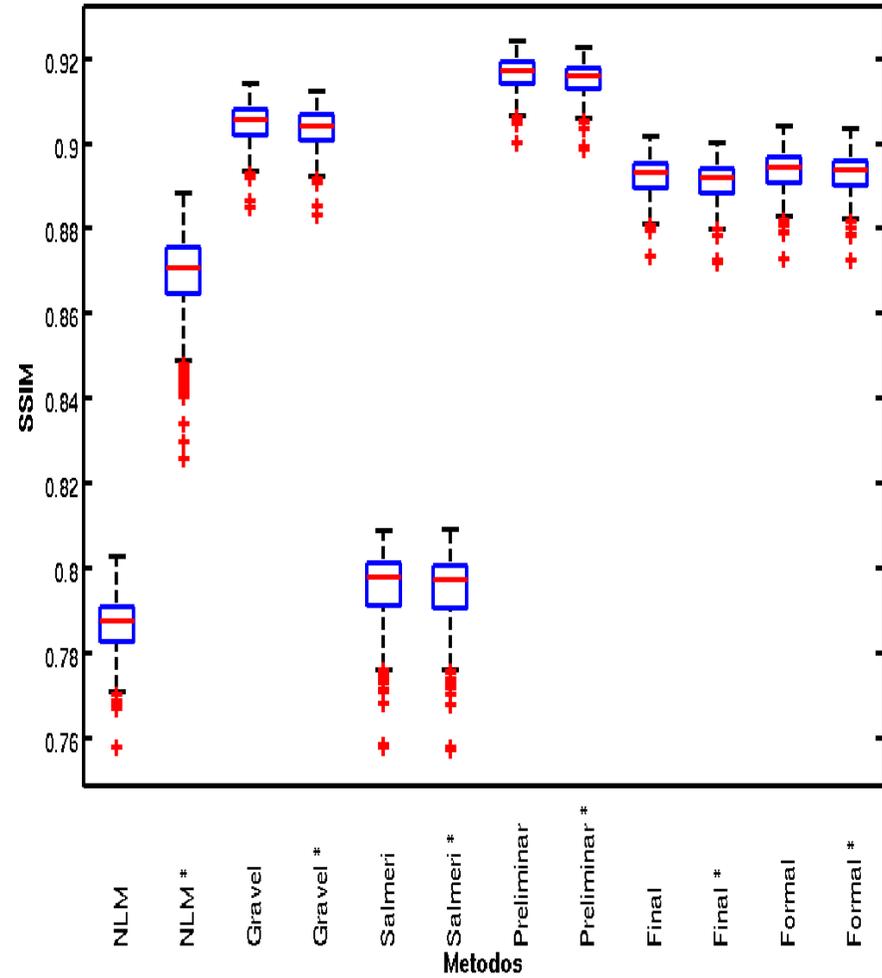
Figura C.2. Resultados comparativos dos métodos de estimação do ruído em termos de (a) PSNR e (b) SSIM para a imagem Mandril com I0 = 8000.

Resultado comparativo dos PSNRs dos metodos de estimacao do ruido para a imagem "sim\_class\_128\_beta\_1000\_iter\_30000" criada com I0 = 8000.



(a)

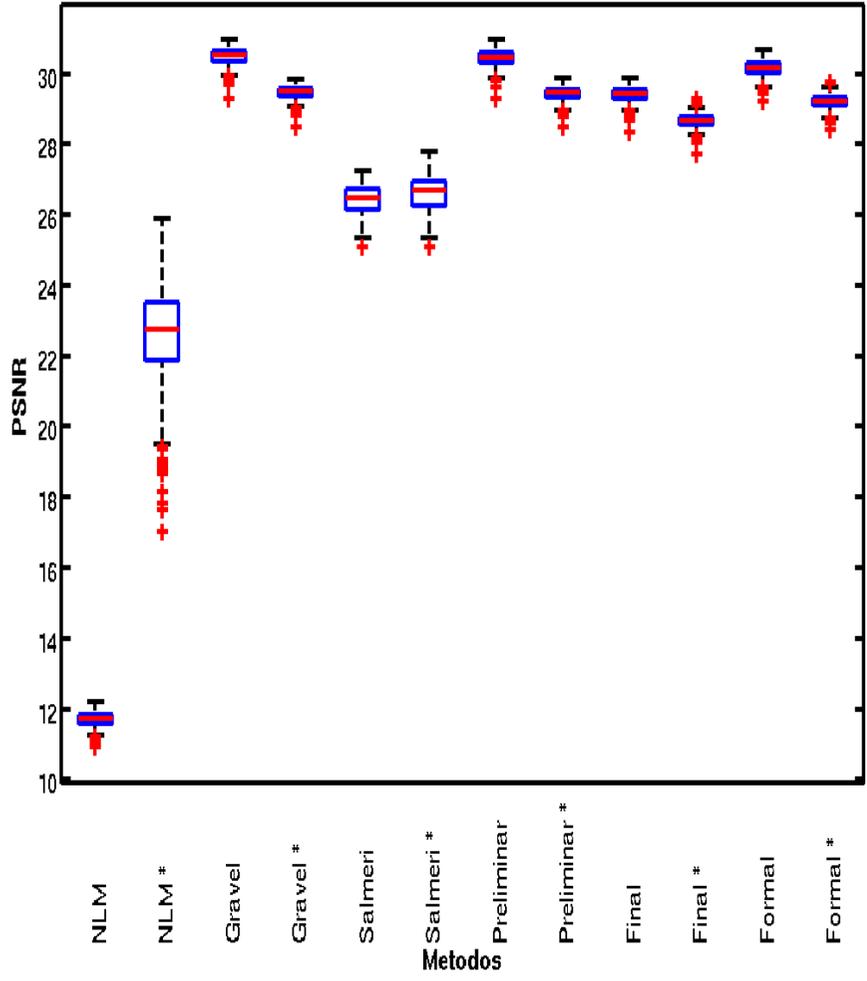
Resultado comparativo dos SSIMs dos metodos de estimacao do ruido para a imagem "sim\_class\_128\_beta\_1000\_iter\_30000" criada com I0 = 8000.



(b)

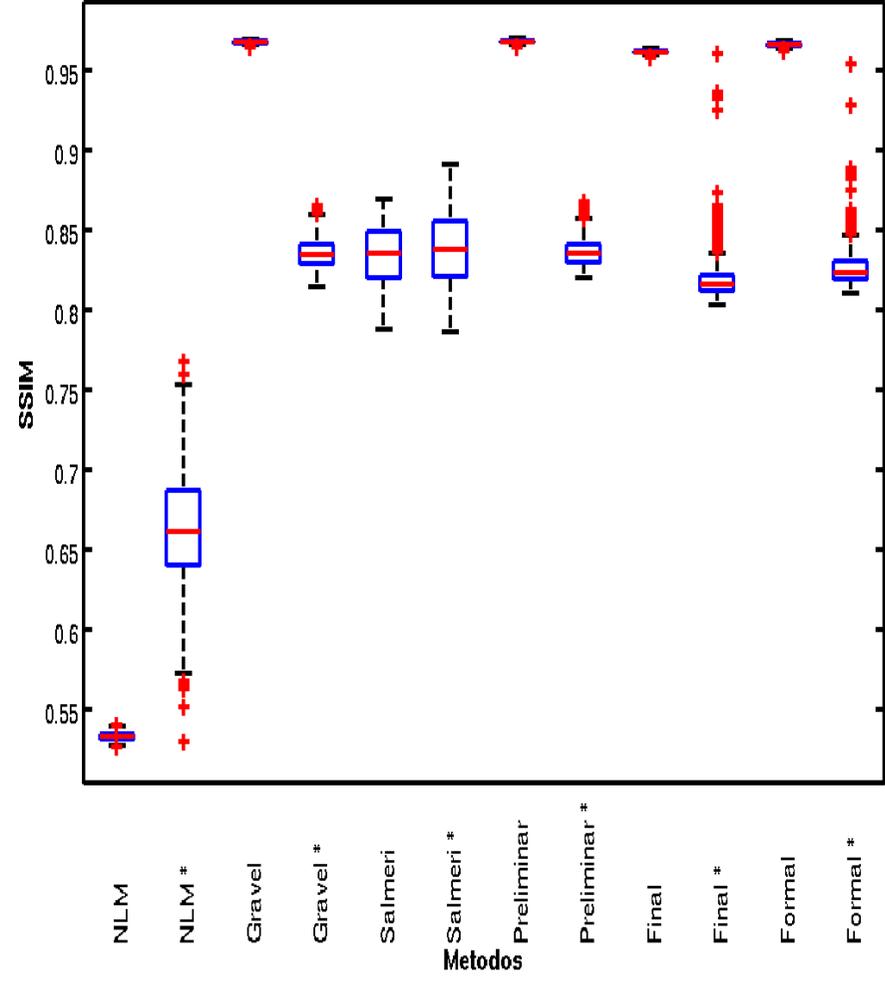
Figura C.3. Resultados comparativos dos métodos de estimação do ruído em termos de (a) PSNR e (b) SSIM para a imagem "sim\_class\_128\_beta\_1000\_iter\_30000" com I0 = 8000.

Resultado comparativo dos PSNRs dos metodos de estimacao do ruido para a imagem "sim\_class\_2\_beta\_50\_iter\_5000" criada com I0 = 8000.



(a)

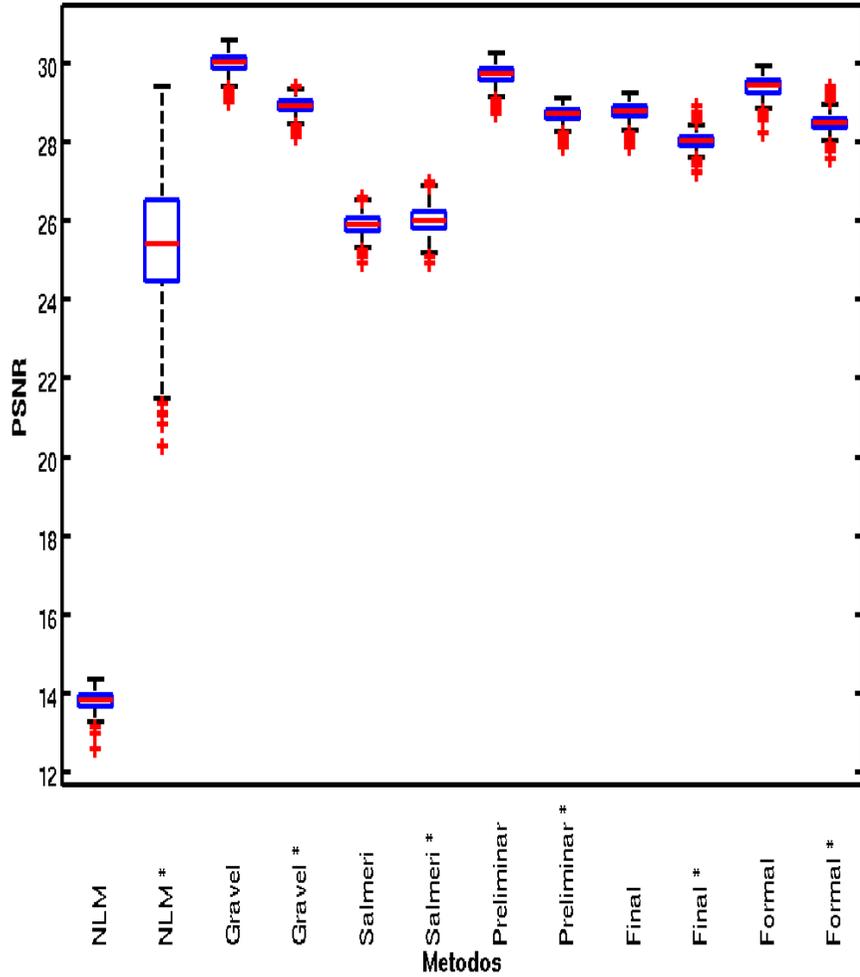
Resultado comparativo dos SSIMs dos metodos de estimacao do ruido para a imagem "sim\_class\_2\_beta\_50\_iter\_5000" criada com I0 = 8000.



(b)

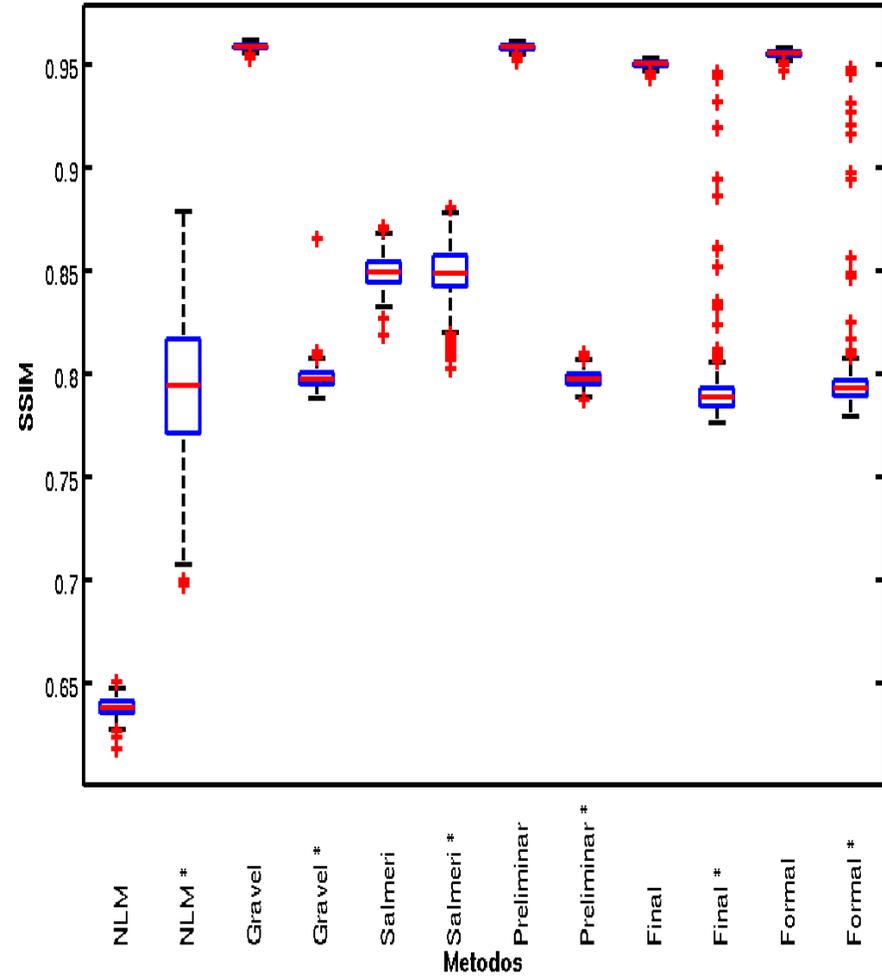
Figura C.4. Resultados comparativos dos métodos de estimação do ruído em termos de (a) PSNR e (b) SSIM para a imagem "sim\_class\_2\_beta\_50\_iter\_5000" com I0 = 8000.

Resultado comparativo dos PSNRs dos metodos de estimacao do ruido para a imagem "sim\_class\_3\_beta\_50\_iter\_5000" criada com I0 = 8000.



(a)

Resultado comparativo dos SSIMs dos metodos de estimacao do ruido para a imagem "sim\_class\_3\_beta\_50\_iter\_5000" criada com I0 = 8000.



(b)

Figura C.5. Resultados comparativos dos métodos de estimação do ruído em termos de (a) PSNR e (b) SSIM para a imagem “sim\_class\_3\_beta\_50\_iter\_5000” com I0 = 8000.

## APÊNDICE D – RESULTADOS DE FILTRAGEM DAS IMAGENS SIMULADAS

Neste Apêndice os resultados de filtragem das imagens simuladas geradas são apresentados e discutidos baseados em experimentos de Monte Carlo, como sugerido em (Moschetti, Palacio *et al.*, 2006), para uma melhor comparação de desempenho entre os métodos de filtragem.

Os métodos comparados e as possíveis combinações de parâmetros para cada método utilizadas neste experimento são apresentadas a seguir:

- 1) **ICM:** Número de Iterações 10 e modelos para verossimilhança e a priori Gaussiana e GMRF, respectivamente;
- 2) **GSA:** Taxa de Aceitação {0.6, 0.7, 0.8, 0.9}, Número de Iterações 10 e modelos para verossimilhança e a priori Gaussiana e GMRF, respectivamente;
- 3) **Non Local Means:** Largura da área de busca, largura do patch, número de iterações, e parâmetros de confiança na quantidade de filtragem  $\alpha$  e na imagem pré-estimada  $\beta$  foram 10, 3, 1, 0.03 e 0.03, respectivamente;
- 4) **Wiener Pontual:** Largura da Janela para estimar parâmetros (W) {3, 5, 7} e estimativa da imagem livre de ruído obtida ou por Non Local Means ou por filtro da média com Largura da Janela definido pelo mesmo selecionado para o W;
- 5) **Wiener com Informação de Fisher (Generalizado):** Taxa de Compromisso  $\alpha$  {0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1} e Largura da Janela para Estimação dos parâmetros (W) {3, 5, 7}. Também, foram considerados os Sistemas de Vizinhança de Primeira Ordem ( $viz = 4$ ) e Segunda Ordem ( $viz = 8$ ), além da estimativa da imagem livre de ruído obtida ou por Non Local Means ou por filtro da média com Largura da Janela definido pelo mesmo selecionado para o W;
- 6) **Wiener com MRF Isotrópico:** Largura da Janela para Estimação dos parâmetros {3, 5, 7} e estimativa da imagem livre de ruído obtida ou por Non Local Means ou por filtro da média com Largura da Janela definido pelo mesmo selecionado para o W;

- 7) **Wiener com MRF Separável:** Largura da Janela para Estimação dos parâmetros  $\{3, 5, 7\}$  e estimativa da imagem livre de ruído obtida ou por Non Local Means ou por filtro da média com Largura da Janela definido pelo mesmo selecionado para o  $W$ .

Vale ressaltar que devido ao alto custo computacional deste experimento, um número reduzido de iterações ou mesmo configurações foi utilizado se comparado ao experimento com imagens reais, motivo pelo qual o MPM, outros métodos de estimação do ruído e modelos a priori não foram considerados aqui. Entretanto, acredita-se que isto não afeta a discussão e mesmo conclusões deste trabalho, já que se procurou selecionar os métodos que se apresentavam mais adequados para serem aplicados nas imagens simuladas, baseado também nos resultados obtidos para as imagens reais.

Além disso, foi considerado em cada método de filtragem que o ruído era dado ou pelo método Final para o caso dependente do sinal ou por um definido como a variância da diferença entre a imagem ruidosa e original para o caso independente do sinal. Vale ressaltar que este último caso é possível ser realizado, pois temos a imagem realmente livre de ruído. E também, justamente por se usar a imagem livre de ruído, espera-se que o seu resultado seja superior. Ainda, para o método Final de estimação do ruído os valores de limiar foram definidos automaticamente pelo Matlab em termos do valor mais alto de magnitude do gradiente de cada imagem e número de bins foi fixado em 256 para todas as imagens.

Ainda, a técnica simples de realce de histograma para melhora de contraste descrita no Capítulo 7 foi aplicada após a filtragem.

Com estas considerações, apresentamos nas Figuras D.1 a D.5 os melhores resultados em termos de PSNR e SSIM de algumas imagens selecionadas. Em geral, encontrou-se certo padrão nos resultados, onde os métodos baseados em Wiener apresentados são equivalentes e superiores aos métodos iterativos. Além disso, como esperado, os resultados utilizando método dependente do sinal foram inferiores ao método utilizado para a estimação do ruído independente do sinal. E ainda, notou-se que o Wiener Generalizado teve o desempenho menos reduzido quando utilizado o método Final do que os outros métodos e suas versões dependentes do sinal.

É importante ressaltar que os resultados obtidos neste experimento, que apontam um desempenho superior do método usado para a estimação do ruído independente do sinal, não

invalidam os resultados obtidos nesta tese, que mostram que o ruído é dependente do sinal e que adaptar a filtragem para considerá-lo apresenta melhor desempenho em CT. Isto se justifica, pois o método para a estimativa do ruído independente neste experimento utiliza a melhor estimativa possível da imagem livre de ruído, que é a própria imagem a ser estimada no processo de filtragem. Portanto, como o método Final está utilizando uma estimada da imagem livre de ruído dada pelo resultado da filtragem da imagem ruidosa por Non Local Means, espera-se que nestas condições o seu desempenho seja inferior. Assim, acredita-se que este resultado mostra apenas que quanto melhor a estimativa da imagem livre de ruído, melhor a estimativa do ruído e, conseqüentemente, um desempenho de filtragem superior.

A fim de uma melhor análise destes resultados e um melhor entendimento da influência dos parâmetros utilizados, nas Figuras D.7 a D.17 são apresentadas os gráficos comparativos entre as diferentes configurações de um mesmo método para algumas imagens, Lena e Mandril, tanto em termos de PSNR quanto SSIM. Basicamente, estas imagens resumem os padrões encontrados nas imagens testadas, uma vez que exceto o caso do Mandril, todas as outras se apresentam semelhantes aos resultados obtidos para a Lena.

Por fim, destes últimos resultados e considerando que a imagem do Mandril contém mais componentes de alta frequência (detalhes) do que a Lena podemos realizar algumas afirmações com relação aos parâmetros.

Primeiramente, para o Wiener Pontual, Wiener com MRF Isotrópico e Separável, há uma tendência ao desempenho ser reduzido conforme se aumenta o parâmetro  $w$ , apesar de que no caso representado pela Lena  $w = 5 \times 5$  foi superior a  $w = 3 \times 3$ , especialmente em termos de SSIM.

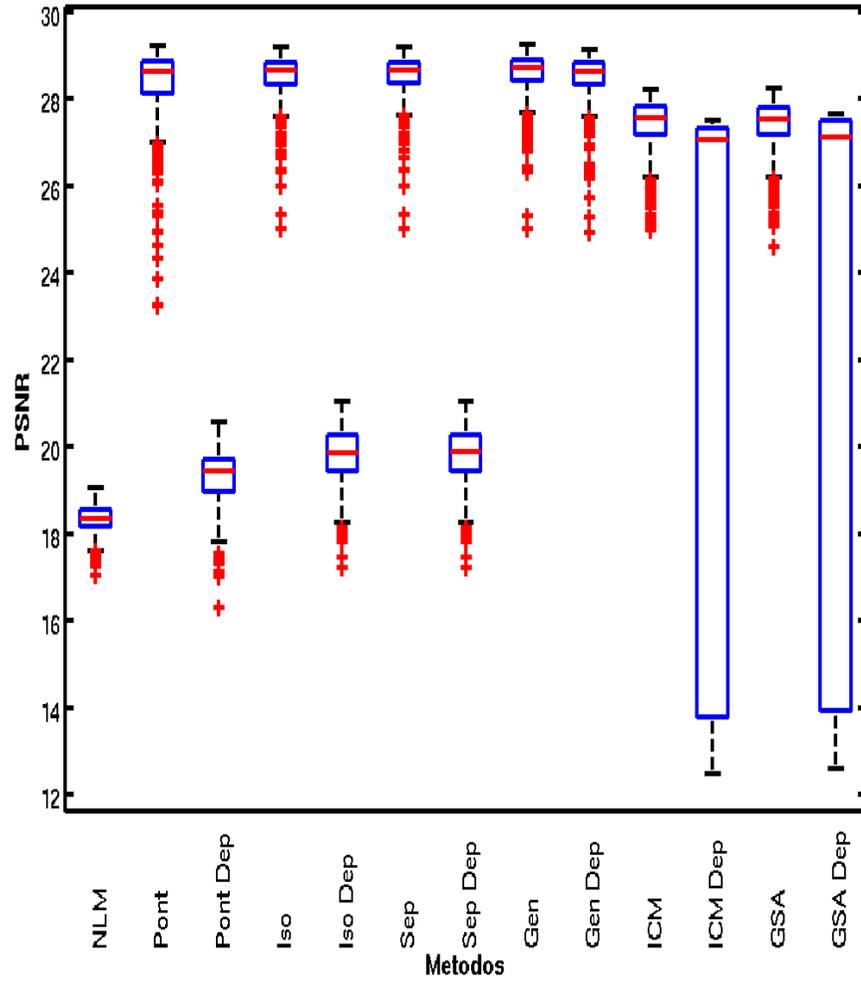
Segundo, para as imagens representadas pela Lena, o uso de estimação da imagem livre do ruído por Non Local Means para os métodos baseados em Wiener foi superior ao filtro da Média, enquanto que para o Mandril há o caso inverso. Como a imagem Mandril apresenta muitos detalhes finos agrupados, isto se justifica devido a uma menor preservação dos detalhes de borda pelo Non Local Means.

Terceiro, para o Wiener Generalizado notou-se que o desempenho tende a cair conforme se aumenta o parâmetro  $w$ . Além disso, notou-se que vizinhança de primeira ordem foi superior ao de segunda ordem. Vale ressaltar ainda que todas as diferenças tendem a cair con-

forme aumenta o parâmetro  $\alpha$ . Ainda, notou-se que no caso de  $w = 3 \times 3$  e vizinhança de primeira ordem, o desempenho para todos os valores de  $\alpha$  foi equivalente.

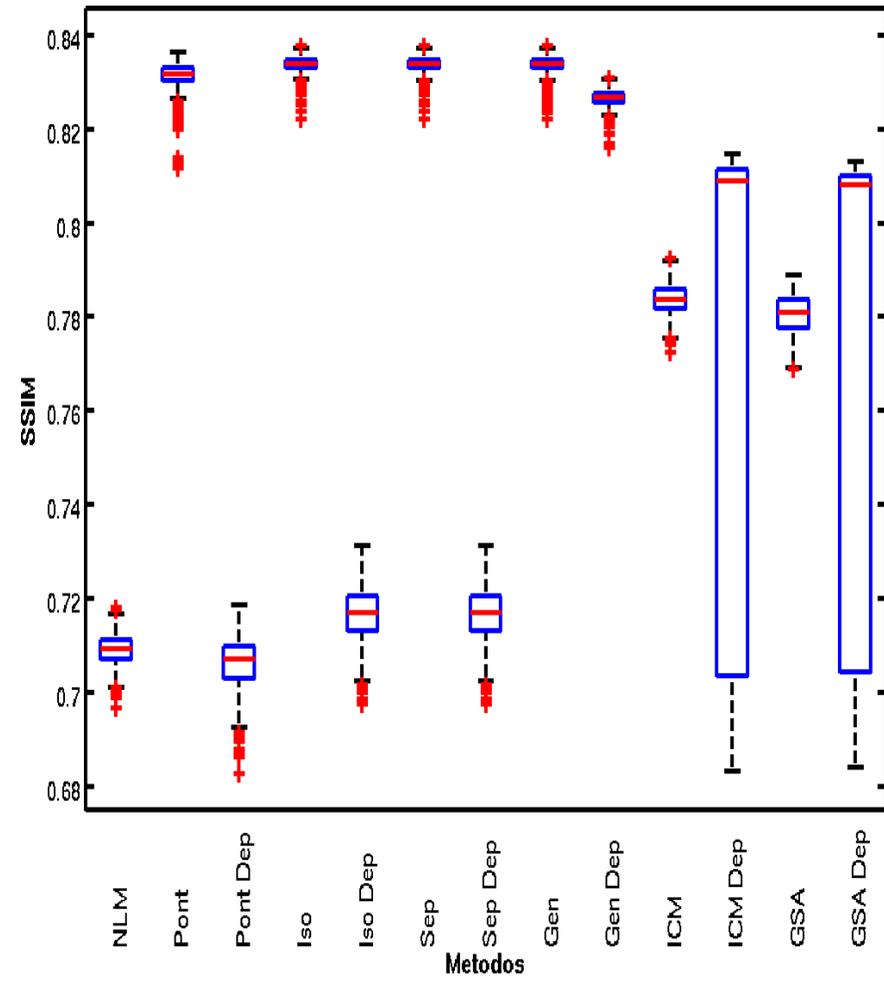
Finalmente, para o GSA, o desempenho aumentou para a Lena e reduziu para o Mandril conforme o parâmetro  $\alpha$  aumentava. Acredita-se que seja por motivo semelhante ao apontado na discussão do desempenho quando se consideram diferentes métodos de estimação da imagem livre de ruído, ao se usar valor de  $\alpha$  maiores, também há uma tendência a uma maior suavização, fazendo com que se percam detalhes importantes.

Resultado comparativo dos PSNRs dos melhores metodos para a imagem  
"lena\_gray\_512" criada com I0 = 8000.



(a)

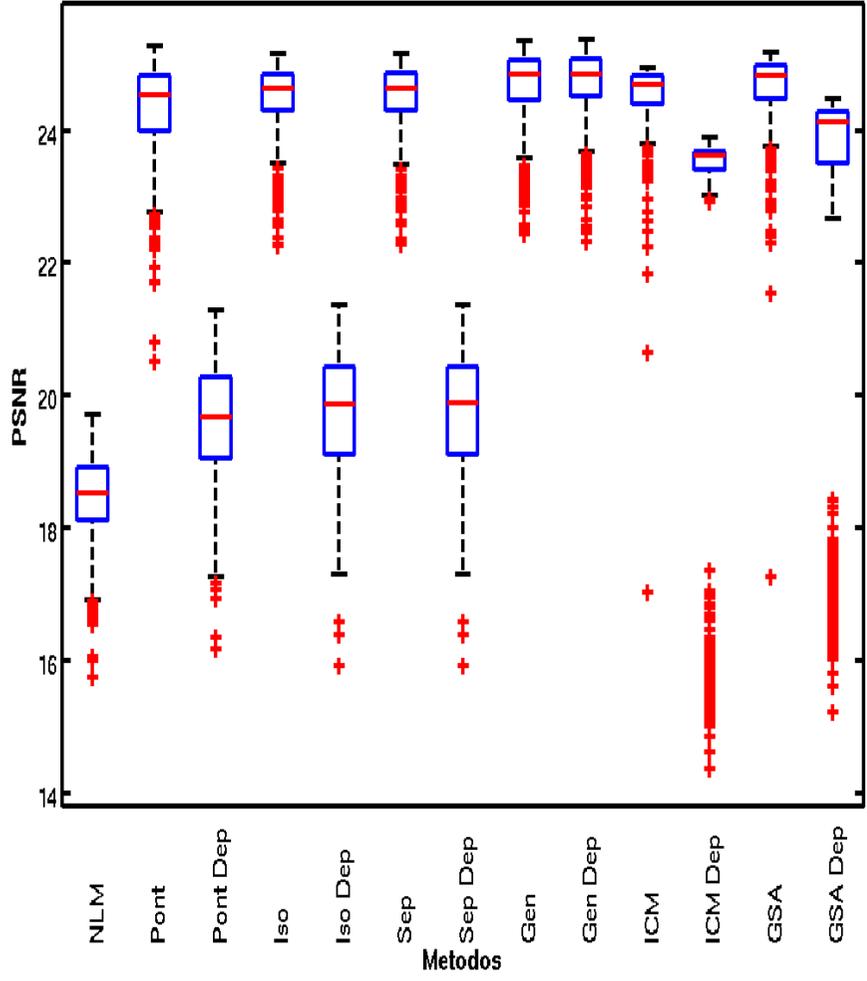
Resultado comparativo dos SSIMs dos melhores metodos para a imagem  
"lena\_gray\_512" criada com I0 = 8000.



(b)

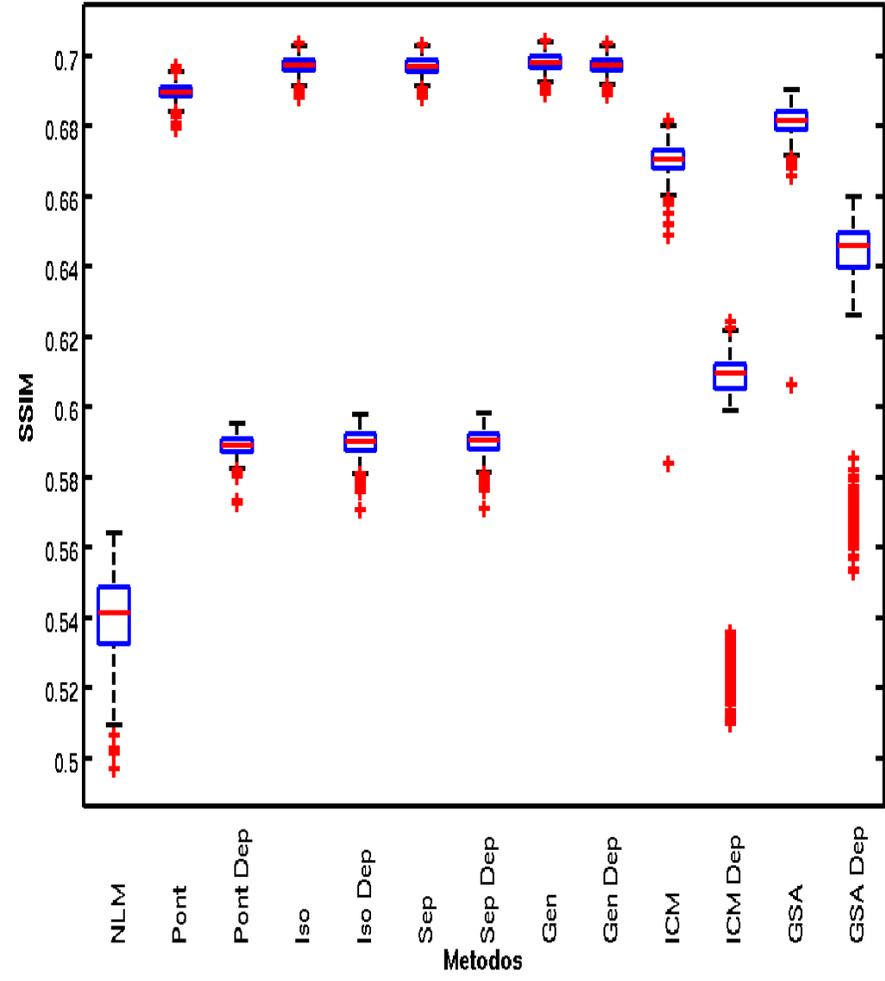
Figura D.1. Melhores resultados de filtragem em termos de (a) PSNR e (b) SSIM para a imagem "Lena" com I0 = 8000.

Resultado comparativo dos PSNRs dos melhores metodos para a imagem "mandril\_gray" criada com I0 = 8000.



(a)

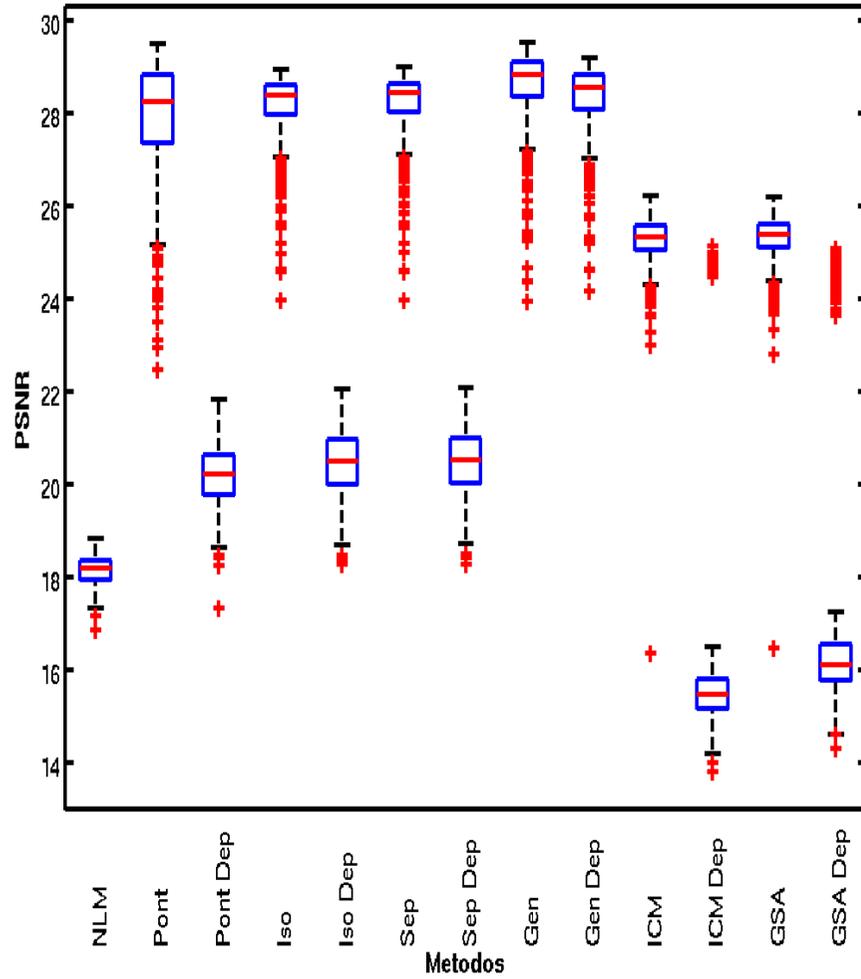
Resultado comparativo dos SSIMs dos melhores metodos para a imagem "mandril\_gray" criada com I0 = 8000.



(b)

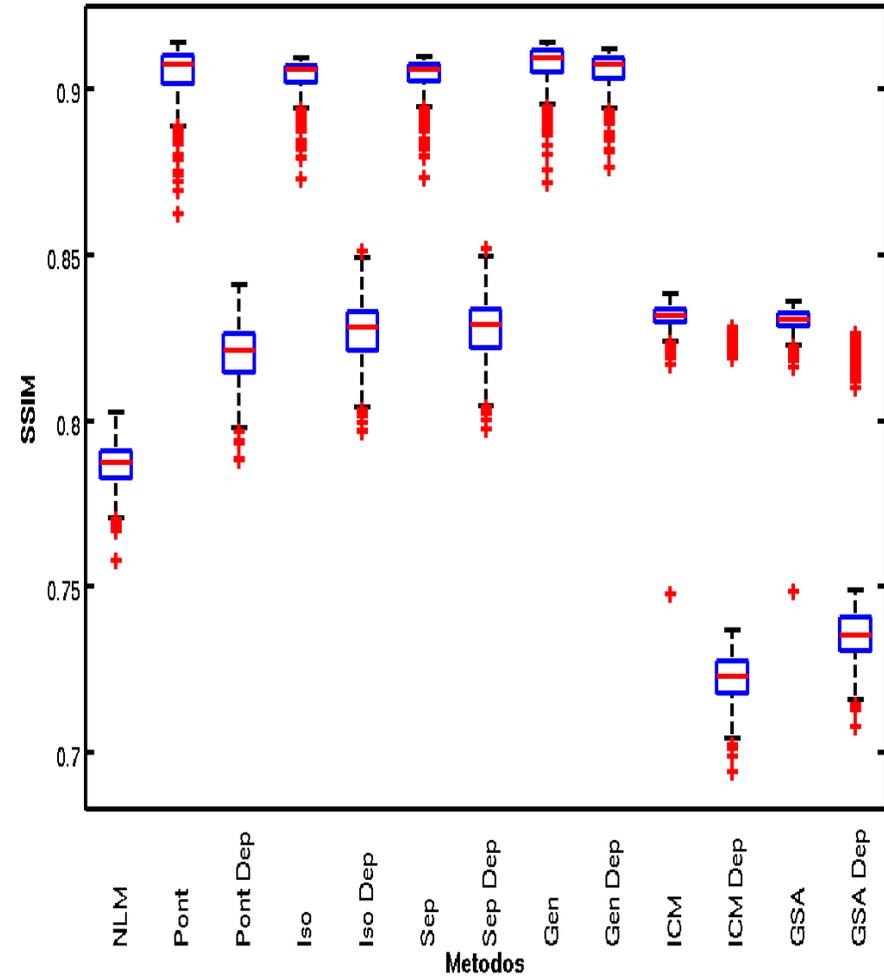
Figura D.2. Melhores resultados de filtragem em termos de (a) PSNR e (b) SSIM para a imagem "Mandril" com I0 = 8000.

Resultado comparativo dos PSNRs dos melhores metodos para a imagem  
 "sim\_class\_128\_beta\_1000\_iter\_30000" criada com I0 = 8000.



(a)

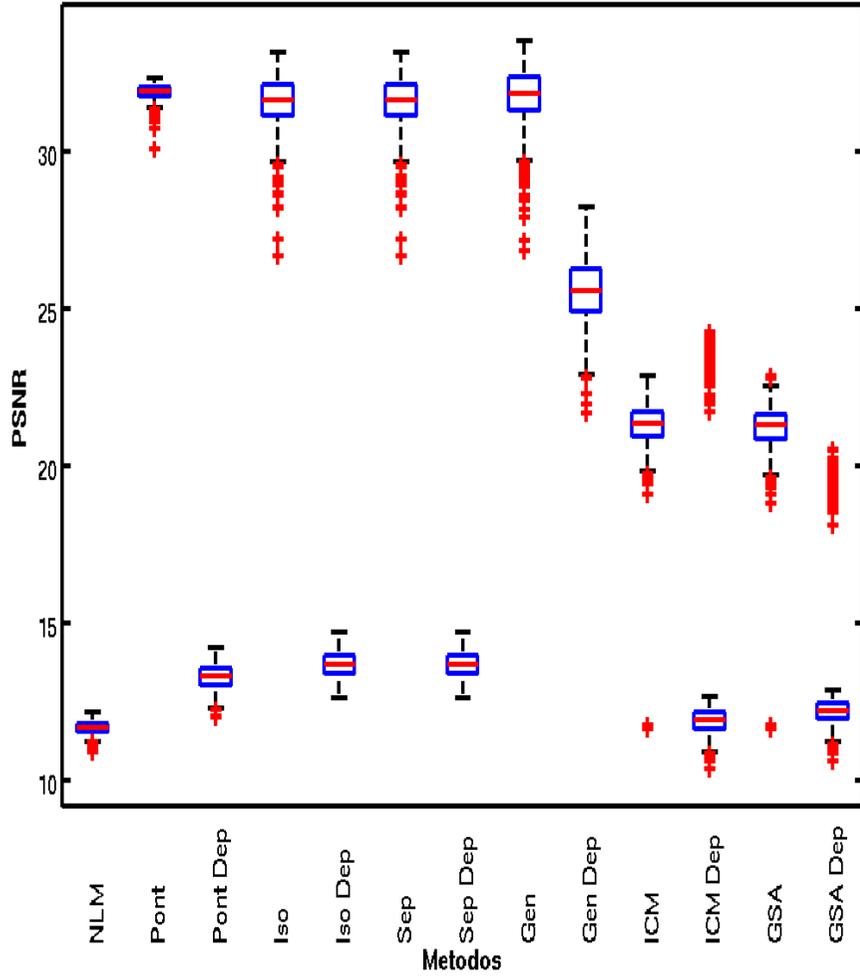
Resultado comparativo dos SSIMs dos melhores metodos para a imagem  
 "sim\_class\_128\_beta\_1000\_iter\_30000" criada com I0 = 8000.



(b)

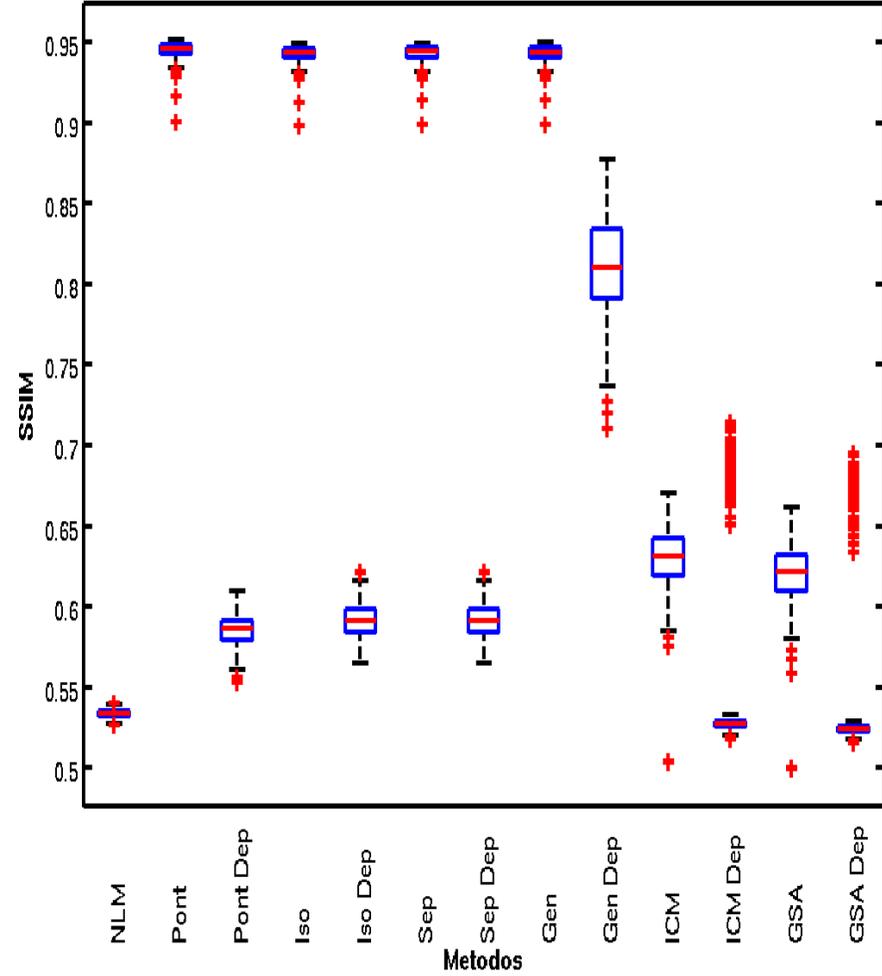
Figura D.3. Melhores resultados de filtragem em termos de (a) PSNR e (b) SSIM para a imagem "sim\_class\_128\_beta\_1000\_iter\_30000" com I0 = 8000.

Resultado comparativo dos PSNRs dos melhores metodos para a imagem "sim\_class\_2\_beta\_50\_iter\_5000" criada com I0 = 8000.



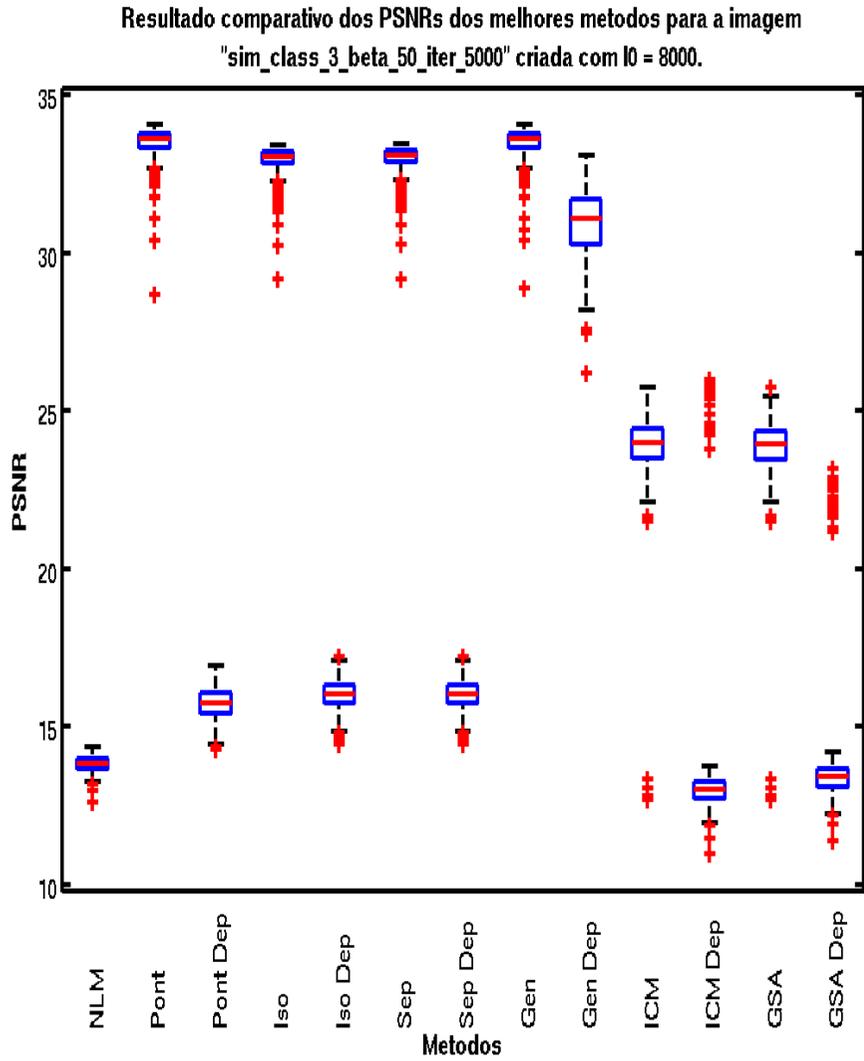
(a)

Resultado comparativo dos SSIMs dos melhores metodos para a imagem "sim\_class\_2\_beta\_50\_iter\_5000" criada com I0 = 8000.

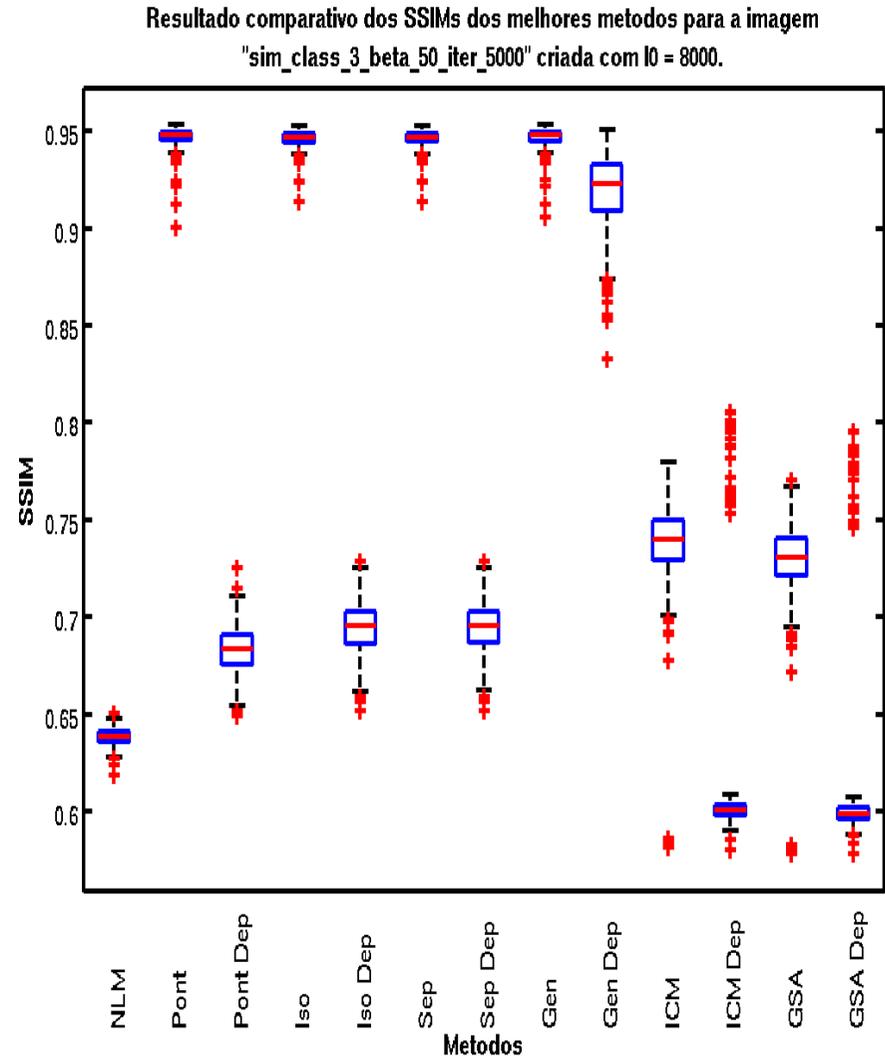


(b)

Figura D.4. Melhores resultados de filtragem em termos de (a) PSNR e (b) SSIM para a imagem "sim\_class\_2\_beta\_50\_iter\_5000" com I0 = 8000.



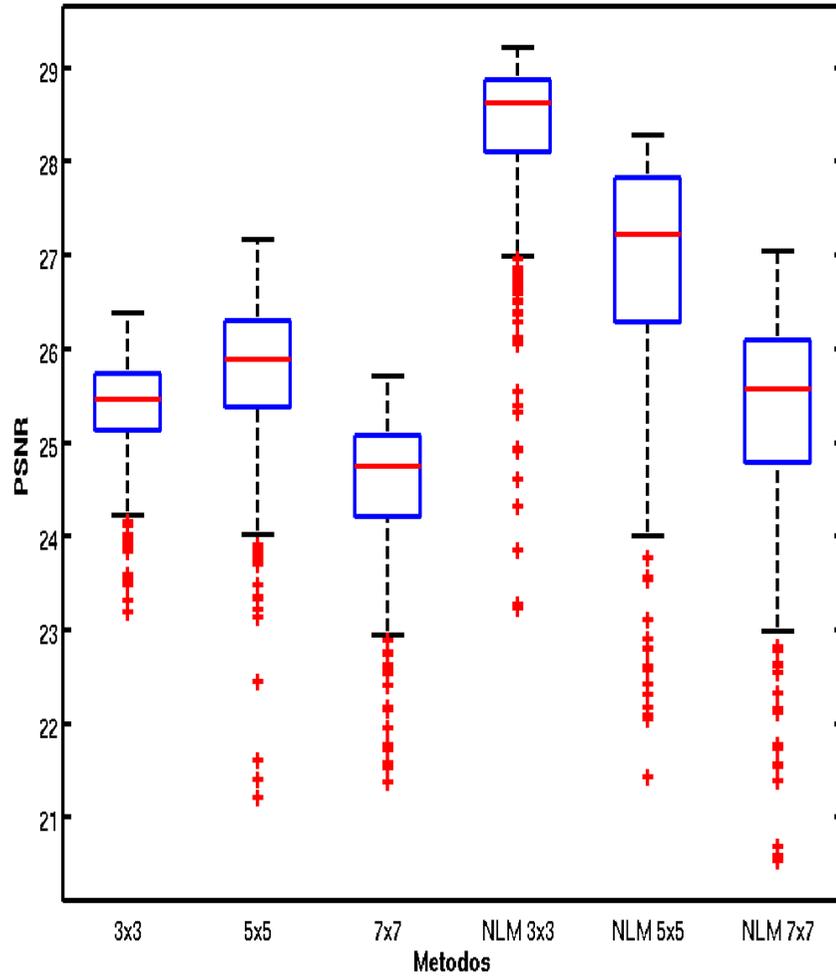
(a)



(b)

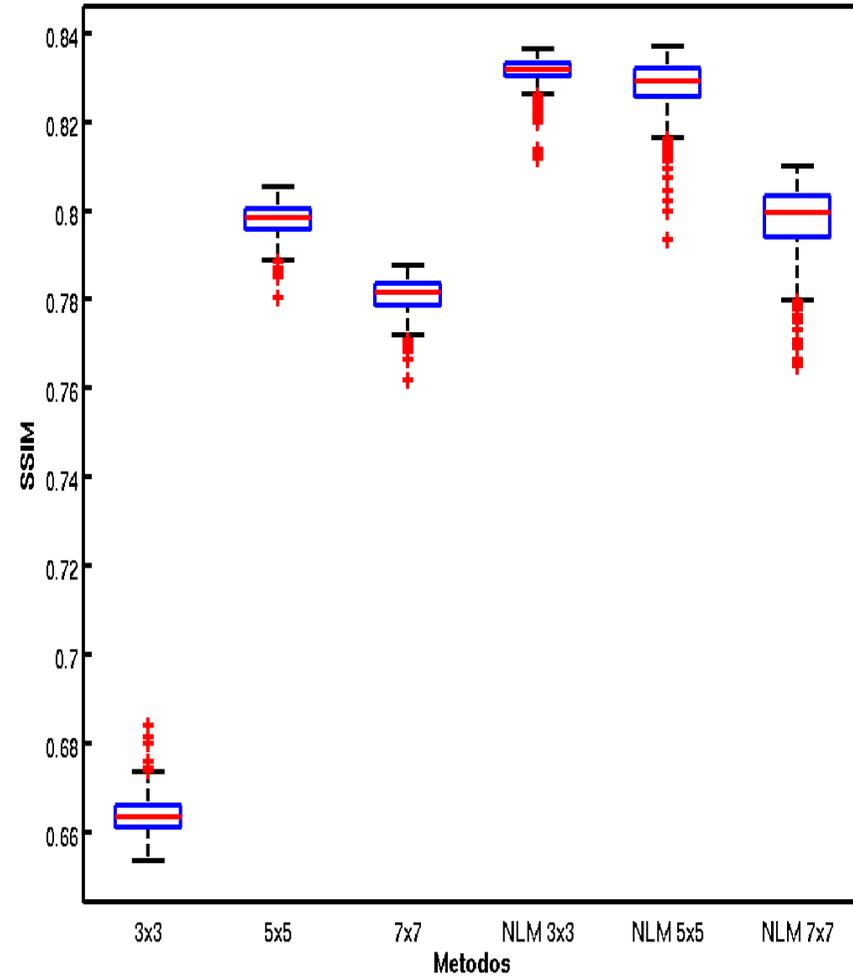
Figura D.5. Melhores resultados de filtragem em termos de (a) PSNR e (b) SSIM para a imagem "sim\_class\_3\_beta\_50\_iter\_5000" com I0 = 8000.

Resultado comparativo dos PSNRs do Wiener Pontual variando o parametro  $w$  para a imagem "lena\_gray\_512" criada com  $I_0 = 8000$ .



(a)

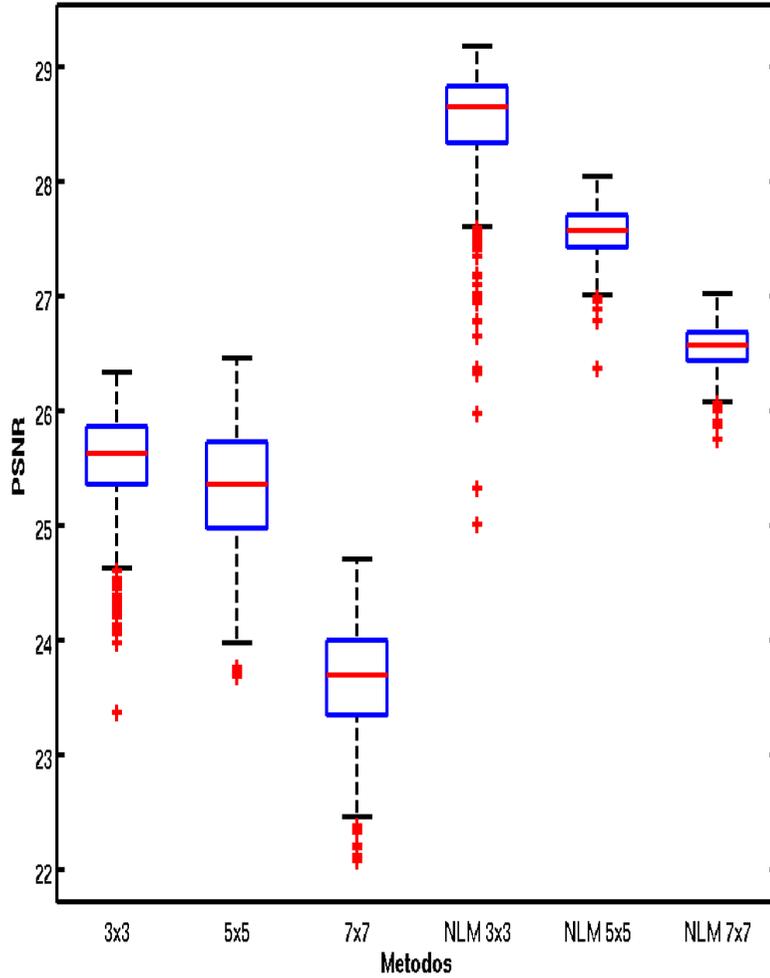
Resultado comparativo dos SSIMs do Wiener Pontual variando o parametro  $w$  para a imagem "lena\_gray\_512" criada com  $I_0 = 8000$ .



(b)

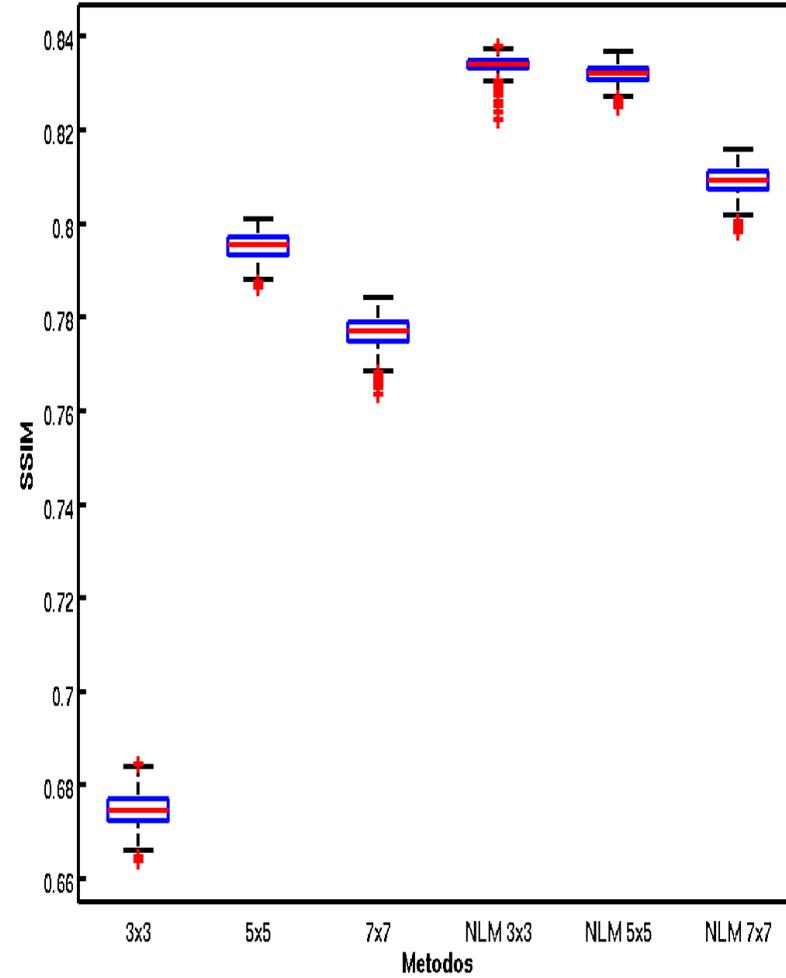
Figura D.6. Comparação entre as diferentes configurações dos parâmetros do Wiener Pontual em termos de (a) PSNR e (b) SSIM para a imagem "Lena" com  $I_0 = 8000$ .

Resultado comparativo dos PSNRs do Wiener com MRF Isotrópico variando o parâmetro  $w$  para a imagem "lena\_gray\_512" criada com  $I_0 = 8000$ .



(a)

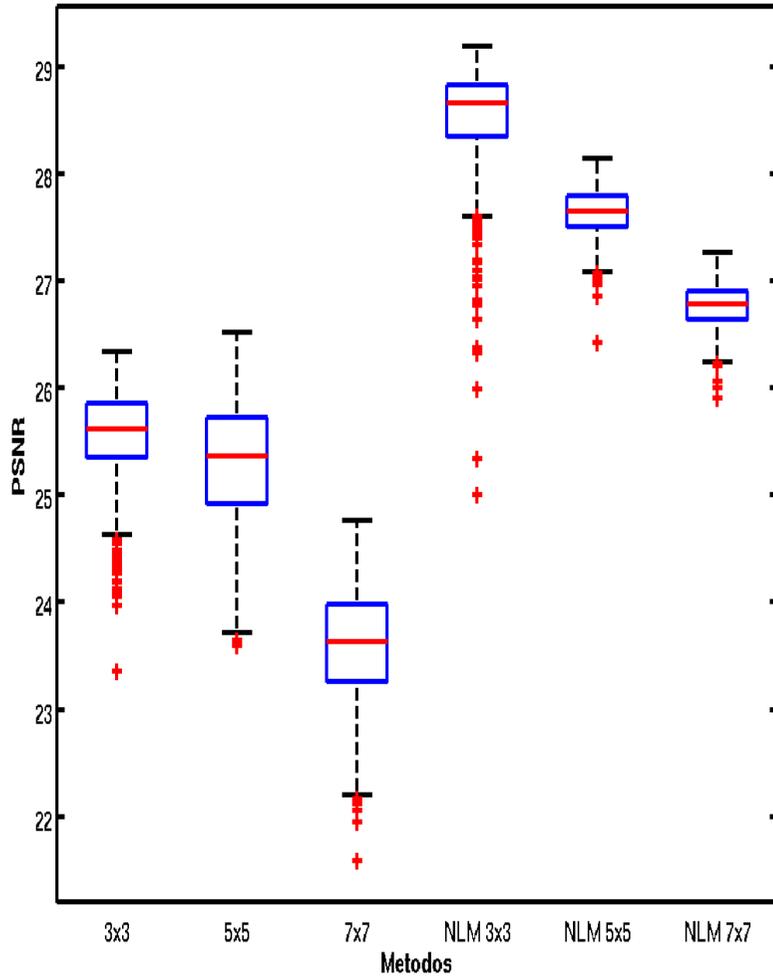
Resultado comparativo dos SSIMs do Wiener com MRF Isotrópico variando o parâmetro  $w$  para a imagem "lena\_gray\_512" criada com  $I_0 = 8000$ .



(b)

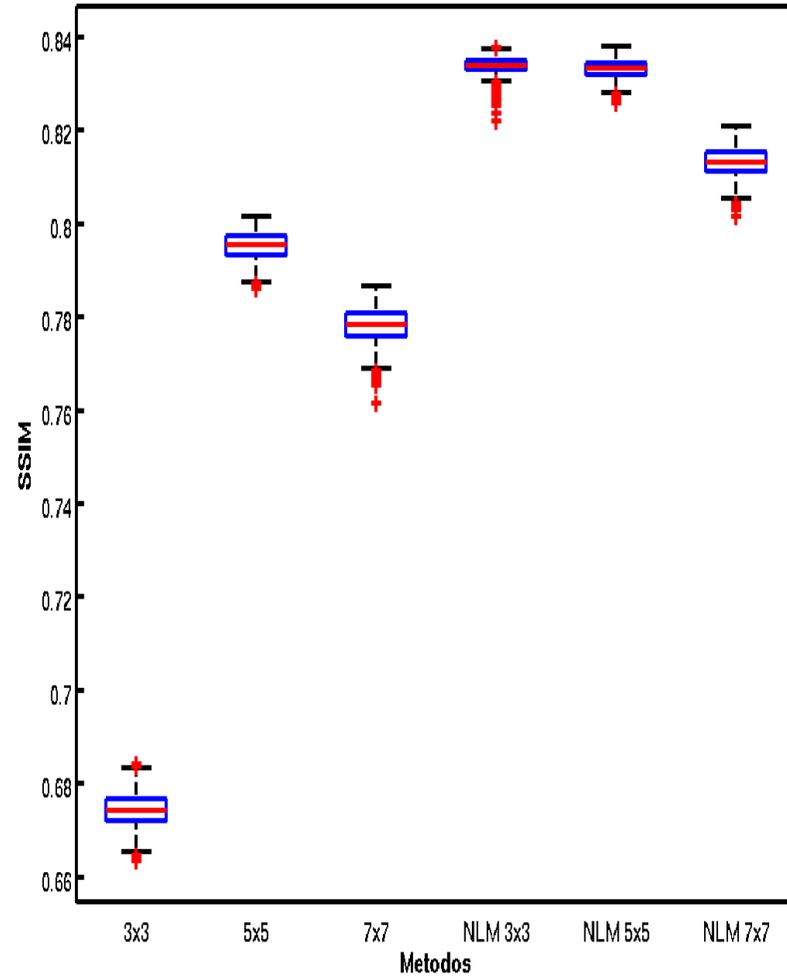
**Figura D.7.** Comparação entre as diferentes configurações dos parâmetros do Wiener com MRF Isotrópico em termos de (a) PSNR e (b) SSIM para a imagem "Lena" com  $I_0 = 8000$ .

Resultado comparativo dos PSNRs do Wiener com MRF Separavel variando o parametro w para a imagem "lena\_gray\_512" criada com I0 = 8000.



(a)

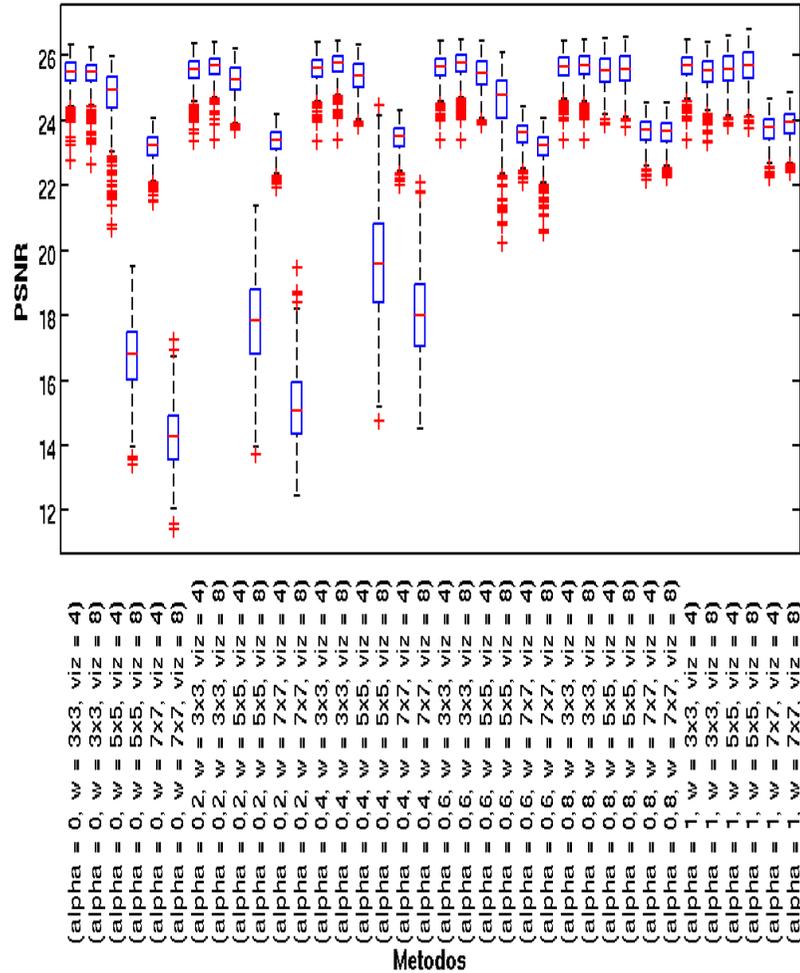
Resultado comparativo dos SSIMs do Wiener com MRF Separavel variando o parametro w para a imagem "lena\_gray\_512" criada com I0 = 8000.



(b)

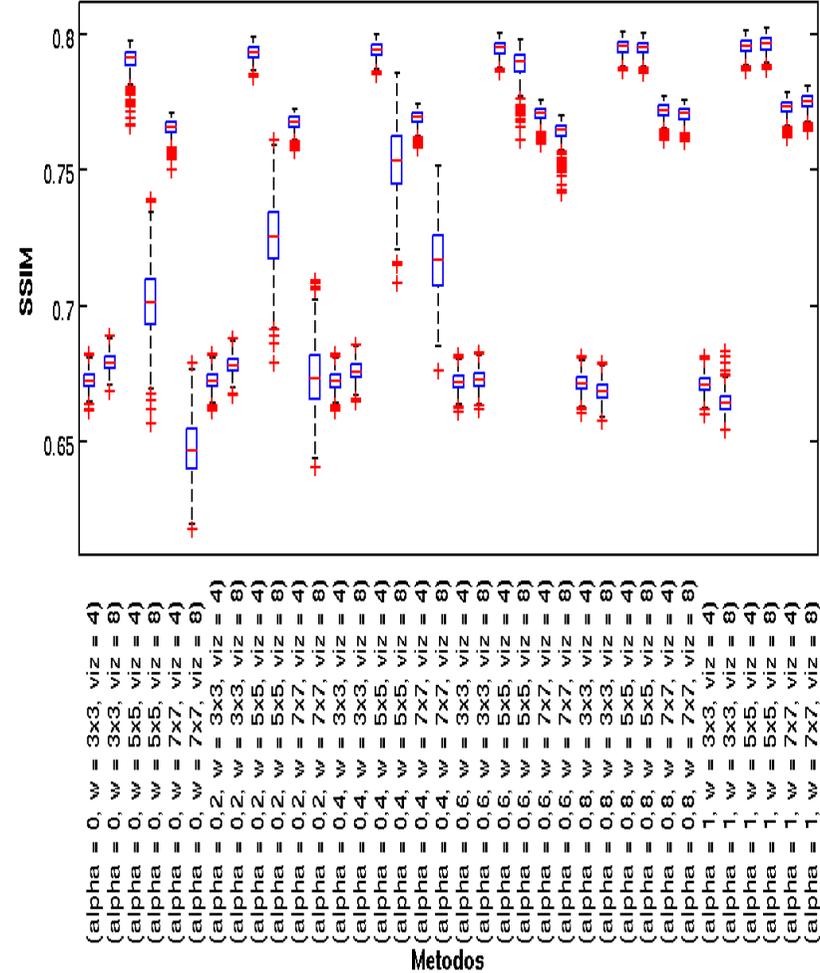
Figura D.8. Comparação entre as diferentes configurações dos parâmetros do Wiener com MRF Separável em termos de (a) PSNR e (b) SSIM para a imagem “Lena” com I0 = 8000.

Resultado comparativo dos PSNRs do Wiener Generalizado (Media) variando os parametros alpha, w, viz para a imagem "lena\_gray\_512" criada com I0 = 8000.



(a)

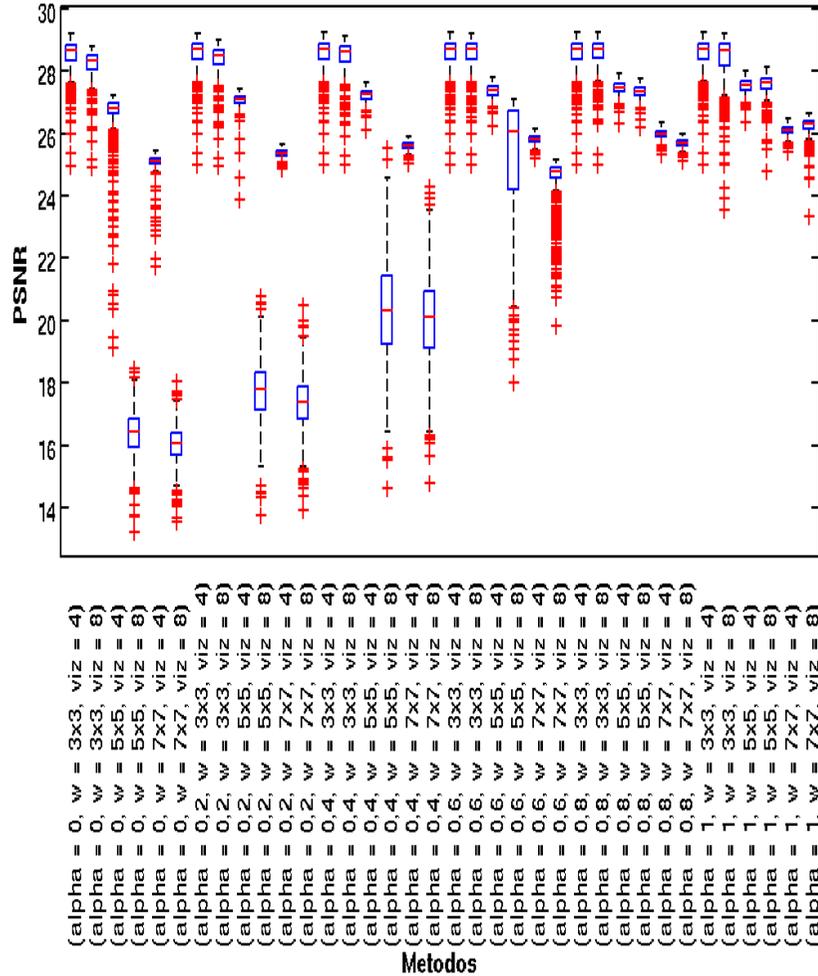
Resultado comparativo dos SSIMs do Wiener Generalizado (Media) variando os parametros alpha, w, viz para a imagem "lena\_gray\_512" criada com I0 = 8000.



(b)

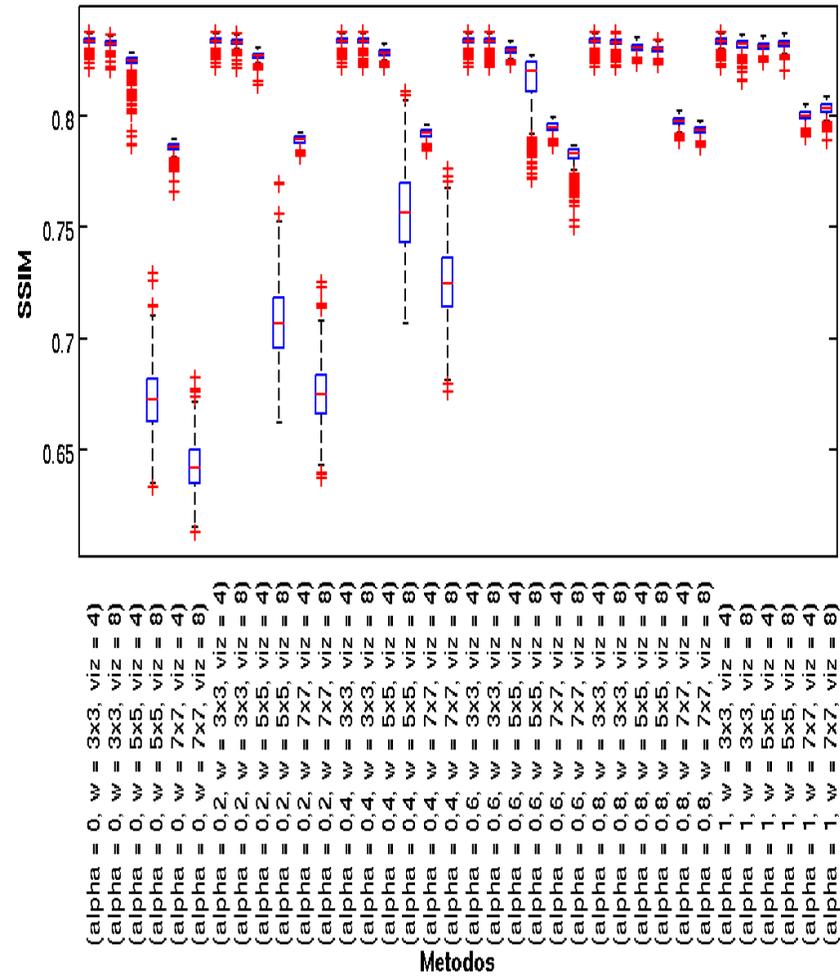
Figura D.9. Comparação entre as diferentes configurações dos parâmetros do Wiener Generalizado com estimativa da imagem livre de ruído dada pelo Filtro da Média em termos de (a) PSNR e (b) SSIM para a imagem “Lena” com I0 = 8000.

Resultado comparativo dos PSNRs do Wiener Generalizado (NLM) variando os parametros alpha, w, viz para a imagem "lena\_gray\_512" criada com I0 = 8000.



(a)

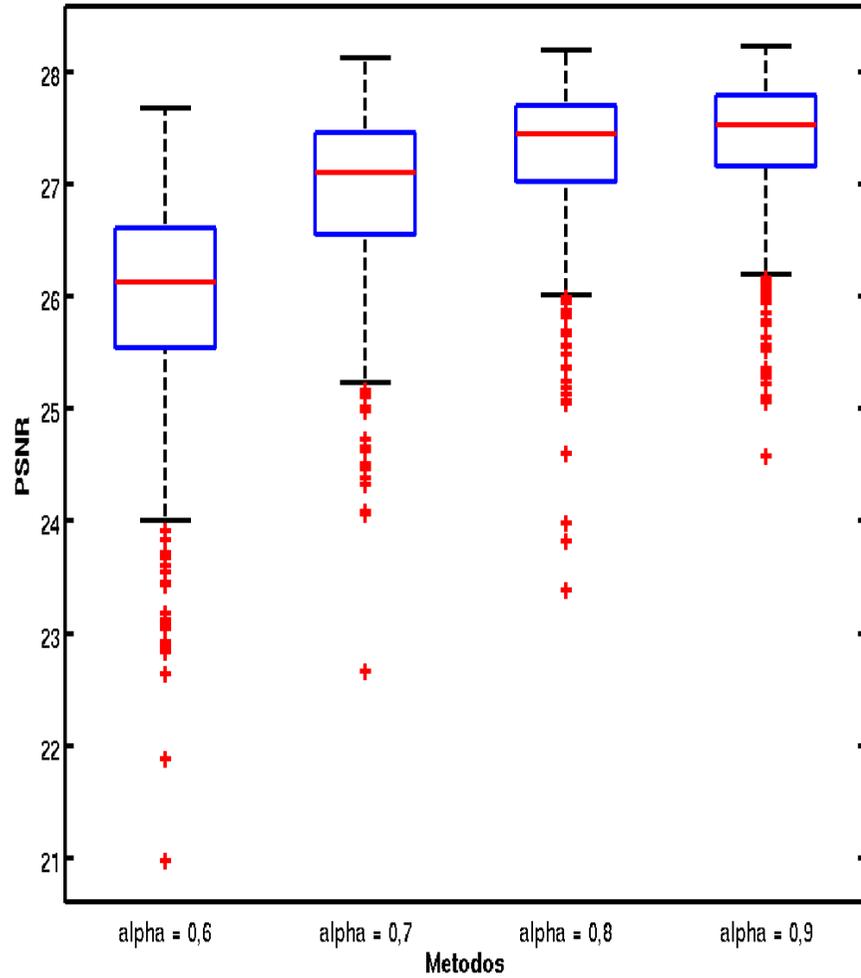
Resultado comparativo dos SSIMs do Wiener Generalizado (NLM) variando os parametros alpha, w, viz para a imagem "lena\_gray\_512" criada com I0 = 8000.



(b)

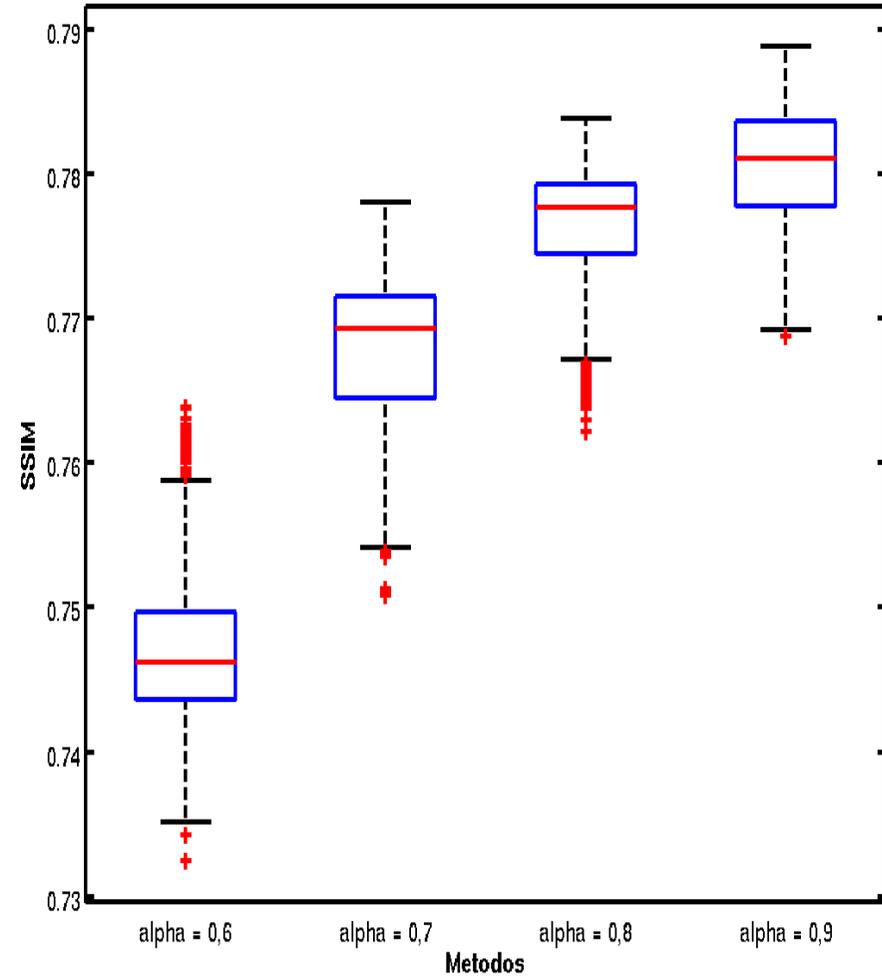
Figura D.10. Comparação entre as diferentes configurações dos parâmetros do Wiener Generalizado com estimativa da imagem livre de ruído dada pelo Non Local Means em termos de (a) PSNR e (b) SSIM para a imagem “Lena” com I0 = 8000.

Resultado comparativo dos PSNRs do GSA variando o parametro alpha para a imagem "lena\_gray\_512" criada com I0 = 8000.



(a)

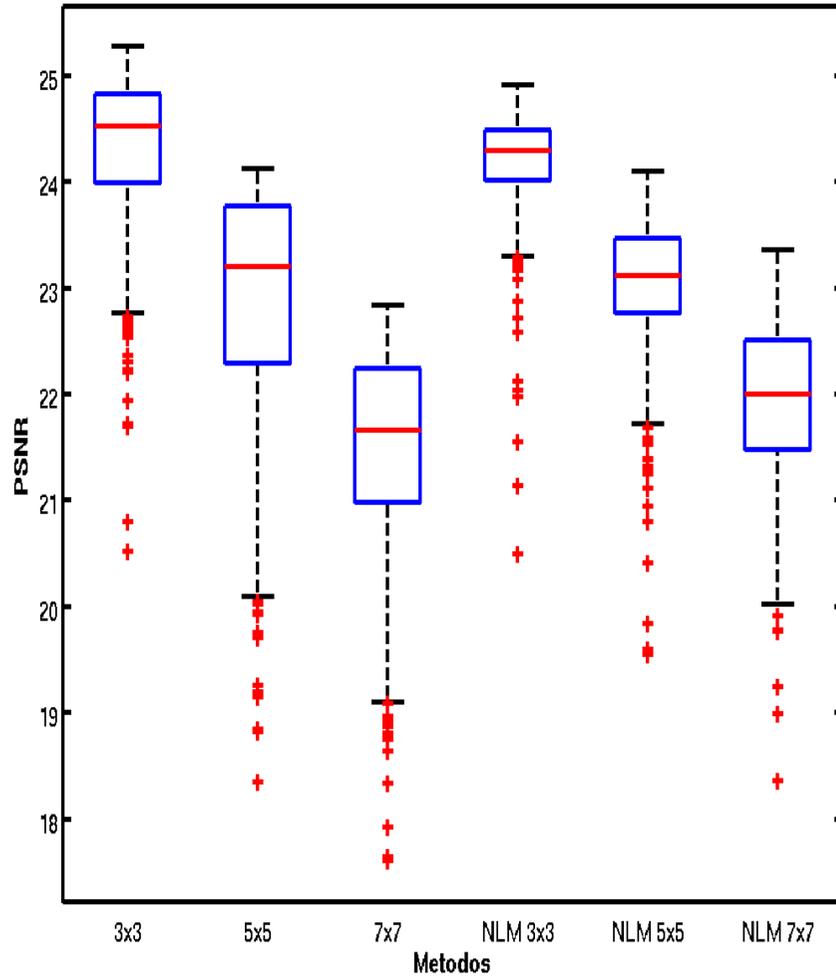
Resultado comparativo dos SSIMs do GSA variando o parametro alpha para a imagem "lena\_gray\_512" criada com I0 = 8000.



(b)

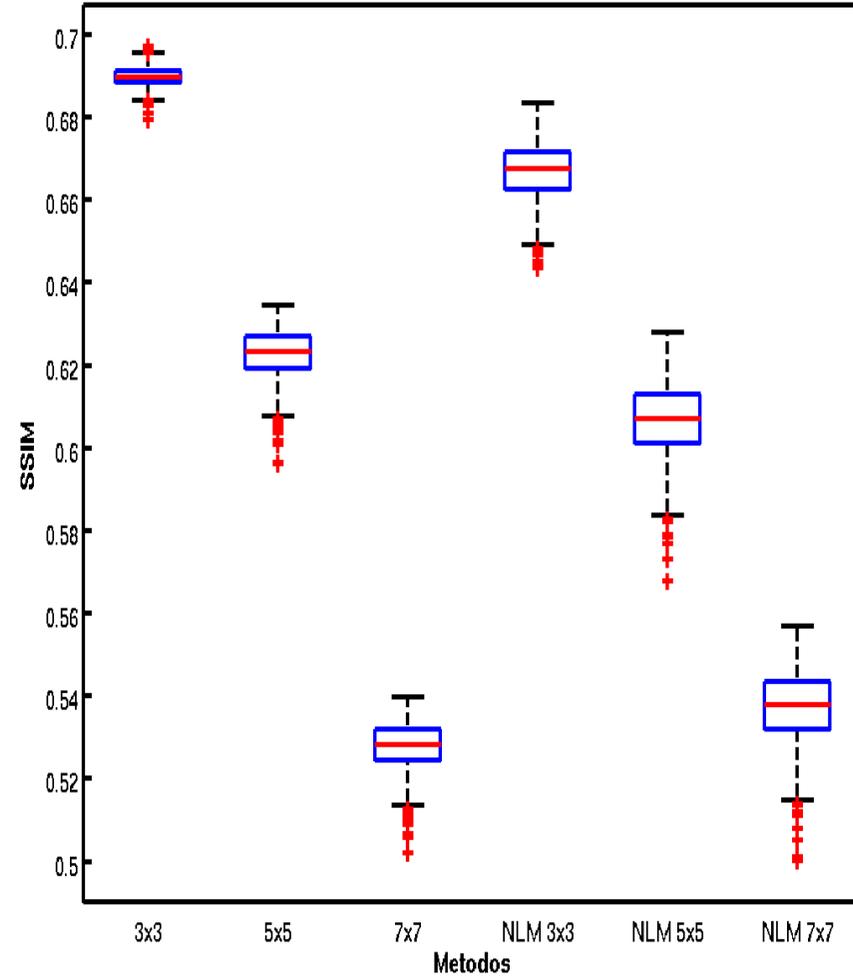
Figura D.11. Comparação entre as diferentes configurações do parâmetro  $\alpha$  do GSA em termos de (a) PSNR e (b) SSIM para a imagem "Lena" com  $I_0 = 8000$ .

Resultado comparativo dos PSNRs do Wiener Pontual variando o parametro  $w$  para a imagem "mandril\_gray" criada com  $I0 = 8000$ .



(a)

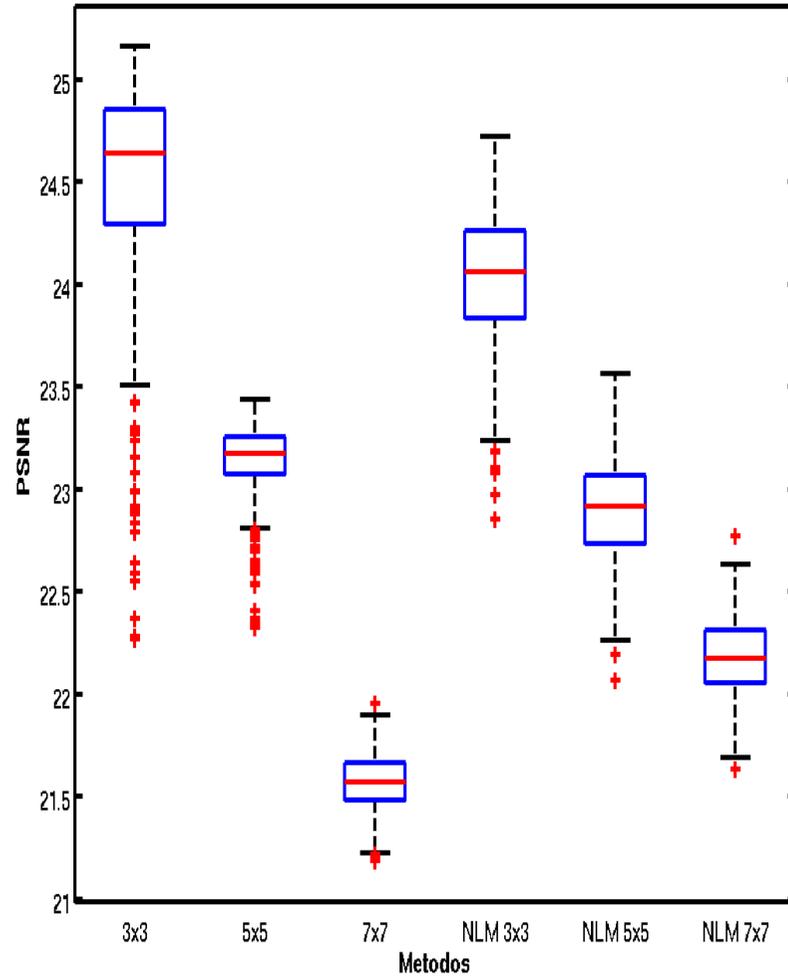
Resultado comparativo dos SSIMs do Wiener Pontual variando o parametro  $w$  para a imagem "mandril\_gray" criada com  $I0 = 8000$ .



(b)

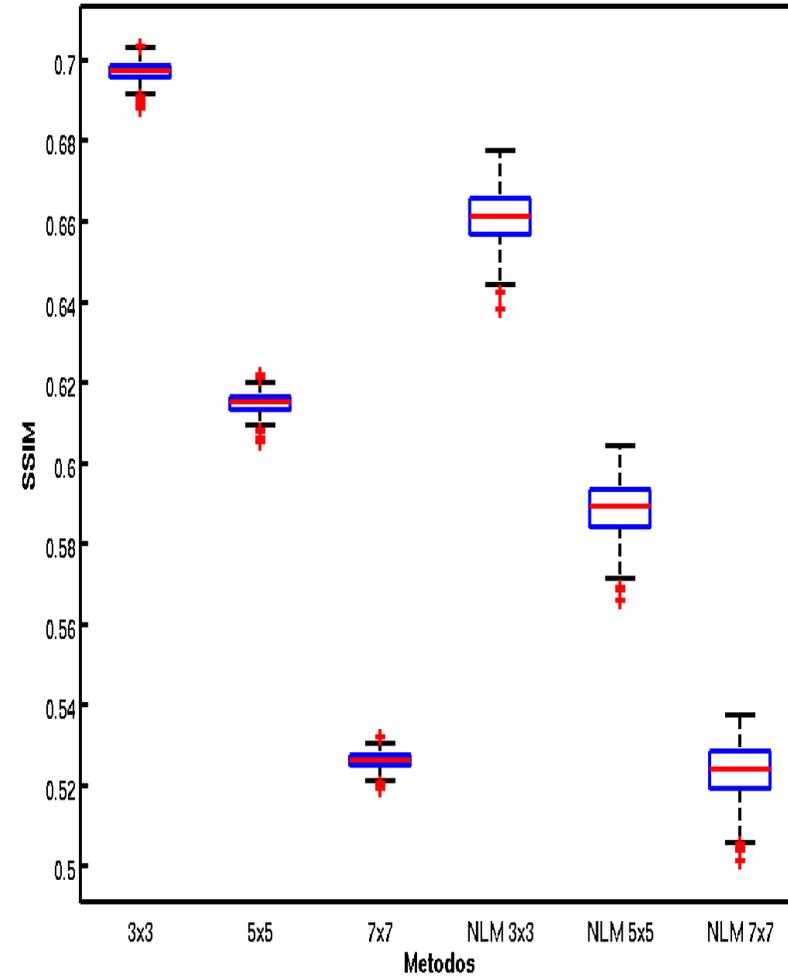
Figura D.12. Comparação entre as diferentes configurações dos parâmetros do Wiener Pontual em termos de (a) PSNR e (b) SSIM para a imagem "Mandril" com  $I0 = 8000$ .

Resultado comparativo dos PSNRs do Wiener com MRF Isotropico variando o parametro w para a imagem "mandril\_gray" criada com  $I_0 = 8000$ .



(a)

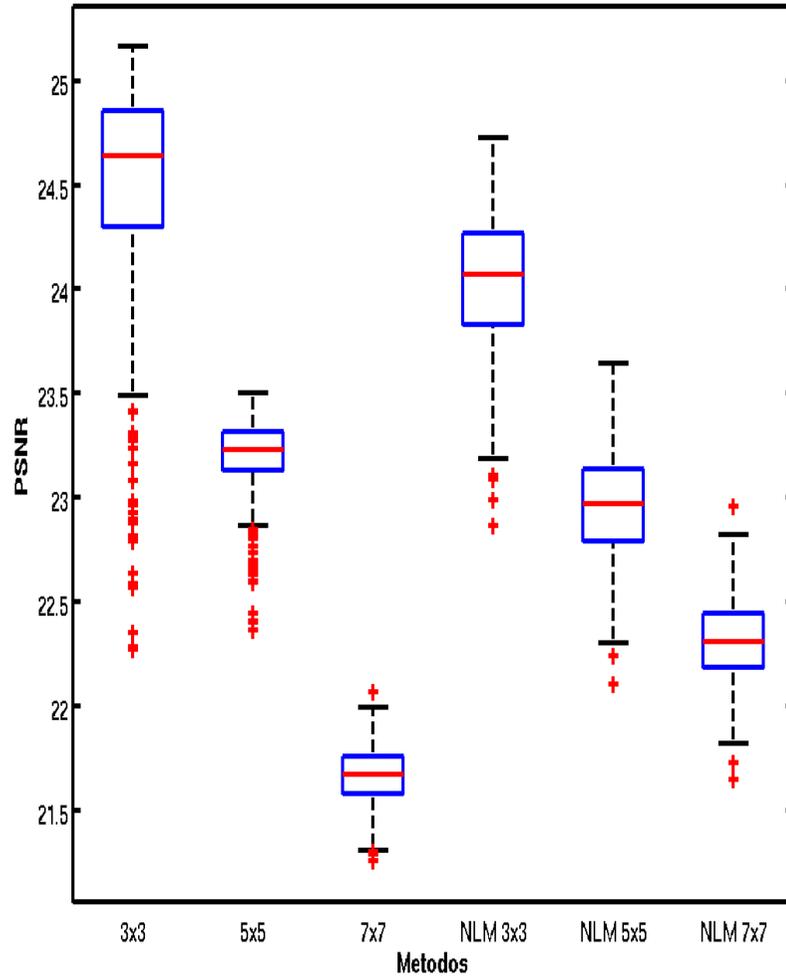
Resultado comparativo dos SSIMs do Wiener com MRF Isotropico variando o parametro w para a imagem "mandril\_gray" criada com  $I_0 = 8000$ .



(b)

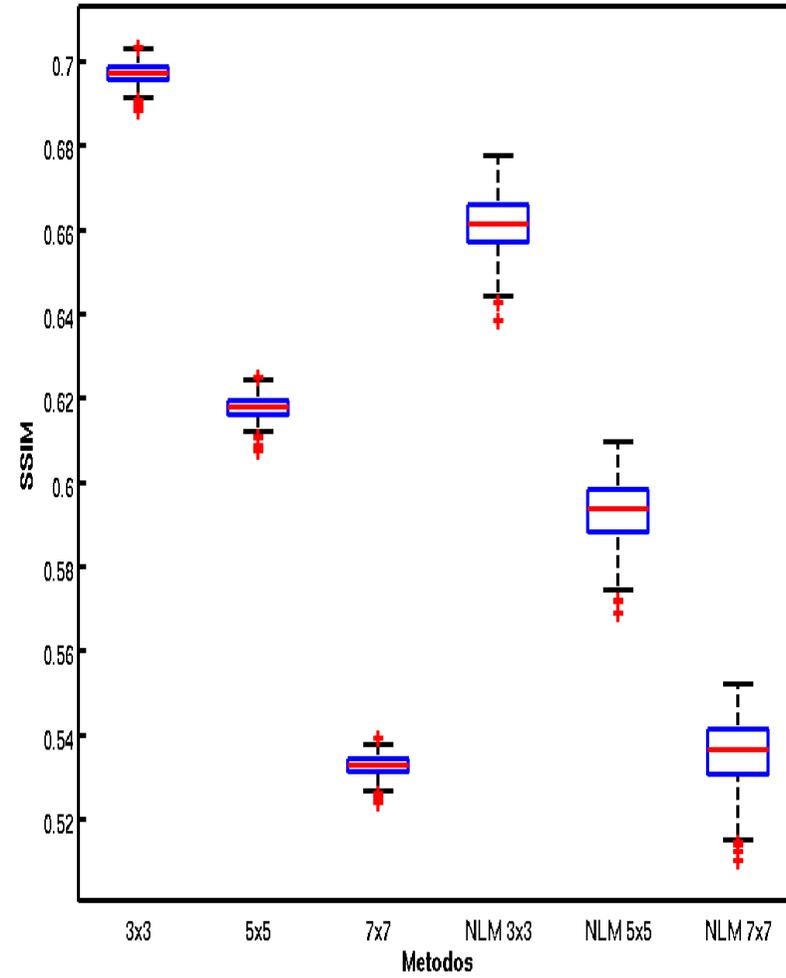
**Figura D.13.** Comparação entre as diferentes configurações dos parâmetros do Wiener com MRF Isotrópico em termos de (a) PSNR e (b) SSIM para a imagem "Mandril" com  $I_0 = 8000$ .

Resultado comparativo dos PSNRs do Wiener com MRF Separavel variando o parametro  $w$  para a imagem "mandril\_gray" criada com  $I_0 = 8000$ .



(a)

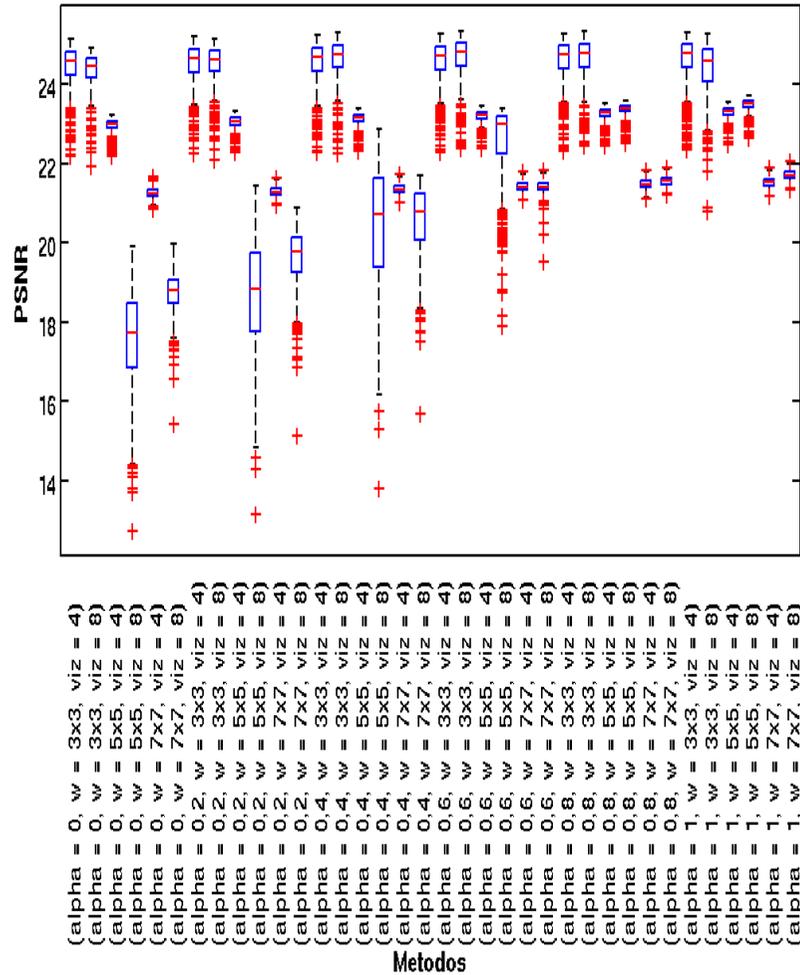
Resultado comparativo dos SSIMs do Wiener com MRF Separavel variando o parametro  $w$  para a imagem "mandril\_gray" criada com  $I_0 = 8000$ .



(b)

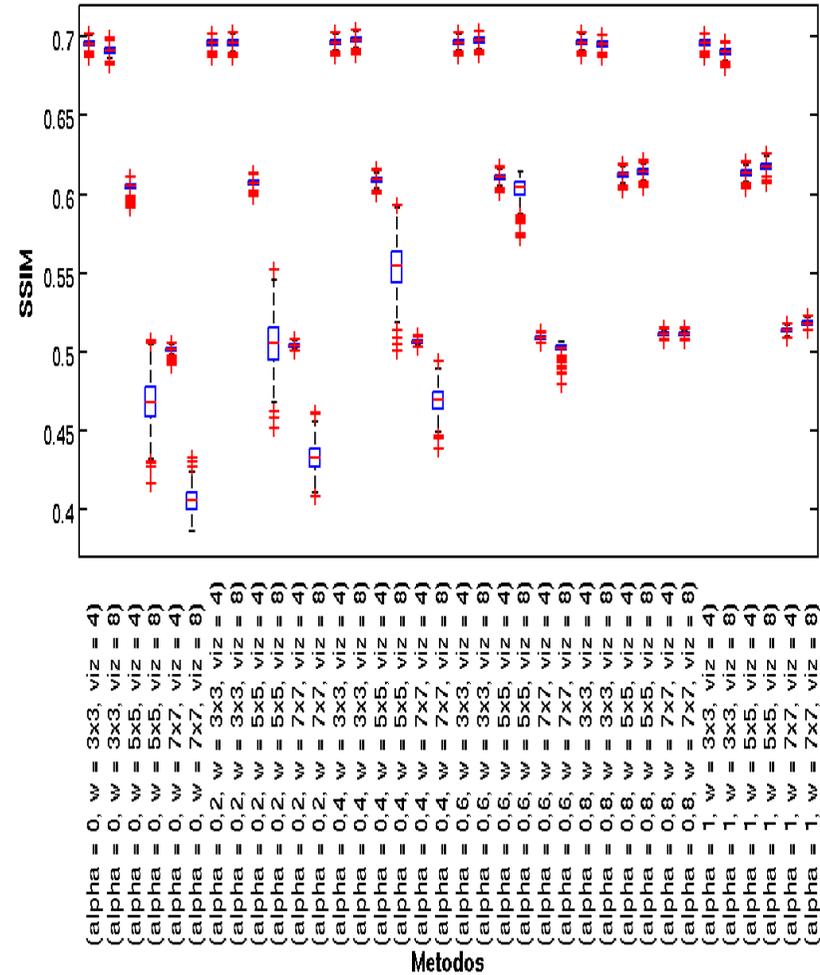
**Figura D.14.** Comparação entre as diferentes configurações dos parâmetros do Wiener com MRF Separável em termos de (a) PSNR e (b) SSIM para a imagem "Mandril" com  $I_0 = 8000$ .

Resultado comparativo dos PSNRs do Wiener Generalizado (Media) variando os parametros alpha, w, viz para a imagem "mandril\_gray" criada com I0 = 8000.



(a)

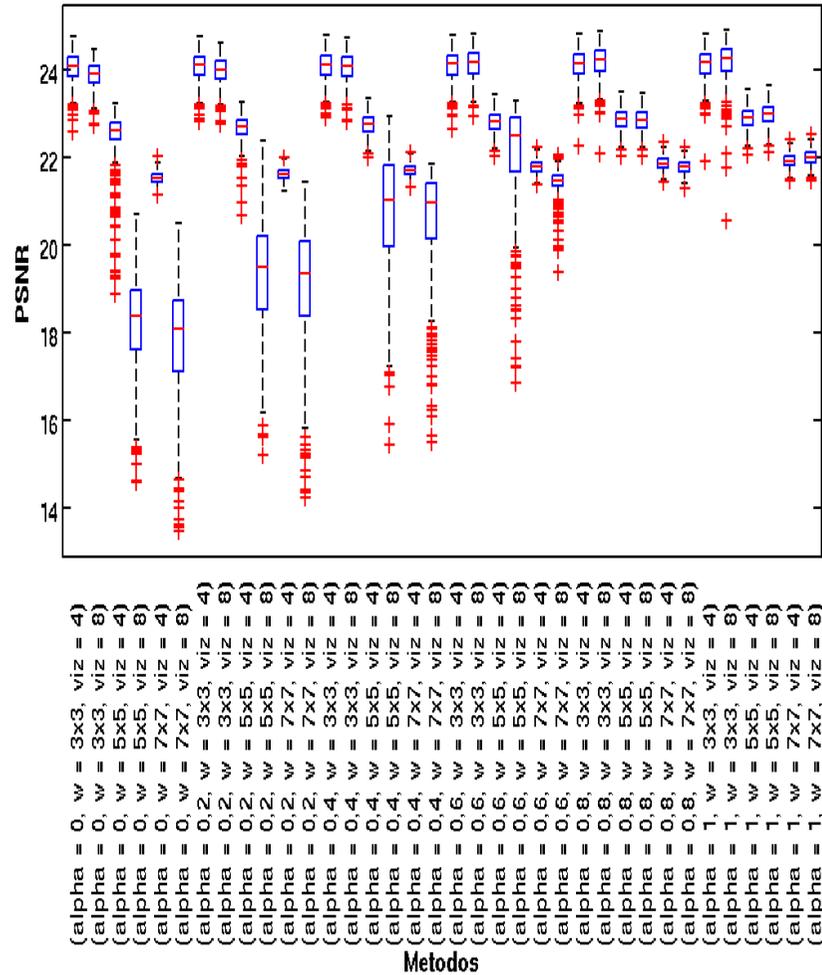
Resultado comparativo dos SSIMs do Wiener Generalizado (Media) variando os parametros alpha, w, viz para a imagem "mandril\_gray" criada com I0 = 8000.



(b)

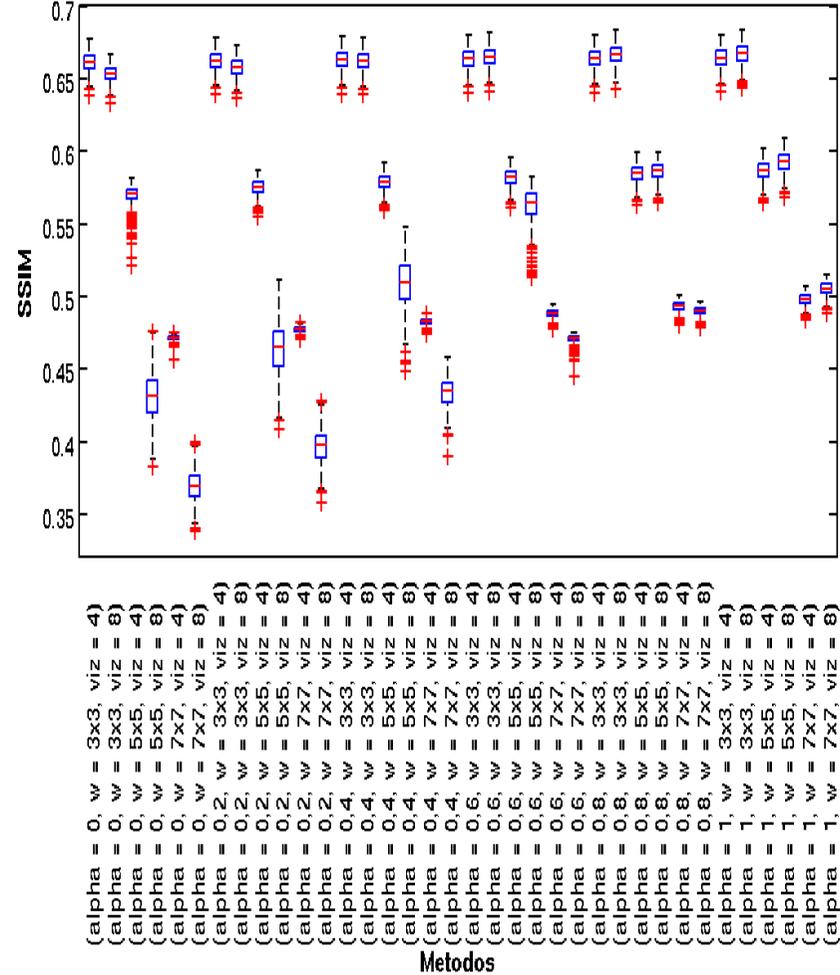
Figura D.15. Comparação entre as diferentes configurações dos parâmetros do Wiener Generalizado com estimativa da imagem livre de ruído dada pelo Filtro da Média em termos de (a) PSNR e (b) SSIM para a imagem "Mandril" com I0 = 8000.

Resultado comparativo dos PSNRs do Wiener Generalizado (NLM) variando os parametros alpha, w, viz para a imagem "mandril\_gray" criada com I0 = 8000.



(a)

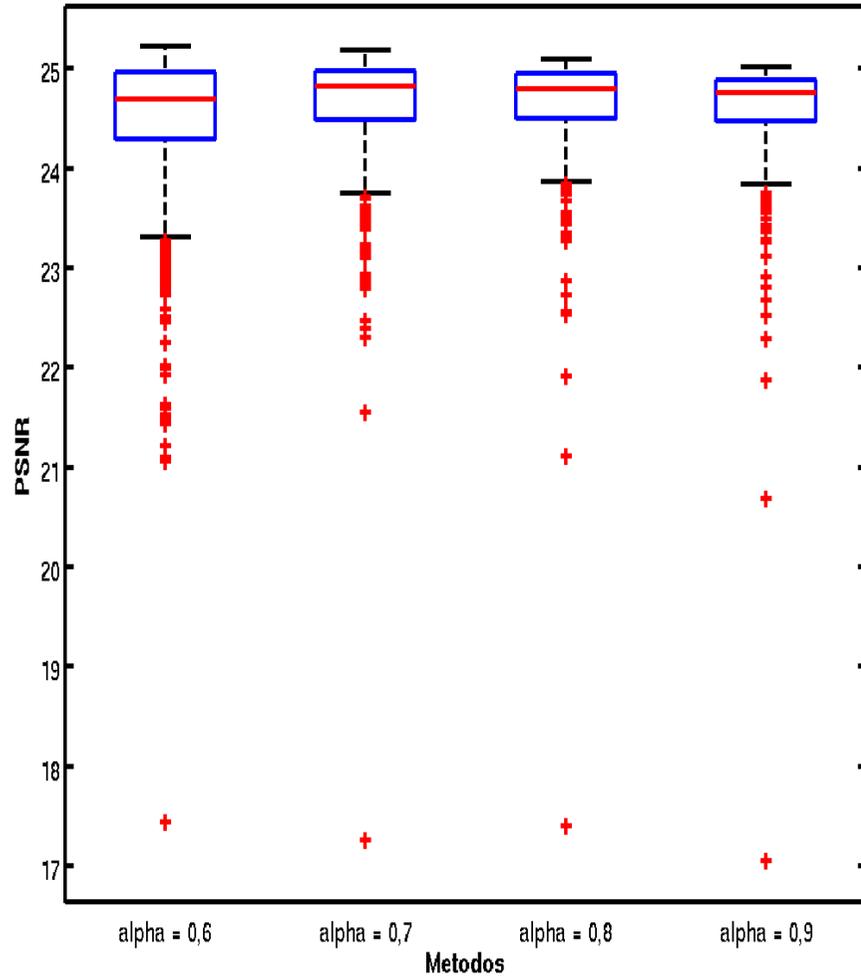
Resultado comparativo dos SSIMs do Wiener Generalizado (NLM) variando os parametros alpha, w, viz para a imagem "mandril\_gray" criada com I0 = 8000.



(b)

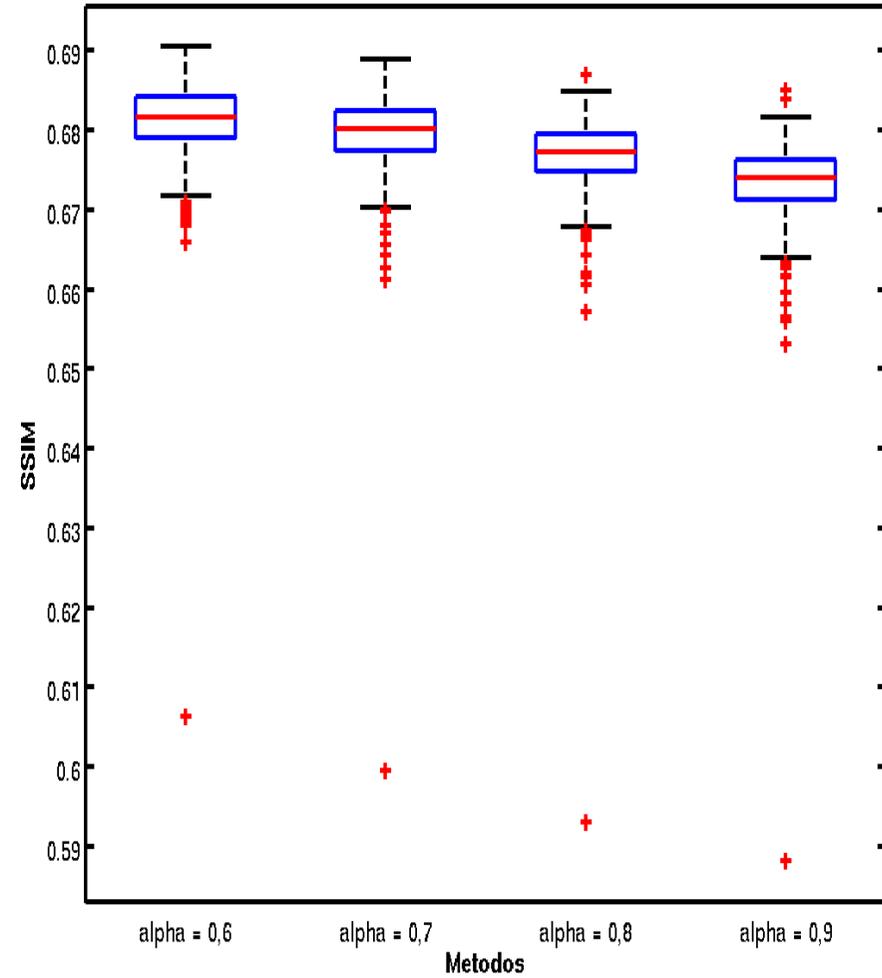
Figura D.16. Comparação entre as diferentes configurações dos parâmetros do Wiener Generalizado com estimativa da imagem livre de ruído dada pelo Non Local Means em termos de (a) PSNR e (b) SSIM para a imagem "Mandril" com I0 = 8000.

Resultado comparativo dos PSNRs do GSA variando o parametro alpha para a imagem "mandril\_gray" criada com I0 = 8000.



(a)

Resultado comparativo dos SSIMs do GSA variando o parametro alpha para a imagem "mandril\_gray" criada com I0 = 8000.



(b)

Figura D.17. Comparação entre as diferentes configurações do parâmetro  $\alpha$  do GSA em termos de (a) PSNR e (b) SSIM para a imagem "Mandril" com  $I_0 = 8000$ .

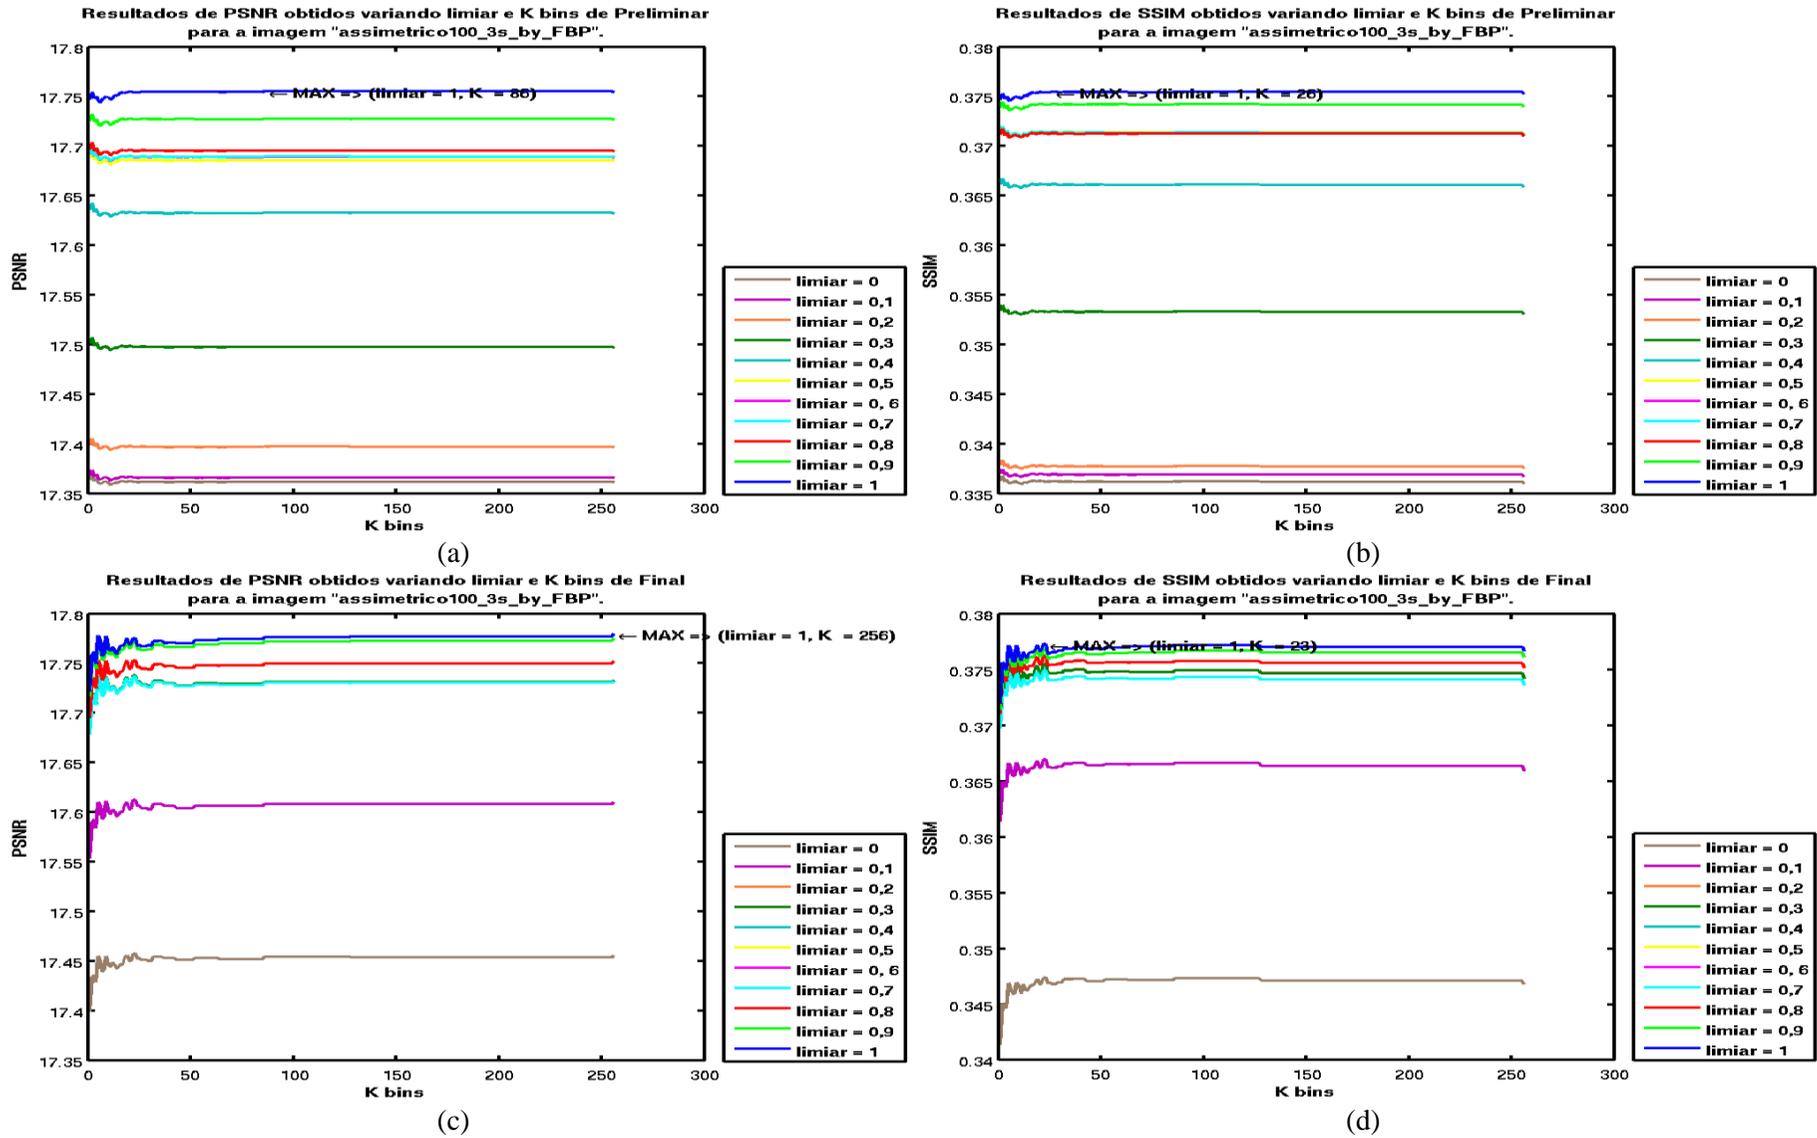
## APÊNDICE E – ESTUDO DOS PARÂMETROS DE LIMIAR E NÚMERO DE BINS DOS MÉTODOS PRELIMINAR E FINAL

Esta Seção tem o propósito de ajudar a identificar como os parâmetros de limiar e número de bins dos métodos de estimação do ruído propostos Preliminar e Final afetam o desempenho da filtragem, ou seja, uma melhor ou pior estimação do ruído. Lembrando que a principal diferença entre os métodos Preliminar e Final, é que este utiliza o Non Local Means e aquele o filtro da Média.

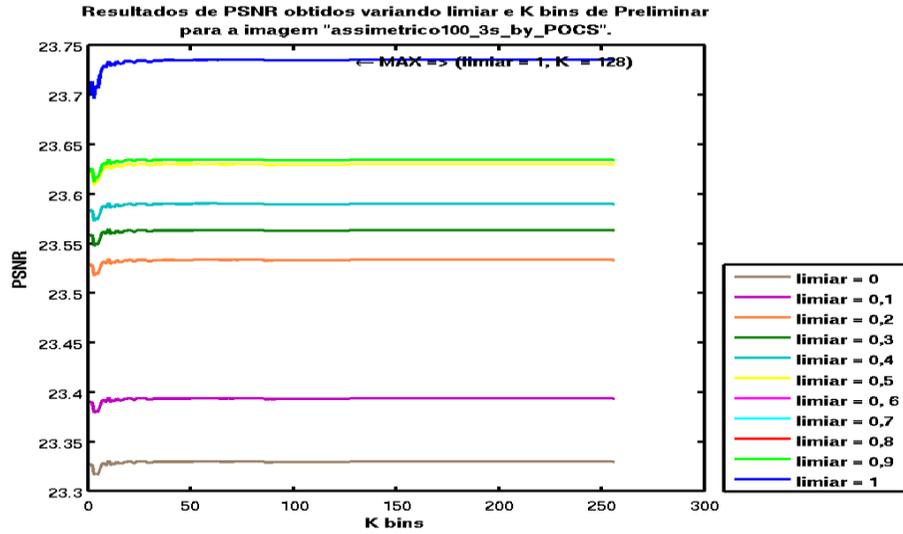
Assim, para esta finalidade foram gerados resultados para o Wiener Generalizado com  $\alpha = 1$ , que corresponde ao Wiener Pontual,  $w = 3 \times 3$  e estimativa da imagem livre de ruído dada por Non Local Means. Além disso, a estimação da variância do ruído dada pelos métodos Preliminar e Final variando os valores de limiar de 0 a 1 (com tamanho de passo de 0,1) e número de bins de 1 a 256 (com tamanho de passo de 1) foram considerados.

Os resultados obtidos para algumas imagens em termos de PSNR e SSIM são apresentados nas Figuras E.1 a E.10.

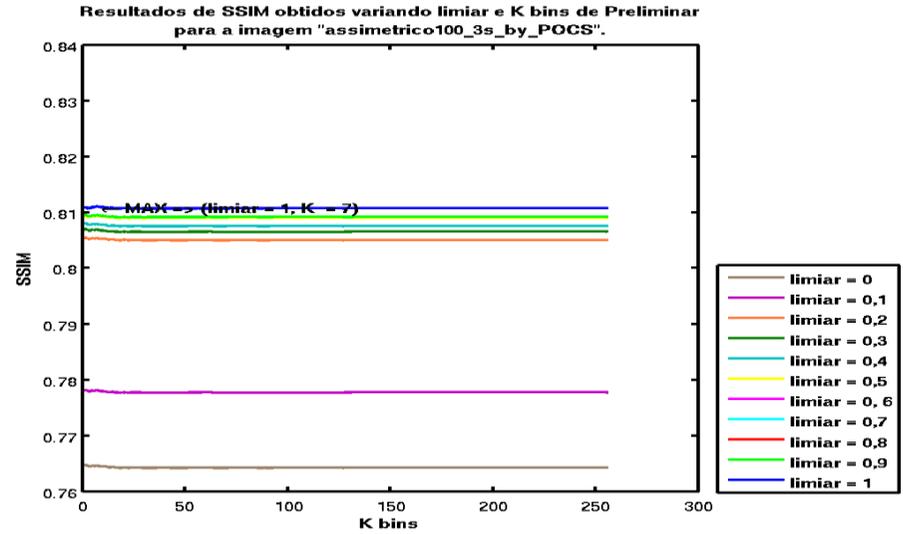
Este importante experimento nos fornece alguns esclarecimentos importantes que estão apontados a seguir. Primeiramente, as linhas de cada valor de limiar apresentam basicamente o mesmo comportamento variando o número de bins. Segundo, nota-se que o valor de limiar = 1, ou seja, a não consideração das bordas na estimação do ruído, é um valor mais seguro, já que na grande maioria dos resultados obtinham desempenho superior para este valor de limiar. Terceiro, o número de bins do método Final parece se ajustar mais ao número de segmentos presentes na imagem do que o método Preliminar. E finalmente, tem-se que o valor de limiar é mais crítico para ambos os métodos, comumente interferindo em maior nível no desempenho se comparado ao número de bins.



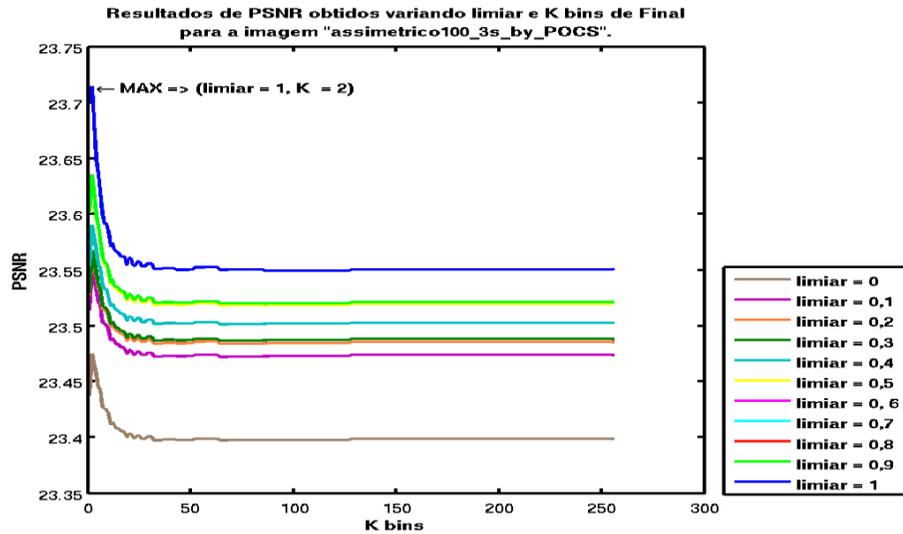
**Figura E.1.** Resultados de filtragem do phantom Assimétrico reconstruído por FBP em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior).



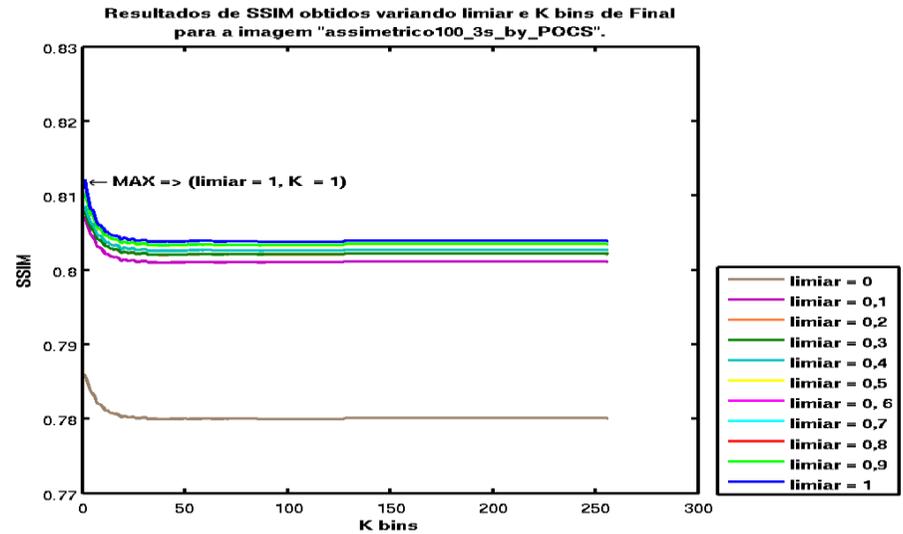
(a)



(b)

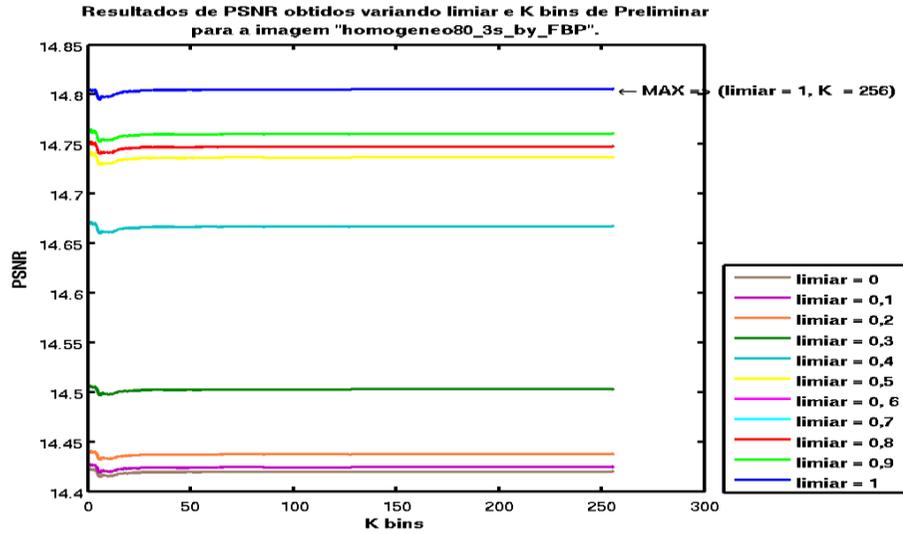


(c)

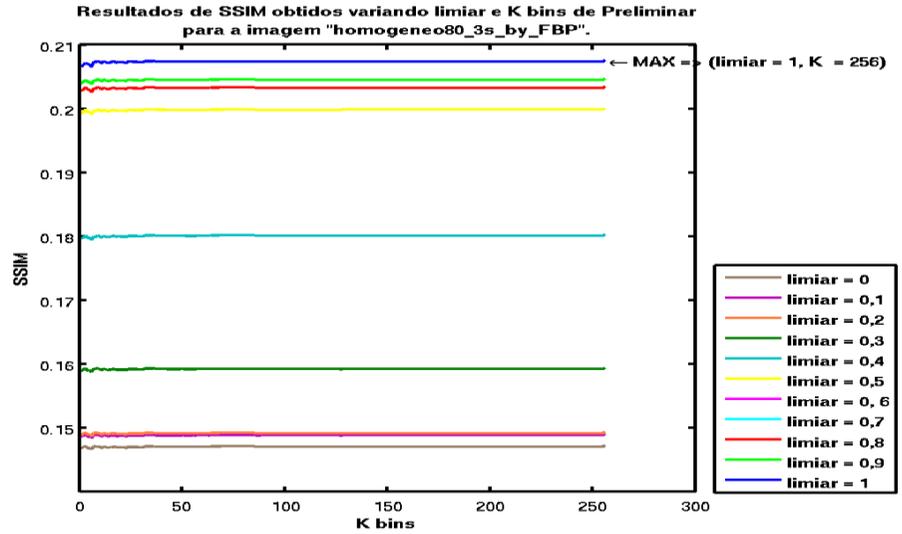


(d)

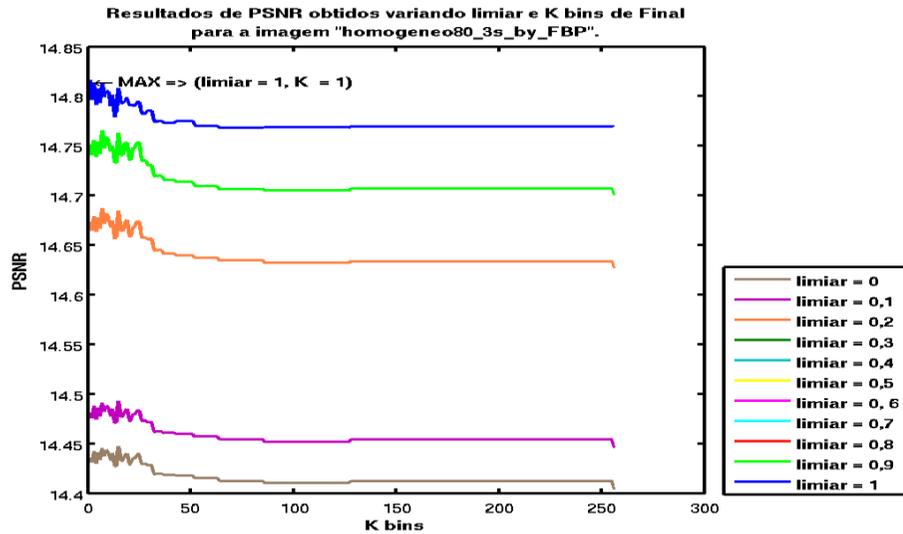
**Figura E.2.** Resultados de filtragem do phantom Assimétrico reconstruído por POCS em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior).



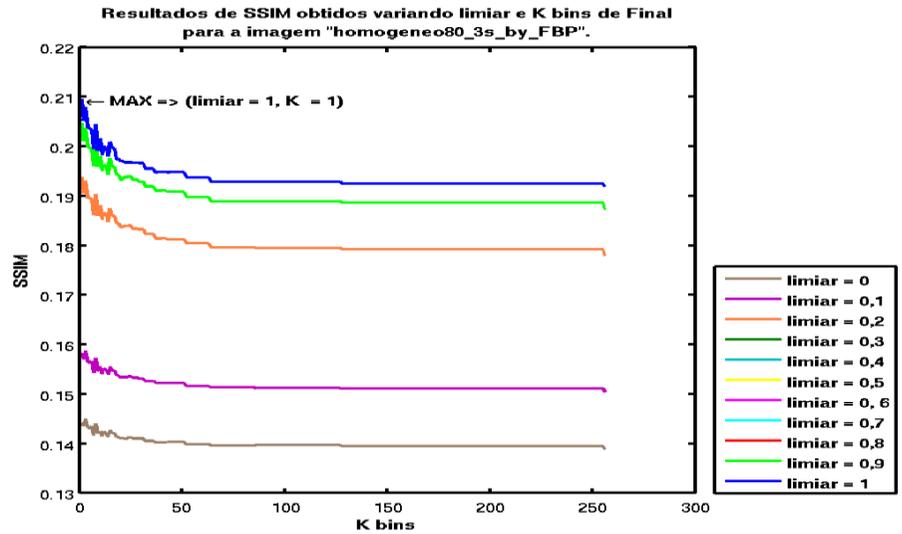
(a)



(b)

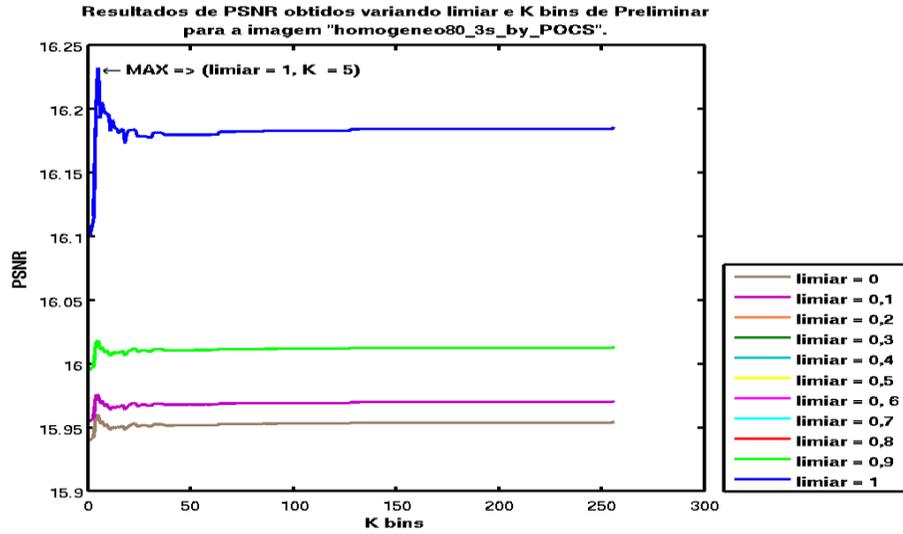


(c)

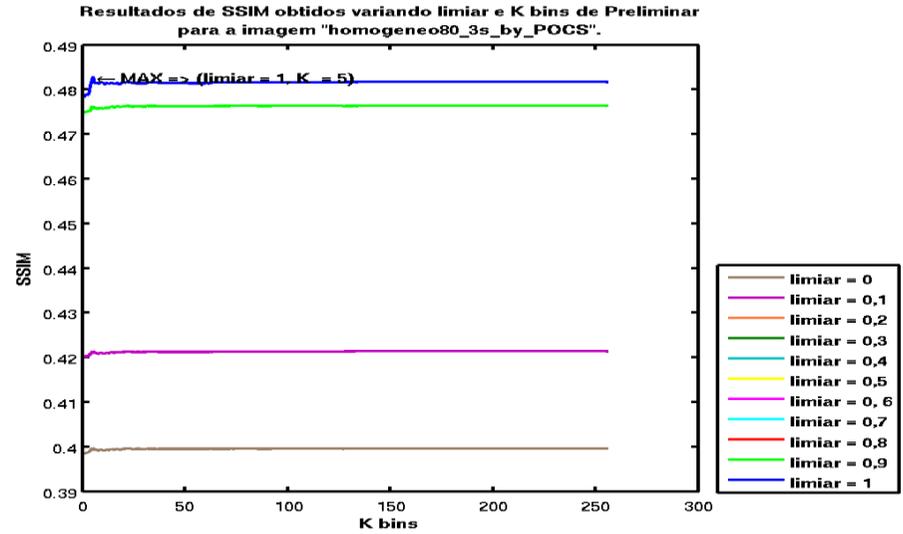


(d)

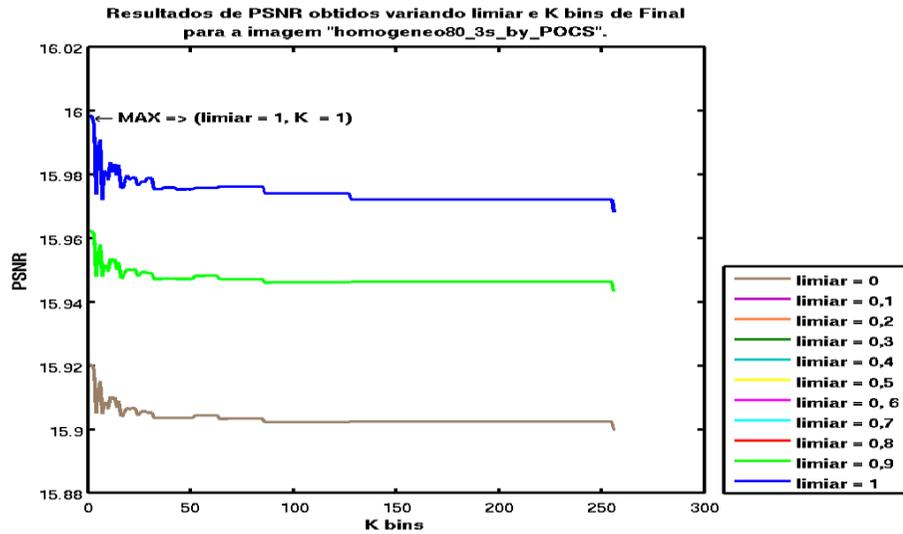
Figura E.3. Resultados de filtragem do phantom Homogêneo reconstruído por FBP em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior).



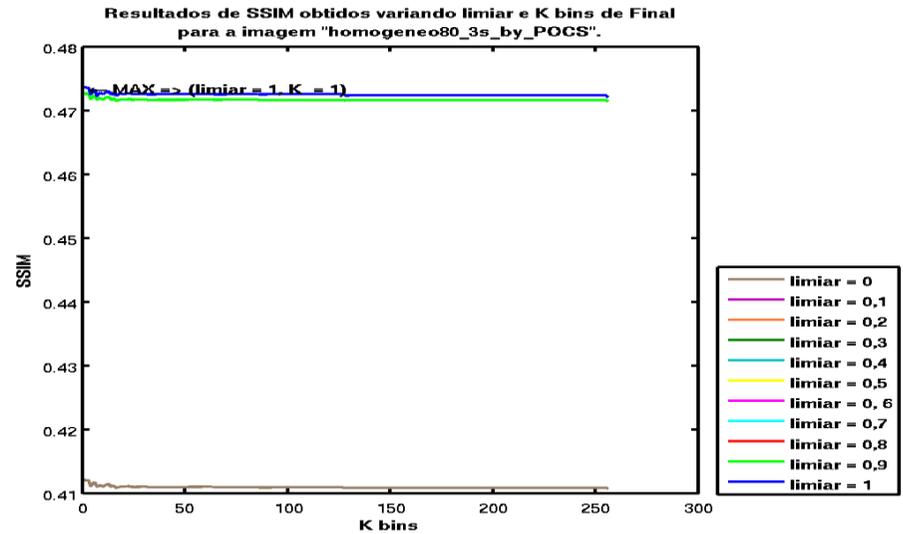
(a)



(b)

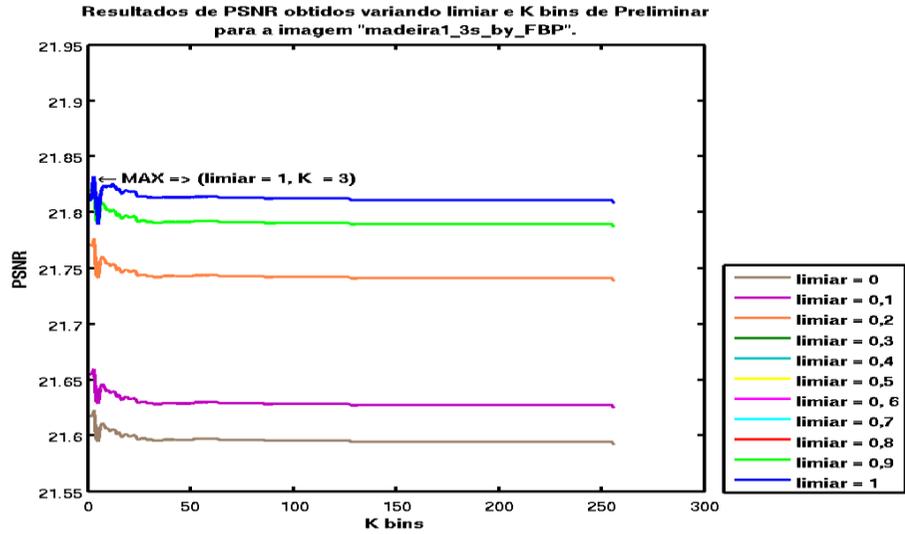


(c)

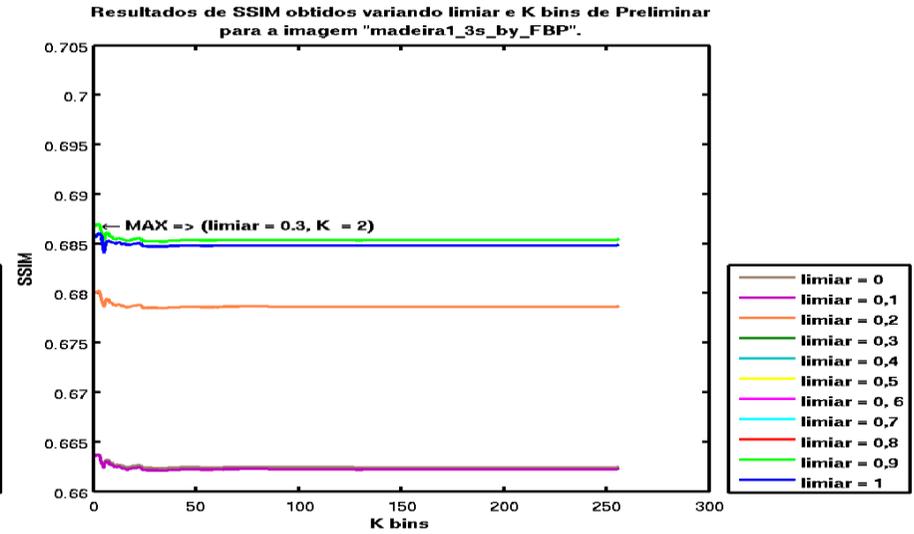


(d)

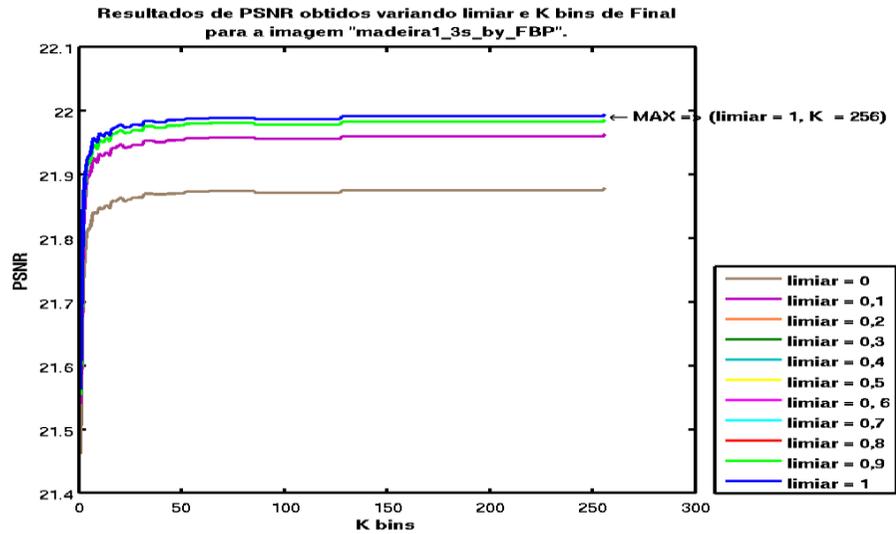
**Figura E.4.** Resultados de filtragem do phantom Homôgeneo reconstruído por POCS em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior).



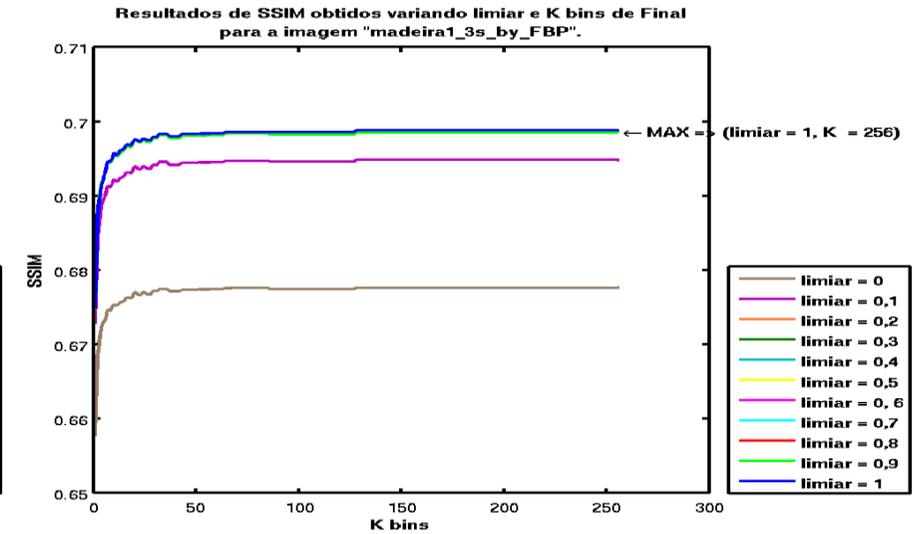
(a)



(b)

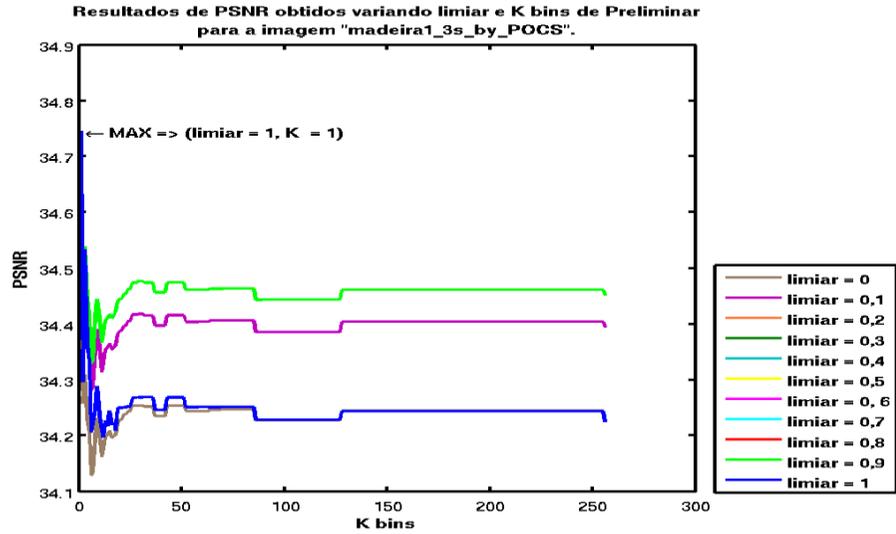


(c)

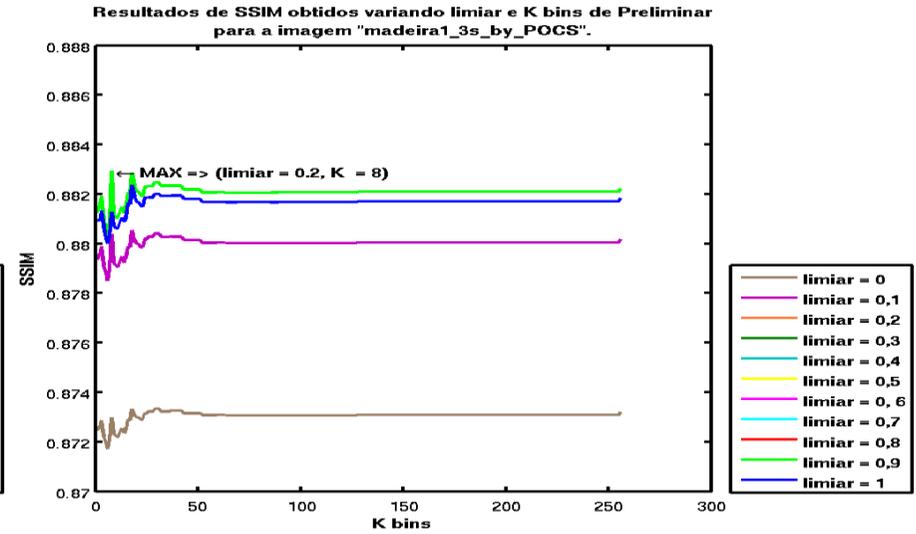


(d)

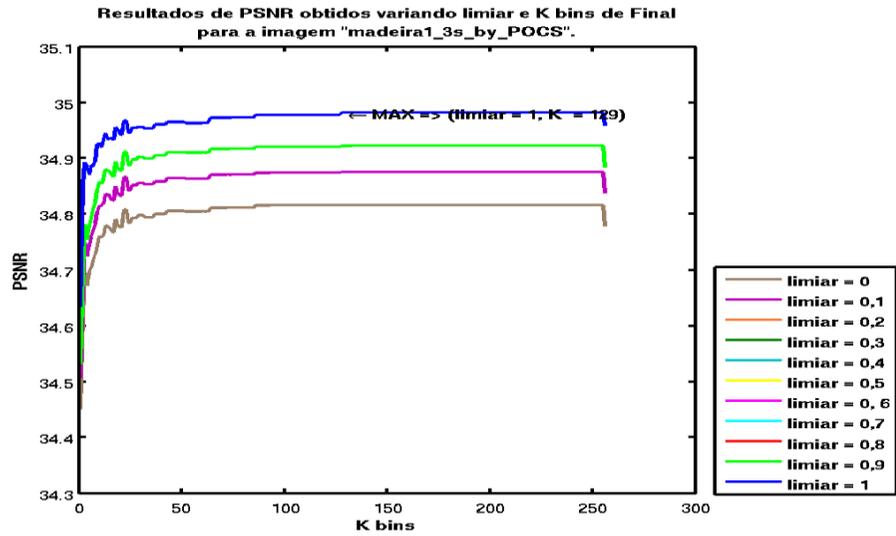
**Figura E.5.** Resultados de filtragem de Madeira 1 reconstruído por FBP em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior).



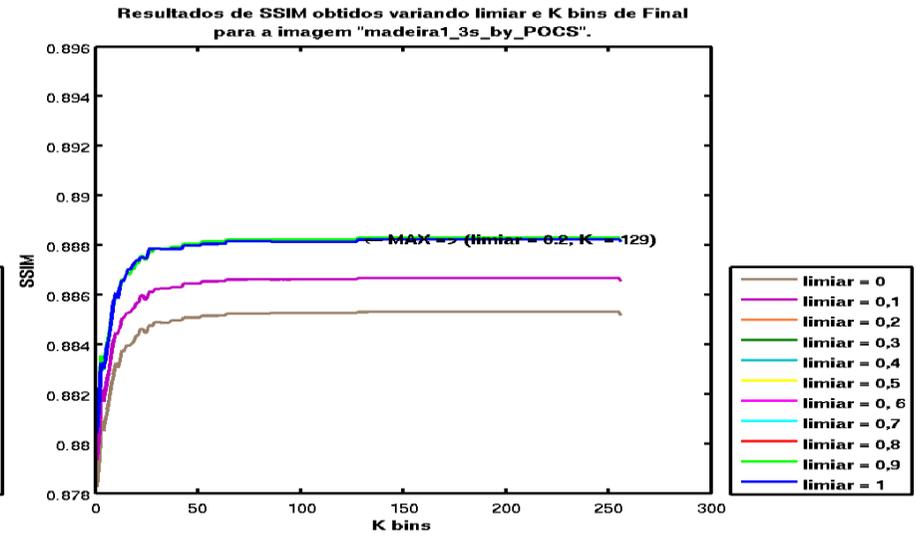
(a)



(b)

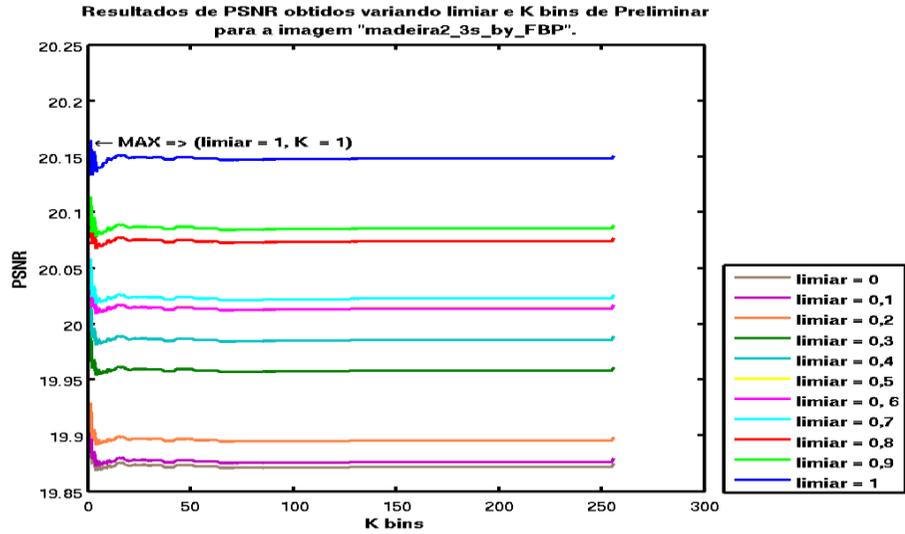


(c)

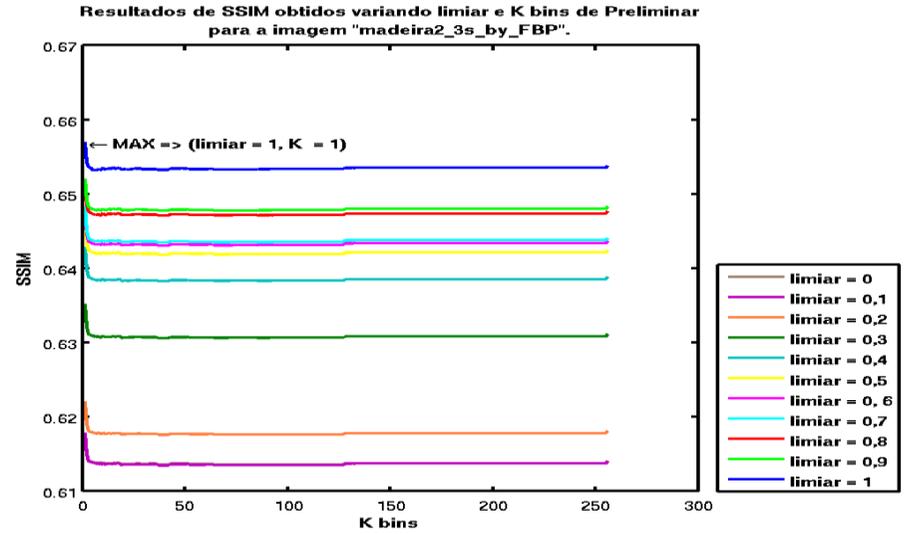


(d)

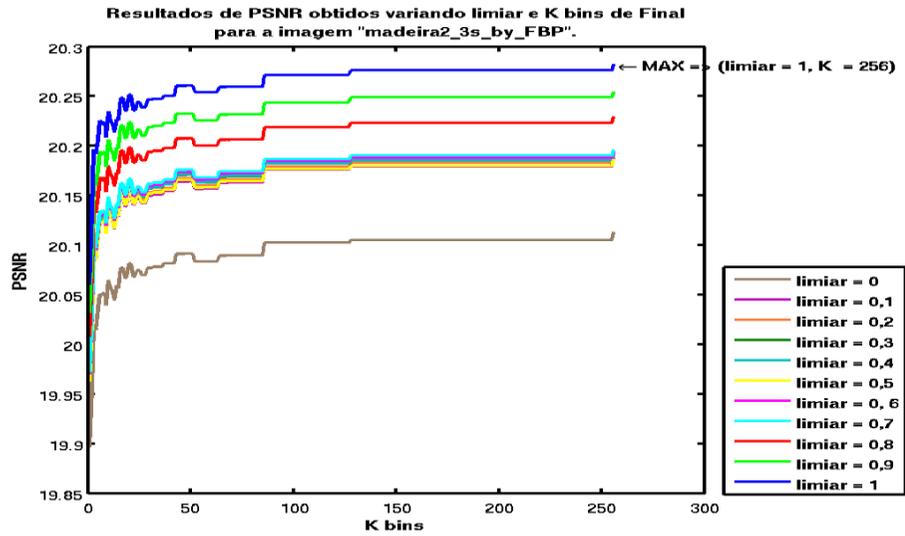
Figura E.6. Resultados de filtragem de Madeira 1 reconstruído por POCS em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior).



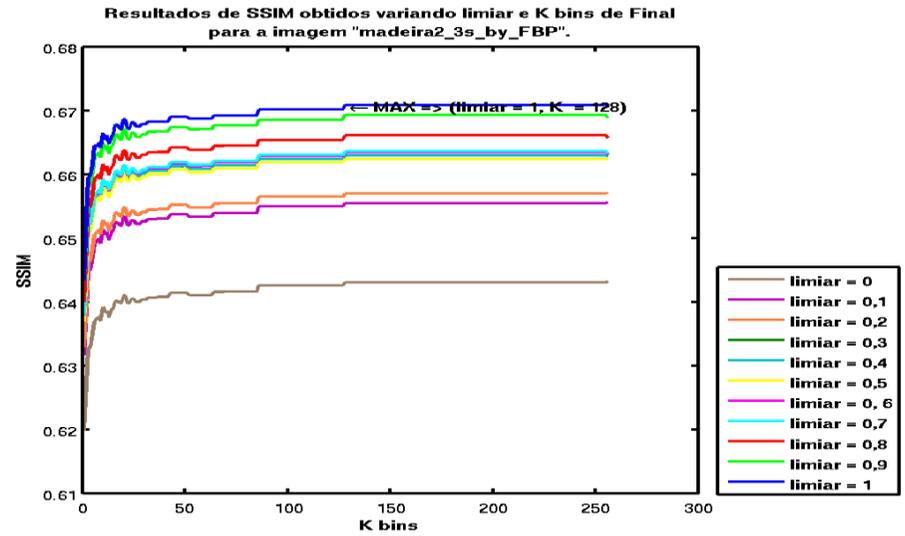
(a)



(b)

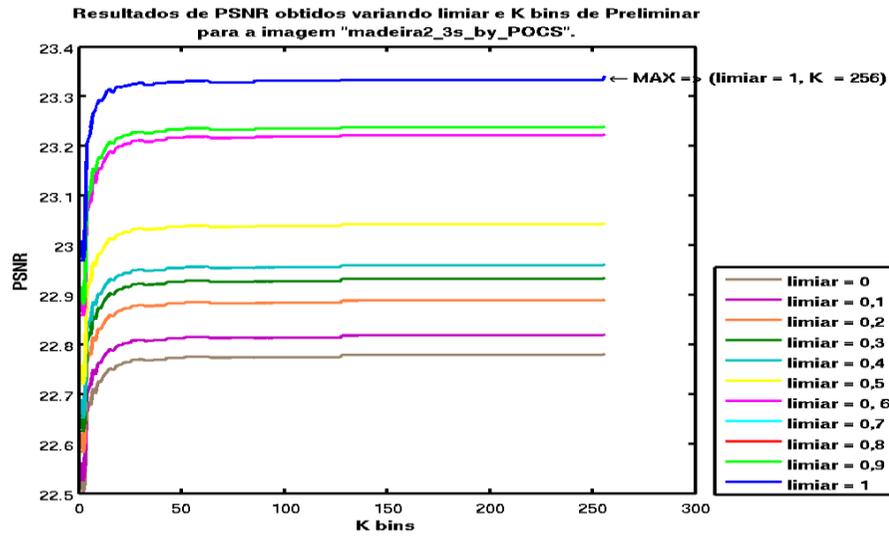


(c)

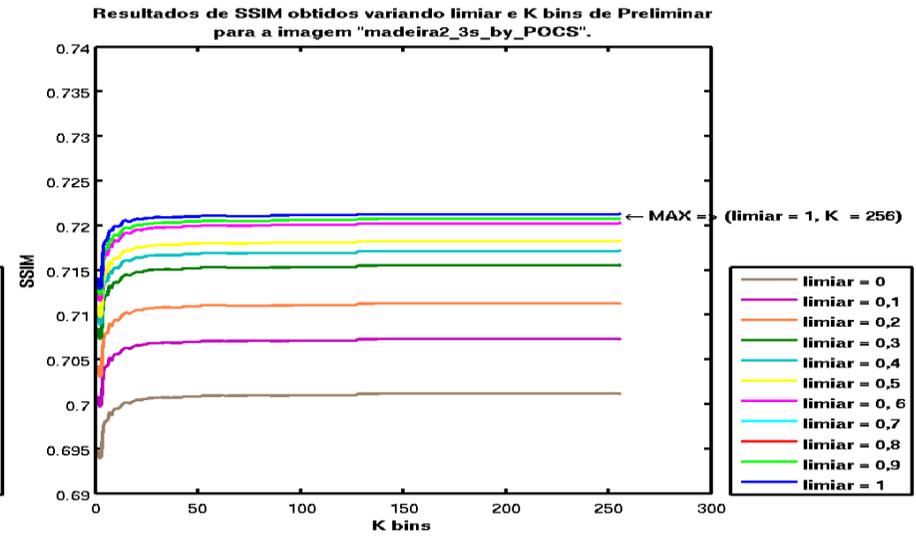


(d)

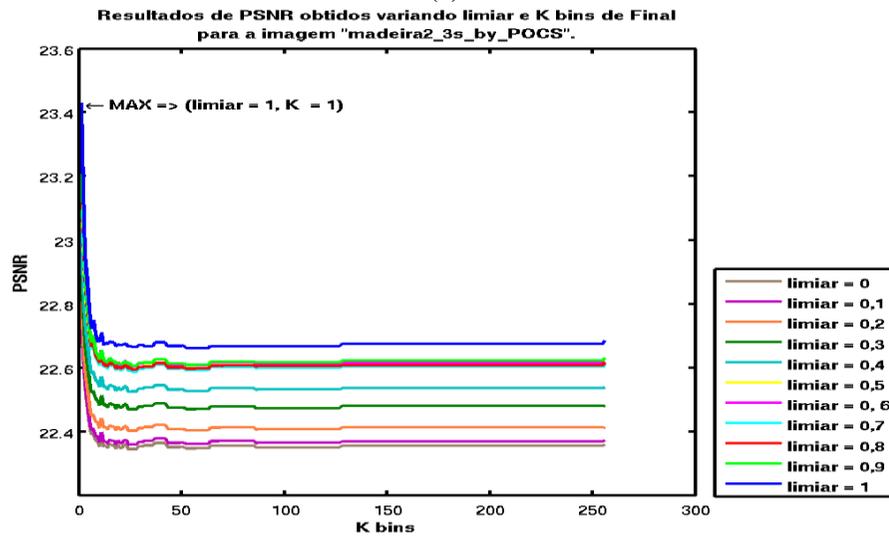
**Figura E.7.** Resultados de filtragem de Madeira 2 reconstruído por FBP em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior).



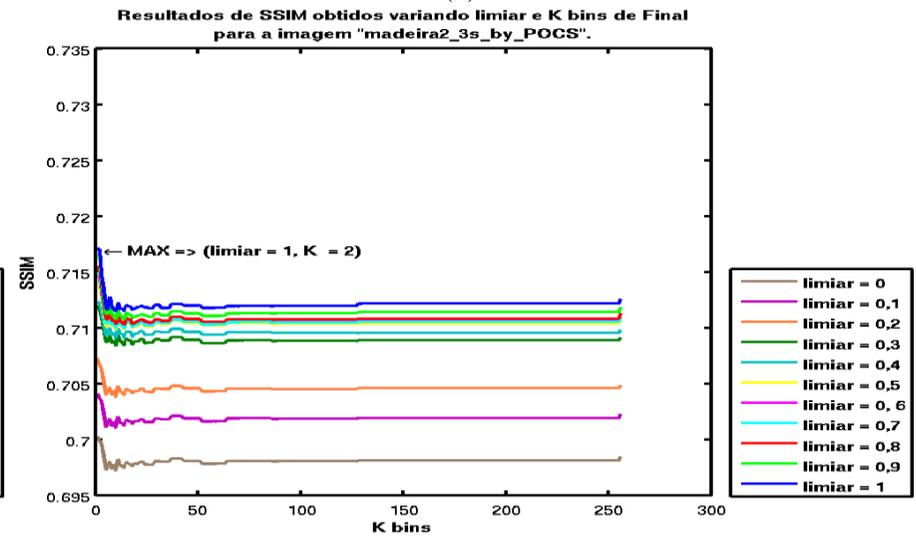
(a)



(b)

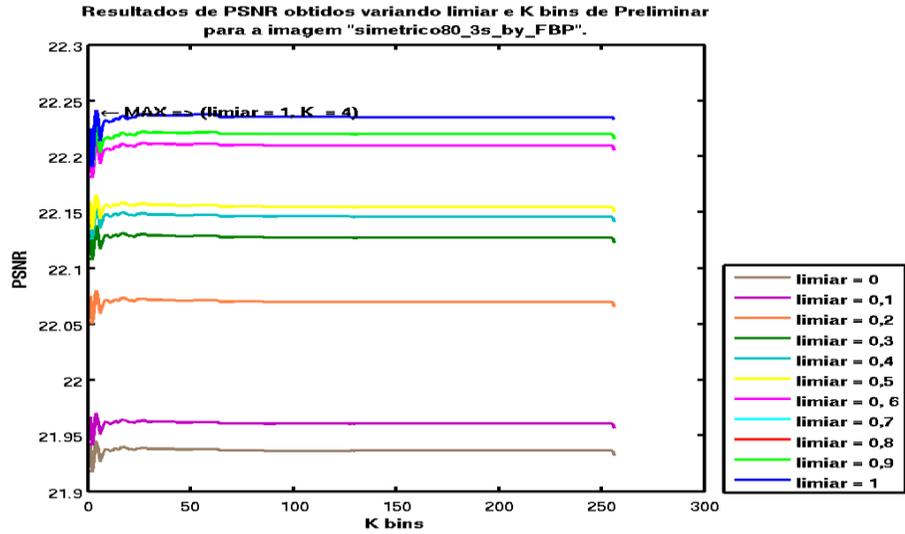


(c)

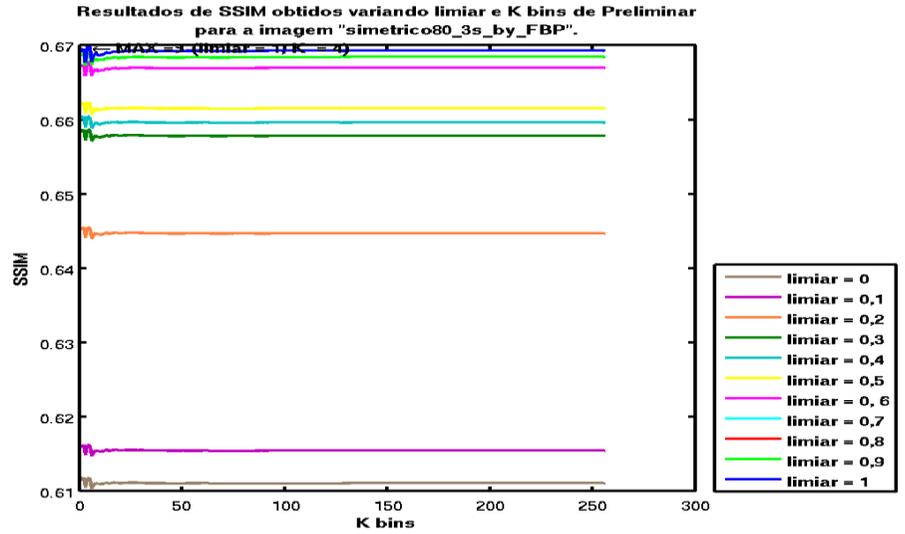


(d)

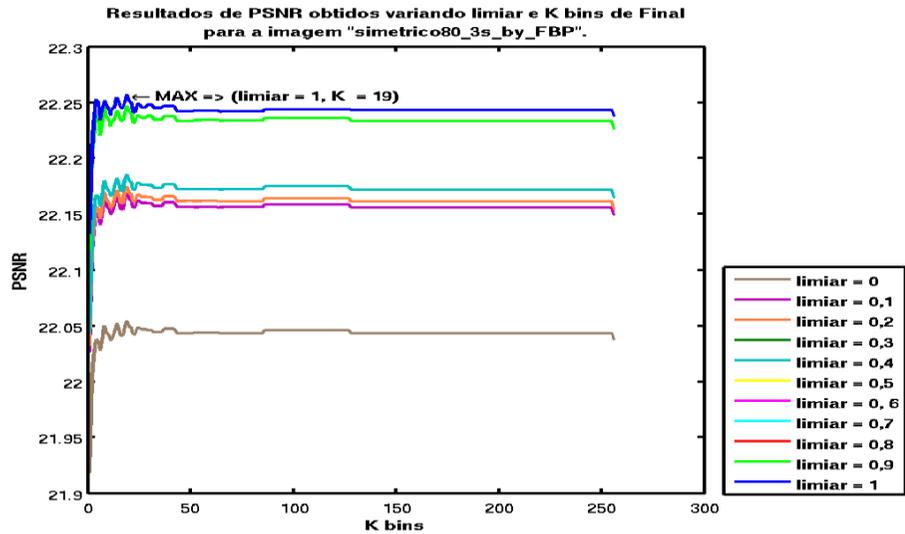
Figura E.8. Resultados de filtragem de Madeira 2 reconstruído por POCS em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior).



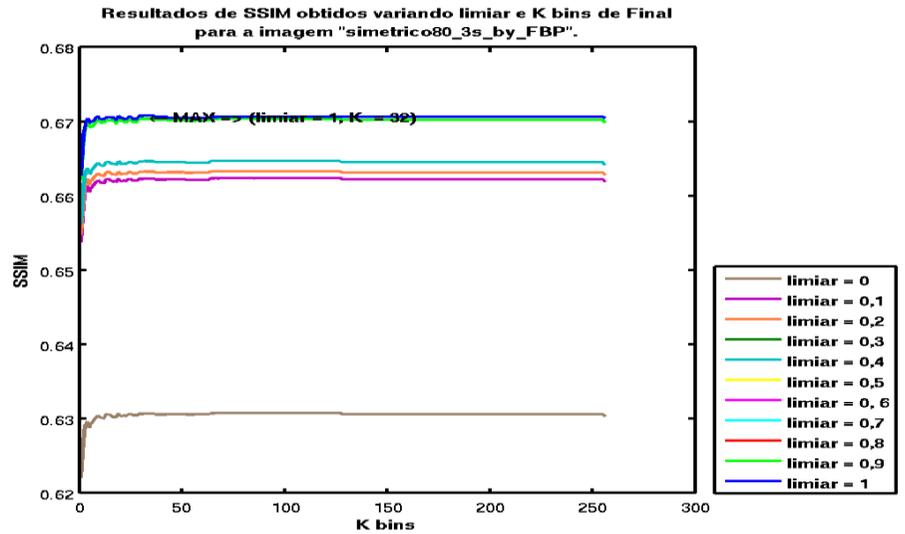
(a)



(b)

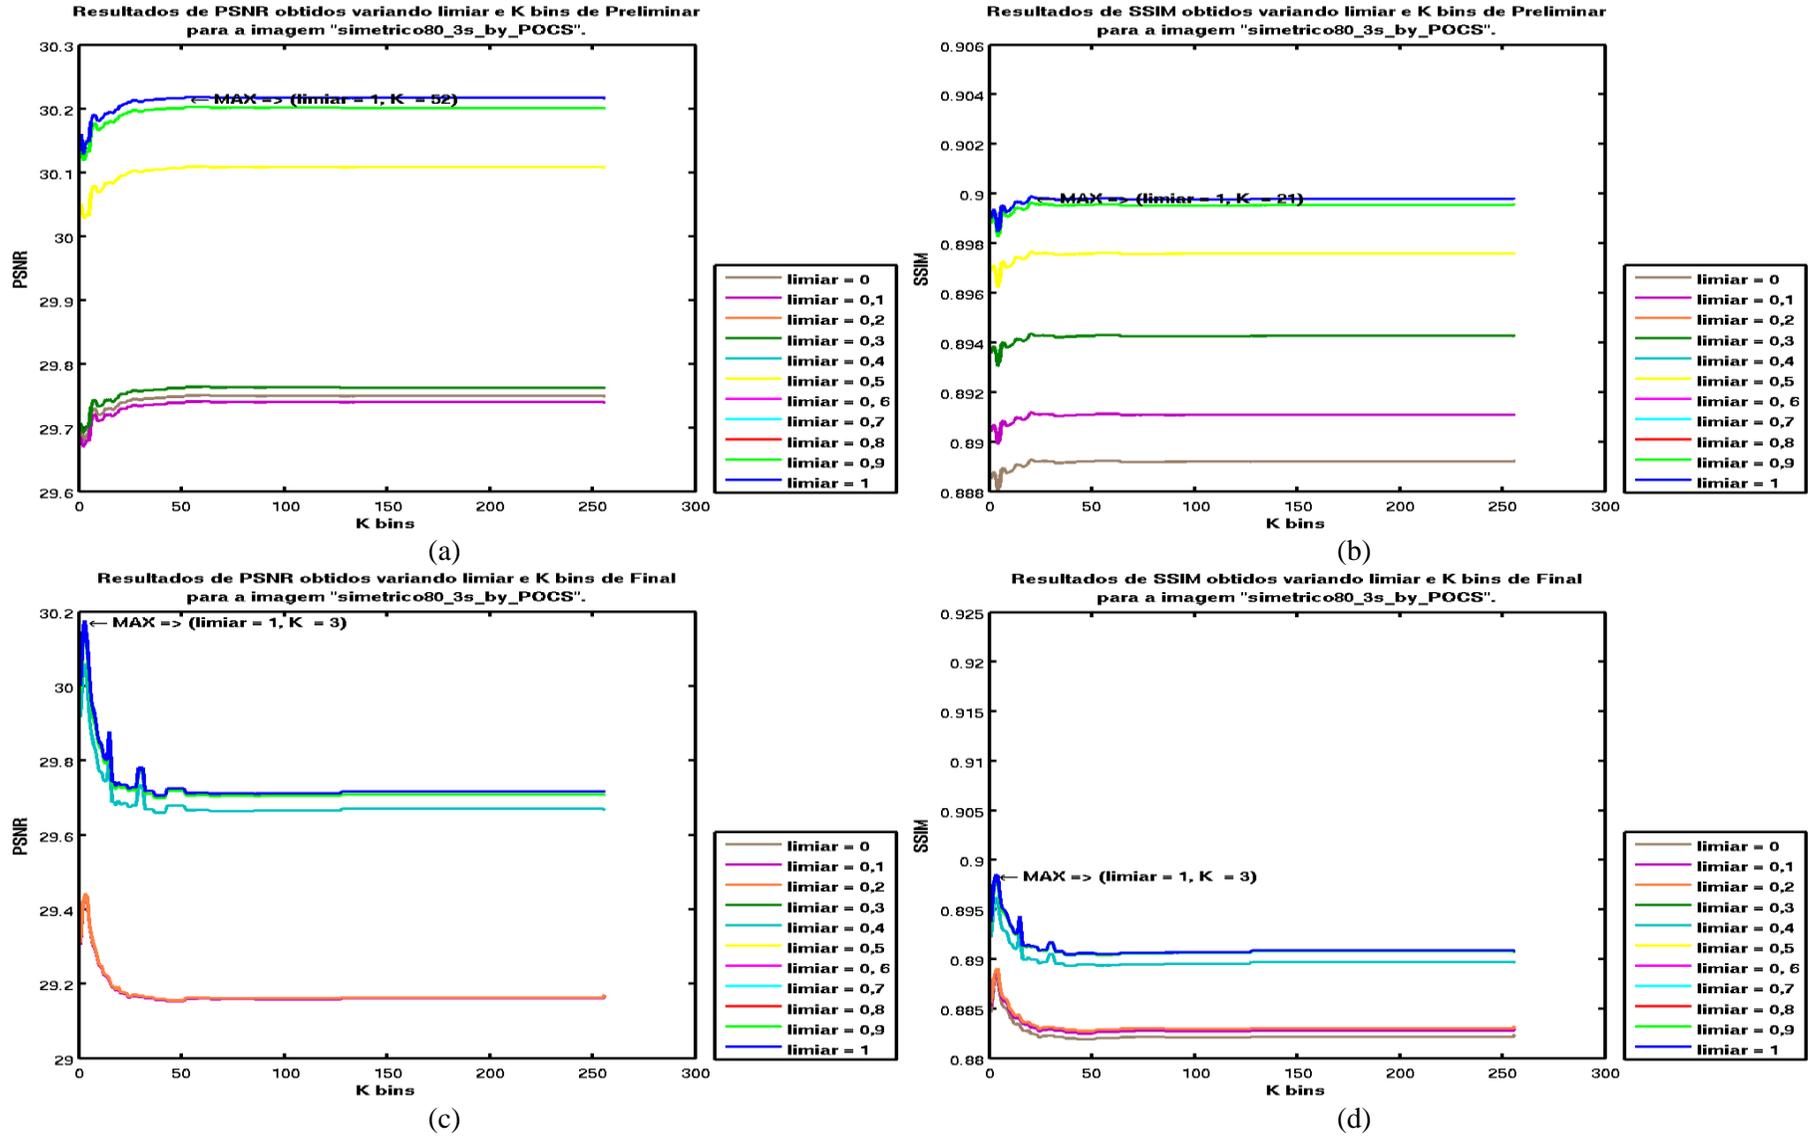


(c)



(d)

**Figura E.9.** Resultados de filtragem do phantom Simétrico reconstruído por FBP em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior).



**Figura E.10.** Resultados de filtragem do phantom Simétrico reconstruído por POCS em termos de PSNR (primeira coluna) e SSIM (segunda coluna) variando os parâmetros de limiar e número de bins para os métodos de estimação do ruído Preliminar (linha superior) e Final (linha inferior).

## APÊNDICE F – ESTUDO DA CONVERGÊNCIA DO ICM E GSA E OUTRAS QUESTÕES

Nos resultados apresentados neste Capítulo, identificou-se que vários dos melhores resultados obtidos para o ICM e GSA utilizavam apenas uma iteração, o que levantou a questão se o desempenho reduzia a cada iteração e até mesmo se um número maior de iterações seria necessário para um bom desempenho.

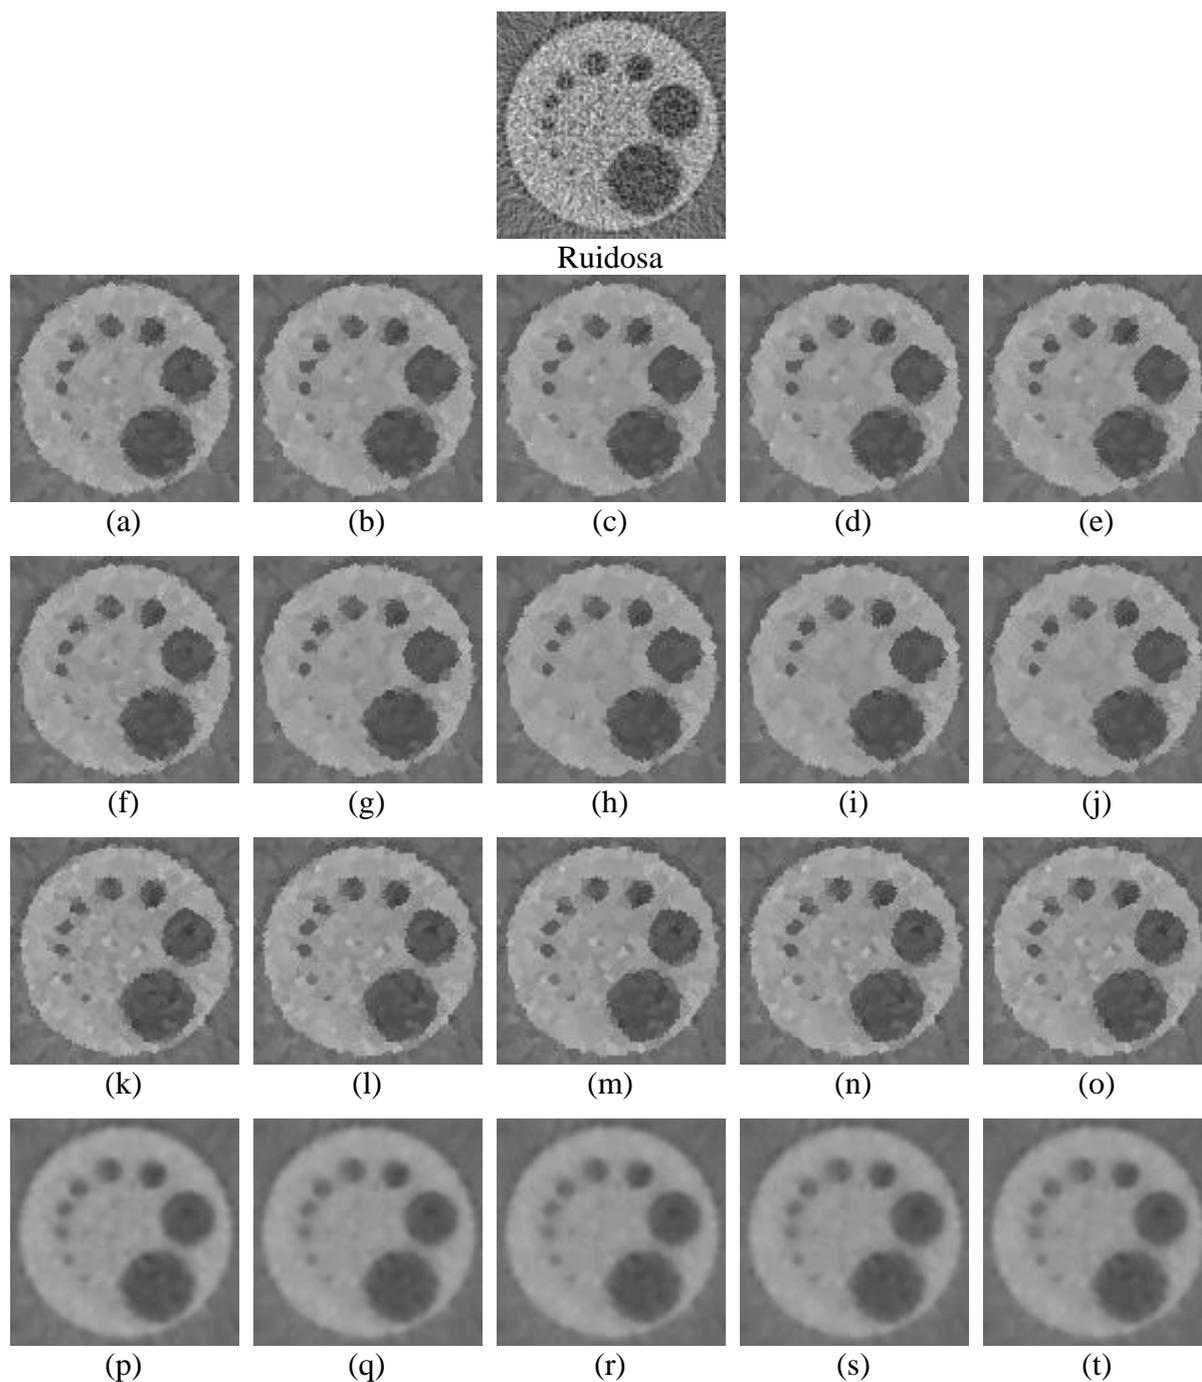
Além disso, para alguns modelos *a priori* considerados, mais especificamente Potts, GIMLL e GIMLL-L1 para o MPM, os resultados pareciam tender a uma segmentação da imagem, o que poderia ser também devido ao número insuficiente de iterações deste método.

Assim, a fim de uma melhor visão sobre estas questões, foram gerados resultados de convergência do ICM em termos de número de pixels alterados de uma iteração para outra (critério de parada), PSNR e SSIM. O método ICM básico considerado neste experimento foi definido para até 50 iterações e todas as combinações de modelos para verossimilhança (Gaussiana, GMRF) e *a priori* (Potts, GIMLL, GIMLL-L1, GMRF) considerados nesta tese foram utilizadas. E ainda, foi utilizado o ICM para a versão independente do sinal.

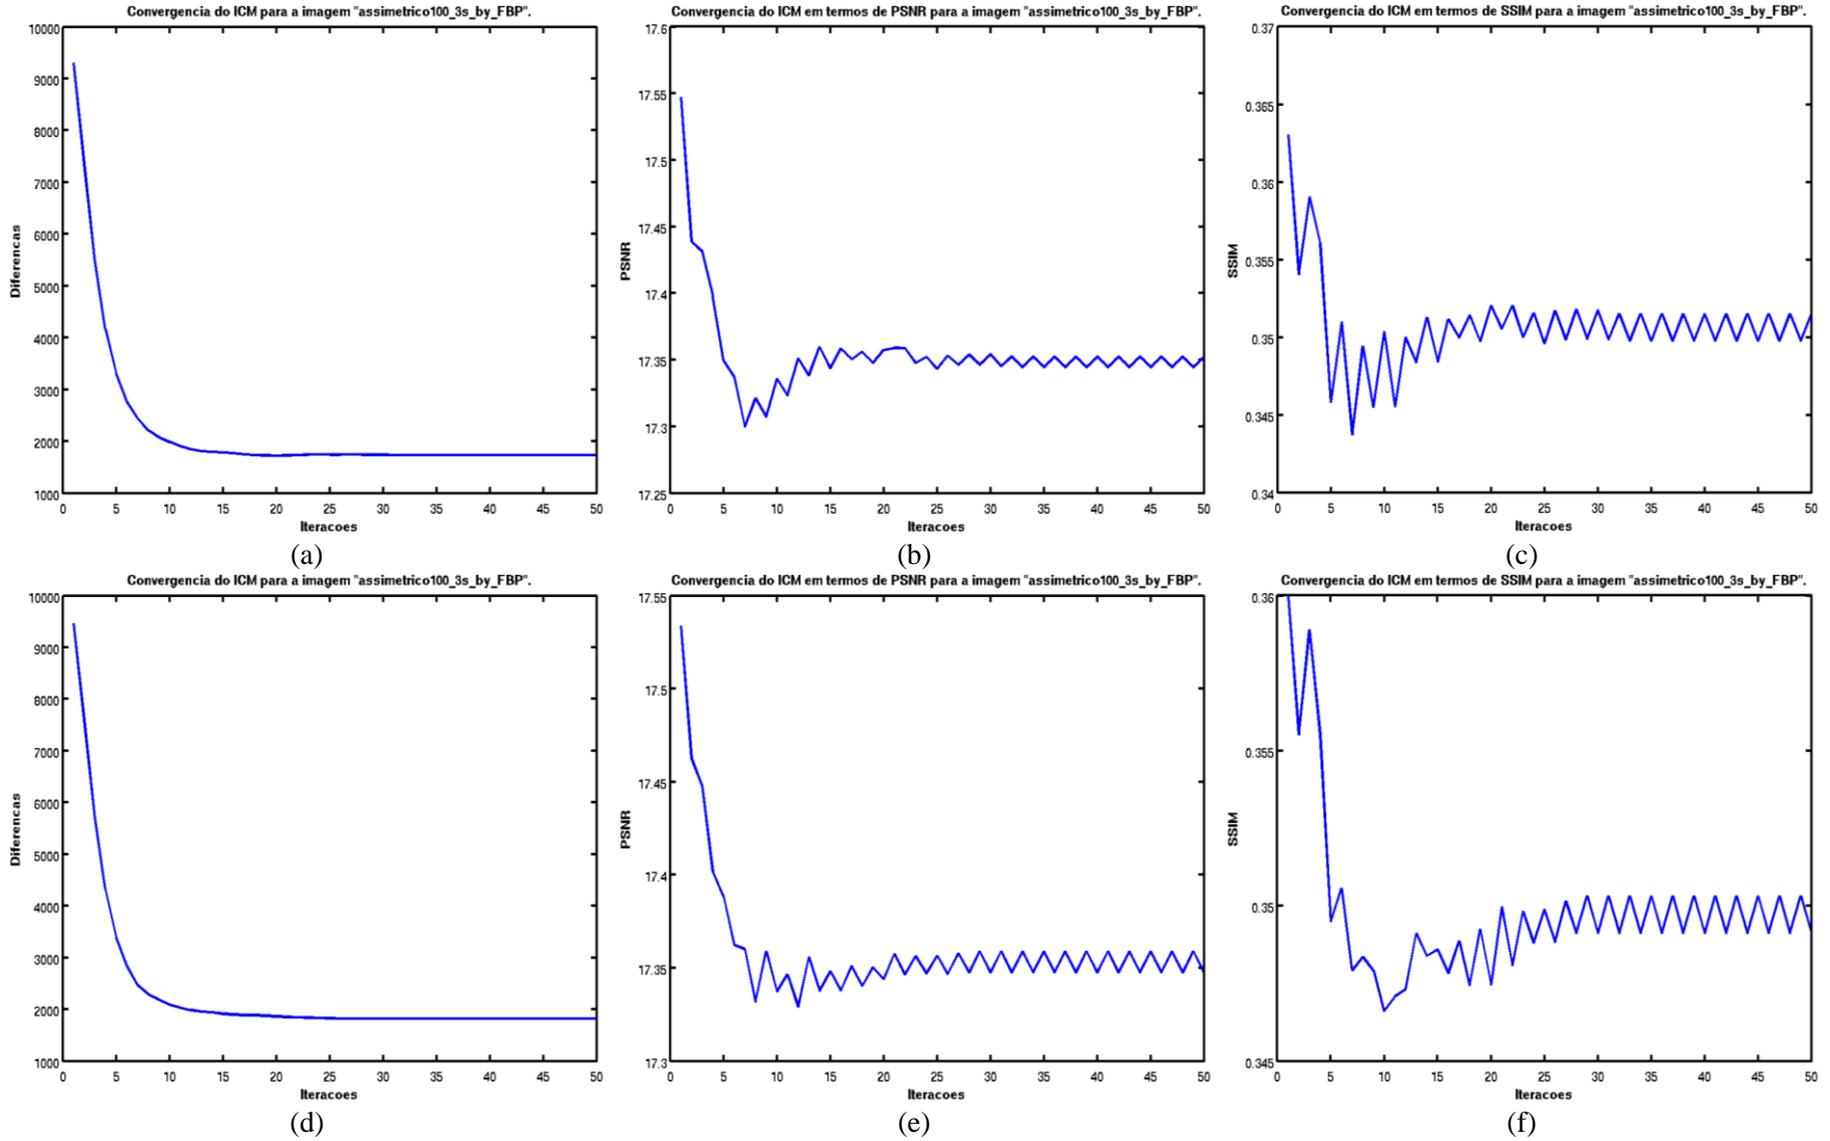
Um resultado característico obtido neste experimento para a grande maioria das imagens reais são apresentados a seguir, nas Figuras F.1 a F.3, sendo basicamente os gráficos de convergência e também imagens representando o estado atual a cada 5 iterações.

Deste resultado que descreve um comportamento geral podemos tirar as seguintes indicações. De fato, quando se considerou os modelos *a priori* Potts, GIMLL e GIMLL-L1 o resultado tendeu à segmentação e não à filtragem do ruído. Além disso, observou-se que para estes modelos após cerca de 20 a 30 iterações o método passou a oscilar entre dois estados, possivelmente atingindo dois estados mínimos locais. No caso das imagens reconstruídas por POCS, esta oscilação acontece, porém a oscilação é menor. Para o modelo *a priori* GMRF, o método atingiu o critério de parada de mudança mínima e parou na maioria das vezes em até 20 iterações. O comportamento foi independente do modelo para verossimilhança utilizado. Além disso, em geral, notou-se que o desempenho foi superior na primeira iteração, tendendo a cair com o aumento do número de iterações.

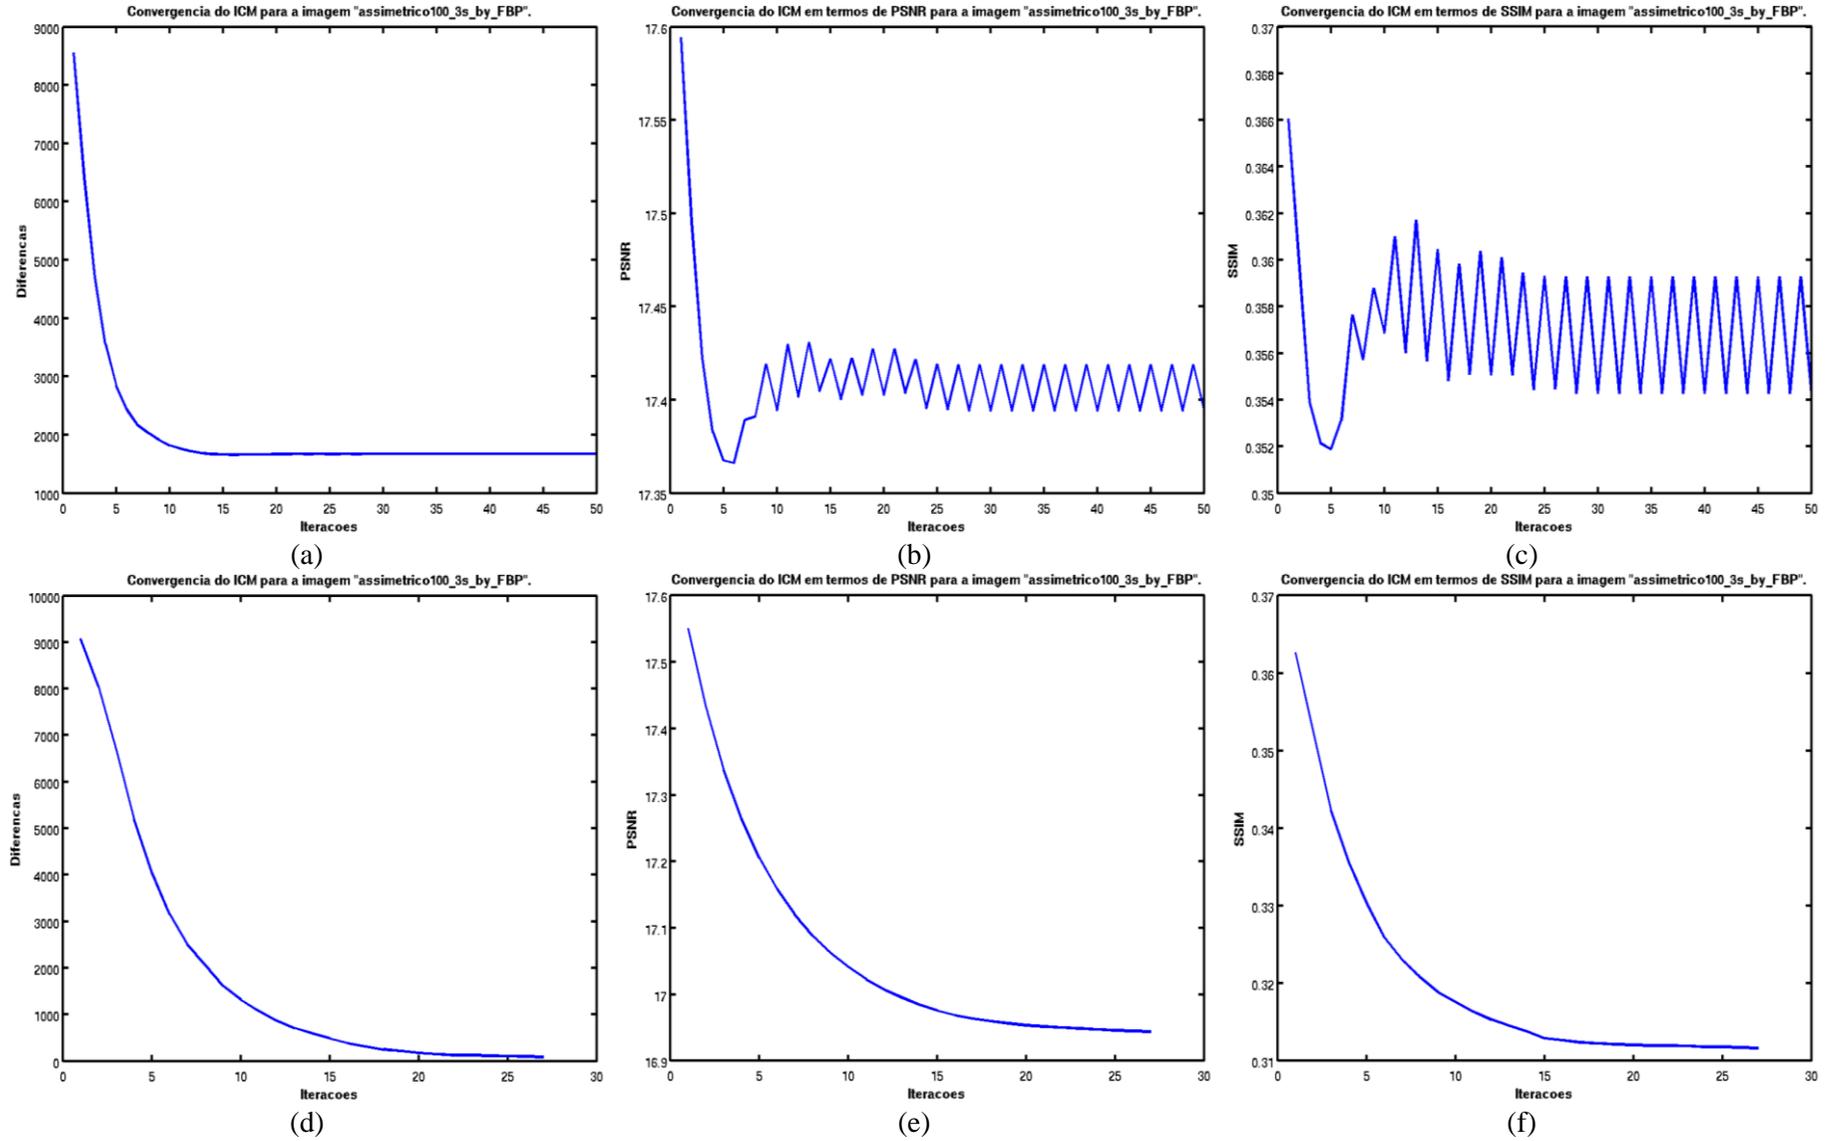
Por fim, a exceção a esta última observação foram os resultados para a imagem do phantom homogêneo, onde o desempenho cresceu conforme maior número de iterações, especialmente em termos de SSIM. Este comportamento pode ser esperado e justificado, pois esta imagem como o próprio nome diz é homogênea, composta basicamente de uma classe no objeto e outra para o fundo e quanto maior o número de iterações maior a tendência a agrupar. Exemplos dos resultados obtidos para esta imagem estão nas Figuras F.4 a F.6.



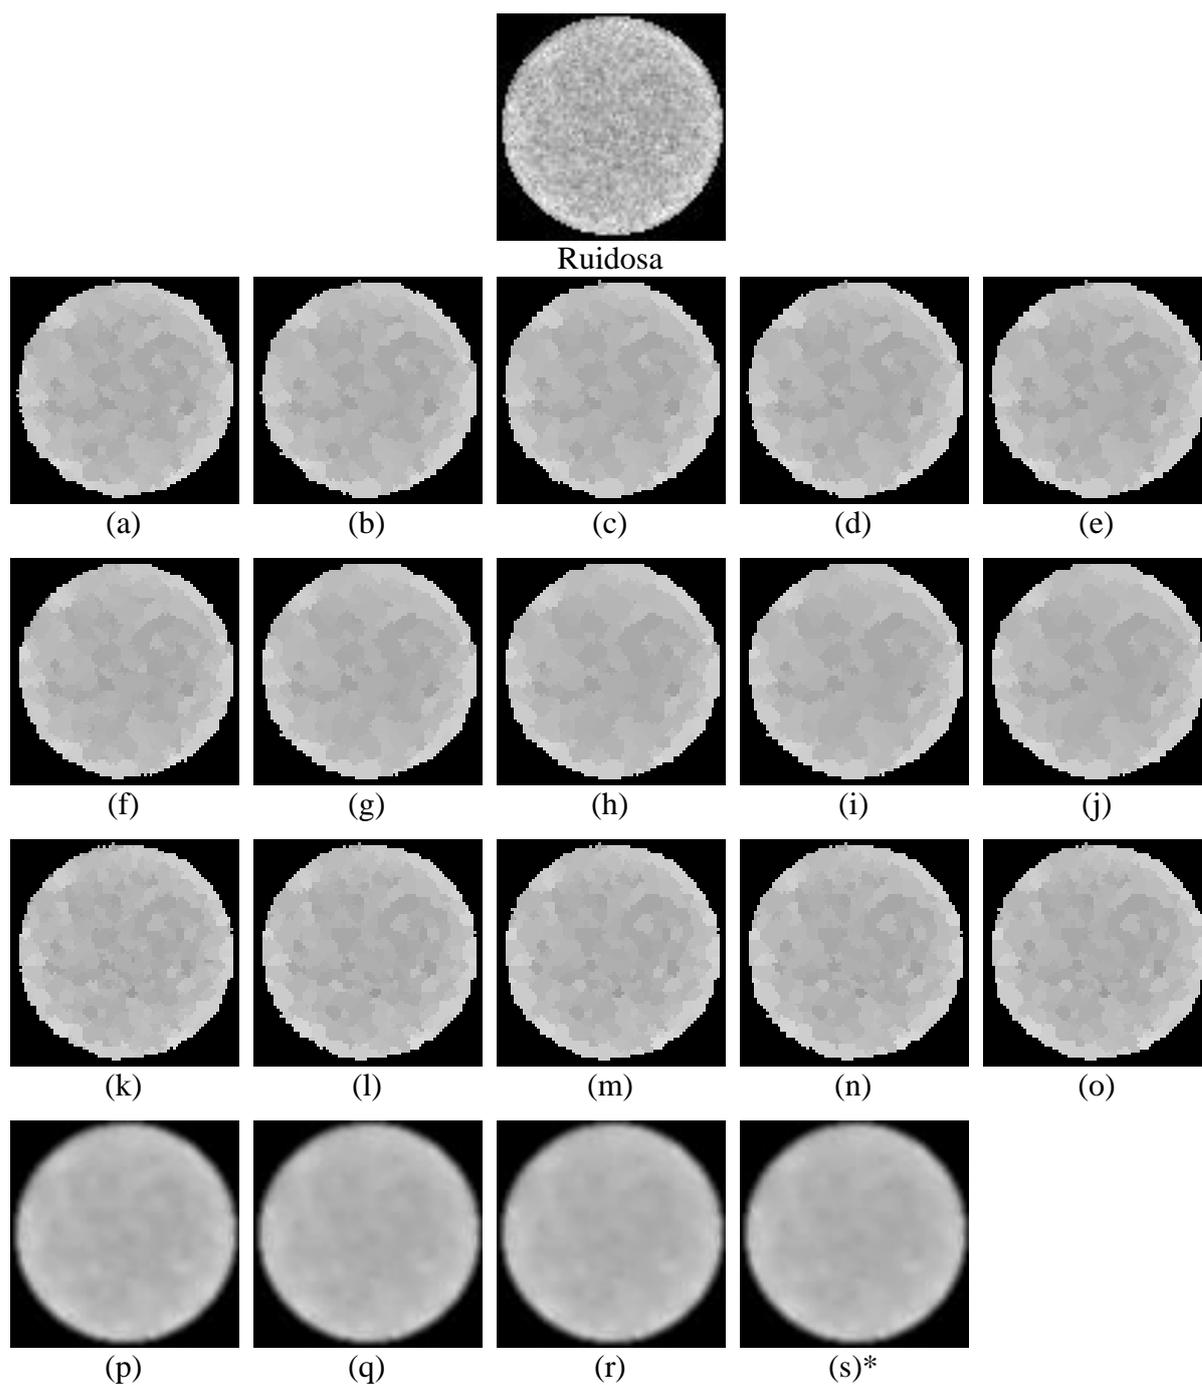
**Figura F.1.** Resultados de Filtragem do ICM do *phantom* Assimétrico reconstruído por FBP com modelos a priori GIMLL (1ª linha), GIMLL-L1 (2ª linha), Potts (3ª linha) e GMRF (4ª linha) com verossimilhança Gaussiana e seus respectivos estados nas iterações 5, 10, 15, 20 e 25, apontados nas colunas de 1 a 5, respectivamente.



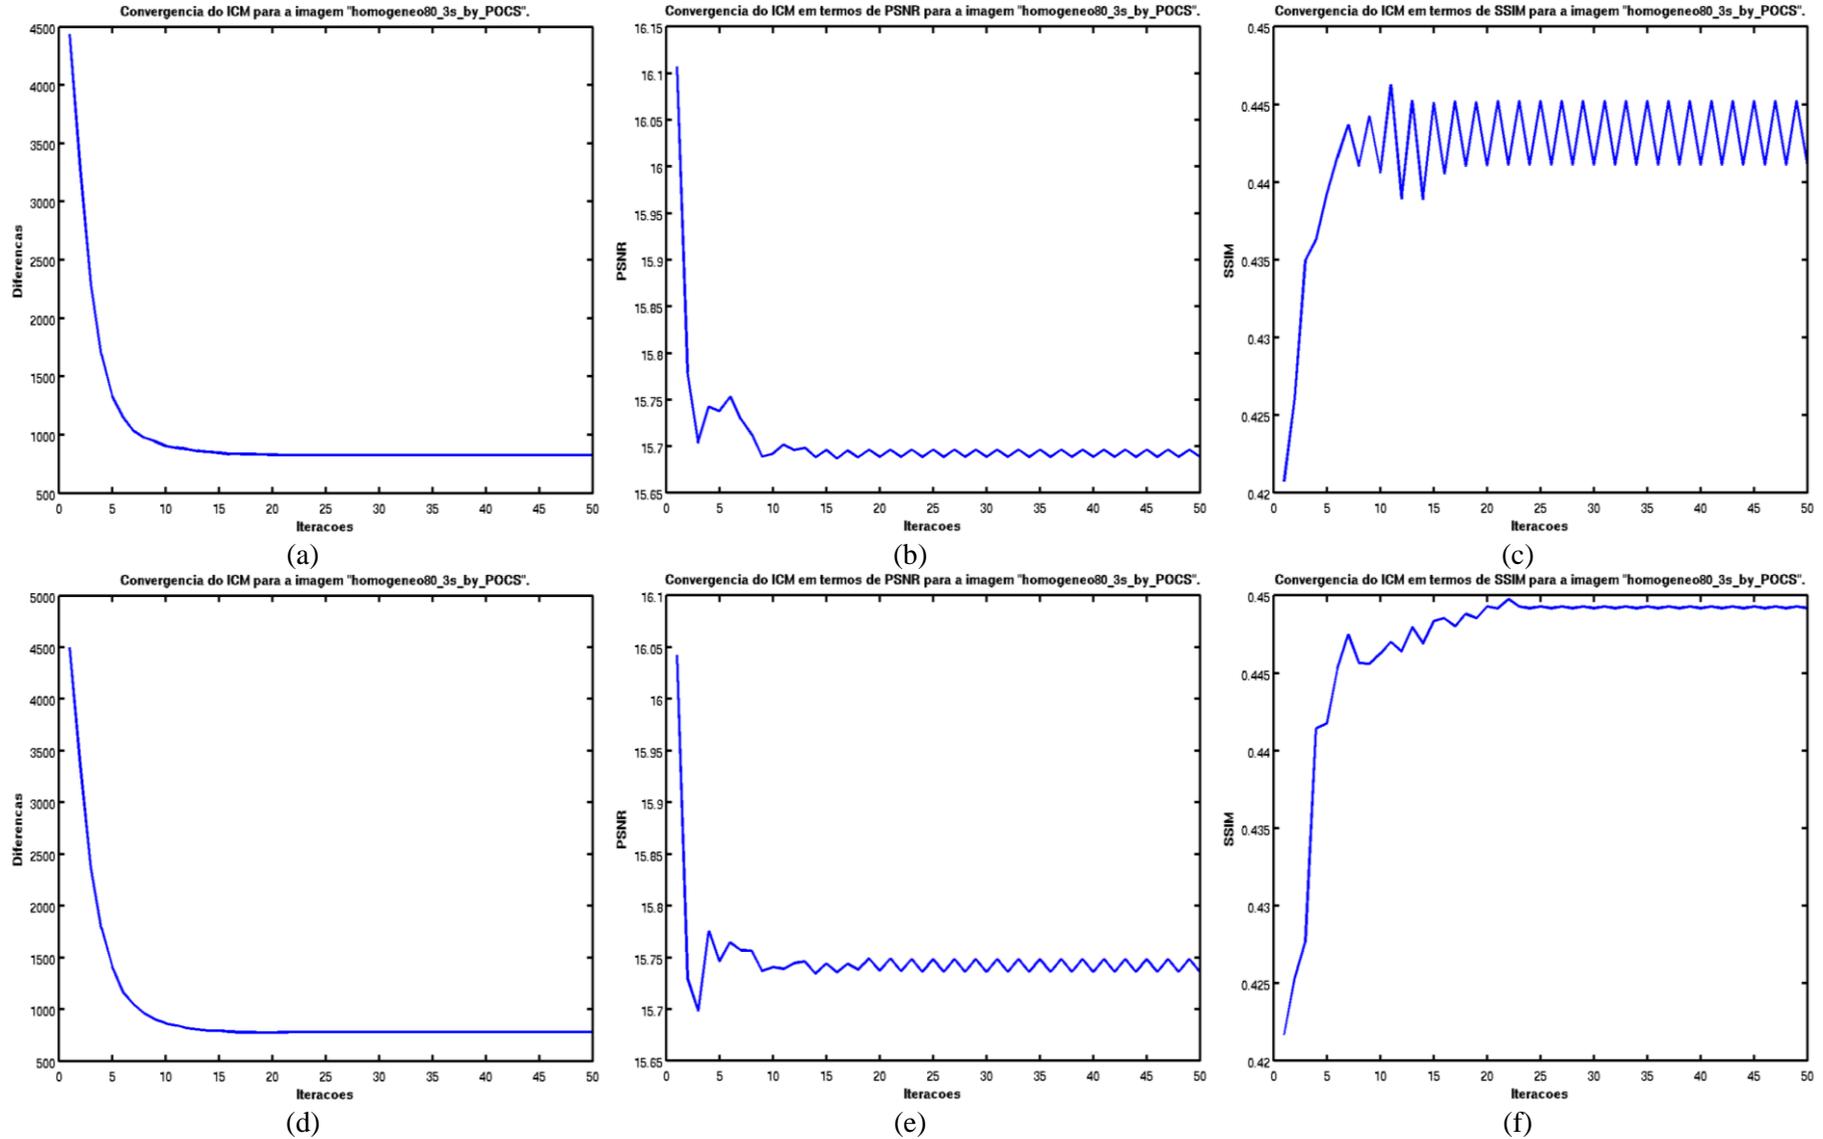
**Figura F.2.** Convergência do ICM em termos de diferença entre iterações (primeira coluna), PSNR (segunda coluna) e SSIM (terceira coluna) para o phantom Assimétrico reconstruído por FBP com modelos a priori GIMLL (linha superior) e GIMLL-L1 (linha inferior) com verossimilhança Gaussiana.



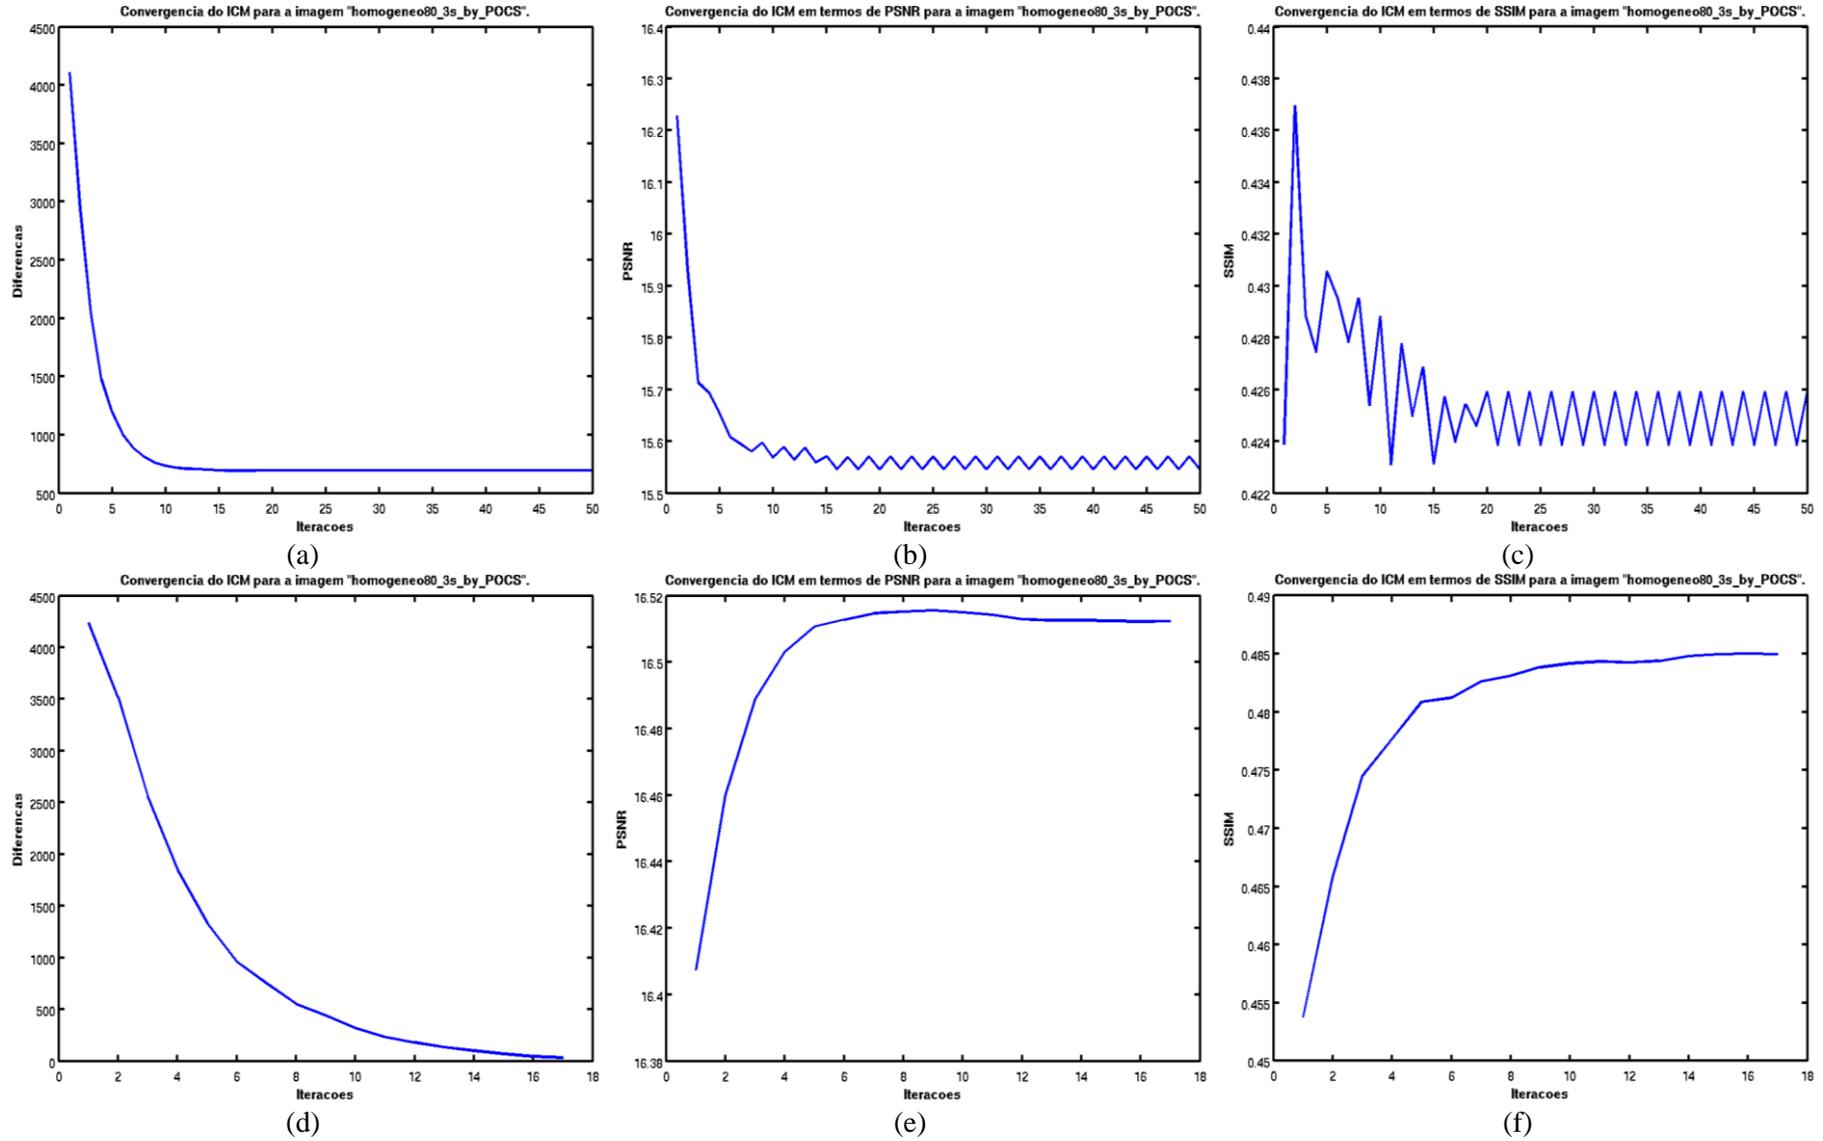
**Figura F.3.** Convergência do ICM em termos de diferença entre iterações (primeira coluna), PSNR (segunda coluna) e SSIM (terceira coluna) para o phantom Assimétrico reconstruído por FBP com modelos a priori Potts (linha superior) e GMRF (linha inferior) com verossimilhança Gaussiana.



**Figura F.4.** Resultados de Filtragem do ICM do *phantom* Homogêneo reconstruído por POCS com modelos a priori GIMLL (1ª linha), GIMLL-L1 (2ª linha), Potts (3ª linha) e GMRF (4ª linha) com verossimilhança Gaussiana e seus respectivos estados nas iterações 5, 10, 15, 20 e 25, apontados nas colunas de 1 a 5, respectivamente. Vale ressaltar que o item (s) marcado por um \* corresponde ao resultado final (usando o modelo a prior GMRF, ICM convergiu na iteração 17).



**Figura F.5.** Convergência do ICM em termos de diferença entre iterações (primeira coluna), PSNR (segunda coluna) e SSIM (terceira coluna) para o phantom Homogêneo reconstruído por POCS com modelos a priori GIMLL (linha superior) e GIMLL-L1 (linha inferior) com verossimilhança Gaussiana.



**Figura F.6.** Convergência do ICM em termos de diferença entre iterações (primeira coluna), PSNR (segunda coluna) e SSIM (terceira coluna) para o phantom Homogêneo reconstruído por POCs com modelos a priori Potts (linha superior) e GMRF (linha inferior) com verossimilhança Gaussiana.