

**UNIVERSIDADE FEDERAL DE SÃO CARLOS**

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**FILTRAGEM DE RUÍDO SPECKLE EM  
IMAGENS DE RADAR DE ABERTURA  
SINTÉTICA POR FILTROS DE MÉDIA NÃO  
LOCAL COM TRANSFORMAÇÃO  
HOMOMÓRFICA E DISTÂNCIAS  
ESTOCÁSTICAS**

**PEDRO AUGUSTO DE ALAGÃO PENNA**

**ORIENTADOR: PROF. DR. NELSON D. A. MASCARENHAS**

São Carlos – SP

Janeiro/2014

**UNIVERSIDADE FEDERAL DE SÃO CARLOS**

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**FILTRAGEM DE RUÍDO SPECKLE EM  
IMAGENS DE RADAR DE ABERTURA  
SINTÉTICA POR FILTROS DE MÉDIA NÃO  
LOCAL COM TRANSFORMAÇÃO  
HOMOMÓRFICA E DISTÂNCIAS  
ESTOCÁSTICAS**

**PEDRO AUGUSTO DE ALAGÃO PENNA**

Dissertação 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 Mestre em Ciência da Computação, área de concentração: Processamento de Imagens e Sinais

Orientador: Prof. Dr. Nelson D. A. Mascarenhas

São Carlos – SP

Janeiro/2014

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

P412fr

Penna, Pedro Augusto de Alagão.

Filtragem de ruído *speckle* em imagens de radar de abertura sintética por filtros de média não local com transformação homomórfica e distâncias estocásticas / Pedro Augusto de Alagão Penna. -- São Carlos : UFSCar, 2014.

170 f.

Dissertação (Mestrado) -- Universidade Federal de São Carlos, 2014.

1. Processamento de imagens. 2. Imagens SAR. 3. Filtragem de ruído. 4. *Speckle*. 5. *Nonlocal means*. 6. Distâncias estocásticas. I. Título.

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

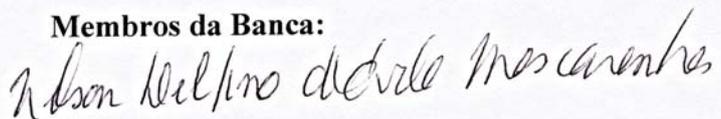
**Universidade Federal de São Carlos**  
**Centro de Ciências Exatas e de Tecnologia**  
**Programa de Pós-Graduação em Ciência da Computação**

**“Filtragem de Ruído Speckle em Imagens de Radar de Abertura Sintética por Filtros de Média Não Local com Transformação Homomórfica e Distâncias Estocásticas”**

**Pedro Augusto de Alagão Penna**

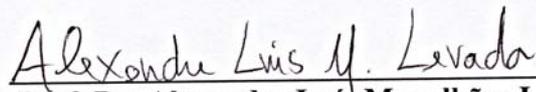
Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação

**Membros da Banca:**



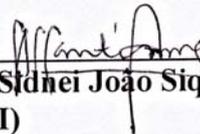
---

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



---

**Prof. Dr. Alexandre Luís Magalhães Levada**  
**(DC/UFSCar)**



---

**Prof. Dr. Sidnei João Siqueira Sant'Anna**  
**(INPE/DPI)**

**São Carlos**  
**Janeiro/2014**

Para Marco, Maria, Ana e Taise.

## AGRADECIMENTOS

Primeiramente agradeço a Deus por ter me dado forças para aguentar diversas turbulências ocorridas durante o desenvolvimento deste trabalho.

Agradeço aos meus pais Marco e Maria pelo apoio financeiro e por acreditarem em mim. E à minha irmã Ana, pelos momentos de silêncio.

Um forte e sincero agradecimento para a pessoa que mais teve cuidado, carinho e paciência comigo nesta importante etapa: Taise Lopes. Te amo profundamente e nunca esquecerei da estória do elefante. Um grande beijo, minha vida.

Um brinde aos meus digníssimos companheiros de república Daniel e Diego pelas risadas tiradas em momentos críticos e/ou caóticos. E, obviamente, em momentos de descontrações.

Agradeço ao professor Nelson Mascarenhas pela sua excelente dedicação como orientador e que foi capaz de criar laços não só acadêmicos mas também de amizade. Um forte abraço.

Agradeço também aos amigos, colegas e ex-colegas do GAPIS: professor Alexandre, Michelle, Denis, Márcia, Gustavo, Andre, Rafael, Bruno “japa”, Davi, Pillon, Paulinho.

Também não posso esquecer da Ísis, “D Dog”, que apareceu de supetao na minha vida e, em poucos meses, amadureceu-me em décadas. E da Lola, minha “fia branca”.

Agradeço ao Itamar, Elenir e Lucas.

E por fim, agradeço ao empenho da Cristina e do Augusto, que fazem parte das secretarias do PPG-CC e do DC.

*Só se pode alcançar um grande êxito quando nos mantemos fiéis a nós mesmos.*

Friedrich Nietzsche

## RESUMO

A elaboração de novos métodos e técnicas de filtragem de imagens ruidosas ainda atraem pesquisadores, que buscam a redução de ruído com a mínima perda dos detalhes, bordas, resolução e remoção de estruturas finas da imagem. Além disto, é de extrema importância ampliar a capacidade dos filtros para diversos modelos de ruído existentes na literatura de Processamento de Imagens e Sinais, como o ruído multiplicativo “speckle”, presente em imagens de radar de abertura sintética (SAR). Esta dissertação de Mestrado tem o objetivo de utilizar um algoritmo de filtragem recente: o “nonlocal means” (NLM), desenvolvido para o ruído branco aditivo gaussiano (AWGN), e ampliar, analisar e comparar a sua capacidade para a filtragem de imagens SAR de intensidade (“despeckling”), as quais são contaminadas com o “speckle”. Esta ampliação do filtro NLM é baseada no uso das distâncias estocásticas e na comparação dos parâmetros estimados através das distribuições  $G^0$  e da inversa da Gama. Por fim, este trabalho compara os resultados sintéticos e reais do filtro proposto com alguns filtros da literatura.

**Palavras-chave:** imagens SAR, intensidade, “speckle”, ruído multiplicativo, filtragem, “despeckling”, “nonlocal means”, distâncias estocásticas, distribuição  $G^0$

## ABSTRACT

The development of new methods and noisy images filtering techniques still attract researchers, which seek to reduce the noise with the minimal loss of details, edges, resolution and removal of fine structures of the image. Moreover, it is extremely important to expand the capacity of the filters for the different noise models present in the Image and Signal Processing literature, like the multiplicative noise speckle, present in the synthetic aperture radar (SAR) images. This Master's degree thesis aims to use a recent denoising algorithm: the nonlocal means (NLM), developed for the additive white gaussian noise (AWGN), and expand, analyze and compare its capacity for intensity SAR images denoising (despeckling), which are contaminated with the speckle. This expansion of the NLM filter is based with the use of the stochastic distances and the comparison of the estimated parameters with de  $G^0$  and the inverse Gamma distributions. Finally, this work compares the synthetic and real results of the proposed filter with some filters of the literature.

**Keywords:** SAR images, intensity, speckle, multiplicative noise, denoising, despeckling, nonlocal means, stochastic distances,  $G^0$  distribution

## LISTA DE FIGURAS

1.1	Modelo dos sinais espalhados (“backscatters”) na superfície. (ARGENTI et al., 2013). . . . .	24
2.1	Da esquerda para direita e da linha de cima para linha de baixo: (a) Imagem contínua; (b) Linha de varredura; (c) Amostragem e quantização; (d) Linha de varredura digital. Figura adaptada de (GONZALEZ; WOODS, 2010). . . . .	28
3.1	Funções densidade de probabilidade mais utilizadas na literatura. Figura adaptada de (GONZALEZ; WOODS, 2010). . . . .	33
3.2	Exemplo da distribuição gaussiana e o ruído gaussiano. Figura adaptada de (NATH, 2013). . . . .	33
3.3	Exemplo da distribuição Gama e o ruído “speckle”. Figura adaptada de (NATH, 2013). . . . .	34
3.4	F.d.p e exemplo do ruído sal e pimenta. Figura adaptada de (NATH, 2013). . . . .	34
4.1	Exemplo da técnica de “multi-look”. (a) sem “multi-look” (“single-look”). (b) “look” = 2. (c) “look” = 4. (d) “look” = 8 (MOREIRA et al., 2013). . . . .	37
4.2	Comparação da resolução de uma região com imageamento SAR. Em (a) foi utilizado um sistema SAR considerado o estado da arte na década de 90. (b) foi utilizado um sistema SAR da geração atual (MOREIRA et al., 2013). . . . .	39
4.3	Diagrama de blocos dos componentes básicos de um sistema de radar. Figura adaptada de (CHAN; KOO, 2008). . . . .	40
4.4	Geometria de um imageamento SAR. $r_0$ representa a menor distância de aproximação, $\Theta_a$ é a largura do feixe do azimuth e $v$ é a velocidade do sensor (MOREIRA et al., 2013). . . . .	42

4.5	Ilustração dos passos básicos do processamento de um sistema SAR. A função de referência do “range” é dependente apenas da forma de onda transmitida do “chirp”. Já a função de referência do azimute depende da geometria e é adaptada à faixa. Figura adaptada de (MOREIRA et al., 2013). . . . .	43
5.1	Vizinhança centralizada em um ponto $(x, y)$ em uma imagem no domínio espacial. Figura adaptada de (GONZALEZ; WOODS, 2010). . . . .	45
5.2	Representação das janelas do “Nonlocal means”. A maior janela em laranja é a janela de busca. A janela em verde é o “patch” referenciado. O “patch” em roxo representa o patch sendo avaliado. O caminho em vermelho indica o caminho a ser percorrido pelo “patch” roxo. . . . .	48
5.3	Exemplo de atribuição de peso: $q_1$ e $q_2$ possuem pesos grandes por causa da similaridade com $p$ . Por outro lado, o valor de $w(p, q_3)$ é bem menor já que as intensidades dos valores dos níveis de cinza são bem diferentes (BUADES; COLL; MOREL, 2005). . . . .	50
5.4	Exemplo de agrupamento dos blocos de imagens contaminadas com ruído branco aditivo gaussiano. $R$ é o bloco referenciado. . . . .	51
5.5	Exemplo de agrupamento em uma imagem artificial. . . . .	51
5.6	Esquema do algoritmo BM3D. Figura adaptada de (LEBRUN, 2012). . . . .	53
5.7	Gráfico da f.d.p do “speckle”. $L$ representa o número de “looks”. Figura adaptada de (ARSENAUL; APRIL, 1976) . . . . .	57
5.8	Função densidade de probabilidade do logaritmo da imagem de intensidade. Quanto maior o número de “looks”, o gráfico se aproxima mais de uma Gaussiana. Figura adaptada de (ARSENAUL; APRIL, 1976) . . . . .	58
5.9	Histograma do ruído multiplicativo (a-c), (b-d) é a versão do log. (a-b) corresponde $L = 1$ e (c-d) para $L = 10$ . (STARCK; MURTAGH; FADILI, 2010) . . . . .	59
5.10	Esquema do filtro PPB iterativo. Figura adaptada de (DELEDALLE; DENIS; TUPIN, 2009) . . . . .	69
5.11	Exemplo dos processos “hard-” e “soft-thresholding” no sinal original. . . . .	72
6.1	Distâncias estocásticas para a distribuição $G^0$ . Figura adaptada de (NASCIMENTO; CINTRA; FRERY, 2010). . . . .	80

6.2	Identities das integrais sob o modelo da $G^0$ . Figura adaptada de (NASCIMENTO; CINTRA; FRERY, 2010). . . . .	80
8.1	Lena em escala de cinza. O quadrado indica a região de tamanho 150x150 pixels escolhida para os testes. . . . .	90
8.2	Varição do número de “looks” na imagem sintética. . . . .	91
8.3	Resultado da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela $G^0$ . Imagem contaminada com “speckle” de 8 “looks”. Da direita para esquerda e de cima para baixo: Aritmética Geométrica, Bhattacharyya, Hellinger, Média Harmônica, Jensen-Shannon, Kullback-Leibler, Rényi e Triangular. . . . .	91
8.4	Resultado da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela Inversa da Gama. Imagem contaminada com "speckle" de 8 "looks". Da direita para esquerda e de cima para baixo: Aritmética Geométrica, Bhattacharyya, Hellinger, Média Harmônica, Jensen-Shannon, Kullback-Leibler, Rényi e Triangular. . . . .	92
8.5	Resultado da filtragem com os demais filtros. Imagem contaminada com "speckle" de 8 "looks". Da esquerda para direita e de cima para baixo: BM3D, FANS, FNLM, FROST, LEE, NLM, NLM-SAP, OBNL, PNLM, PPB GAUSS IT, PPB GAUSS NIT, PPB NAKA IT, PPB NAKA NIT, SAIST, SAR-BM3D. . . . .	93
8.6	Resultado da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela $G^0$ . Imagem contaminada com "speckle" de 3 "looks". Da direita para esquerda e de cima para baixo: Aritmética Geométrica, Bhattacharyya, Hellinger, Média Harmônica, Jensen-Shannon, Kullback-Leibler, Rényi e Triangular. . . . .	94
8.7	Resultado da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela inversa da Gama. Imagem contaminada com "speckle" de 3 "looks". Da direita para esquerda e de cima para baixo: Aritmética Geométrica, Bhattacharyya, Hellinger, Média Harmônica, Jensen-Shannon, Kullback-Leibler, Rényi e Triangular. . . . .	95
8.8	Resultado da filtragem com os demais filtros. Imagem contaminada com "speckle" de 3 "looks". Da esquerda para direita e de cima para baixo: BM3D, FANS, FNLM, FROST, LEE, NLM, NLM-SAP, OBNL, PNLM, PPB GAUSS IT, PPB GAUSS NIT, PPB NAKA IT, PPB NAKA NIT, SAIST, SAR-BM3D. . . . .	96

8.9	Resultado da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela $G^0$ . Imagem contaminada com "speckle" de 1 "look". Da direita para esquerda e de cima para baixo: Aritmética Geométrica, Bhattacharyya, Hellinger, Média Harmônica, Jensen-Shannon, Kullback-Leibler, Rényi e Triangular. . . . .	97
8.10	Resultado da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela Inversa da Gama. Imagem contaminada com "speckle" de 1 "look". Da direita para esquerda e de cima para baixo: Aritmética Geométrica, Bhattacharyya, Hellinger, Média Harmônica, Jensen-Shannon, Kullback-Leibler, Rényi e Triangular. . . . .	97
8.11	Resultado da filtragem com os demais filtros. Imagem contaminada com "speckle" de 1 "look". Da esquerda para direita e de cima para baixo: BM3D, FANS, FNLM, FROST, LEE, NLM, NLM-SAP, OBNL, PNLN, PPB GAUSS IT, PPB GAUSS NIT, PPB NAKA IT, PPB NAKA NIT, SAIST, SAR-BM3D. . . . .	98
8.12	Imagem SAR em Intensidade com polarização HH e $L = 4$ , com 3 regiões realçadas. . . . .	103
8.13	Imagem SAR em Intensidade com polarização HV e $L = 4$ . . . . .	103
8.14	Imagem SAR em Intensidade com polarização VV e $L = 4$ . . . . .	104
8.15	Regiões ruidosas. Da esquerda para a direita: polarização HH, HV, VV. De cima para baixo: R1, R2, R3. . . . .	104
8.16	Comparação das filtrações do filtro NLM com as distâncias estocásticas nas regiões HH com as estimções pela $G^0$ e Inversa da Gama. De cima para baixo são as distâncias Aritmética Geométrica, Bhattacharyya, Hellinger, Média Harmônica, Jensen-Shannon, Kullback-Leibler, Rényi e Triangular. As colunas ímpares são estimções pela $G^0$ e as colunas pares pela inversa da Gama. . . . .	105
8.17	Comparação das filtrações do filtro NLM com as distâncias estocásticas nas regiões HV com as estimções pela $G^0$ e Inversa da Gama. De cima para baixo são as distâncias Aritmética Geométrica, Bhattacharyya, Hellinger, Média Harmônica, Jensen-Shannon, Kullback-Leibler, Rényi e Triangular. As colunas ímpares são estimções pela $G^0$ e as colunas pares pela inversa da Gama. . . . .	106

8.18	Comparação das filtragens do filtro NLM com as distâncias estocásticas nas regiões VV com as estimações pela $G^0$ e Inversa da Gama. De cima para baixo são as distâncias Aritmética Geométrica, Bhattacharyya, Hellinger, Média Harmônica, Jensen-Shannon, Kullback-Leibler, Rényi e Triangular. As colunas ímpares são estimações pela $G^0$ e as colunas pares pela inversa da Gama. . . . .	107
8.19	Comparação das filtragens com os demais filtros nas regiões 1 e 2. De cima para baixo: FANS, FNLM, FROST, LEE, NLM, NLM-SAP. As regiões alternam-se de três em três colunas. . . . .	108
8.20	Comparação das filtragens com os demais filtros nas regiões 1 e 2. De cima para baixo: OBNL, PNLN, PPB GAUSS IT, PPB GAUSS NIT, PPB NAKA IT, PPB NAKA NIT, SAR-BM3D. As regiões alternam-se de três em três colunas. . . . .	109
8.21	Comparação das filtragens com os demais filtros na região 3. De cima para baixo: FANS, FNLM, FROST, LEE, NLM, NLM-SAP. . . . .	110
8.22	Comparação das filtragens com os demais filtros na região 3. De cima para baixo: OBNL, PNLN, PPB GAUSS IT, PPB GAUSS NIT, PPB NAKA IT, PPB NAKA NIT, SAR-BM3D. . . . .	111
8.23	Razão $r$ das regiões com a polarização HH para o NLM com as distâncias estocásticas. Quanto menor a presença de bordas e artefatos, maior o desempenho do filtro. Nas colunas ímpares foram utilizados os parâmetros estimados pela $G^0$ , nas pares, pela inversa da Gama. . . . .	112
8.24	Razão $r$ das regiões com a polarização HV para o NLM com as distâncias estocásticas. Quanto menor a presença de bordas e artefatos, maior o desempenho do filtro. Nas colunas ímpares foram utilizados os parâmetros estimados pela $G^0$ , nas pares, pela inversa da Gama. . . . .	113
8.25	Razão $r$ das regiões com a polarização VV para o NLM com as distâncias estocásticas. Quanto menor a presença de bordas e artefatos, maior o desempenho do filtro. Nas colunas ímpares foram utilizados os parâmetros estimados pela $G^0$ , nas pares, pela inversa da Gama. . . . .	114
8.26	Razão $r$ das regiões com a polarização HH para os demais filtros. Quanto menor a presença de bordas e artefatos, maior o desempenho do filtro. De cima para baixo: FANS, FNLM, FROST, LEE, NLM, NLM-SAP. . . . .	115

8.27	Razão $r$ das regiões com a polarização HH para os demais filtros. Quanto menor a presença de bordas e artefatos, maior o desempenho do filtro. De cima para baixo: OBNL, PNLM, PPB GAUSS IT, PPB GAUSS NIT, PPB NAKA IT, PPB NAKA NIT, SAR-BM3D. . . . .	116
8.28	Razão $r$ das regiões com a polarização HV para os demais filtros. Quanto menor a presença de bordas e artefatos, maior o desempenho do filtro. De cima para baixo: FANS, FNLM, FROST, LEE, NLM, NLM-SAP. . . . .	117
8.29	Razão $r$ das regiões com a polarização HV para os demais filtros. Quanto menor a presença de bordas e artefatos, maior o desempenho do filtro. De cima para baixo: OBNL, PNLM, PPB GAUSS IT, PPB GAUSS NIT, PPB NAKA IT, PPB NAKA NIT, SAR-BM3D. . . . .	118
8.30	Razão $r$ das regiões com a polarização VV para os demais filtros. Quanto menor a presença de bordas e artefatos, maior o desempenho do filtro. De cima para baixo: FANS, FNLM, FROST, LEE, NLM, NLM-SAP. . . . .	119
8.31	Razão $r$ das regiões com a polarização VV para os demais filtros. Quanto menor a presença de bordas e artefatos, maior o desempenho do filtro. De cima para baixo: OBNL, PNLM, PPB GAUSS IT, PPB GAUSS NIT, PPB NAKA IT, PPB NAKA NIT, SAR-BM3D. . . . .	120

## LISTA DE TABELAS

6.1	Funções $h$ e $\phi$ utilizadas para desenvolver as distâncias estocásticas. Tabela adaptada de (NASCIMENTO; CINTRA; FRERY, 2010). . . . .	78
8.1	Medidas do PSNR e SSIM da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela $G^0$ . Imagem contaminada com "speckle" de 8 "looks". $PSNR = 14,81$ e $SSIM = 0,19$ baseados na média sobre 10 realizações do "speckle". . . . .	94
8.2	Medidas do PSNR e SSIM da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela Inversa da Gama. Imagem contaminada com "speckle" de 8 "looks". $PSNR = 14,81$ e $SSIM = 0,19$ baseados na média sobre 10 realizações do "speckle". . . . .	95
8.3	Medidas do PSNR e SSIM da filtragem do NLM com os demais filtros. Imagem contaminada com "speckle" de 8 "looks". $PSNR = 14,81$ e $SSIM = 0,19$ baseados na média sobre 10 realizações do "speckle". . . . .	99
8.4	Medidas do PSNR e SSIM da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela $G^0$ . Imagem contaminada com "speckle" de 3 "looks". $PSNR = 10,51$ e $SSIM = 0,10$ baseados na média sobre 10 realizações do "speckle". . . . .	99
8.5	Medidas do PSNR e SSIM da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela Inversa da Gama. Imagem contaminada com "speckle" de 3 "looks". $PSNR = 10,51$ e $SSIM = 0,10$ baseados na média sobre 10 realizações do "speckle". . . . .	99
8.6	Medidas do PSNR e SSIM da filtragem do NLM com os demais filtros. Imagem contaminada com "speckle" de 3 "looks". $PSNR = 10,51$ e $SSIM = 0,10$ baseados na média sobre 10 realizações do "speckle". . . . .	100

8.7	Medidas do PSNR e SSIM da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela $G^0$ . Imagem contaminada com "speckle" de 1 "look". $PSNR = 5,78$ e $SSIM = 0,04$ baseados na média sobre 10 realizações do "speckle". . . . .	100
8.8	Medidas do PSNR e SSIM da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela Inversa da Gama. Imagem contaminada com "speckle" de 1 "look". $PSNR = 5,78$ e $SSIM = 0,04$ baseados na média sobre 10 realizações do "speckle". . . . .	100
8.9	Medidas do PSNR e SSIM da filtragem do NLM com os demais filtros. Imagem contaminada com "speckle" de 1 "look". $PSNR = 5,78$ e $SSIM = 0,04$ baseados na média sobre 10 realizações do "speckle". . . . .	101
9.1	Tempo de execução da filtragem com o método proposto pela $G^0$ com as oito distâncias estocásticas de uma realização do "speckle" para $L = 1$ . . . . .	123
9.2	Tempo de execução da filtragem com o método proposto pela $G^0$ com as oito distâncias estocásticas de uma realização do "speckle" para $L = 3$ . . . . .	123
9.3	Tempo de execução da filtragem com o método proposto pela $G^0$ com as oito distâncias estocásticas de uma realização do "speckle" para $L = 8$ . . . . .	124
9.4	Tempo de execução da filtragem com o método proposto pela Inversa da Gama com as oito distâncias estocásticas de uma realização do "speckle" para $L = 1$ . . . . .	124
9.5	Tempo de execução da filtragem com o método proposto pela Inversa da Gama com as oito distâncias estocásticas de uma realização do "speckle" para $L = 3$ . . . . .	124
9.6	Tempo de execução da filtragem com o método proposto pela Inversa da Gama com as oito distâncias estocásticas de uma realização do "speckle" para $L = 8$ . . . . .	125
9.7	Tempo de execução da filtragem com os demais filtros de uma realização do "speckle" para $L = 1$ . . . . .	125
9.8	Tempo de execução da filtragem com os demais filtros de uma realização do "speckle" para $L = 3$ . . . . .	126
9.9	Tempo de execução da filtragem com os demais filtros de uma realização do "speckle" para $L = 8$ . . . . .	126
A.1	Valores ENL da região 1 HH do filtro proposto com as distâncias estocásticas e estimadores da $G^0$ . . . . .	138

A.2	Valores ENL da região 1 HH do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. . . . .	138
A.3	Valores ENL da região 1 HH dos demais filtros. . . . .	139
A.4	Valores ENL da região 2 HH do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . . . . .	139
A.5	Valores ENL da região 2 HH do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. . . . .	140
A.6	Valores ENL da região 2 HH dos demais filtros. . . . .	140
A.7	Valores ENL da região 3 HH do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . . . . .	141
A.8	Valores ENL da região 3 HH do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. . . . .	141
A.9	Valores ENL da região 3 HH dos demais filtros. . . . .	141
A.10	Valores ENL da região 1 HV do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . . . . .	142
A.11	Valores ENL da região 1 HV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. . . . .	142
A.12	Valores ENL da região 1 HV dos demais filtros. . . . .	143
A.13	Valores ENL da região 2 HV do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . . . . .	143
A.14	Valores ENL da região 2 HV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. . . . .	143
A.15	Valores ENL da região 2 HV dos demais filtros. . . . .	144
A.16	Valores ENL da região 3 HV do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . . . . .	144
A.17	Valores ENL da região 3 HV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. . . . .	144
A.18	Valores ENL da região 3 HV dos demais filtros. . . . .	145

A.19	Valores ENL da região 1 VV do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . . . . .	145
A.20	Valores ENL da região 1 VV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. . . . .	145
A.21	Valores ENL da região 1 VV dos demais filtros. . . . .	146
A.22	Valores ENL da região 2 VV do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . . . . .	146
A.23	Valores ENL da região 2 VV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. . . . .	146
A.24	Valores ENL da região 2 VV dos demais filtros. . . . .	147
A.25	Valores ENL da região 3 VV do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . . . . .	147
A.26	Valores ENL da região 3 VV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. . . . .	147
A.27	Valores ENL da região 3 VV dos demais filtros. . . . .	148
A.28	Valores do índice B da região 1 HH do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . . . . .	149
A.29	Valores do índice B da região 1 HH do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. . . . .	149
A.30	Valores do índice B da região 1 HH dos demais filtros. . . . .	150
A.31	Valores do índice B da região 2 HH do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . . . . .	150
A.32	Valores do índice B da região 2 HH do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. . . . .	150
A.33	Valores do índice B da região 2 HH dos demais filtros. . . . .	151
A.34	Valores do índice B da região 3 HH do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . . . . .	151
A.35	Valores do índice B da região 3 HH do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. . . . .	151

A.36	Valores do índice B da região 3 HH dos demais filtros. . . . .	152
A.37	Valores do índice B da região 1 HV do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . . . . .	152
A.38	Valores do índice B da região 1 HV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. . . . .	152
A.39	Valores do índice B da região 1 HV dos demais filtros. . . . .	153
A.40	Valores do índice B da região 2 HV do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . . . . .	153
A.41	Valores do índice B da região 2 HV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. . . . .	153
A.42	Valores do índice B da região 2 HV dos demais filtros. . . . .	154
A.43	Valores do índice B da região 3 HV do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . . . . .	154
A.44	Valores do índice B da região 3 HV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. . . . .	154
A.45	Valores do índice B da região 3 HV dos demais filtros. . . . .	155
A.46	Valores do índice B da região 1 VV do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . . . . .	156
A.47	Valores do índice B da região 1 VV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. . . . .	156
A.48	Valores do índice B da região 1 VV dos demais filtros. . . . .	157
A.49	Valores do índice B da região 2 VV do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . . . . .	157
A.50	Valores do índice B da região 2 VV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. . . . .	157
A.51	Valores do índice B da região 2 VV dos demais filtros. . . . .	158
A.52	Valores do índice B da região 3 VV do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . . . . .	158

A.53	Valores do índice B da região 3 VV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. . . . .	158
A.54	Valores do índice B da região 3 VV dos demais filtros. . . . .	159
A.55	Valores do índice $C_{\hat{f}}$ da região 1 HH do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . Valor $C_f = 3, 12$ . . . . .	160
A.56	Valores do índice $C_{\hat{f}}$ da região 1 HH do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. Valor $C_f = 3, 12$ . . . . .	160
A.57	Valores do índice $C_{\hat{f}}$ da região 1 HH com os demais filtros. Valor $C_f = 3, 12$ . . . . .	161
A.58	Valores do índice $C_{\hat{f}}$ da região 2 HH do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . Valor $C_f = 3, 35$ . . . . .	161
A.59	Valores do índice $C_{\hat{f}}$ da região 2 HH do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. Valor $C_f = 3, 35$ . . . . .	161
A.60	Valores do índice $C_{\hat{f}}$ da região 2 HH com os demais filtros. Valor $C_f = 3, 35$ . . . . .	162
A.61	Valores do índice $C_{\hat{f}}$ da região 3 HH do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . Valor $C_f = 2, 35$ . . . . .	162
A.62	Valores do índice $C_{\hat{f}}$ da região 3 HH do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. Valor $C_f = 2, 35$ . . . . .	162
A.63	Valores do índice $C_{\hat{f}}$ da região 3 HH com os demais filtros. Valor $C_f = 2, 35$ . . . . .	163
A.64	Valores do índice $C_{\hat{f}}$ da região 1 HV do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . Valor $C_f = 1, 80$ . . . . .	163
A.65	Valores do índice $C_{\hat{f}}$ da região 1 HV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. Valor $C_f = 1, 80$ . . . . .	163
A.66	Valores do índice $C_{\hat{f}}$ da região 1 HV com os demais filtros. Valor $C_f = 1, 80$ . . . . .	164
A.67	Valores do índice $C_{\hat{f}}$ da região 2 HV do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . Valor $C_f = 1, 80$ . . . . .	164
A.68	Valores do índice $C_{\hat{f}}$ da região 2 HV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. Valor $C_f = 1, 80$ . . . . .	164
A.69	Valores do índice $C_{\hat{f}}$ da região 2 HV com os demais filtros. Valor $C_f = 1, 80$ . . . . .	165

A.70	Valores do índice $C_{\hat{f}}$ da região 3 HV do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . Valor $C_f = 1,02$ . . . . .	165
A.71	Valores do índice $C_{\hat{f}}$ da região 3 HV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. Valor $C_f = 1,02$ . . . . .	165
A.72	Valores do índice $C_{\hat{f}}$ da região 3 HV com os demais filtros. Valor $C_f = 1,02$ . . . . .	166
A.73	Valores do índice $C_{\hat{f}}$ da região 1 VV do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . Valor $C_f = 2,67$ . . . . .	167
A.74	Valores do índice $C_{\hat{f}}$ da região 1 VV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. Valor $C_f = 2,67$ . . . . .	167
A.75	Valores do índice $C_{\hat{f}}$ da região 1 VV com os demais filtros. Valor $C_f = 2,67$ . . . . .	168
A.76	Valores do índice $C_{\hat{f}}$ da região 2 VV do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . Valor $C_f = 2,22$ . . . . .	168
A.77	Valores do índice $C_{\hat{f}}$ da região 2 VV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. Valor $C_f = 2,22$ . . . . .	168
A.78	Valores do índice $C_{\hat{f}}$ da região 2 VV com os demais filtros. Valor $C_f = 2,22$ . . . . .	169
A.79	Valores do índice $C_{\hat{f}}$ da região 3 VV do filtro proposto com as distâncias estocásticas e estimadores da $G_I^0$ . Valor $C_f = 2,07$ . . . . .	169
A.80	Valores do índice $C_{\hat{f}}$ da região 3 VV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. Valor $C_f = 2,07$ . . . . .	169
A.81	Valores do índice $C_{\hat{f}}$ da região 3 VV com os demais filtros. Valor $C_f = 2,07$ . . . . .	170

# SUMÁRIO

<b>CAPÍTULO 1 – INTRODUÇÃO</b>	<b>23</b>
1.1 Organização . . . . .	25
<b>CAPÍTULO 2 – IMAGEM DIGITAL E RUÍDOS</b>	<b>27</b>
2.1 Ruído aditivo . . . . .	29
2.2 Ruído multiplicativo: “Speckle” . . . . .	29
<b>CAPÍTULO 3 – F.D.P’S E DISTRIBUIÇÕES</b>	<b>31</b>
3.1 Distribuições <i>Gama</i> , <i>K</i> e $G^0$ . . . . .	34
<b>CAPÍTULO 4 – FUNDAMENTOS DE SAR</b>	<b>36</b>
4.1 Histórico . . . . .	37
4.2 Radar . . . . .	40
<b>CAPÍTULO 5 – FILTROS</b>	<b>44</b>
5.1 Filtros para ruído aditivo . . . . .	45
5.2 Filtros adaptativos . . . . .	47
5.3 Filtro de Wiener (Mínimo erro quadrático) . . . . .	47
5.4 “Nonlocal means” (NLM) . . . . .	48
5.5 BM3D . . . . .	49
5.6 Filtros para ruído multiplicativo . . . . .	54
5.6.1 Transformação Homomórfica . . . . .	56

5.6.2	Filtro de Lee (LLMMSE - “Local Linear Minimum Mean Square Error”) e de Lee Refinado . . . . .	58
5.6.3	Filtro de Kuan (LLMMSE) . . . . .	60
5.6.4	Filtro de Frost (MMSE) . . . . .	61
5.6.5	Filtros MAP (“Maximum a Posteriori”) . . . . .	63
5.6.6	Filtros com transformada wavelet discreta . . . . .	63
5.6.7	Filtros com abordagens não Bayesianas . . . . .	64
5.6.8	Filtro de Deledalle (PPB - “Probabilistic Patch Based”) . . . . .	66
5.6.9	SAR-BM3D . . . . .	71
5.7	Outras versões inspiradas pelo NLM e BM3D . . . . .	73
 <b>CAPÍTULO 6 – DISTÂNCIAS ESTOCÁSTICAS COM A <math>G^0</math></b>		<b>76</b>
 <b>CAPÍTULO 7 – MEDIDAS PARA AVALIAÇÃO DOS FILTROS</b>		<b>81</b>
7.1	Índices com referências . . . . .	82
7.2	Índices sem referências . . . . .	83
 <b>CAPÍTULO 8 – PROPOSTA E RESULTADOS</b>		<b>86</b>
8.1	Estimação pela inversa da Gama . . . . .	87
8.2	Implementação . . . . .	88
8.3	Configuração dos parâmetros do NLM . . . . .	88
8.4	Análise em imagens sintéticas . . . . .	89
8.5	Análise em imagem SAR real . . . . .	102
 <b>CAPÍTULO 9 – CONCLUSÃO</b>		<b>121</b>
9.1	Trabalhos futuros . . . . .	122
 <b>REFERÊNCIAS</b>		<b>127</b>
 <b>GLOSSÁRIO</b>		<b>135</b>

<b>CAPÍTULO A –TABELAS DOS RESULTADOS</b>	<b>138</b>
A.1 ENL . . . . .	138
A.2 Índice B . . . . .	149
A.3 Índice $C_{\hat{f}}$ . . . . .	160

# Capítulo 1

## INTRODUÇÃO

---

---

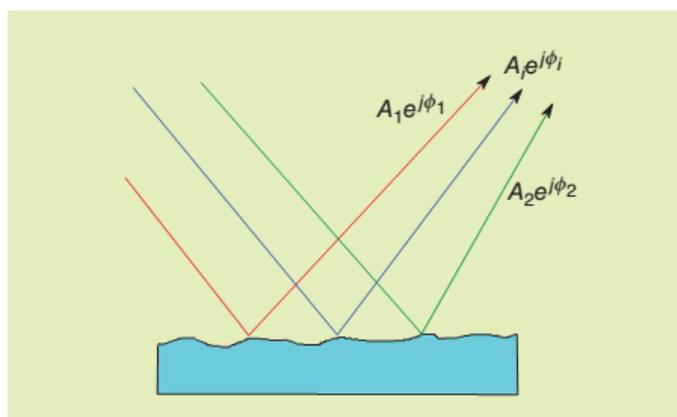
*Neste capítulo se aborda brevemente o contexto e a motivação desta dissertação de Mestrado que envolve filtragem de imagens SAR. Na seção 1.1 é descrita a organização deste documento com uma pequena explicação de cada capítulo.*

O desenvolvimento e ampliação de técnicas para a remoção de ruídos nas imagens é um problema bastante estudado na área de Processamento de Imagens e Sinais e ainda continua atraindo pesquisadores que buscam desenvolver melhores métodos para a filtragem de imagens ruidosas (CHATTERJEE; MILANFAR, 2010). A restauração de imagens pode ser aplicada em várias áreas: astronomia, medicina, ciência forense, etc (NATH, 2013).

As técnicas de filtragem de imagens procuram recuperar imagens corrompidas, com base em um conhecimento a priori do fenômeno de degradação. Além disto, elas podem desenvolver critérios para definir estimativas do resultado desejado e avaliar a qualidade da imagem filtrada (GONZALEZ; WOODS, 2010).

Muitos algoritmos ainda não atingiram um nível de aplicabilidade desejada, ou seja, mesmo suavizando o ruído eles necessitam ser aperfeiçoados. Eles mostram um ótimo desempenho quando a imagem utilizada corresponde ao algoritmo, isto é, uma imagem que tenha resultado superior às demais utilizadas. Mas, de modo geral, estes algoritmos falham e criam artefatos (“ringing”, “blur”, “staircase effect”, “checkerboard effect”, “wavelet outliers”, etc) ou removem estruturas finas da imagem.

Além disto, com o crescimento do número de sensores ou pixels por unidade de área de um chip, dispositivos modernos de captura de imagens são altamente sensíveis ao ruído. Então, empresas que desenvolvem estes dispositivos dependem dos algoritmos elaborados para reduzir os efeitos dos artefatos nas imagens filtradas. Porém, grande parte dos métodos elaborados são baseados no ruído aditivo, e alguns pesquisadores dedicam-se a ampliar a capacidade de um



**Figura 1.1: Modelo dos sinais espalhados (“backscatters”) na superfície. (ARGENTI et al., 2013).**

filtro para poder tratar imagens com ruído multiplicativo. Imagens SAR (“Synthetic Aperture Radar” - Radar de Abertura Sintética), sonares, lasers e ultrassom são exemplos que podem ser contaminadas com este tipo de ruído.

Segundo (HORTA, 2009), os avanços nas pesquisas voltadas para imagens SAR são de extrema importância para o monitoramento e estudos da superfície terrestre. Um sistema SAR atua na faixa de micro-ondas e, por isso, é independente da luz solar e de fatores climáticos. Ele é menos afetado que os sensores ópticos.

Imagens SAR são contaminadas com o “speckle”, o qual é um fenômeno comum em sistemas de sensoriamento que utilizam iluminação coerente. O sistema envia pulsos eletromagnéticos em direção a um alvo e analisa o eco de retorno. O “speckle” aparece devido às interferências no sinal de retorno pelos elementos do alvo de uma superfície. Ele adiciona um aspecto granuloso na imagem dificultando sua análise e interpretação.

SAR é um sistema que produz uma radiação e captura os sinais retroespalhados de uma pequena área da cena (“resolution cell”). O sinal de retorno é complexo e pode ser visto como uma somatória do retorno de vários “scatters”:  $Ae^{\zeta\phi} = \sum_i A_i e^{\zeta\phi_i}$ , sendo  $\zeta = \sqrt{-1}$  a unidade imaginária, como na Figura 1.1.  $A_i$  representa a amplitude e  $\phi_i$  a fase dos sinais, que são dadas de acordo com alguns fatores: atenuação da propagação, “scatters” dos alvos imageados, diretividade da antena. Se for considerado que as fases de cada sinal dos “scatters” são muito diferentes e que elas podem ser somadas de uma maneira construtiva ou destrutiva, então a amplitude do sinal recebido varia aleatoriamente. Logo, mesmo que a refletividade subjacente seja uniforme, ela aparece afetada por um ruído granular após o imageamento (ARGENTI et al., 2013).

Recentemente, o método desenvolvido por Buades, Coll e Morel (2005) para filtrar ruído aditivo Gaussiano e os métodos baseados nele, como os de Dabov et al. (2007) e Aharon, Elad

e Bruckstein (2006), superaram várias técnicas já consagradas na literatura e são considerados o estado da arte por Chatterjee e Milanfar (CHATTERJEE; MILANFAR, 2010). Os trabalhos mencionados trabalham com a idéia de similaridade entre os pixels de uma dada imagem, ou seja, pixels de um “patch” que possuem seus níveis de cinza próximos, segundo algum critério, aos pixels de outro “patch” serão considerados similares. “Patch” é um conjunto de pixels dentro de uma janela de  $n$  linhas por  $n$  colunas. Esta idéia de similaridade foi primeiramente mostrada por Efros e Leung (EFROS; LEUNG, 1999). Um dos desafios da área de filtragem é desenvolver uma técnica que seja capaz de remover diferentes tipos de ruídos (modelo aditivo e modelo multiplicativo), como o método proposto por Deledalle, Denis e Tupin (2009) e inserir dentro da abordagem do filtro de Buades, Coll e Morel (2005) outras medidas de similaridade, como em Teuber e Lang (2012).

Esta dissertação, inspirada pelos trabalhos de Buades, Coll e Morel (2005) e Nascimento, Cintra e Frery (2010), tem o objetivo de analisar a filtragem do NLM (“Non-local means”) descrito na seção 5.4 utilizando a transformação homomórfica e a estimação dos parâmetros de rugosidade e escala pela distribuição  $G^0$ . Além disto, através do trabalho de Cheng et al. (2013), que compara a estimação dos parâmetros pela  $G^0$  com vários métodos, surgiu a inspiração para trabalhar com a distribuição da inversa da Gama na transformação homomórfica para estimar os parâmetros do “backscatter”, após uma pré-filtragem com o NLM. Estes parâmetros serão utilizados com as distâncias estocásticas para filtrar imagens SAR em intensidade.

## 1.1 Organização

Esta dissertação possui os capítulos divididos na seguinte maneira:

1. Introdução: O atual capítulo, no qual se aborda brevemente o contexto atual da área de Processamento de Imagens e Sinais com foco em pesquisas de filtragens de ruídos.
2. Imagem digital e ruídos: Neste capítulo encontra-se uma breve revisão bibliográfica dos dois modelos de ruído estudados neste trabalho: aditivo e multiplicativo.
3. F.D.P's e distribuições: São abordadas as funções densidade de probabilidade (f.d.p's) mais comuns na área de Processamento de Imagens e Sinais.
4. Fundamentos de SAR: Algumas propriedades e um pequeno histórico do sistema SAR são discutidos neste capítulo com o intuito de esclarecer o processo de imageamento deste tipo sistema.

5. Filtros: Os tipos de filtros analisados para filtrar os ruídos aditivo e multiplicativo. Os filtros NLM e BM3D (“Block Matching 3D”) são apresentados e brevemente descritos, uma vez que são considerados os estado da arte na literatura atual.
6. Distâncias estocásticas com a  $G^0$ : As distâncias estocásticas desenvolvidas utilizadas para análise e classificação de imagens SAR são apresentadas.
7. Medidas de desempenho: Neste capítulo se abordam as medidas de desempenho mais comuns utilizadas na literatura para avaliar os resultados sintéticos.
8. Proposta e resultados: A proposta do trabalho é descrita neste capítulo, a maneira como o algoritmo foi implementado e os resultados obtidos com imagens SAR simuladas e SAR real.
9. Conclusão: Capítulo que é feita uma avaliação dos resultados obtidos comparados com outros filtros propostos na literatura. Além de sugerir possíveis trabalhos futuros.

# Capítulo 2

## IMAGEM DIGITAL E RUÍDOS

---

---

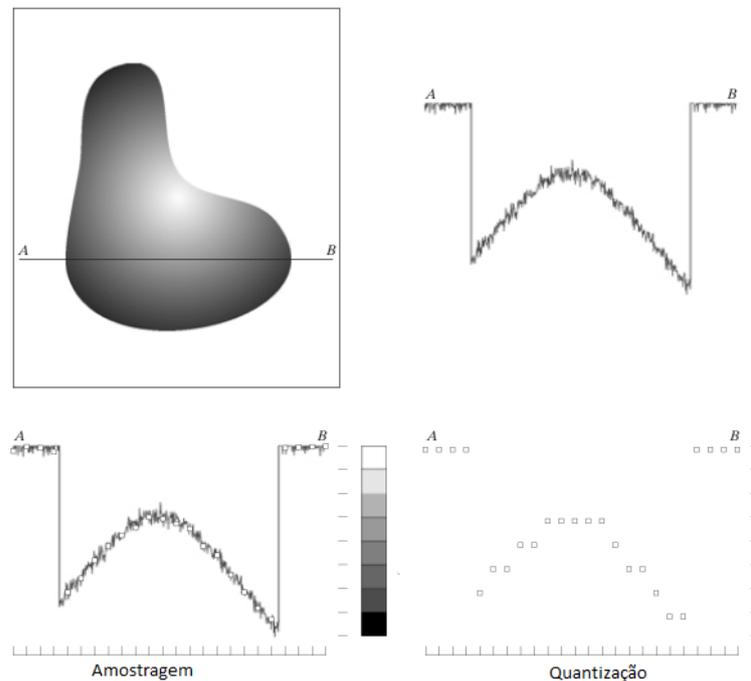
*Neste capítulo serão abordados alguns fundamentos da imagem digital e os tipos de ruídos mais estudados na literatura: ruído aditivo e ruído multiplicativo.*

Grande parte das imagens são geradas pela combinação de uma fonte emissora (pulso eletromagnético, ultrassom, computador, etc) e a reflexão ou absorção de energia dessa fonte pelos elementos presentes no ambiente (objetos cotidianos, solo, etc) (GONZALEZ; WOODS, 2010).

Uma imagem digital é criada convertendo os dados contínuos captados para o formato digital através de dois processos para a sua discretização: amostragem e quantização. A imagem  $f$  pode ser contínua nas coordenadas  $x$  e  $y$  e também na sua amplitude, a qual existe para cada par  $(x, y)$  e é chamada de intensidade ou nível de cinza. Amostragem é o processo de discretização dos valores das coordenadas do espaço. Já a quantização é o processo de discretização dos valores da amplitude. O resultado após os dois processos é uma imagem digital bidimensional cujos processos de amostragem e quantização são ilustrados na Figura 2.1 (GONZALEZ; WOODS, 2010).

De acordo com Nath (2013), alguns dos tipos de imagens mais utilizados na área são:

- Imagem binária: é o tipo mais simples das imagens e ela conta com apenas duas cores: preto e branco. O valor zero representa a cor preta e o branco é representado pelo valor um; geralmente esta imagem é criada a partir de uma imagem em escala de cinza. Este tipo de imagem é aplicada na área de Visão Computacional onde a forma geral ou informações do contorno da imagem são importantes.
- Imagem em escala de cinza: os valores dos pixels desta imagem estão, em geral, entre zero e duzentos e cinquenta e cinco. O valor zero representa a cor preta e o valor 255 indica o valor branco. Os outros valores (1 - 254) representam diferentes níveis de cinza.



**Figura 2.1:** Da esquerda para direita e da linha de cima para linha de baixo: (a) Imagem contínua; (b) Linha de varredura; (c) Amostragem e quantização; (d) Linha de varredura digital. Figura adaptada de (GONZALEZ; WOODS, 2010).

Como esta imagem contém informação de intensidade, ela é referida também como imagem de intensidade. Isto é válido para imagens quantizadas em oito bits.

- Imagem colorida: é considerada uma imagem monocromática formada por três bandas monocromáticas, as quais são de cores diferentes. Cada banda fornecerá a informação do brilho da banda espectral correspondente. As cores típicas são vermelho (“red”), verde (“green”) e azul (“blue”) e são referidas como RGB.

A imagem em escala de cinza convertida após os processos de amostragem e quantização é uma matriz  $f(x,y)$  com  $M$  linhas e  $N$  colunas. A seção do plano real que se expande pelas coordenadas é chamada de domínio espacial, com  $x$  e  $y$  sendo chamadas de coordenadas espaciais. Além disto, existem três formas básicas de representar a imagem digital: representação gráfica na superfície, matriz de intensidade visual e matriz numérica com seus elementos representando os elementos da imagem (pixel). As duas últimas maneiras são as mais úteis, pois os resultados na manipulação da imagem são vistos mais rapidamente (GONZALEZ; WOODS, 2010).

## 2.1 Ruído aditivo

Conforme descrito anteriormente, uma imagem digital em escala de cinza é representada como uma matriz. Cada par  $((x, y), f(x, y))$ , onde  $f(x, y)$  é o valor em  $(x, y)$ , é chamado de pixel. No caso de imagens em níveis de cinza,  $(x, y)$  é um ponto em duas dimensões (2D) e  $f(x, y)$  é um valor real. Em imagens coloridas  $f(x, y)$  é uma tripla de valores para os componentes vermelho, verde e azul.

O modelo de uma imagem digital com o ruído aditivo pode ser dado por:

$$z(x, y) = f(x, y) + n(x, y), \quad (2.1)$$

onde  $f(x, y)$  é a intensidade do pixel (valor real, sem ruído) com  $(x, y) \in I$ ,  $z(x, y)$  é a imagem observada e  $n(x, y)$  representa, tipicamente, um ruído branco aditivo independente e identicamente distribuído (i.i.d) com uma média zero e variância  $\sigma^2$ .

O ruído pode surgir durante a aquisição e/ou transmissão das imagens. Além da qualidade dos elementos dos sensores, estes são afetados por condições ambientais ou atmosféricas (iluminação, temperatura, umidade, descargas atmosféricas, etc) (GONZALEZ; WOODS, 2010).

Quando o espectro de Fourier do ruído é constante, o ruído é chamado de ruído branco. Este nome é dado devido às propriedades físicas da luz branca, a qual possui todas as frequências no espectro visível nas mesmas proporções (GONZALEZ; WOODS, 2010).

## 2.2 Ruído multiplicativo: “Speckle”

SAR é uma técnica aeroespacial que gera mapas com altas resoluções de superfícies terrestres. Sistemas SAR podem obter imagens de grandes áreas com boas resoluções em todas as condições de tempo (BIBO; ZHANG; FUQIANG, 2012). Para o imageamento destas áreas, existe um processamento coerente, o qual gera um ruído dependente do sinal com característica granular chamado “speckle” (MALLADI; KASILINGAM; COSTA, 2003). Bibo et al em (BIBO; ZHANG; FUQIANG, 2012) afirmam que a origem do “speckle” pode ser explicada pela interferência aleatória entre o retorno coerente emitido pelos numerosos retroespalhadores (“scatterers”) presentes na superfície.

Imagens contaminadas com o “speckle” não devem ser tratadas com filtros projetados para ruído aditivo, pois o “speckle” corrompe o sinal de retorno de uma maneira multiplicativa. Existem técnicas que contornam esta barreira, como os filtros homomórficos e o filtro de Wiener.

Portanto, nas duas formas mais comuns de obter uma imagem SAR - imagem SAR de amplitude e intensidade - o formato do ruído não é Gaussiano. Na obtenção da imagem, o sinal de retorno é complexo. Estas duas maneiras são as maneiras mais comuns que os usuários adquirem para trabalhar nas imagens SAR.

O modelo multiplicativo é o mais utilizado em imagens SAR. Ele determina que o retorno  $Z$  é baseado no produto entre duas variáveis aleatórias independentes: o “speckle”  $Y$  e o retroespalhamento do terreno  $X$ , que depende do tipo da área a que cada pixel pertence. Várias distribuições podem ser utilizadas para o retroespalhamento, visando o modelamento de diferentes tipos de classes e suas características do grau de homogeneidade. Para algumas características de imageamento, tais como frequência, polarização, ângulo de incidência, resolução espacial e espaçamento entre pixel, pasto é mais homogêneo que floresta, e esta pode ser mais homogênea que uma área urbana.

Existem várias maneiras de modelar as variáveis  $X$  e  $Y$ . As funções densidade de probabilidade (f.d.p’s) mais comuns para modelar o retorno  $Z$  com 1 “look” são a Exponencial e a Rayleigh para detecções quadráticas (imagens SAR em intensidade) e lineares (imagens SAR em amplitude) respectivamente (FRERY et al., 1997). Já para imagens SAR com vários “looks”, estas podem ser modeladas por uma função Gama. Frery et al em (FRERY et al., 1997) propuseram a distribuição recíproca da Gama ( $\Gamma^{-\frac{1}{2}}$ ) para o retroespalhamento de amplitude e de intensidade que gerou uma nova distribuição do retorno chamada  $G^0$  ( $G_A^0$  para imagens SAR em amplitude e  $G_I^0$  para imagens SAR em intensidade). Ela possui três parâmetros:  $n$ ,  $\gamma$  e  $\alpha$ , os quais representam, respectivamente, o número de “looks”, escala e rugosidade. A vantagem desta distribuição em relação às clássicas é que ela modela muito bem áreas extremamente heterogêneas como cidades, áreas heterogêneas como florestas e áreas homogêneas como pastos (MEJAIL et al., 2003). Porém, é importante ressaltar que o grau de homogeneidade depende das características do imageamento. Devido ao fato deste trabalho possuir o objetivo de aplicar e avaliar os resultados em imagens SAR em intensidade, a imagem será modelada com a  $G_I^0$ .

Apesar do “speckle” carregar informações sobre a área iluminada, ele degrada a aparência da imagem e dificulta a performance para análises e interpretações. A técnica de “multilooks” reduz o ruído mas ao custo da perda de resolução em azimuth (PARRILLI et al., 2012), ou seja, a imagem tende a ficar mais suavizada.

O conhecimento preciso das propriedades estatísticas do “speckle” é importante para o processamento e entendimento de uma imagem SAR. Essas propriedades podem ser utilizadas para discriminar os tipos de terreno utilizados e para desenvolver filtros especializados para a redução do speckle (FRERY et al., 1997).

# Capítulo 3

## F.D.P'S E DISTRIBUIÇÕES

---

---

*Neste capítulo serão apresentadas as funções densidade de probabilidade (f.d.p's) e as distribuições mais abordadas na literatura de Processamento de Imagens e Sinais. Aqui, as f.d.p's são relacionadas com os ruídos gaussiano, Rayleigh, gama, uniforme, exponencial e impulsivo.*

De acordo com (NATH, 2013), quando existe um modelo para o processo de degradação, o processo inverso pode ser aplicado na imagem ruidosa para restaurá-la ao seu formato original.

Segundo (GONZALEZ; WOODS, 2010), os valores de intensidade no componente de ruído podem ser considerados variáveis aleatórias caracterizadas por uma função densidade de probabilidade (f.d.p). A seguir, são citadas as f.d.p's mais comuns na literatura para modelar o ruído. A Figura 3.1 mostra os gráficos das funções destas f.d.p's.

**Ruído gaussiano:** é o modelo mais utilizado devido à possibilidade de manipulação matemática no domínio espacial e da frequência. A f.d.p de uma variável aleatória gaussiana,  $z$ , é expressa por:

$$f_Y(y) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(y-\bar{y})^2}{2\sigma^2}\right), \quad (3.1)$$

na qual  $y$  representa intensidade,  $\bar{y}$  é o valor esperado de  $y$ ,  $\sigma$  é o desvio padrão e  $\sigma^2$  é a variância de  $y$ . Ele é uniformemente distribuído sobre o sinal, ou seja, cada pixel da imagem ruidosa é a soma do pixel real e o valor aleatório da distribuição Gaussiana. Esta distribuição possui a forma de um sino (NATH, 2013). O gráfico do ruído gaussiano modelado é ilustrado na Figura 3.2, mais informações sobre esta figura disponíveis em (NATH, 2013).

**Ruído de Rayleigh:**

$$f_Y(y) = \begin{cases} \frac{2}{b}(y - \alpha) \exp\left(-\frac{(y-\alpha)^2}{b}\right) & \text{para } y \geq \alpha \\ 0 & \text{para } y < \alpha \end{cases} \quad (3.2)$$

O valor esperado e variância são dados, respectivamente por  $\bar{y} = \alpha + \sqrt{\frac{\pi b}{4}}$  e  $\sigma^2 = \frac{b(4-\pi)}{4}$ .

**Ruído de Erlang (Gama):**

$$f_Y(y) = \begin{cases} \frac{a^b y^{(b-1)}}{(b-1)!} \exp(-ay) & \text{para } y \geq 0 \\ 0 & \text{para } y < 0 \end{cases} \quad (3.3)$$

, onde  $a > 0$ ,  $b$  é um inteiro positivo e “!” indica fatorial. O valor esperado e a variância são dados, respectivamente, por  $\bar{y} = \frac{b}{a}$  e  $\sigma^2 = \frac{b}{a^2}$ . Esta f.d.p é chamada de Gama quando o denominador é trocado pela função gama  $\Gamma(b)$ . Além disso, ela pode representar a distribuição do “speckle”, que é um ruído multiplicativo diferentemente do ruído gaussiano. A Figura 3.3 exemplifica o ruído speckle e a f.d.p Gama.

**Ruído exponencial:**

$$f_Y(y) = \begin{cases} a \exp(-ay) & \text{para } y \geq 0 \\ 0 & \text{para } y < 0 \end{cases} \quad (3.4)$$

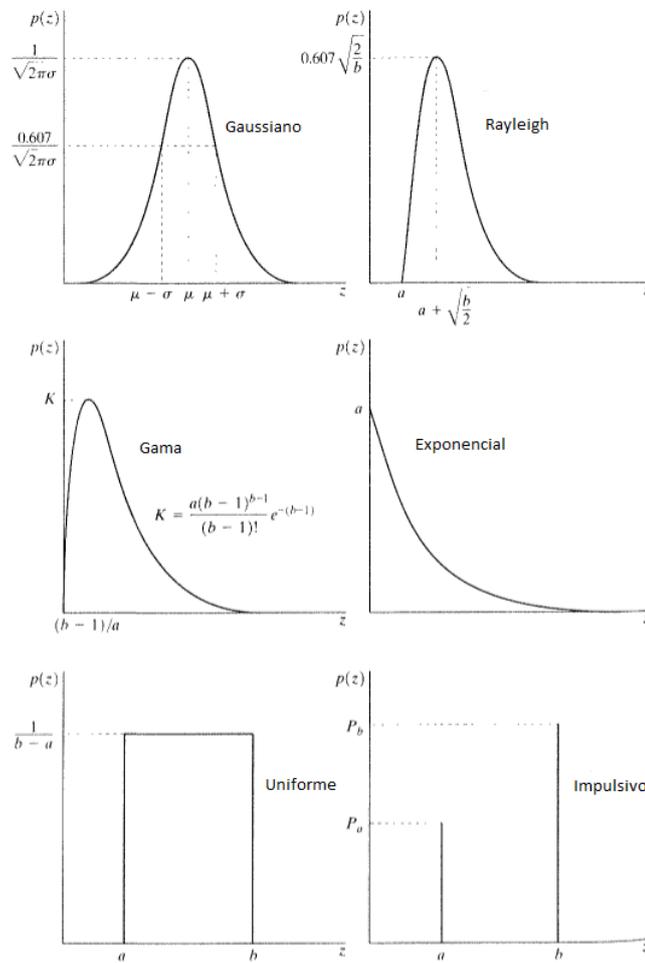
, com  $a > 0$ . O valor esperado e a variância são dados, respectivamente, por  $\bar{y} = \frac{1}{a}$  e  $\sigma^2 = \frac{1}{a^2}$ . Esta f.d.p pode ser considerada um caso especial da f.d.p de Erlang para  $b = 1$ .

**Ruído uniforme:**

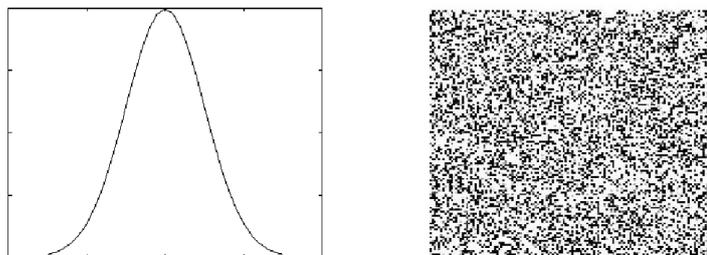
$$f_Y(y) = \begin{cases} \frac{1}{b-a} & \text{se } a \leq y \leq b \\ 0 & \text{caso contrário} \end{cases} \quad (3.5)$$

O valor esperado é obtido por  $\bar{y} = \frac{a+b}{2}$  e a variância é dada por  $\sigma^2 = \frac{(b-a)^2}{12}$ .

**Ruído impulsivo (sal e pimenta):** os pixels corrompidos receberão os valores mínimos e máximos da imagem, dando à imagem a aparência de “sal e pimenta”. O valor padrão do ruído pimenta, para imagens quantizadas em oito bits, é 0 e para o sal, 255. Geralmente, este ruído é ocasionado pelo mal funcionamento dos sensores das câmeras, posições de memória com defeitos ou erros de temporização durante o processo de digitalização da imagem.



**Figura 3.1:** Funções densidade de probabilidade mais utilizadas na literatura. Figura adaptada de (GONZALEZ; WOODS, 2010).



**Figura 3.2:** Exemplo da distribuição gaussiana e o ruído gaussiano. Figura adaptada de (NATH, 2013).

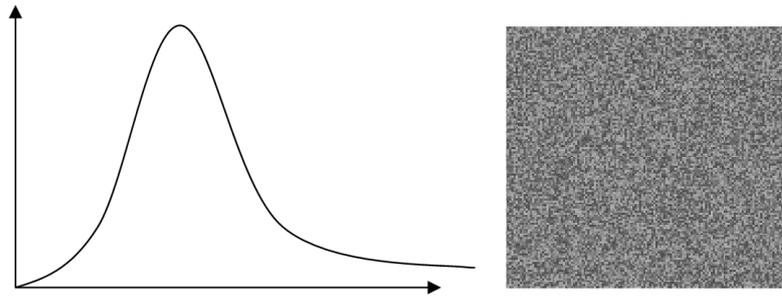


Figura 3.3: Exemplo da distribuição Gama e o ruído “speckle”. Figura adaptada de (NATH, 2013).

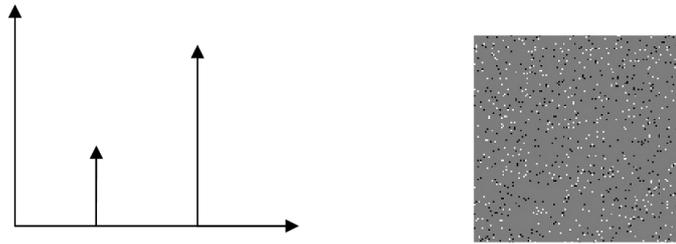


Figura 3.4: F.d.p e exemplo do ruído sal e pimenta. Figura adaptada de (NATH, 2013).

$$f_Y(y) = \begin{cases} P_a & \text{para } y = a \\ P_b & \text{para } y = b \\ 0 & \text{caso contrário} \end{cases} \quad (3.6)$$

Se  $b > a$ , a intensidade  $b$  aparecerá na imagem como um ponto claro e a intensidade  $a$  será um ponto escuro. Se  $P_a = 0$  ou  $P_b = 0$ , o ruído é chamado de unipolar. Caso nenhuma das probabilidades for zero e elas forem aproximadamente iguais, os valores do ruído serão semelhantes aos grãos de sal e pimenta distribuídos aleatoriamente na imagem. Esse ruído também é chamado de “spike” e “data-drop-out”. A Figura 3.4 exemplifica este ruído.

### 3.1 Distribuições Gama, $K$ e $G^0$

O trabalho de Frery et al. (1997) cita algumas distribuições para trabalhar com imagens SAR em intensidade no modelo de ruído multiplicativo. Lembrando que uma imagem SAR é dada pelo retorno  $Z$  que é o produto de duas variáveis  $X$  e  $Y$ , que modelam, respectivamente, o terreno e o “speckle”. Então  $Z$ , segundo Frery et al. (1997), pode seguir as seguintes distribuições:

**Distribuição Gama ( $G(L, \gamma)$ ):** que é o resultado do produto de um delta de Dirac  $\delta$  representando  $X$  por uma distribuição Gama representando  $Y$ . Sua f.d.p é caracterizada por:

$$f_{Z_i}(x) = \frac{\gamma}{\Gamma(L)} (\gamma x)^{L-1} \exp(-\gamma x) \quad (3.7)$$

onde  $L$  representa o número de "looks",  $\gamma$  é a escala e  $x$  é a variável aleatória.

**Distribuição  $K$  para intensidade ( $K_I(\alpha, \lambda, L)$ ):** o resultado é o produto de uma distribuição Gama representando  $X$  e outra distribuição Gama representando  $Y$ . Os parâmetros  $\alpha$ ,  $\lambda$  e  $L$  caracterizam, respectivamente, rugosidade, escala e número de "looks". Sua f.d.p é expressa por:

$$f_{Z_I}(x) = \frac{2\lambda L}{\Gamma(\alpha)\Gamma(L)} (\lambda Lx)^{\left(\frac{\alpha+L}{2-1}\right)} K_{\alpha-L}(2\sqrt{\lambda Lx}) \quad \alpha, \lambda, L, x > 0. \quad (3.8)$$

**Distribuição  $G^0$  para intensidade ( $G_I^0(-\alpha, \gamma, L)$ ):** seu resultado é o produto da distribuição recíproca de Gama representando  $X$  por uma distribuição Gama representando  $Y$ . Essa distribuição também possui três parâmetros:  $\alpha$  para a rugosidade,  $\gamma$  para a escala e  $L$  para o número de "looks".

$$f_{Z_I}(x) = \frac{L^L \Gamma(L-\alpha) x^{L-1}}{\gamma^\alpha \Gamma(L) \Gamma(-\alpha) (\gamma + Lx)^{L-\alpha}} \quad -\alpha, \gamma, L, x > 0. \quad (3.9)$$

O parâmetro  $\alpha$  para  $K_I$  e  $G_I^0$  representa uma região homogênea (rio, lago, pasto) quando o valor  $|\alpha| \rightarrow \infty$ . Se  $|\alpha| \rightarrow 1$  na  $G_I^0$  ou  $|\alpha| \rightarrow 0$  na  $K_I$ , o parâmetro representa uma região heterogênea (área urbana, floresta). Porém, é importante destacar que o grau de homogeneidade de uma imagem SAR depende das características do imageamento.

# Capítulo 4

## FUNDAMENTOS DE SAR

---

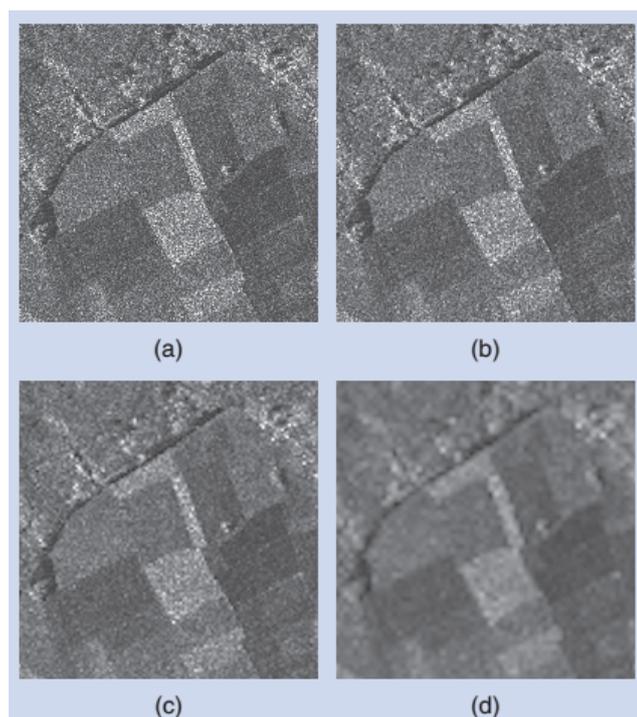
---

*Este capítulo tem o intuito de esclarecer algumas propriedades do imageamento dos sistemas SAR. Tais sistemas fornecem imagens de alta resolução independentemente do tempo e da iluminação. Suas imagens são utilizadas em vários campos de pesquisas, como alterações climáticas, monitoração do meio ambiente e mapeamento da Terra.*

De acordo com Moreira et al. (2013), as técnicas de imageamento SAR vêm sendo utilizadas para o sensoriamento remoto da superfície terrestre por mais de trinta anos. Atualmente, mais de quinze sensores SAR orbitais são operados e dez novos sistemas SAR estão programados para serem lançados nos próximos cinco anos. Estes sistemas fornecem imagens de alta resolução independentemente da luz do dia, cobertura das nuvens e condições do tempo na maioria das vezes.

As imagens SAR são, na maioria das vezes, adquiridas para trabalho no formato de intensidade. O ruído “speckle”, que é uma perturbação granular usualmente modelada como um ruído multiplicativo, é causado pela presença de muitos “scatters” na região. A somatória coerente das suas amplitudes resulta em fortes flutuações do “backscatterer”. Conseqüentemente, a intensidade na imagem final não é mais determinística e segue uma distribuição exponencial em um “look”. Embora seja referido como ruído, o “speckle” não pode ser reduzido pelo aumento da potência do sinal transmitido, pois possui uma característica multiplicativa, ou seja, a sua variância aumenta com a intensidade da potência (MOREIRA et al., 2013).

Para diminuir o “speckle” existe a técnica “multi-look”, que é uma média não coerente dos valores de intensidade da imagem. Esta técnica degrada a resolução da imagem, porém diminui a presença do speckle como visto na Figura 4.1. O efeito do “speckle”, segundo Moreira et al. (2013), é enfraquecido também em sistemas SAR de alta resolução. Além disto, para diminuir sua presença nas imagens SAR, nas últimas décadas vários métodos de filtragem foram



**Figura 4.1:** Exemplo da técnica de “multi-look”. (a) sem “multi-look” (“single-look”). (b) “look” = 2. (c) “look” = 4. (d) “look” = 8 (MOREIRA et al., 2013).

propostos para sua redução (ARGENTI et al., 2013). Na literatura, estes métodos são conhecidos pelo termo “despeckling”.

## 4.1 Histórico

As descobertas e desenvolvimentos iniciais dos sistemas SAR nas décadas de cinquenta e sessenta foram dominadas pelas pesquisas militares. Tais sistemas eram utilizados para propósitos de reconhecimento e detecção de construções (MOREIRA et al., 2013). De acordo com Chan e Koo (2008), os radares eram desenvolvidos como ferramentas para detecção de navios e aviões na década de vinte. O primeiro sistema de pulso de radar, segundo Chan e Koo (2008), foi desenvolvido em 1934 pelo NRL (“Naval Research Laboratory”) dos EUA. Ao mesmo tempo, sistemas de radares para buscar e detectar aviões foram desenvolvidos pela Grã-Bretanha e Alemanha durante a década de trinta. O primeiro radar de imageamento, desenvolvido na Segunda Guerra Mundial, utilizava um “scanner” chamado “B-scan” que produzia uma imagem de formato retangular.

Até a década de cinquenta, segundo Moreira et al. (2013), os radares recebiam o nome de SLAR (“Side-Looking Airborne Radar”) e não utilizavam o princípio da abertura sintética. As primeiras versões do sistema SLAR eram utilizadas com propósitos militares. Estes radares

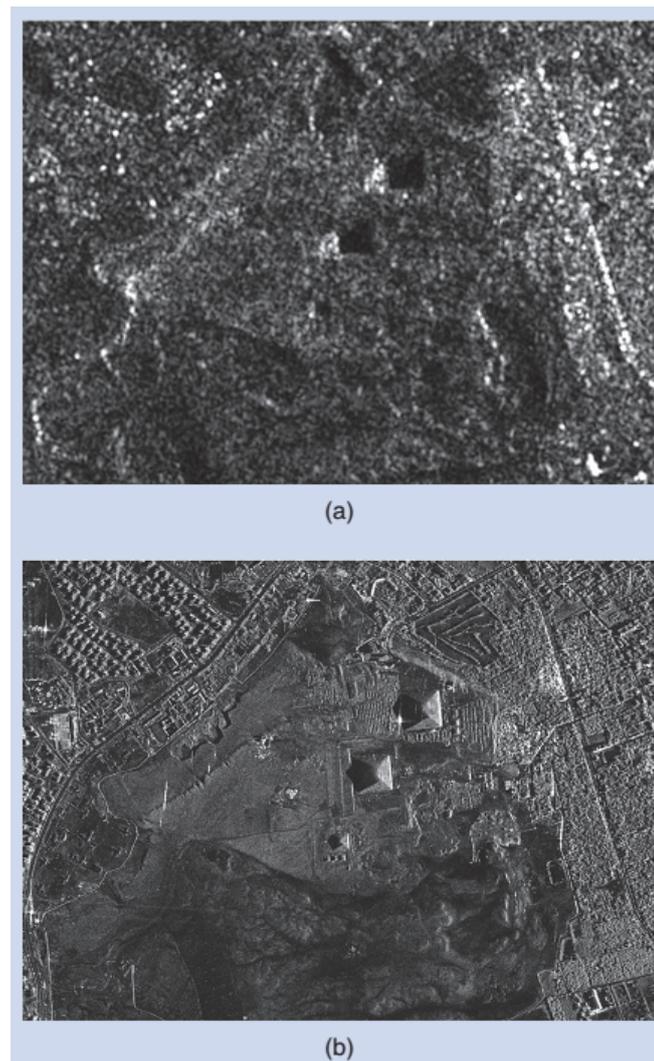
tinham o azimute (nome dado à direção de vôo) moderado, o que causava o deterioramento da imagem conforme o “slant” (distância oblíqua) aumentava. Com a invenção de Carl Wiley em 1951 seguida da criação de uma patente em 1965 por Wiley (WILEY, 1965), a limitação do azimute do SLAR foi posta em cheque pelo uso dos radares coerentes. Isto acarretou uma melhoria na resolução do azimute. Nos anos seguintes, este conceito foi estendido para o princípio de abertura sintética como é conhecido atualmente, e a resolução do azimute tornou-se independente da distância oblíqua. Este princípio utiliza a antena do radar para sintetizar uma antena longa.

O uso do SAR para sensoriamento remoto, através da seleção apropriada da frequência de operação, é alcançado pelo sinal das micro-ondas que podem penetrar nuvens, neblina, chuva, nevoeiro. Logo, ele pode ser operado em quaisquer condições de tempo na maioria das vezes. Além disto, ele é um sensor ativo, ou seja, ele possui sua própria fonte de iluminação, permitindo que possa ser operado de dia e de noite. Sistemas SAR são utilizados em vários campos de pesquisas, como por exemplo: monitoração do gelo e oceano, mineração, monitoração de poluição pelo óleo, oceanografia, monitoração de neve, etc. O potencial deste sistema acarretou no desenvolvimento de inúmeros sistemas para aviões e satélites (CHAN; KOO, 2008).

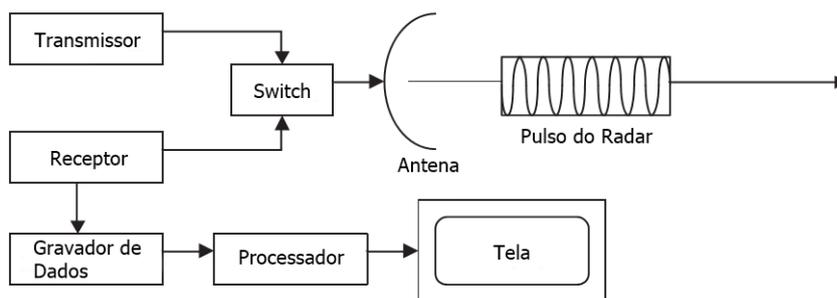
Nas décadas de setenta e oitenta, vários sistemas foram desenvolvidos para recuperar informações geo/biofísicas da superfície terrestre (MOREIRA et al., 2013). Já nas décadas de oitenta e noventa foram desenvolvidas as seguintes técnicas de imageamento SAR:

- Polarimetria: técnica avançada utilizada para a extração de parâmetros. É amplamente utilizada para a derivação de informação física qualitativa e quantitativa para a terra, neve, gelo, oceano e aplicações urbanas baseadas na medição e exploração de propriedades polarimétricas de “scatters” de construções humanas e naturais.
- Interferometria: técnica utilizada para a medição do deslocamento da superfície terrestre, deformações do solo e movimentos de geleiras.

Nos últimos dez anos houve um forte progresso com a Interferometria SAR polarimétrica (Pol-InSAR) e na tomografia para obter informações relacionadas ao volume dos “scatters”. Mais recentemente, a tomografia holográfica foi proposta e vem sendo estudada para gerar uma imagem de trezentos e sessenta graus dos “scatteres”. A Figura 4.2 ilustra a diferença da resolução do imageamento entre um sistema SAR considerado o estado da arte da década de noventa e um sistema SAR da geração atual. É possível perceber que a riqueza de detalhes e da resolução permitem uma melhor análise da cena.



**Figura 4.2:** Comparação da resolução de uma região com imageamento SAR. Em (a) foi utilizado um sistema SAR considerado o estado da arte na década de 90. (b) foi utilizado um sistema SAR da geração atual (MOREIRA et al., 2013).



**Figura 4.3: Diagrama de blocos dos componentes básicos de um sistema de radar. Figura adaptada de (CHAN; KOO, 2008).**

## 4.2 Radar

Radar, de acordo com Chan e Koo (2008), é um acrônimo de “RADio Detection And RAn-ging” e atua como um “flash” de uma câmera mas, na frequência de rádio. Os componentes típicos do radar são: transmissor, “switch”, antena, receptor e gravador de dados. Eles são ilustrados pela Figura 4.3. O transmissor gera um onda eletromagnética de alta energia na frequência de rádio, o “switch” direciona o pulso para a antena e retorna o eco para o receptor. A antena transmite o pulso eletromagnético para a área a ser imageada e coleta os ecos. O sinal retornado é convertido em número digital pelo receptor e a função do gravador de dados é armazenar os valores para um processamento a posteriori e exibição.

Segundo Moreira et al. (2013), um sistema SAR é formado por um radar instalado em uma plataforma com movimento retilíneo. Similar aos radares convencionais, ele transmite sequencialmente pulsos eletromagnéticos com alta energia e recebe os ecos do sinal de retorno. Os pulsos transmitidos interagem com objetos e a superfície terrestre (“backscatters”) e somente uma porção deles retornam para a antena do radar. A direção do vôo e a linha de visão recebem o nome de, respectivamente, azimute e faixa “slant”.

O radar pode ser classificado em dois tipos de acordo com a sua antena:

- radar mono estático: sua antena transmite e recebe os pulsos eletromagnéticos.
- radar bi ou multi estático: cada antena fica responsável pela transmissão ou captação dos pulsos eletromagnéticos.

No caso do SAR, o tempo consecutivo de transmissão e recepção do sinal translada em diferentes posições devido à movimentação da plataforma. Uma combinação coerente apropriada do sinal recebido permite a construção de aberturas virtuais da antena para receber o sinal de retorno, que são mais longas do que o comprimento físico da antena. Este atributo do SAR é a

origem do termo “abertura sintética”, garantido a ele a propriedade para se tornar um radar de imageamento. A imagem é gerada a partir do processamento dos dados brutos após a formação da abertura sintética e ela representa uma medida de refletividade da cena (alvo imageado).

A amplitude do sinal de retorno depende das propriedades físicas (geometria, rugosidade) e elétricas (permitividade) do objeto ou território imageado. E dependendo da frequência do sinal, pode ocorrer uma alta penetração da energia deste sinal no objeto. Logo, este deve ser modelado como volume (vegetação, gelo, neve e solo seco).

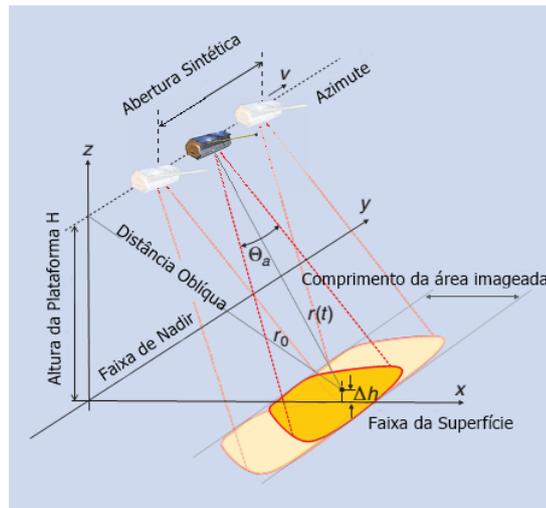
O sistema de radar mais simples fornece um mapa de refletividade 2-D da superfície. Alvos com alto sinal de “backscatter” são identificados com pontos brilhantes. Já superfícies lisas ou planas são áreas escuras. Isto ocorre na maioria dos imageamentos, já que a refletividade de um alvo depende das suas características eletromagnéticas e dos parâmetros do sensor, tais como frequência, ângulo de incidência, polarização, etc.

A Figura 4.4 ilustra a geometria SAR. A faixa “slant” é a direção perpendicular ao azimute do radar. A largura de faixa (“swath width”) representa a extensão da superfície para a cena do radar e o seu comprimento depende da duração da captação dos dados, ou seja, quanto tempo o radar fica ligado. Em um tempo  $t$ , a distância obtida entre a movimentação do radar na velocidade constante  $\rho$  e um ponto no solo, representado pelas coordenadas  $(\mathbf{x}, \mathbf{y}, \mathbf{z}) = (x_0, 0, \Delta h)$  é obtido através do teorema de Pitágoras:

$$r(\varpi) = \sqrt{r_0^2 + (\rho\varpi)^2} \approx r_0 + \frac{(\rho\varpi)^2}{2r_0} \quad \text{para } \rho\varpi/r_0 \ll 1, \quad (4.1)$$

onde  $\varpi = \varpi_0 = 0$  é o tempo de maior aproximação, quando a distância é mínima e  $r(\varpi_0) = r_0 = \sqrt{(H - \Delta h)^2 + x_0^2}$  com a altura da plataforma  $H$ .

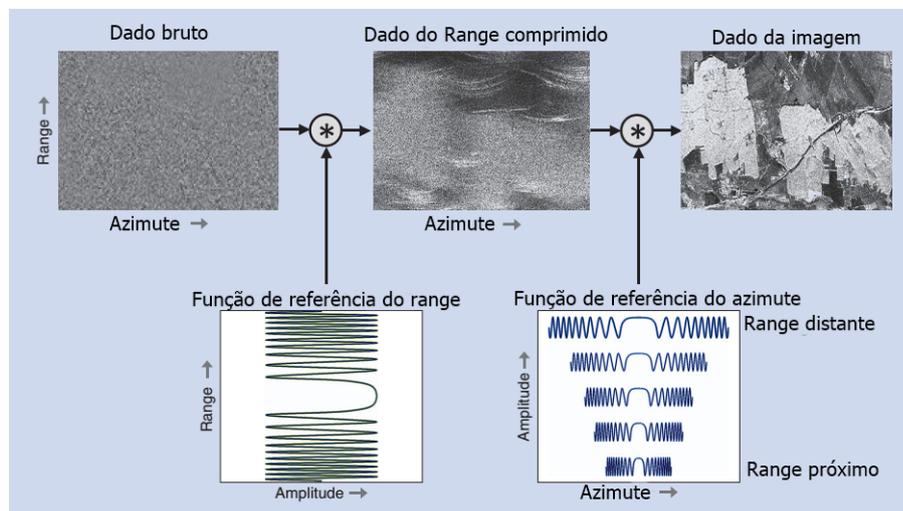
Os processos do sistema SAR são resumidos na Figura 4.5. O processamento pode ser descrito como duas operações de filtros combinados por todas as dimensões do “range” e do azimute. No primeiro passo é feita a compressão do sinal transmitido do “chirp”, que é o sinal modulado de frequência linear, para um pulso curto. Ao invés de realizar uma convolução no domínio temporal, é feita uma multiplicação no domínio da frequência pelo conjugado complexo do espectro do “chirp”. O resultado, segundo Moreira et al. (2013), é uma imagem com o “range” comprimido, o qual mostra apenas as informações sobre a distância relativa entre o radar e qualquer ponto da superfície. Já o segundo passo, é feita a compressão do azimute com o mesmo raciocínio do primeiro passo. O sinal é multiplicado pela sua função de referência, que é o conjugado complexo da resposta esperada de um alvo na superfície. Dado um “scatter” no “range”  $r(t)$  dado pela equação 4.1, o sinal do azimute pode ser modelado por:



**Figura 4.4: Geometria de um imageamento SAR.**  $r_0$  representa a menor distância de aproximação,  $\Theta_a$  é a largura do feixe do azimute e  $v$  é a velocidade do sensor (MOREIRA et al., 2013).

$$s_a(t) = A\sqrt{\sigma_0} \exp(\zeta\varphi^{scatt}) \exp\left(-\zeta\frac{4\pi}{\lambda}r(t)\right), \quad (4.2)$$

onde  $A$  representa a dependência do sinal recebido em parâmetros do sistema, tais como a energia da transmissão e perdas, e a ponderação padrão da antena em função do azimute a ângulos de elevação.  $\sigma_0$  é a seção transversal do radar e  $\varphi^{scatt}$  é a fase do “scatter”.  $4\pi r(t)/\lambda$  é a variação da fase do azimute devido a alteração da distância e  $\zeta = \sqrt{-1}$  representa a unidade imaginária.



**Figura 4.5:** Ilustração dos passos básicos do processamento de um sistema SAR. A função de referência do “range” é dependente apenas da forma de onda transmitida do “chirp”. Já a função de referência do azimuth depende da geometria e é adaptada à faixa. Figura adaptada de (MOREIRA et al., 2013).

# Capítulo 5

## FILTROS

---

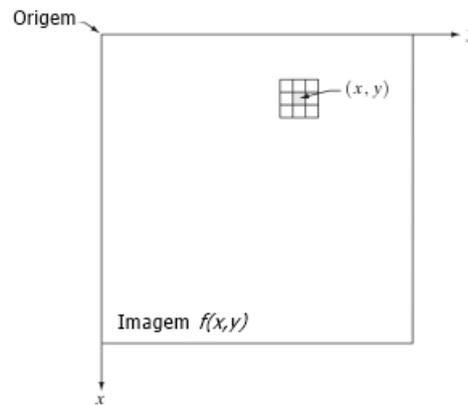
---

*Neste capítulo serão apresentados alguns filtros da literatura. Filtros para ruído aditivo, ruído multiplicativo, filtro de Wiener e filtros adaptativos. Também serão apresentados os filtros NLM, BM3D, PPB, que atualmente são os filtros que instigam os pesquisadores com foco na restauração de imagens e os utilizam para criar novas versões inspiradas pelo princípio de similaridade entre “patches”.*

De acordo com Nath (2013), uma grande porção da área de Processamento de Imagens é dedicada à restauração de imagens. Filtrar uma imagem é um processo que envolve manipulação dos dados da imagem obtida para produzir uma imagem visualmente melhor, ou seja, a restauração é a remoção ou atenuação das degradações, como os borramentos, que é a formação imperfeita da imagem (ex: movimento relativo entre a câmera e a cena original, um sistema óptico fora de foco, turbulência atmosférica e o movimento entre câmera e solo de fotografias aéreas), e os ruídos, que costumam aparecer através de um canal ruidoso na transmissão dos dados ou durante o processo de quantização dos dados para serem guardados no formato digital.

A filtragem pode ser considerada como um ato de aceitar ou negar a passagem de alguns componentes da imagem. Por exemplo, o filtro *passa-baixa* aceita baixas frequências e seu efeito final é suavizar (borrar) a imagem. De maneira similar, os filtros espaciais, máscaras, “kernels”, “templates” e janelas podem suavizar a imagem e podem ser utilizados para a filtragem não linear. Alguns destes filtros, como o filtro Laplaciano não servem para a suavização (GONZALEZ; WOODS, 2010).

A Figura 5.1 ilustra a área onde um filtro espacial poderia atuar. A região possui uma vizinhança  $3 \times 3$  centrada nas coordenadas  $(x, y)$  da imagem, também chamada de “patch”, e, um exemplo, seria ocorrer uma operação sobre os pixels dessa vizinhança. Após o término



**Figura 5.1: Vizinhança centralizada em um ponto  $(x, y)$  em uma imagem no domínio espacial. Figura adaptada de (GONZALEZ; WOODS, 2010).**

da filtragem na vizinhança, o pixel centralizado seria sobreposto e o filtro marcaria uma nova vizinhança centralizada no próximo pixel. Segundo Gonzalez e Woods (2010), se a operação realizada sobre os pixels da imagem for linear, o filtro é chamado de filtro espacial linear, Caso contrário, o filtro é não-linear e possui alguma capacidade para filtrar bordas.

## 5.1 Filtros para ruído aditivo

Um filtro de média aritmética suaviza uma imagem e pode ser definido como a média dos pixels contidos dentro de uma vizinhança. Seja  $S_{xy}$  o conjunto de coordenadas de uma vizinhança  $m \times n$  centrada no ponto  $(x, y)$ . O filtro calculará o valor médio na imagem corrompida  $z(x, y)$  dentro da vizinhança e esse valor será o valor da imagem filtrada  $\hat{f}$  no ponto  $(x, y)$  (GONZALEZ; WOODS, 2010) conforme a equação 5.1. Mais claramente, ele reduz a intensidade entre os pixels adjacentes com uma janela deslizante que substituirá o valor central dentro da janela pela média.

$$\hat{f}_{(x,y)} = \frac{1}{mn} \sum_{(s,t) \in S_{xy}} z(s,t) \quad (5.1)$$

O filtro espacial terá o tamanho  $m \times n$  com todos os valores dos coeficientes sendo  $1/mn$ . Este filtro atenua o ruído porém com o custo de borramento da imagem.

O filtro da média ponderada aplica pesos em cada pixel da vizinhança com uma tentativa de diminuir o borramento no processo de filtragem. Este filtro é implementado com uma máscara de convolução. Já o filtro de média geométrica determina o valor do pixel restaurado como o produto de pixels dentro da vizinhança elevando à potência  $1/mn$ , onde  $m$  e  $n$  são, respectiva-

mente, o comprimento e a altura da vizinhança, ou seja, o tamanho do “patch”. A equação 5.2 mostra o cálculo para este filtro.

$$\hat{f}_{(x,y)} = \left[ \prod_{(s,t) \in S_{xy}} z(s,t) \right]^{\frac{1}{mn}} \quad (5.2)$$

A característica do filtro de média geométrica é perder menos detalhes da imagem, porém existe uma suavização semelhante à média aritmética.

O filtro com a média harmônica gera bons resultados para o valor 255 (sal) do ruído sal e pimenta, porém não é ótimo para os valores 255 (pimenta). Além disso, possui um bom desempenho para o ruído gaussiano. A expressão 5.3 mostra a sua operação:

$$\hat{f}_{(x,y)} = \frac{mn}{\sum_{(s,t) \in S_{xy}} \frac{1}{z(s,t)}} \quad (5.3)$$

O filtro da mediana é um exemplo de filtro espacial não-linear (GONZALEZ; WOODS, 2010). Ele também utiliza o princípio da janela deslizante do filtro da média. A resposta de um filtro não linear é baseada na classificação dos valores dos pixel. O valor do pixel central do “patch” será substituído pela expressão 5.4.

$$\hat{f}_{(x,y)} = \text{mediana}_{(s,t) \in S_{xy}} z(s,t). \quad (5.4)$$

Filtros baseados na mediana geram bons resultados na redução de ruído com um borramento menor do que os filtros lineares de suavização. Estes filtros são bastante eficazes para o ruído do tipo sal e pimenta (impulsivo), mas não são eficazes com ruído gaussiano ponto a ponto.

Outro filtro espacial não linear é o filtro de máximo e mínimo (GONZALEZ; WOODS, 2010). O filtro de máximo localiza os pontos mais claros de uma imagem e o filtro de mínimo determina os pontos mais escuros. As equações 5.5 e 5.6 representam, respectivamente, o filtro máximo e o filtro mínimo.

$$\hat{f}_{(x,y)} = \max_{(s,t) \in S_{xy}} z(s,t) \quad (5.5)$$

$$\hat{f}_{(x,y)} = \min_{(s,t) \in S_{xy}} z(s,t) \quad (5.6)$$

O filtro de ponto médio, segundo Gonzalez e Woods (2010), calcula o ponto médio entre

os valores máximos e mínimos na vizinhança. Ele combina filtragem linear e não linear e é mais eficaz para um ruído aleatoriamente distribuído, como o ruído gaussiano e uniforme. Ele é descrito pela equação 5.7.

$$\hat{f}_{(x,y)} = \frac{1}{2} \left[ \max_{(s,t) \in S_{xy}} z(s,t) + \min_{(s,t) \in S_{xy}} z(s,t) \right] \quad (5.7)$$

## 5.2 Filtros adaptativos

Os filtros discutidos na seção anterior não levam em consideração como as características da imagem variam de um ponto a outro. Os filtros adaptativos são baseados nas medidas estatísticas da imagem dentro da vizinhança. Eles possuem um desempenho superior aos filtros anteriores, porém com o custo de possuir maior complexidade (GONZALEZ; WOODS, 2010).

As medidas estatísticas mais fáceis de serem obtidas de uma imagem, que podem ser consideradas um conjunto de variáveis aleatórias, são a média e a variância. A média está relacionada com a intensidade média da região na qual ela é calculada, e a variância determina uma medida de contraste dessa região.

O filtro deve operar em uma região  $S_{xy}$  e a sua resposta está relacionada com quatro valores: valor da imagem com ruído  $g(x,y)$ , variância do ruído  $\sigma_n^2$  que corrompe a imagem  $f(x,y)$ , a qual deve ser o único valor com conhecimento a priori ou estimado, média local dos pixels  $m_L$  em  $S_{xy}$  e a variância local dos pixels  $\sigma_L^2$ .

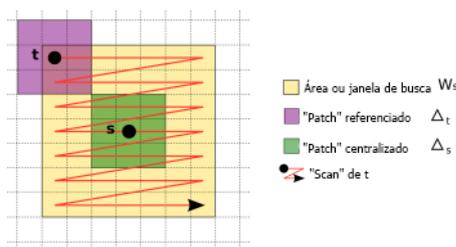
## 5.3 Filtro de Wiener (Mínimo erro quadrático)

Neste método considera-se a imagem e o ruído como variáveis aleatórias, e o objetivo é encontrar uma estimativa  $\hat{f}$  da imagem não corrompida  $f$ , de forma que o erro quadrático médio entre elas seja minimizado. A medida do erro é expressa por:

$$e^2 = E(f - \hat{f})^2, \quad (5.8)$$

onde  $E$ . é o valor esperado do argumento. O mínimo da função de erro da equação acima é dado no domínio da frequência pela expressão

$$\hat{F}_{(u,v)} = \left[ \frac{1}{H(u,v) \left[ |H(u,v)|^2 + S_n(u,v)/S_f(u,v) \right]} \right] G(u,v), \quad (5.9)$$



**Figura 5.2: Representação das janelas do “Nonlocal means”. A maior janela em laranja é a janela de busca. A janela em verde é o “patch” referenciado. O “patch” em roxo representa o patch sendo avaliado. O caminho em vermelho indica o caminho a ser percorrido pelo “patch” roxo.**

na qual  $H(u, v)$  é a transformada de Fourier da função de degradação e  $G(u, v)$  é a transformada de Fourier da imagem degradada. A imagem restaurada no domínio espacial será dada pela transformada inversa de Fourier da estimativa  $\hat{F}(u, v)$  no domínio da frequência.  $S_n(u, v)$  é o espectro de potência do ruído e  $S_f(n, v)$  é o espectro de potência da imagem não degradada. Se o ruído for zero,  $S_n(u, v)$  desaparece e o filtro de Wiener é reduzido ao filtro inverso (GONZALEZ; WOODS, 2010).

## 5.4 “Nonlocal means” (NLM)

Os filtros citados nas seções anteriores e muitos outros elaborados na literatura de Processamento de Imagens possuem uma característica em comum: eles trabalham apenas localmente, ou seja, um pixel central em uma vizinhança de  $m \times n$  pixels terá seu novo valor computado e substituído baseado nos valores de todos os pixels dentro dessa vizinhança espacial.

O trabalho de Buades et al (BUADES; COLL; MOREL, 2005) expande esse conceito e denomina o filtro de “Nonlocal means”. Este filtro realiza uma média ponderada, cujos pesos são determinados através de um critério de similaridade radiométrica estabelecido entre os pixels de uma imagem. O conceito de similaridade utilizado por Buades, Coll e Morel (2005) é expresso pela distância euclidiana entre um “patch” (vizinhança) de um pixel referenciado e o “patch” centralizado em outro pixel ambos dentro de uma janela de busca. Por isso o conceito “nonlocal”. Os “patches” que forem considerados similares ao “patch” do pixel referenciado receberão pesos com valores altos, enquanto que “patches” considerados distantes do pixel referenciado receberão pesos de ponderação baixa. Na Figura 5.2 é ilustrado o funcionamento das janelas de busca e dos “patches” do filtro NLM. O “patch” referenciado  $\Delta_t$  centralizado no pixel  $t$ , dentro da janela de busca  $W_s$ , será avaliado pelo algoritmo NLM se é similar ao “patch” centralizado no pixel  $s$ ,  $\Delta_s$ . O NLM percorrerá toda a janela de busca.

Dada uma imagem ruidosa discreta  $z = \{z(i) | i \in I\}$ , sendo  $I$  o domínio da imagem, o valor

estimado do NLM representado por  $NL[z](i)$ , para um pixel  $i$  nas coordenadas  $(x, y)$ , é computado como uma média ponderada de todos os pixels da imagem conforme a equação 5.10,

$$NL[z](i) = \sum_{j \in I} w(i, j) z(j) \quad (5.10)$$

onde a família dos pesos  $\{w(i, j)\}_j$  depende da similaridade entre os pixels  $i$  e  $j$ , e satisfazem a condição  $0 \leq w(i, j) \leq 1$  e  $\sum_j w(i, j) = 1$ .

A similaridade entre os pixels depende da intensidade do nível de cinza. Essa similaridade é medida pela distância euclidiana  $\|z(N_i) - z(N_j)\|_{2,c}^2$ , onde  $c > 0$  é o desvio padrão de um “kernel” Gaussiano, e  $z(N_i)$  e  $z(N_j)$  representam os vetores dos “patches”. A aplicação da distância euclidiana nos “patches” ruidosos aparece na equação 5.11,

$$E\|z(N_i) - z(N_j)\|_{2,c}^2 = \|u(N_i) - u(N_j)\|_{2,\alpha}^2 + 2\sigma^2 \quad (5.11)$$

onde  $u$  e  $z$  são, respectivamente, a imagem original e a imagem ruidosa, e  $\sigma^2$  é o desvio padrão do ruído. A equação 5.11 mostra que os pixels mais similares a  $i$  em  $v$  também são esperados serem os mais similares a  $i$  em  $u$ . Os pixels dos “patches” similares possuem pesos grandes na média. Esses pesos são definidos pela equação 5.12,

$$w(i, j) = \frac{1}{Z(i)} e^{-\frac{\|z(N_i) - z(N_j)\|_{2,\alpha}^2}{h^2}} \quad (5.12)$$

onde  $Z(i)$  é uma constante normalizadora expressa pela equação 5.13.

$$Z(i) = \sum_j e^{-\frac{\|z(N_i) - z(N_j)\|_{2,\alpha}^2}{h^2}}, \quad (5.13)$$

e o parâmetro  $h$  atua na suavização da filtragem controlando a queda dos pesos. A Figura 5.3 exemplifica a atribuição de pesos.

## 5.5 BM3D

Este filtro proposto por Dabov et al (DABOV et al., 2007) utiliza os mesmos princípios do “NL-means” e obtém uma representação esparsa no domínio da transformada 3D. O algoritmo utiliza um conjunto de blocos 2D, que é um conjunto de “patches” similares. Quando estes blocos são agrupados, o algoritmo os chama de grupo, que é um bloco 3D. O processo de



**Figura 5.3:** Exemplo de atribuição de peso:  $q1$  e  $q2$  possuem pesos grandes por causa da similaridade com  $p$ . Por outro lado, o valor de  $w(p, q3)$  é bem menor já que as intensidades dos valores dos níveis de cinza são bem diferentes (BUADES; COLL; MOREL, 2005).

filtragem é chamado de “Collaborative filtering” e possui três passos:

- Aplicar a transformada 3D no grupo
- Redução na transformada
- Aplicar transformada 3D inversa

De maneira análoga ao NLM, a similaridade é computada através da distância euclidiana. Caso ela seja menor que um limiar dado, o bloco analisado será considerado similar ao bloco referenciado. Assim, os estimadores 3-D do grupo, o qual é representado por um vetor de fragmentos 2-D filtrados, serão calculados. E, devido à similaridade entre esses fragmentos, a transformada wavelet pode obter uma forte representação esparsa do sinal para que o ruído possa ser bem separado no processo.

O processo revela as estruturas finas, como bordas e texturas, e preserva as características únicas essenciais de cada bloco, os quais serão retornados às suas posições originais. Como esses blocos serão sobrepostos, cada pixel terá muitos estimadores diferentes que serão combinados. Esse outro processo é chamado de agregação. As Figuras 5.4 e 5.5 ilustram o processo de agrupamento. Dado um bloco referenciado, o algoritmo BM3D localiza blocos similares e forma um grupo.

Para medir a similaridade entre os blocos, Dabov et al. (2007) propõem uma pré-filtragem grosseira aplicando uma transformada 2-D linear no “patch” referenciado e no avaliado. Então

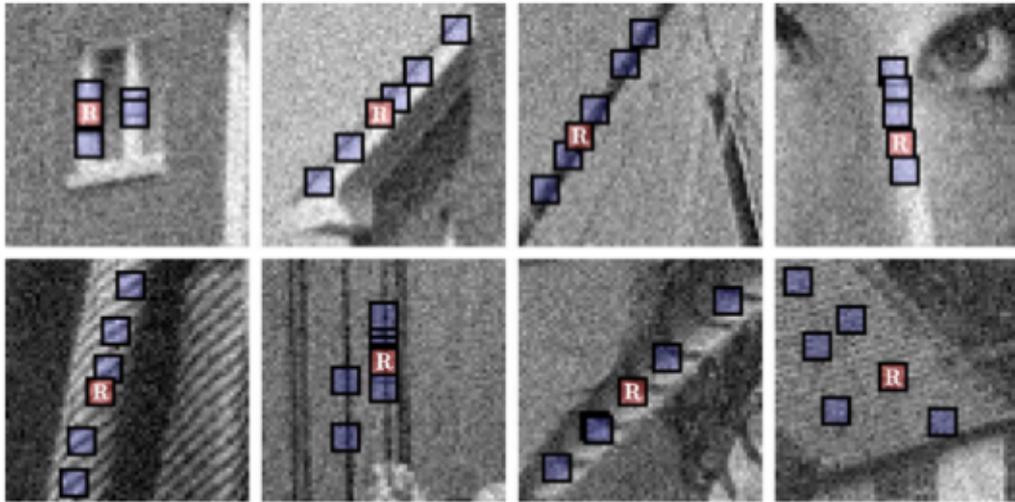


Figura 5.4: Exemplo de agrupamento dos blocos de imagens contaminadas com ruído branco aditivo gaussiano. R é o bloco referenciado.

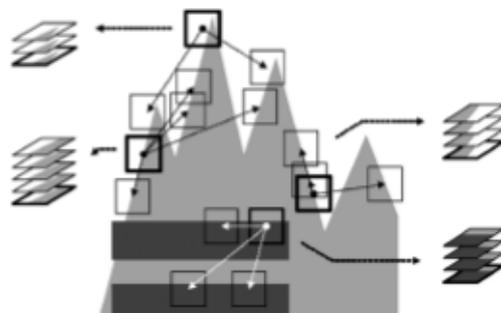


Figura 5.5: Exemplo de agrupamento em uma imagem artificial.

os coeficientes são obtidos com um “hard-thresholding”, conforme a equação 5.14,

$$d(Z_{x_R}, Z_x) = \frac{\| \Upsilon'(T_{2D}^{ht}(Z_{x_R})) - \Upsilon'(T_{2D}^{ht}(Z_x)) \|_2^2}{(N_1^{ht})^2} \quad (5.14)$$

onde  $\Upsilon'$  representa o “hard-thresholding” com o valor do limiar  $\lambda_{2D\sigma}$ ,  $T_{2D}^{ht}$  indica a transformada 2-D e  $N_1^{ht}$  é o número de blocos similares. Calculando a distância na equação 5.14, o resultado do “block-matching” (BM) é um conjunto das coordenadas dos blocos similares ao bloco  $Z_{x_R}$  dado pela equação 5.15.  $Z_x$  é o bloco avaliado, ou seja, que terá sua similaridade analisada em comparação ao bloco referenciado  $Z_{x_R}$ .  $X$  representa o domínio da imagem.

$$S_{x_R}^{ht} = \{x \in X : d(Z_{x_R}, Z_x) \leq \tau_{match}^{ht}\} \quad (5.15)$$

onde  $\tau_{match}^{ht}$  é o limiar máximo da distância para qual dois blocos sejam considerados similares.

Após formado o grupo, é aplicada uma transformada wavelet 3-D e uma transformada 3-D inversa conforme a equação 5.16,

$$\hat{Y}_{S_{x_R}^{ht}}^{ht} = T_{3D}^{ht^{-1}}(\Upsilon(T_{3D}^{ht}(Z_{S_{x_R}^{ht}}))) \quad (5.16)$$

onde  $\Upsilon$  é o “hard-thresholding” com o valor do limiar  $\lambda_{3D\sigma}$ . Em seguida, é aplicado um processo de filtragem de Wiener adaptativo para o BM3D. Depois disto, é aplicada a sua inversa criando um novo grupo e os pesos para cada fragmento dos grupos são gerados.

O estimador global básico  $\hat{y}^{basic}$  é computado por uma média ponderada de  $\hat{Y}_{S_{x_R}^{ht}}^{ht}$  utilizando os pesos  $w_{x_R}^{ht}$  definidos pela equação 5.17

$$w_{x_R}^{ht} = \begin{cases} \frac{1}{\sigma^2 N_{har}^{x_R}}, & \text{se } N_{har}^{x_R} \geq 1 \\ 1 & \text{caso contrário} \end{cases} \quad (5.17)$$

$$\hat{y}^{basic}(x) = \frac{\sum_{x_R \in X} \sum_{x_m \in S_{x_R}^{ht}} w_{x_R}^{ht} \hat{Y}_{x_m}^{ht, x_R}(x)}{\sum_{x_R \in X} \sum_{x_m \in S_{x_R}^{ht}} w_{x_R}^{ht} X_{x_m}(x)}, \forall x \in X \quad (5.18)$$

onde  $\sigma^2$  é o desvio padrão e  $X_{x_m} : X \rightarrow 0, 1$  é uma função característica do suporte do quadrado de um bloco localizado em  $x_m \in X$ .

O estimador final  $\hat{y}^{final}$  é também computado pela equação 5.18 substituindo, respectivamente,  $\hat{y}^{basic}$ ,  $\hat{Y}_{x_m}^{ht, x_R}$ ,  $S_{x_R}^{ht}$  e  $w_{x_R}^{ht}$  por  $\hat{y}^{final}$ ,  $\hat{Y}_{x_m}^{wie, x_R}$ ,  $S_{x_R}^{wie}$  e  $w_{x_R}^{wie}$ , onde:

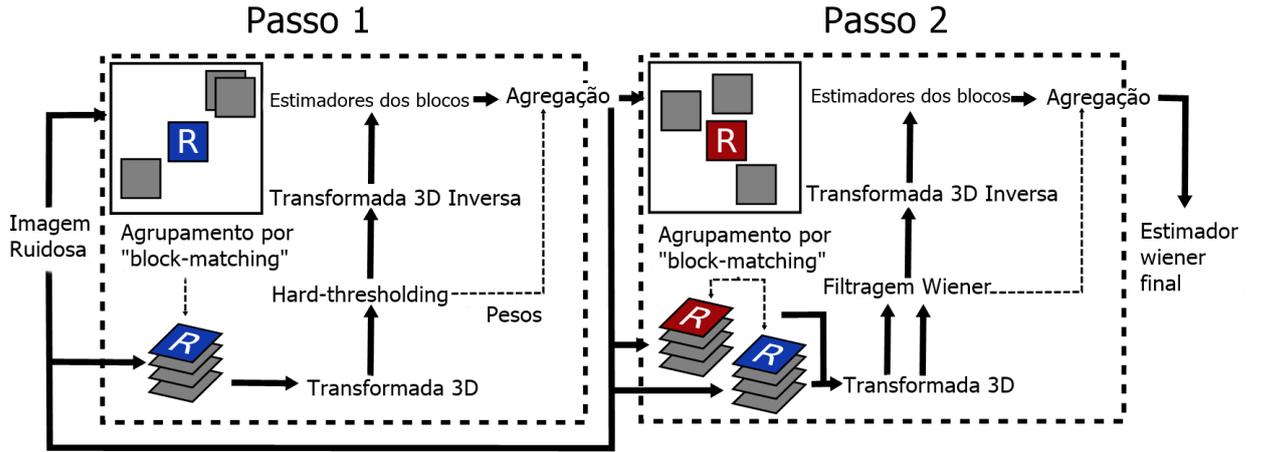


Figura 5.6: Esquema do algoritmo BM3D. Figura adaptada de (LEBRUN, 2012).

$$S_{x_R}^{wie} = \{x \in X : \frac{\|\hat{y}_{x_R}^{basic} - \hat{y}_x^{basic}\|_2^2}{(N_1^{wie})^2} < \tau_{match}^{wie}\} \quad (5.19)$$

O conjunto  $S_{x_R}^{wie}$  formará outros dois grupos:  $\hat{Y}_{S_{x_R}^{wie}}^{basic}$ , que agrupa os blocos estimados, e  $Z_{S_{x_R}^{wie}}$ , que agrupa os blocos ruidosos  $Z_{x \in S_{x_R}^{wie}}$ .

$$W_{S_{x_R}^{wie}} = \frac{|T_{3D}^{wie}(\hat{Y}_{S_{x_R}^{wie}}^{basic})|^2}{|T_{3D}^{wie}(\hat{Y}_{S_{x_R}^{wie}}^{basic})|^2 + \sigma^2} \quad (5.20)$$

A equação 5.20 será utilizada para a redução dos coeficientes wavelet. A equação 5.21 produzirá o grupo das estimativas.

$$\hat{Y}_{S_{x_R}^{wie}}^{wie} = T_{3D}^{wie^{-1}}(W_{S_{x_R}^{wie}} T_{3D}^{wie}(Z_{S_{x_R}^{wie}})). \quad (5.21)$$

com os pesos definidos por 5.22. A Figura 5.6 exemplifica os dois passos do algoritmo BM3D. No primeiro passo, é aplicada uma transformada 3D no grupo de blocos similares, seguida por um “hard-thresholding” e a transformada 3D inversa. Assim computa-se o estimador básico. Já no segundo passo, é utilizado este estimador juntamente com o grupo dos blocos similares e o “hard-thresholding” é substituído por um filtro de Wiener. Após a agregação encontra-se o estimador final.

$$w_{x_R}^{wie} = \sigma^{-2} \|W_{S_{x_R}^{wie}}\|_2^{-2} \quad (5.22)$$

## 5.6 Filtros para ruído multiplicativo

A principal desvantagem das imagens SAR é a presença do “speckle”. Ele é um ruído granular dependente do sinal, que degrada visualmente a aparência das imagens e pode diminuir a performance das análises e extração de informações para pesquisas. Além disso, o “speckle” não é apenas ruído, ele possui conteúdo de informação da imagem. Por isso, é de interesse para a comunidade de Processamento de Imagens e Sinais a elaboração de processos de redução do “speckle” (“despeckling”), os quais devem ser elaborados e modelados cuidadosamente para evitar a perda de informações úteis das imagens, como a média local do “backscatter”, características lineares, detalhes finos e texturas. Outro fator que atrai pesquisadores para esta área é o crescimento da nova geração de satélites SAR (ARGENTI et al., 2013), por exemplo:

- Constelação COSMO - Skymed: quatro satélites lançados pela ASI (“Italian Space Agency”) entre 2007 e 2010. Mais dois satélites serão adicionados com previsão para 2014 e 2015.
- Constelação gêmea Terra SAR-X / TanDem-X: lançados pela DRI (“German Space Agency”) entre 2007 e 2010.
- Constelação de satélites Sentinel-1a/-1b: previstos para 2013 e 2015 pela ESA (“European Space Agency”).
- RADARSAT 3 - missão canadense em um futuro próximo com três satélites a serem lançados em 2017.

A redução do “speckle” em imagens SAR ainda é uma grande preocupação na área de Processamento de Imagens. Quanto menor a presença speckle, maior será a preservação da informação de estruturas (bordas, texturas e outros alvos) cruciais para uma interpretação precisa para extrair informações e/ou na classificação de imagens SAR (YANG; CLAUSI, 2009), já que, segundo Achim (2006), o “speckle” carrega informações úteis da superfície que está sendo mapeada. Existem inúmeras atividades que trabalham com imagens SAR: sensoriamento remoto para mapeamento, busca e resgate, detecção de minérios, reconhecimento de alvos, etc. A vantagem de se trabalhar com os sistemas SAR é que eles superam as limitações de imageamento noturno e sob nuvens apresentadas pelos sistemas ópticos (ACHIM, 2006).

Segundo (TOUZI, 2002), os modelos mais conhecidos que vêm sendo utilizados como base no desenvolvimento de filtros para o speckle são: o modelo multiplicativo e o modelo do produto. A diferença entre estes modelos está na maneira de representar o ruído, pois o modelo do produto define a expressão da f.d.p da imagem observada. Para estes dois modelos, redu-

zir o “speckle” com filtros não-lineares baseados no modelo de ruído aditivo não é eficiente (MALLADI; KASILINGAM; COSTA, 2003).

O modelo multiplicativo é expresso por Touzi (2001) como  $Z(x, y) = X(x, y) \times Y(x, y)$ , onde  $Z$  é a intensidade observada do pixel localizado na coordenada  $(x, y)$ ,  $X$  é o retroespalhamento do terreno e  $Y$  representa o speckle. Com a suposição da equação de  $Z$  satisfazer todas as posições  $(x, y)$ , Touzi (TOUZI, 2001) define a f.d.p para o modelo do produto como

$$f_{Z(x,y)} = \int_0^{+\infty} P_{|n(x,y)|^2}(Z(x,y)|X(x,y))P_X(X(x,y))dX(x,y), \quad (5.23)$$

onde  $P_S$  é a distribuição espacial da média do “speckle” e  $n(x, y)$  é o modelo complexo do “speckle”. Já Touzi (TOUZI, 2002) afirma que a distinção entre os vários modelos multiplicativos propostos para o “speckle”, bem como a distinção entre o modelo multiplicativo e o modelo do produto, é muito vaga na literatura. Ele também cita em (TOUZI, 2002) que o modelo multiplicativo serviu para o desenvolvimento dos filtros MMSE (“minimum mean-square error”) de Lee (LEE, 1980), Kuan (KUAN et al., 1985) e Frost (FROST et al., 1982), enquanto que o modelo do produto foi utilizado como base para a definição dos filtros MAP (“maximum a posteriori”) Bayesian Gaussian em (KUAN et al., 1987), Gama em (LOPES et al., 1990) e “model-based despeckling” em (WALESSA; DATCU, 2000).

Porém, com o MMSE, não é ideal aplicar esses filtros em bordas e regiões com texturas para reduzir o “speckle” em áreas homogêneas, pois informações estruturais da imagem podem ser perdidas. Os filtros de Lee e de Kuan aproximam a média local em regiões homogêneas, enquanto tendem a reter a observação original em pixels com alta atividade. A desvantagem é que ambos suavizam muito a textura da imagem e são ineficientes para as bordas (ZHONG; LI; JIAO, 2010).

Nos anos 90 ocorreu a difusão de wavelets e surgiram filtros para atuarem no domínio da transformada baseados no ruído AWGN. A redução do ruído com wavelet pode ser aplicada em imagens SAR depois da transformação homomórfica que converte o o modelo do ruído multiplicativo para o modelo aditivo.

Depois deste período, foi utilizada uma abordagem de wavelet com “hard” e “soft thresholding” que mostrou um ganho de performance no domínio espacial com filtros adaptativos em imagens SAR reais e sintéticas. Posteriormente, ocorreram melhorias otimizando os parâmetros através da abordagem estatística Bayesiana. Todas as técnicas baseadas em wavelets incorporam alguma forma de adaptatividade espacial no processo de filtragem com o intuito de preservar os limites e texturas da imagem (PARRILLI et al., 2012).

A filtragem anisotrópica também foi aplicada, bem como o modelo ROF (Rudin-Osher-Fatemi) de Rudin, Osher e Fatemi (1992), que considera as informações estatísticas a priori do ruído. Este modelo pode preservar bordas e outros detalhes. Estas abordagens não lineares podem ser consideradas como uma média ponderada onde o peso de cada pixel depende da distância e da similaridade do valor do pixel com o pixel sendo restaurado. A não linearidade foi estendida para o “speckle” como, por exemplo, o filtro SRAD (BIBO; ZHANG; FUQIANG, 2012).

SRAD (“Speckle Reducing Anisotropic Diffusion”) de Yongjian e Acton (YONGJIAN; ACTON, 2002) e wavelets contribuíram com uma melhoria na preservação de bordas. Estes métodos incorporam um gradiente local na filtragem do “speckle” com características sensíveis a bordas. Mas eles são insuficientes para preservar texturas finas (YANG; CLAUSI, 2009).

GMRF (“Gaussian Markov Random Fields”) também foi utilizado para filtrar o “speckle”. Embora tenha um resultado significativo na preservação de texturas, existe uma restauração pobre nas bordas (YANG; CLAUSI, 2009). Um problema comum entre estes filtros é que os pixels pertencentes ao mesmo tipo de padrão estrutural (bordas, texturas primitivas e regiões homogêneas) não podem ser fielmente identificados. Isto causa uma falsa mistura de componentes de diferentes estruturas, degradando-as (YANG; CLAUSI, 2009).

### 5.6.1 Transformação Homomórfica

Segundo Arsenaul e April (1976), com detecção quadrática, a função densidade de probabilidade do “speckle” pode ser expressa pela equação 5.24,

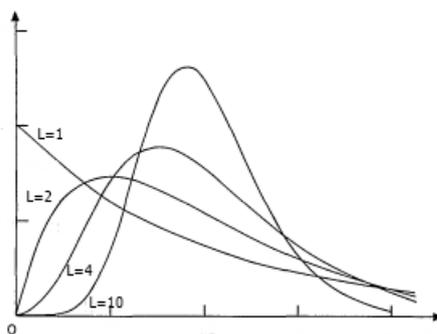
$$f_Z(Z) = \frac{L^L}{\Gamma(L)Z_0} \left(\frac{Z}{Z_0}\right)^{L-1} \exp\left(-\frac{LZ}{Z_0}\right), \quad (5.24)$$

onde  $Z_0$  é a média da intensidade e  $L$  é o número de “looks”. A Figura 5.7 representa graficamente a f.d.p, que é uma distribuição Gama (STARCK; MURTAGH; FADILI, 2010).

Um dos trabalhos pioneiros para a filtragem do “speckle” foi proposto por Arsenaul e April (1976), o qual utiliza a abordagem homomórfica através do logaritmo do “speckle”  $Y$ , conforme mostra a equação 5.25, para poder trabalhar com algum método baseado no ruído aditivo.

$$\hat{Y} = \log(Y) \quad (5.25)$$

Esta transformação converte o ruído multiplicativo para aditivo e o torna independente do



**Figura 5.7:** Gráfico da f.d.p do “speckle”.  $L$  representa o número de “looks”. Figura adaptada de (ARSENAUL; APRIL, 1976)

sinal. Contudo, a filtragem da imagem no domínio logaritmo resulta num viés, fazendo com que o valor esperado do estimador seja diferente do valor original da imagem. Então, faz-se necessário remover esta diferença na imagem filtrada antes de aplicá-la à função exponencial. Com o logaritmo, a imagem ruidosa original  $Z$  definida por  $Z = XY$ , onde  $X$  é o retroespalhamento e  $sY$  é o ruído speckle, pode ser expressa pela equação 5.26.

$$\hat{Y} = \log(Y) = \log(X) + \log(Y). \quad (5.26)$$

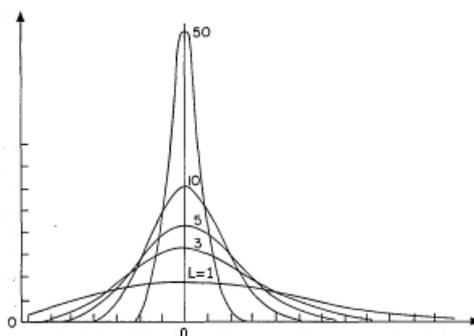
E a função densidade probabilidade do logaritmo do speckle pode ser representada pela equação 5.27.

$$f = \left[ \frac{L^L}{\Gamma(L)} \right] \exp(-L[\log(Y) + \exp(\log(Y))]). \quad (5.27)$$

Segundo Arsenaul e April (1976), quando o número de “looks” for igual a um, a distribuição é uma Fischer-Tippett e, portanto, a distribuição correspondente no domínio da intensidade é uma exponencial negativa. A Figura 5.8 mostra graficamente a f.d.p da equação 5.27.

De acordo com Starck, Murtagh e Fadili (2010), a média e a variância de  $s$  podem ser calculadas, respectivamente por  $\psi_0(L) - \log(L)$  e  $\psi_1(L)$ , onde  $L$  é o número de “looks” e  $\psi_n(z)$  é a função poligama. O ruído  $Y$  não é Gaussiano e nem possui a média zero, mas tende a Gaussiano com a variância  $\psi_1(L)$  conforme  $L$  aumenta. A figura 5.9 mostra esta situação do ruído tender a uma Gaussiana. Então, é esperado que métodos desenvolvidos para o ruído aditivo tenham uma boa performance através dos seguintes passos:

1. Tomar o logaritmo da imagem SAR de entrada.
2. Aplicar a filtragem.



**Figura 5.8:** Função densidade de probabilidade do logaritmo da imagem de intensidade. Quanto maior o número de “looks”, o gráfico se aproxima mais de uma Gaussiana. Figura adaptada de (ARSENAUL; APRIL, 1976)

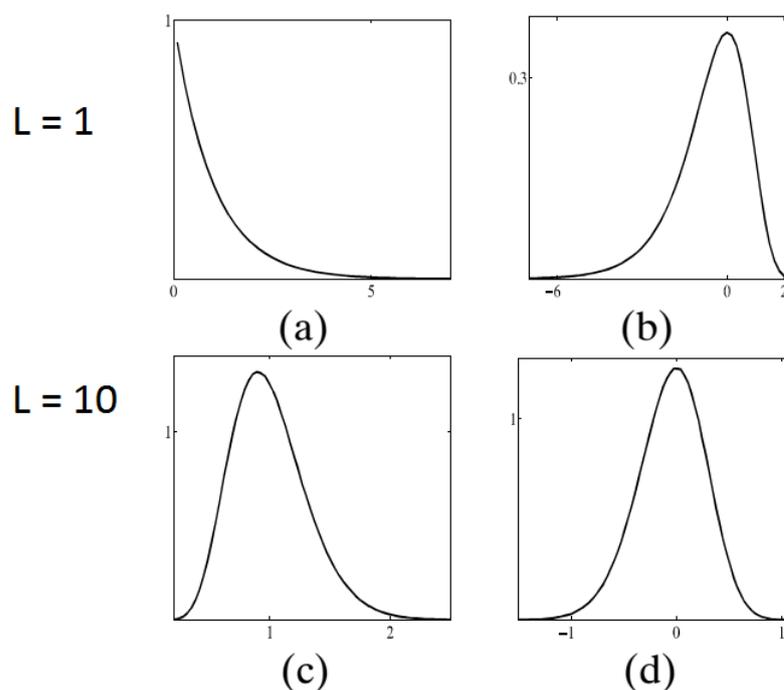
3. O ruído no domínio logaritmo possui uma média não zero que, segundo Starck, Murtagh e Fadili (2010), pode ser calculada por  $\psi_0(L) - \log(L)$ . Ela introduz um viés, o qual pode ser corrigido subtraindo o valor da média antes de aplicar uma função exponencial.
4. Aplicar uma função exponencial para transformar novamente ao domínio original da imagem.

Outros métodos foram abordados depois do tratamento homomórfico, como os filtros de Lee, Frost e Kuan, que atuam no domínio original da imagem SAR utilizando modelos estatísticos locais da imagem no modelo multiplicativo com filtros lineares desenvolvidos sobre a abordagem do MMSE (“minimum-mean-square-error” - mínimo erro quadrático médio) (PARRILLI et al., 2012).

### 5.6.2 Filtro de Lee (LLMMSE - “Local Linear Minimum Mean Square Error”) e de Lee Refinado

Os filtros pioneiros foram elaborados no domínio espacial com base nas propriedades estatísticas da refletividade e do “speckle” (ARGENTI et al., 2013). O trabalho de Lee (LEE, 1980), que contém soluções para ambos ruídos aditivo dependente do sinal e o “speckle”, utiliza a média e a variância locais de um “patch”, que devem ser iguais à média e variância de uma amostra (pixel). Seja  $f(x, y)$  o valor do pixel  $(x, y)$  em uma imagem de em níveis de cinza de duas dimensões  $n \times m$ , a média  $\mu$  e a variância  $\sigma^2$  locais definidas pelas equações 5.28 e 5.29 são calculadas dentro de uma janela  $(2n + 1) \times (2m + 1)$ .

$$\mu = \frac{1}{(2n + 1)(2m + 1)} \sum_{k=i-n}^{n+i} \sum_{l=j-m}^{m+j} x_{k,l} \quad (5.28)$$



**Figura 5.9:** Histograma do ruído multiplicativo (a-c), (b-d) é a versão do log. (a-b) corresponde  $L = 1$  e (c-d) para  $L = 10$ . (STARCK; MURTAGH; FADILI, 2010)

$$\sigma^2 = \frac{1}{(2n+1)(2m+1)} \sum_{k=i-n}^{n+i} \sum_{l=j-m}^{m+j} (x_{k,l} - \mu)^2 \quad (5.29)$$

Lee (LEE, 1980) define um pixel ruidoso  $Z(x,y)$  representado por  $Z(x,y) = X(x,y)Y(x,y)$  e obteve a relação:  $Z(x,y) = \bar{Y}(x,y)X(x,y) + \bar{X}(Y(x,y) - \bar{Y}(x,y))$ , onde  $\bar{Y}(x,y)$  é a média do ruído  $Y(x,y)$  e  $X(x,y)$  é o pixel original. A média e variância a priori de  $X(x,y)$  são computadas a partir de  $Z(x,y)$  pelas equações 5.30 e 5.31,

$$\bar{X}(x,y) = \frac{\bar{Z}(x,y)}{\bar{Y}(x,y)} \quad (5.30)$$

$$Q(x,y) = \frac{\text{var}(Z(x,y)) + Z(x,y)^2}{\sigma_2^2 + \bar{Y}(x,y)^2} - \bar{X}(x,y)^2, \quad (5.31)$$

onde  $\text{var}(Z(x,y))$  é a variância de  $Z(x,y)$ .  $\bar{Z}(x,y)$  e  $\text{var}(Z(x,y))$  são aproximados pela média e variância locais da imagem ruidosa.

Utilizando as duas equações acima, Lee (LEE, 1980) obteve o estimador  $\hat{X}(X,Y) = \bar{X}(x,y) + k(x,y)(Z(x,y) - \bar{Y}(x,y)\bar{X}(x,y))$ , onde  $k(x,y) = \frac{\bar{Y}(x,y)Q(x,y)}{\bar{X}(x,y)^2\sigma_2^2 + \bar{Y}(x,y)^2Q(x,y)}$ .

Lee (1981) propôs uma versão refinada para contornar as desvantagens dos limites de bor-

das que eram deixados ruidosos pela versão anterior (ARGENTI et al., 2013). Para aprimorar a filtragem, uma vez que uma borda é detectada em uma janela móvel, o algoritmo utiliza um gradiente local para estimar a orientação. Oito janelas não quadradas com bordas orientadas são permitidas. A estimação da média e variância locais são feitas dentro da janela que melhor se ajusta na orientação da borda. Se nenhuma janela é detectada, os estimadores são calculados na janela. Este filtro pode introduzir alguns artefatos em áreas com texturas. Além disto, com o tamanho da janela fixo, texturas com alta variação espacial e características finas lineares podem ser alteradas.

### 5.6.3 Filtro de Kuan (LLMMSE)

Este filtro apresenta algumas características semelhantes ao filtro Lee, pois ambos trabalham com o LLMMSE. Uma imagem  $X(x,y)$  corrompida com “speckle”  $Y(x,y)$  terá como resultado  $Z(x,y) = X(x,y)Y(x,y)$ , onde  $Y$  é independente de  $X$  e terá sua média estacionária e variância dadas pelas equações 5.32 e 5.33.

$$E(Y(x,y)) = E(Y) \quad (5.32)$$

$$\sigma_Y^2 = E[(Y(x,y) - E(Y))^2] \quad (5.33)$$

Kuan et al. (1985) definem uma observação de  $Z(x,y)$  normalizada:  $Z(x,y) = Z(x,y)/E(Y)$ , tal que  $E(Z(x,y)) = E(X(x,y))$  e representa  $Z(x,y)$  conforme a equação 5.34.

$$Z(x,y) = X(x,y) + \left[ \frac{(Y(x,y) - E(Y))}{E(Y)} \cdot X(x,y) \right] \quad (5.34)$$

Kuan et al. (1985) definem  $n(x,y) = (Y(x,y)/E(Y) - 1)X(x,y)$  como o ruído aditivo dependente do sinal e computam a sua variância  $\sigma_n^2(x,y)$  através de 5.35,

$$\sigma_n^2(x,y) = \frac{\sigma_Y^2[(E(X(x,y)))^2 + \sigma_X^2(x,y)]}{[E(Y)]^2} \quad (5.35)$$

A partir disto, Kuan et al. (1985) computam a variância de  $X$ :

$$\sigma_X^2(x,y) = \frac{\sigma_Z^2(x,y) - \sigma_Y^2[E(Z(x,y))]^2/[E(Z)]^2}{1 + \sigma_Z^2/[E(Z)]^2}. \quad (5.36)$$

Com essas equações, Kuan et al. (1985) apresentam o seguinte estimador da imagem filtrada:

$$\hat{X}(x, y) = \bar{X}(x, y) + \frac{v_X(x, y)(Z(x, y) - \bar{X}(x, y))}{v_X(x, y) + \sigma_Y^2[(\bar{X}(x, y))^2 + v_X(x, y)]/[E(Y)]^2}, \quad (5.37)$$

onde  $\bar{X}(x, y)$  e  $\sigma_X^2(x, y)$  são, respectivamente, a média e variância locais de  $X(x, y)$ .  $\sigma_Y^2/[E(Y)]^2$  é um parâmetro que caracteriza o grau do ruído multiplicativo. Deve-se observar que o filtro de Lee é uma aproximação do filtro ótimo para o ruído multiplicativo de Kuan, por tomar o termo linear de uma expansão em série de Taylor.

#### 5.6.4 Filtro de Frost (MMSE)

Este filtro proposto por Frost et al. (1982) é um filtro adaptativo linear e utiliza o critério MMSE para a estimativa da imagem original. A principal característica deste filtro é considerar a correlação entre pixels vizinhos. O valor filtrado é uma combinação linear dos valores dos pixels dentro de uma janela local com uma função de ponderação Gaussiana que depende da variação do coeficiente local da imagem ruidosa definido como a razão do desvio padrão com a média local (ARGENTI et al., 2013).

Frost et al. (1982) estimam  $X(x, y)$  de  $Z(x, y)$  através de uma resposta de impulso  $m(t)$  e uma função de transferência  $M(f)$  que são obtidas minimizando o erro quadrático médio dado por 5.38,

$$\varepsilon^2 = E[(X(t) - Z(t) * m(t))^2] \quad (5.38)$$

onde  $t = (x, y)$  é a coordenada espacial. A solução pelo MMSE acarreta na função de transferência 5.39,

$$M(f) = \begin{cases} \left[ \frac{\bar{Y}S_X(f)}{S_X(f)*S_Y(f)} \right] \frac{1}{H^*(f)} & \text{para } f \neq 0 \\ \frac{1}{\bar{Y}} & \text{para } f = 0 \end{cases}, \quad (5.39)$$

onde  $\bar{Y} = E[Y(t)]$ ,  $Y(t)$  é a variável aleatória representando o ruído e  $f = (f_x, f_y)$  é a coordenada de frequência espacial.  $S_X(f)$  e  $S_Y(f)$  são, respectivamente as densidades de potências espectrais da refletividade do terreno e do ruído.  $H^*(f)$  é a função de transferência do sistema do sistema, o qual não é dependente dos dados e pode ser considerado constante em uma determinada largura de banda (FROST et al., 1982). O filtro da equação 5.39 é válido para regiões

homogêneas nas quais  $\hat{f}(t)$  pode ser processado como um modelo estacionário aleatório (FROST et al., 1982). A parte dependente dos dados do filtro  $M'(f)$  é expressa por 5.40.

$$M'(f) = \frac{\bar{Y}S_X(f)}{S_X(f) * S_Y(f)} \quad (5.40)$$

Segundo (FROST et al., 1982), o modelo padrão para  $X(t)$  é um processo autorregressivo com uma função de correlação  $R_X(\tau)$  e uma densidade espectral  $S_X(f)$  dadas por 5.41 e 5.42,

$$R_X(\tau) = \sigma_X^2 \exp(-a|\tau|) + X^{-2} \quad (5.41)$$

$$S_X(f) = \frac{2\sigma_X^2 a}{a^2 + 4\pi^2 f^2} + X^{-2} \delta(f), \quad (5.42)$$

onde os parâmetros  $\sigma_X^2$ ,  $X$  e  $a$  possuem valores diferentes para as diferentes categorias do terreno. O modelo para o ruído branco multiplicativo é:

$$R_Y(\tau) = \sigma_Y^2 \delta(\tau) + Y^{-2} \quad (5.43)$$

$$S_Y(f) = \sigma_Y^2 + Y^{-2} \delta(f), \quad (5.44)$$

onde os parâmetros  $\sigma_{nY}^2$  e  $Y$  são dependentes dos sensores, mas não da região. Substituindo as densidades espectrais de  $X(t)$  e  $Y(t)$  na equação 5.40, a resposta do impulso do filtro é expressa por

$$m'(t) = K_1 \alpha \exp(-\alpha|t|), \quad (5.45)$$

com

$$\alpha = \sqrt{2a \left[ \frac{\bar{Y}}{\sigma_Y} \right]^2 \left[ \frac{1}{1 + \left( \frac{\bar{X}}{\sigma_X} \right)^2} \right] + a}, \quad (5.46)$$

onde  $K_1$  é uma constante normalizadora.

### 5.6.5 Filtros MAP (“Maximum a Posteriori”)

De acordo com Argenti et al. (2013), o protótipo dos filtros MAP no domínio espacial é o filtro  $\Gamma$ -MAP proposto por Lopes et al. (1990). Neste filtro admite-se que tanto a refletividade do alvo quanto o “speckle” seguem uma distribuição Gama solucionando uma equação MAP (“Maximum a Posteriori”). Este filtro foi desenvolvido para suavizar o ruído enquanto preserva bordas ou características de formas da imagem. O tamanho da janela do filtro afeta muito a qualidade das imagens filtradas. Se o filtro é muito pequeno, o algoritmo não é eficiente. Já se o filtro é muito grande, detalhes sutis da imagem serão perdidos. Normalmente utiliza-se uma janela de  $7 \times 7$  pixels (ARGENTI et al., 2013).

Uma versão refinada do filtro  $\Gamma$ -MAP que apresenta uma melhora de adaptatividade geométrica foi proposta por Baraldi e Parmiggiani (1995). Segundo (ARGENTI et al., 2013), este filtro marca o início de uma certa saturação no desempenho dos métodos de filtragem do “speckle” no domínio espacial, mesmo que métodos Bayesianos sofisticados com estimação MAP associada com campos aleatórios Markovianos ou campos aleatórios de Gibbs para o modelamento a priori sejam introduzidos conforme em (WALESSA; DATCU, 2000).

### 5.6.6 Filtros com transformada wavelet discreta

No filtro de Meer, Park e Cho (1994) considera-se uma vizinhança local formada por um conjunto de três janelas móveis concêntricas ( $7 \times 7$ ,  $5 \times 5$ ,  $3 \times 3$ ). Um índice de homogeneidade é dado para cada janela. A média espacial da maior janela ( $7 \times 7$ ) satisfazendo o critério de homogeneidade, que é definido como um limiar, será a saída. Se tal janela não existir, o estimador LLMMSE Kuan na janela  $3 \times 3$  mais profunda, ou seja, que está mais próxima do centro, será atribuído ao pixel central. Este filtro é efetivo para preservar bordas, características lineares e alvos.

Já o filtro RLP (“Relational Laplacian Pyramid”) proposto por Aiazzi et al. (1998), teve como base a pirâmide Laplaciana aprimorada de (AIAZZI; ALPARONE; BARONTI, 1998). As suas camadas passa-faixa são obtidas tomando a razão pixel por pixel entre um nível da pirâmide Gaussiana e a versão interpolada do nível superior de menor resolução. Enquanto o ícone da banda base, que corresponde ao topo da pirâmide Gaussiana, pode ser deixado de processar devido ao seu alto SNR (“Signal to Noise Ratio”) obtido através de uma filtragem passa-baixa em cascata, os níveis de passa-faixa do RLP são processados por meio do filtro de Kuan.

Segundo Argenti et al. (2013), filtragem no domínio wavelet-homomórfico foi extensamente utilizada durante os últimos vinte anos e performances superiores aos filtros espaciais

convencionais foram reconhecidas. Os métodos clássicos de “hard-” e “soft-thresholding” de Donoho (1995) foram utilizados por Guo et al. (1994). Limiarização baseada em funções não lineares (funções sigmóides) foram aplicadas por Sveinsson e Benediktsson (2003). Já Zeng e Cumming (1998) associou uma estimação MMSE com uma combinação das f.d.p’s GG (Gaussiana Generalizada) / Gaussiana para modelar, respectivamente, a refletividade e o ruído. Na pesquisa de Xie, Pierce e Ulaby (2002), a estimação MMSE foi aplicada após a modelagem dos coeficientes wavelet através da mistura Gaussiana e campos Markovianos aleatórios para caracterizar as dependências espaciais. Recentemente, Achim (2006) trabalhou com a estimação MAP com uma distribuição Rayleigh a priori para o sinal e os modelos Gama ou Nakagami para o ruído em, respectivamente, imagem SAR de intensidade e amplitude.

A filtragem não homomórfica no domínio wavelet aparece com menos frequência na literatura, pois a estimação dos parâmetros das f.d.p’s do sinal e do ruído tornam-se complexas, mesmo sendo vantajosa a ausência do viés devido ao mapeamento não linear do logaritmo (ARGENTI et al., 2013). Foucher, Benie e Boucher (2001) utilizaram wavelet para a remoção do “speckle” com a estimação baseada no critério MAP e o sistema Pearson de distribuições. Argenti et al. (2012) apresentaram o estimador LMMSE ótimo com a suposição de Gaussianidade. Dai et al. (2004) trabalharam com o estimador LMMSE com misturas de f.d.p’s Gaussianas aprimoradas com o uso de detector de bordas de Touzi, Lopes e Bousquet (1988) para aprimorar a filtragem do “speckle” nos contornos. Estimações MAP e MMSE associadas às f.d.p’s Laplaciana e Gaussiana para o sinal e ruído foram propostas por Argenti et al. (2012). As distribuições  $\Gamma$  Generalizada e Gaussiana foram aplicadas para filtragem MAP por Hongzhen et al. (2012) e por Li et al. (2013b). Já Fukuda e Hirosawa (1999) e Hawwar e Reza (2002) propuseram métodos não Bayesianos baseados na classificação dos coeficientes wavelet do sinal e ruído.

### 5.6.7 Filtros com abordagens não Bayesianas

#### **Filtros estatísticas de ordem e morfológico:**

Segundo (ARGENTI et al., 2013), a partir do filtro da mediana, os filtros estatísticas de ordem conseguiram popularidade graças às suas características peculiares de preservação das bordas. Alparone, Baronti e Carla (1995) elaboraram uma versão condicional do filtro da mediana substituindo o valor do pixel central da janela com uma amostra da mediana se, e somente se, o primeiro é reconhecido como valor discrepante. Uma versão adaptativa do filtro da mediana ponderada foi proposta para o “speckle” por (ALPARONE et al., 1996), que é um filtro de mediana central e preserva bordas, texturas e suaviza o ruído de fundo. O filtro geométrico (GF) (CRIMMINS, 1985) é uma ferramenta para preservar as bordas suavizando o “speckle” e uma

versão decimada de (ALPARONE; GARZELLI, 1998) foi proposta para ruído espacialmente correlacionado, incluindo o “speckle”. Estes métodos descritos não foram designados explicitamente para o “speckle”. Atualmente, estes métodos estão cada vez menos sendo utilizados.

#### **Difusão Anisotrópica:**

A difusão anisotrópica (PERONA; MALIK, 1990), segundo (ARGENTI et al., 2013), é uma técnica bastante popular na área de Processamento de Imagens. Esta técnica reduz o ruído sem remover partes significativas da imagem como bordas, linhas e outros detalhes importantes para a interpretação da imagem. Ela foi empregada para remover o “speckle” por (YONGJIAN; ACTON, 2002) nomeando-a SRAD (“Speckle Reducing Anisotropic Diffusion”). O SRAD explora os coeficientes instantâneos de variação, o qual é uma função de magnitude do gradiente local, e operadores Laplacianos. Este filtro supera filtros tradicionais para o “speckle” nos termos de preservação da média, redução de variância e localização de bordas. Mas, a suavização não realista introduzida o torna ineficiente para imagens SAR, pois detalhes finos e texturas úteis para análises são destruídos.

#### **Filtro Sigma:**

Este filtro foi originalmente projetado para ruído aditivo por Lee (LEE, 1983a) e estendido para o “speckle” também por Lee (LEE, 1983b). Este filtro, segundo (ARGENTI et al., 2013), teve como motivação a probabilidade sigma da distribuição Gaussiana, e suaviza a imagem pela média somente da vizinhança dos pixels que possuem a intensidade dentro da faixa sigma do pixel central. Conseqüentemente, as bordas são preservadas e detalhes sutis e linhas finas, como rodovias, são preservadas. Uma versão aprimorada deste filtro foi elaborada em (ALPARONE; BARONTI; GARZELLI, 1995) propondo uma filtragem sem viés de imagens afetadas pelo ruído multiplicativo. Recentemente, Lee et al. (2009) redefiniram a faixa sigma baseada da f.d.p do “speckle” e para diminuir o problema de borramento de fortes “scatters”, uma técnica de preservação da assinatura do alvo foi desenvolvida juntamente com a incorporação de um estimador LLMMSE.

#### **Filtro Bilateral:**

O filtro bilateral foi elaborado por Tomasi e Manduchi (TOMASI; MANDUCHI, 1998) e foi recentemente aplicado para remover o “speckle” por Zhang, Zhang e Yang (2011). Neste filtro, cada pixel dentro de uma janela é ponderado pela distância com o centro, como no filtro Frost, e pela diferença com o valor do pixel central, como no filtro sigma. Li et al. (2013b) elaboraram uma versão adaptativa para o “speckle” que utiliza uma função Gaussiana para a ponderação espacial e utiliza um filtro estatística de ordem para rejeitar valores discrepantes. Apesar da sua

elegância e baixo custo computacional, na presença de um ruído muito forte, como a técnica de “single-look”, a versão orientada para o “speckle” passa por limitações dadas pela função espacial com tamanho finito. Segundo Argenti et al. (2013), uma maneira de contornar este problema é aplicar a abordagem do filtro NLM.

### **Filtros baseados em "Compressive Sensing":**

“Compressive Sensing” (CS) , segundo (ARGENTI et al., 2013), é uma nova representação do sinal que, recentemente, se tornou muito popular e atraiu a atenção de vários pesquisadores que trabalham no campo de restauração de imagens ruidosas. Esta técnica sugere que um sinal de uma imagem natural satisfaz um modelo esparso, ou seja, ele pode ser visto como uma combinação de poucos elementos do sinal, chamados de dicionários ou átomos. Os modelos esparsos são a base do CS, o qual surgiu a partir dos trabalhos de (DONOHO, 2006) e (CANDÉS; ROMBERG; TAO, 2006) e é uma representação do sinal com um número menor de amostras abaixo da taxa de Nyquist. Resumidamente, em termos matemáticos, a imagem observada é modelada como  $z = Af + n$ , onde  $A$  é o dicionário,  $f$  é o vetor esparso, tal que a norma  $l_0$  definida por  $\|f\|_0 \leq K$ , com  $K \ll M$ , onde  $M$  é a dimensão de  $f$ , e  $n$  é o ruído que não satisfaz o modelo esparso. A partir disto, filtrar baseado n

o CS é encontrar o vetor mais esparso  $\|z - Af\|_2^2 < \varepsilon$ , onde  $\varepsilon$  denota a variância do ruído. Na literatura já podem ser encontrados alguns trabalhos relacionados na remoção do “speckle” com a técnica do CS, como os trabalhos (YANG; ZHANG, 2012), (FOUCHER, 2008) e (HAO; FENG; XU, 2012). Yang e Zhang (YANG; ZHANG, 2012) trabalharam com dicionários combinados com “wavelets” e “shearlets”. “Wavelets” fornecem expansões esparsas para estruturas de tipo “ponto” enquanto “shearlets” fornecem expansões esparsas para estruturas do tipo “curva”. Já o método de Foucher (2008) utiliza o algoritmo K-SVD de Aharon, Elad e Bruckstein (2006) para filtrar imagens SAR. O filtro de Hao, Feng e Xu (2012) é dividido em três passos: uma imagem ótima é obtida no domínio do logaritmo através de dicionários treinados, em seguida utiliza-se o método de “total variation” para melhorar a imagem obtida e por fim, aplica-se uma função exponencial para retornar ao domínio original. Além destes filtros, Jiang, Jiang e Sang (2012) também elaboraram um modelo não local esparso para imagens SAR.

### **5.6.8 Filtro de Deledalle (PPB - “Probabilistic Patch Based”)**

Resumidamente, de acordo com Argenti et al. (2013), este filtro utiliza a abordagem do filtro NLM para filtrar o “speckle” substituindo a distância euclidiana do NLM por uma medida probabilística que leva em consideração a f.d.p da imagem SAR, e propondo um procedimento iterativo para refinar os pesos.

Muitas filtragens clássicas utilizam a média local: o valor do pixel  $p$  restaurado é obtido com a média dos seus pixels vizinhos. No filtro Gaussiano o valor é a média de quatro pixels adjacentes. A abordagem “nonlocal” proposta em (BUADES; COLL; MOREL, 2005) para AWGN mostrou ser um ótimo potencial de avanço na área de processamento de imagens.

Pesquisadores envolvidos com imagens SAR também resolveram adotar esses novos filtros para ampliar a capacidade da filtragem do “speckle”. (PARRILLI et al., 2012) e (DELEDALLE; DENIS; TUPIN, 2009) são exemplos bem sucedidos de filtragem SAR, sendo o último um exemplo capaz de remover tanto o ruído aditivo como o multiplicativo. Além disso, existem outros trabalhos abordando o conceito de “nonlocal means” que atuam com a transformação homomórfica do “speckle”, como por exemplo, (YANG; CLAUSI, 2009) e (BIBO; ZHANG; FUQIANG, 2012).

Deledalle, Denis e Tupin (2009) elaboraram a remoção do ruído como um problema de estimação pela máxima verossimilhança ponderada (WMLE - “Weighted Maximum Likelihood Estimation”). Os pesos são iterativamente refinados baseados na similaridade entre os “patches” ruidosos e a similaridade dos “patches” extraídos do estimador a priori.

Seja  $\hat{u}$  a estimação da imagem real  $u^*$  de uma imagem ruidosa  $v$ . As imagens são consideradas definidas em uma matriz regular discreta  $\Omega$ .  $v_s$  será o valor do pixel ruidoso no local  $s \in \Omega$ . A verossimilhança  $p(v_s|\theta_s^*)$  foi considerada a distribuição paramétrica do ruído não-correlacionado, com  $\theta_s^*$  sendo um parâmetro desconhecido de variação espacial.

Então, remover o ruído é equivalente a encontrar o melhor estimador  $\hat{\theta}_s$  de  $\theta_s^*$ . Em cada local  $s$ , o estimador de máxima verossimilhança (MLE) define um estimador  $\hat{\theta}_s$  de  $\theta_s^*$  de um conjunto  $S_{\theta_s^*}$  formado por variáveis aleatórias independentes e identicamente distribuídas. Este estimador é expresso por:

$$\hat{\theta}_s^{(MLE)} = \operatorname{argmax}_{\theta_s} \sum_t \delta_{S_{\theta_s^*}}(t) \log(p(v_t|\theta_s)), \quad (5.47)$$

com  $\delta_{S_{\theta_s^*}} = 1$  se  $t \in S_{\theta_s^*}$ , 0 caso contrário. Então, Deledalle, Denis e Tupin (2009) definem o estimador WMLE como:

$$\hat{\theta}_s^{(WMLE)} \triangleq \operatorname{argmax}_{\theta_s} \sum_t w(s,t) \log(p(v_t|\theta_s)) \quad (5.48)$$

Para ruído aditivo, este trabalho mostra que o estimador WMLE é definido como uma média ponderada (WA - “Weighted Average”):

$$\hat{\theta}_s^{(WA)} \triangleq \frac{\sum_t w(s,t)v_t}{\sum_t w(s,t)}. \quad (5.49)$$

$w(s,t)$  é computado comparando dois “patches”  $\Delta_s$  e  $\Delta_t$  centralizados, respectivamente, nos locais  $s$  e  $t$ :

$$w(s,t)^{NL} \triangleq \exp\left(-\frac{1}{h} \sum_k \alpha_k |v_{s,k} - v_{t,k}|^2\right), \quad (5.50)$$

onde  $v_{s,k}$  e  $v_{t,k}$  são os  $k$ -ésimos vizinhos,  $\alpha_k$  representa um “kernel” gaussiano e  $h$  controla o decaimento da função exponencial.

O filtro PPB visa definir um peso adequado para generalizar a distância euclidiana do NLM e estendê-lo para ruídos não aditivos. O peso será expresso pela probabilidade, dada a imagem ruidosa  $v$ , que dois “patches”  $\Delta_s$  e  $\Delta_t$  tenham o mesmo parâmetro:

$$w(s,t)^{(PPB)} \triangleq p(\theta_{\Delta_s}^* = \theta_{\Delta_t}^* | v)^{1/h}, \quad (5.51)$$

onde  $\theta_{\Delta_s}^*$  e  $\theta_{\Delta_t}^*$  denotam sub-imagens extraídas do parâmetro da imagem  $\theta^*$  dos respectivos “patches”  $\Delta_s$  e  $\Delta_t$ .  $h > 0$  é um parâmetro escalar similar ao NLM.

Na suposição de independência do pixel dos “patches”, a probabilidade de similaridade pode ser decomposta em um produto  $\prod_k p(\theta_{s,k}^* = \theta_{t,k}^* | v_{s,k}, v_{t,k})$ . Em um modelo bayesiano sem conhecimento de  $p(\theta_{s,k}^* = \theta_{t,k}^*)$  e  $p(v_{s,k}, v_{t,k})$ , a probabilidade  $p(\theta_{s,k}^* = \theta_{t,k}^* | v_{s,k}, v_{t,k})$  pode ser considerada proporcional à máxima verossimilhança  $p(v_{s,k}, v_{t,k} | \theta_{s,k}^* = \theta_{t,k}^*)$ . A similaridade pela máxima verossimilhança é definida por (DELEDALLE; DENIS; TUPIN, 2009) como:

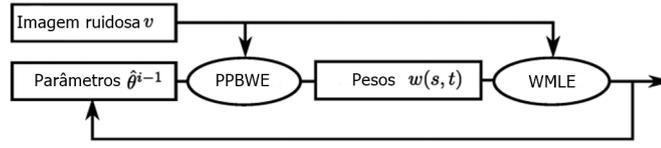
$$p(v_{s,k}, v_{t,k} | \theta_{s,k}^* = \theta_{t,k}^*) \propto \int_D p(v_{s,k} | \theta_{s,k}^* = \theta) p(v_{t,k} | \theta_{t,k}^* = \theta) d\theta, \quad (5.52)$$

onde  $D$  é a definição do domínio do parâmetro  $\theta$ .

Para calcular os pesos iterativamente, adiciona-se o estimador prévio da  $i$ -ésima iteração  $\hat{\theta}^{i-1}$  na equação 5.51.

$$w(s,t)^{(it.PPB)} \triangleq p(\theta_{\Delta_s}^* = \theta_{\Delta_t}^* | v, \hat{\theta}^{i-1})^{1/h}. \quad (5.53)$$

Então, a probabilidade de similaridade no processo iterativo pode ser decomposta como o produto de probabilidades  $p(\theta_{s,k}^* = \theta_{t,k}^* | v_{s,k}, v_{t,k}, \hat{\theta}^{i-1})$ . Em um modelo bayesiano sem o conhe-



**Figura 5.10: Esquema do filtro PPB iterativo. Figura adaptada de (DELEDALLE; DENIS; TUPIN, 2009)**

cimento de  $p(v_{s,k}, v_{t,k})$  e assumindo que o evento  $v_{s,k}, v_{t,k} | \theta_{s,k}^* = \theta_{t,k}^*$  seja independente de  $\hat{\theta}^{i-1}$ , Deledalle, Denis e Tupin (2009) mostram a seguinte relação:

$$p(\theta_{s,k}^* = \theta_{t,k}^* | v_{s,k}, v_{t,k}, \hat{\theta}^{i-1}) \propto \underbrace{p(v_{s,k}, v_{t,k} | \theta_{s,k}^* = \theta_{t,k}^*)}_{\text{verossimilhança}} \times \underbrace{p(\theta_{s,k}^* = \theta_{t,k}^* | \hat{\theta}^{i-1})}_{\text{a priori}}. \quad (5.54)$$

O termo de verossimilhança definido na equação 5.54 corresponde à fidelidade dos dados. O termo a priori é uma função de similaridade entre as duas distribuições dos dados. O cálculo do termo a priori é obtido por

$$p(\theta_{s,k}^* = \theta_{t,k}^* | \hat{\theta}^{i-1}) \propto \exp \left( -\frac{1}{T} \int_D (p(t | \hat{\theta}_{s,k}^{i-1}) - p(t | \hat{\theta}_{t,k}^{i-1})) \log \left( \frac{p(t | \hat{\theta}_{s,k}^{i-1})}{p(t | \hat{\theta}_{t,k}^{i-1})} \right) dt \right), \quad (5.55)$$

onde  $D$  é o domínio dos valores dos pixels e  $T > 0$  é um valor positivo real. Os parâmetros  $T$  e  $h$  atuam em conjunto para balancear a troca entre a redução do ruído e a fidelidade do estimador. A Figura 5.10 mostra o esquema do filtro PPB iterativo. O PPPWE (PPB “Weights Estimator”) computa os pesos  $w(s, t)$  utilizando a imagem ruidosa  $v$  e o estimador  $\hat{\theta}^{i-1}$ . O WMLE computa o novo parâmetro  $\hat{\theta}^i$  utilizando os pesos  $w(s, t)$  e a imagem ruidosa  $v$ . O processo é repetido até que não ocorra mais mudanças entre dois estimadores consecutivos (DELEDALLE; DENIS; TUPIN, 2009).

Deledalle, Denis e Tupin (2009) derivam o algoritmo iterativo de cálculo dos pesos para os casos do ruído gaussiano aditivo e o “speckle”.

Para o ruído aditivo, considera-se que os valores do pixel  $I_s$  sejam independente e identicamente distribuídos de acordo com uma distribuição normal  $N(\mu_s^*, \sigma^2)$ , onde  $\mu_s^*$  é a imagem subjacente original e  $\sigma^2$  a variância do ruído. O estimador é calculado por:

$$\hat{\mu}_s^{(WMLE)} = \frac{\sum_t w(s, t) I_t}{\sum_t w(s, t)}, \quad (5.56)$$

e os pesos na iteração  $i$  são definidos por:

$$w(s,t)^{it.PPB} = \exp \left[ - \sum_k \left( \frac{1}{h} \frac{|I_{s,k} - I_{t,k}|^2}{4\sigma^2} + \frac{1}{T} \frac{|\hat{R}_{s,k}^{i-1} - \hat{R}_{t,k}^{i-1}|^2}{\sigma^2} \right) \right]. \quad (5.57)$$

Segundo (DELEDALLE; DENIS; TUPIN, 2009), em uma versão não-iterativa,  $T \rightarrow +\infty$ , o filtro PPB é exatamente como o filtro NLM. Então, o filtro PPB pode ser considerado como uma extensão iterativa do filtro NLM.

Para os testes com o “speckle”, Deledalle, Denis e Tupin (2009) trabalharam com imagens SAR em amplitude. As amplitudes do pixel  $A_s$  são modeladas seguindo uma distribuição Nakagami-Rayleigh:

$$p(A_s | R_s^*) = \frac{2L^L}{\Gamma(L)R_s^{*L}} A_s^{2L-1} \exp \left( - \frac{LA_s^2}{R_s^*} \right), \quad (5.58)$$

onde  $R^*$  é a imagem refletida e  $L$  o número equivalente de “looks”. A imagem em amplitude original  $A^*$  é a raiz quadrada da imagem  $R^*$ . Então, o estimador para imagem SAR é dado por:

$$\hat{R}_s^{(WMLE)} = \frac{\sum_t w(s,t) A_t^2}{\sum_t w(s,t)}. \quad (5.59)$$

Finalmente, os pesos na iteração  $i$  para a imagem SAR em amplitude podem ser definidos através de:

$$w(s,t)^{(it.PPB)} = \exp \left[ - \sum_k \left( \frac{1}{\tilde{h}} \log \left( \frac{A_{s,k}}{A_{t,k}} + \frac{A_{t,k}}{A_{s,k}} \right) + \frac{L}{T} \frac{|\hat{R}_{s,k}^{i-1} - \hat{R}_{t,k}^{i-1}|^2}{\hat{R}_{s,k}^{i-1} \hat{R}_{t,k}^{i-1}} \right) \right], \quad (5.60)$$

onde  $\tilde{h} = h/(2L - 1)$ . Segundo os autores, em uma versão não iterativa,  $T \rightarrow +\infty$ , o filtro é baseado no mesmo esquema do NLM, substituindo a distância euclidiana por um critério de similaridade adaptado para o “speckle”, dado por:

$$\log \left( \frac{A_1}{A_2} + \frac{A_2}{A_1} \right), \quad (5.61)$$

onde  $A_1$  e  $A_2$  são dois valores da imagem observada.

### 5.6.9 SAR-BM3D

O filtro SAR-BM3D apresentado em (PARRILLI et al., 2012), teve o seu método baseado nos conceitos do NLM e na redução no domínio wavelet. Ele segue a estrutura do BM3D (original para AWGN) mas teve os passos do algoritmo modificados para tratar imagens SAR, e é utilizada uma medida probabilística de similaridade no processo “block-matching”. As imagens SAR são contaminadas com o “speckle”, o qual carrega informações da imagem mas a degrada dificultando a análise. Embora a técnica de “multi-look” reduza o efeito do “speckle”, ela ocasiona a perda de resolução da imagem. Por isso a elaboração de técnicas de filtragem do “speckle” de imagens SAR continua atraindo pesquisadores.

As seguintes contribuições do filtro SAR-BM3D podem ser citadas:

- Utilizar uma medida ad-hoc inspirada por Deledalle, Denis e Tupin (2009) para agrupar blocos (“patches”) similares.
- Recorrer à estimação LLMMSE na fase de redução.
- Utilizar “undecimated wavelet” para melhorar a confiabilidade da estimativa.

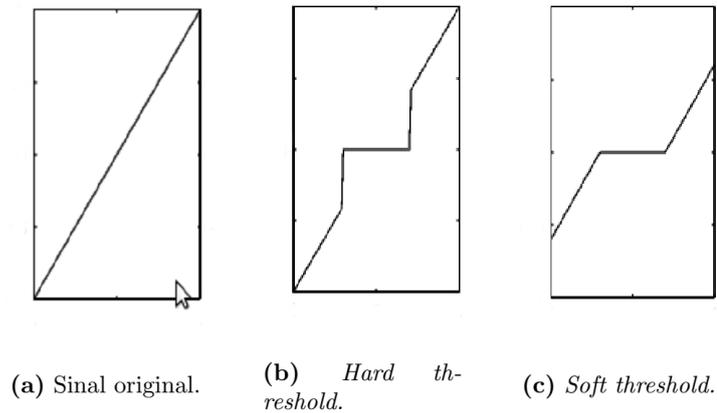
O BM3D utiliza a transformada wavelet (WT - “Wavelet Transform”) que fornece uma representação esparsa das imagens: coeficientes altos representam bordas, e o ruído é representado por coeficientes pequenos. Uma simples forma de limiarizar os coeficientes permite uma forte rejeição de ruído com uma boa preservação dos detalhes.

O processo que remove valores menores que um limiar e mantém valores maiores ou iguais chama-se “hard-thresholding”. Este processo é exemplificado pela equação 5.62. O processo de “soft-thresholding” reduz os valores acima do limiar  $\lambda$  e os pequenos valores recebem zero. A equação 5.63 mostra um exemplo do “soft-thresholding”. A Figura 5.11 ilustra os dois processos citados.

$$\rho_{hard}(y) = \begin{cases} y, & |y| > \lambda \\ 0, & \text{caso contrário} \end{cases} \quad (5.62)$$

$$\rho_{soft}(y) = \begin{cases} y - \lambda, & y \geq \lambda \\ y + \lambda, & y \leq -\lambda \\ 0, & \text{caso contrário} \end{cases} \quad (5.63)$$

A seguir, os dois passos do BM3D são descritos resumidamente:



**Figura 5.11: Exemplo dos processos “hard-” e “soft-thresholding” no sinal original.**

**Primeiro passo:**

1. Agrupamento: para cada bloco referenciado, os blocos mais similares são localizados de acordo com um critério mínimo da distância euclidiana.
2. Filtragem Colaborativa: cada grupo 3D (conjunto de blocos) sofre WT, “hard thresholding”, WT inversa.
3. Agregação: todos os blocos filtrados retornam ao local original e contribuem com pesos adequados para computar o estimador básico.

**Segundo passo:**

1. Agrupamento: blocos são localizados de acordo com o estimador básico do 1º passo.
2. Filtragem Colaborativa: cada grupo (da imagem ruidosa) sofre DCT/WT, filtragem de Wiener, transformada inversa.
3. Agregação: igual ao 1º passo.

Parrilli et al. (2012) modificaram os passos para levar em consideração as estatísticas do ruído “speckle” da seguinte maneira:

- Adaptar o critério utilizado para identificar os blocos similares: no BM3D, para cada bloco referenciado, ele procura pelos similares (em uma área de busca adequada) nos termos da distância euclidiana. Em imagens SAR, esta distância perde a significância. Então, utilizou-se uma outra medida de similaridade ad-hoc.

- Adaptar a filtragem colaborativa. Substituiu o “hard thresholding” pelo LLMMSE e utilizando a transformada wavelet discreta (UDWT) para obter uma estimativa mais confiável no 1º passo. A UDWT garante a propriedade de deslocamento da invariância (evitando artefatos como o fenômeno de Gibbs após o “hard thresholding”) e fornece um número maior de amostras para as estimativas subsequentes.

## 5.7 Outras versões inspiradas pelo NLM e BM3D

**SAFIR:** Este filtro foi proposto por Boulanger et al. (2008). Ele restaura imagens contaminadas com os ruídos Poisson e Gaussiano com uma transformada de estabilização da variância para remover a dependência entre a média e a variância.

**OBNL:** Coupe et al. (2009) utilizaram uma abordagem Bayesiana para derivar o filtro NLM e filtrar imagens de ultrassom com a distância de Pearson como critério de comparação da similaridade dos “patches”.

**EBNL:** Foi proposto em (ZHONG; LI; JIAO, 2011) e, como o OBNL, também utiliza uma abordagem Bayesiana incorporando a técnica do filtro sigma para contornar o problema de viés causado pela forte suposição de que o “patch” da imagem fornece uma boa aproximação do parâmetro. Além disto, é incorporada a pré-seleção do pixel baseada na faixa sigma, que contribui para a preservação dos detalhes da imagem, como bordas, texturas e “scatters” fortes.

**CII-NLM:** Este método foi elaborado em (XUE et al., 2013) e utiliza a integral do cosseno para reduzir o custo computacional do NLM. A função de ponderação é decomposta em uma combinação linear de funções do cosseno.

**O-EBLN:** Este filtro proposto em (GOMEZ et al., 2013) é uma otimização do filtro EBNL que reduz significativamente a variância enquanto mantém a média da imagem ruidosa. Ele interage com o usuário através de um algoritmo genético iterativo (IGA) proposto em (TAKAGI, 2001) que guiará o projeto de construção do filtro EBNL sob a supervisão do usuário (“designer do filtro”).

**FANS:** Cozzolino et al. (2013) inspiraram-se no SAR-BM3D com uma variação do tamanho da área de busca guiada por um nível de atividade de cada “patch” e uma terminação antecipada probabilística baseada nas estatísticas do “speckle” com o objetivo de aumentar a velocidade do agrupamento.

**FAST NLM (FNLM):** Foi elaborado para criomicroscopia eletrônica em (DARBON et al., 2008). Este filtro oferece uma filtragem mais rápida pois existe uma implementação vetorizada e

paralela do NLM com uma propriedade de separação da filtragem da vizinhança dos “patches”.

**FAST NLM (outro algoritmo):** Karnati, Uliyar e Dey (2009) substituíram a janela dos “patches” por uma abordagem de pirâmide de multi-resolução modificada que fornece poucas comparações entre os pixels.

**NLM-SURELET:** O método de Ville e Kocher (2011) faz uma derivação do SURE (“Stein’s unbiased risk estimate”) de Stein (1981) com uma projeção linear das vizinhanças. O SURE também é utilizado para otimizar os parâmetros por um algoritmo de busca ou resolvendo um sistema de equações lineares.

**NLM-SAP:** O “Non-local Methods with Shape-Adaptive Patches” de Deledalle, Duval e Salmon (2012) substitui a forma quadrada padrão dos “patches” por vários formatos que podem obter uma vantagem da geometria local da imagem. Este filtro utiliza FFT e a abordagem do SURE.

**NL-Bayes:** É um filtro muito recente proposto em (LEBRUN; BUADES; MOREL, 2013b) e tem a participação do criador do filtro NLM. Ele utiliza uma abordagem Bayesiana e mescla o NLM com o BM3D. Além disto, na implementação em (LEBRUN; BUADES; MOREL, 2013a), é apresentado o NL-PCA descrito como uma fusão do BM3D com o filtro TSID de (ZHANG et al., 2010).

**GNLM:** Este algoritmo foi elaborado em (LUO; PAN; NGUYEN, 2012) e modificou o NLM original para incorporar a dependência do ruído dentro da função de ponderação e propôs dois passos iterativos inspirados pelo BM3D. Este filtro pode ser utilizados em ruídos i.i.d e não i.i.d.

**PNLM:** É uma versão probabilística do NLM criada em (WU et al., 2013) que pode ser utilizada para outros tipos de ruídos focando na função de ponderação.

**MLN:** O filtro de Guo, Wang e Hou (2011) foi utilizado para filtrar imagens de ultrassom e também foi baseado no NLM e possui dois passos. No primeiro passo existe uma estimação pela máxima verossimilhança para calcular uma imagem inicial livre de ruído e, no segundo passo, aplica-se o filtro NLM.

**IANLM:** É um filtro iterativo adaptativo elaborado em (ZHAN; ZHANG; DING, 2012) para o “speckle” em imagens de ultrassom. O “speckle” é transformado em ruído aditivo por uma operação de raiz quadrada. Logo em seguida, o parâmetro de controle da suavização é estimado através da seleção de regiões homogêneas. Por último, uma estratégia combinada com um “clustering” local baseado na intensidade dos pixels realiza a suavização da imagem.

**SFAW:** Li et al. (2013a) modificaram o filtro bilateral e deram o nome de SFAW (“Space-domain filter with alterable window”). Este filtro apresenta uma adaptatividade geométrica na função espacial e de similaridade, respectivamente guiadas por: o coeficiente de variação local e o modelo conjunto da f.d.p de dois pixels possuindo a mesma refletividade.

**DA-NLM:** Este filtro foi proposto em (JOJY et al., 2013) e incorpora pesos adaptativos descontínuos ao invés dos pesos gaussianos do NLM. Os pesos são derivados a partir de uma técnica recente proposta em (SUBRAHMANYAM; RAJAGOPALAN; ARAVIND, 2008) chamada “Importance Sampling Unscented Kalman Filter” (ISUKF).

**SNLM:** Zhan, Zhang e Ding (2013) sugerem que um parâmetro de suavização do NLM fixo para toda a imagem torna difícil para este filtro restaurar bordas e outras estruturas. Logo, é projetado um filtro utilizando o algoritmo de bordas SUSAN de ??). Assim, é possível controlar o parâmetro cada pixel que responde a este algoritmo.

**NL-Lee:** Este filtro idealizado em (ZHONG et al., 2013) foi baseado na similaridade da estrutura dos “patches” do NLM com a similaridade de homogeneidade. O NL-Lee combina o modelo do NLM, mas mescla o filtro de Lee em uma maneira distributiva. Ele apresenta uma boa troca entre a suavização do “speckle” e a preservação dos detalhes.

**NL-NLG:** Ramachandran e Nair (2012) incorporaram ao NLM um filtro não linear Gaussiano com dois parâmetros ajustáveis, que controlam a quantidade de ruído removido e a suavização, para identificar a similaridade entre “patches” e restaurar o valor dos pixels. Segundo os autores, este filtro preserva informações estruturais e de bordas enquanto suprime o “speckle”. Além disto, o NL-NLG pode ser estendido para três dimensões facilitando a filtragem do volume.

**SAIST:** O filtro “Spatially-Adaptive Iterative Singular-value Thresholding” elaborado em (DONG; SHI; LI, 2013) generaliza o “BayesShrink” de Chang, Yu e Vetterli (2000) do modelo de filtragem local para o não local e realiza uma otimização esparsa.

# Capítulo 6

## DISTÂNCIAS ESTOCÁSTICAS COM A $G^0$

---

---

Como descrito na Seção 3.1, uma imagem SAR que será analisada com a distribuição  $G^0$  terá suas regiões caracterizadas por três parâmetros:

- $\alpha$ : caracteriza a rugosidade de uma região da imagem
- $\gamma$ : parâmetro de escala
- $L$ : número de “looks”

Segundo Nascimento, Cintra e Frery (2010), avaliar a distância entre duas amostras da imagem SAR é uma etapa importante na análise da imagem, pois a análise do contraste frequentemente possui o problema de quantificar o quanto duas regiões da imagem são distinguíveis entre si.

A distância fornece uma base para o problema de separabilidade e, portanto, no desempenho da classificação das amostras. No trabalho (NASCIMENTO; CINTRA; FRERY, 2010), oito distâncias estocásticas são avaliadas em testes de hipóteses que empregam a estimação por máxima verossimilhança.

Nos últimos anos, houve um maior interesse em adaptar ferramentas de informações teóricas, também conhecidas por medidas de divergência, no processamento de imagens. O conceito de divergências estocásticas é uma dessas ferramentas, a qual já foi utilizada em pesquisas de classificação de imagens, análise de “cluster”, testes “goodness-of-fit” e processamento de imagens polarimétricas (NASCIMENTO; CINTRA; FRERY, 2010).

Uma imagem pode ser definida como um conjunto de regiões, que podem ser descritas por diferentes f.d.p’s. Seja o retorno de uma superfície expresso por  $Z = XY$ , onde  $X$  é o retroespalhador com informações da superfície, e  $Y$  representando o “speckle”.  $X$  em (NASCIMENTO;

CINTRA; FRERY, 2010) segue uma distribuição recíproca de gama,  $X \sim \Gamma(\alpha, \gamma)$ , com a f.d.p dada pela equação 6.1.

$$f_X(x; \alpha, \gamma) = \frac{\gamma^{-\alpha}}{\Gamma(-\alpha)} x^{\alpha-1} \exp(-\frac{\gamma}{x}), \quad -\alpha, \gamma, x > 0. \quad (6.1)$$

Em imagens SAR de intensidade com “single-look”,  $Y$  é exponencialmente distribuído com média unitária. Logo, imagens com “multilooks” podem ter  $Y$  descrito por uma distribuição gama,  $Y \sim \Gamma(L, L)$ , com a densidade expressa pela equação 6.2.

$$f_Y(y; L) = \frac{L^L}{\Gamma(L)} y^{L-1} \exp(-Ly), \quad y > 0, L \geq 1 \quad (6.2)$$

Considerando as equações acima,  $Z$  pode ser descrito pela distribuição  $G_I^0$ ,  $Z \sim G_I^0(\alpha, \gamma, L)$ . Então  $Z$  é expresso pela equação 6.3.

$$f_Z(z; \alpha, \gamma, L) = \frac{L^L \Gamma(L-\alpha)}{\gamma^\alpha \Gamma(-\alpha) \Gamma(L)} z^{L-1} (\gamma + Lz)^{\alpha-L}, \quad -\alpha, \gamma, z > 0, L \geq 1 \quad (6.3)$$

Esta distribuição pode caracterizar tanto regiões homogêneas como heterogêneas, e pode ter os parâmetros  $\alpha$  e  $\gamma$  estimados por vários métodos: redução de viés, técnicas robustas, algoritmos para pequenas amostras e a estimação por máxima verossimilhança. Nascimento, Cintra e Frery (2010) trabalharam com a estimação por máxima verossimilhança, e obtiveram um sistema não-linear para os estimadores de  $\alpha$  e  $\gamma$  com as seguintes equações:

$$\psi^0(L - \hat{\alpha}) - \psi^0(-\hat{\alpha}) - \log(\hat{\gamma}) + \frac{1}{n} \sum_{i=1}^n \log(\hat{\gamma} + Lz_i) = 0 \quad (6.4)$$

$$-\frac{\hat{\alpha}}{\hat{\gamma}} + \frac{\hat{\alpha} - L}{n} \sum_{i=1}^n (\hat{\gamma} + Lz_i)^{-1} = 0, \quad (6.5)$$

onde  $\psi^0(\cdot)$  é a função digama. De modo geral, as equações acima não fornecem uma fórmula fechada para a solução. Então, a otimização por métodos numéricos pode ser considerada. Nascimento, Cintra e Frery (2010) utilizaram o método BFGS (Broyden-Fletcher-Goldfarb-Shanno) descrito em (FLETCHER, 2000).

Além disto, Nascimento, Cintra e Frery (2010) apresentam a classe de divergência  $(h, \phi)$ . Sejam  $X$  e  $Y$  variáveis aleatórias no mesmo espaço de probabilidade com as respectivas densidades  $f_X(x; \theta_1)$  e  $f_Y(y; \theta_2)$ , onde  $\theta_i$  é o vetor de parâmetros  $(\alpha_i, \gamma_i, L_i)$ , para  $i = 1$  ou  $i = 2$ , a divergência  $(h, \phi)$  é expressa por 6.6

**Tabela 6.1: Funções  $h$  e  $\phi$  utilizadas para desenvolver as distâncias estocásticas. Tabela adaptada de (NASCIMENTO; CINTRA; FRERY, 2010).**

$(h, \phi)$	$h(y)$	$\phi(x)$
Kullback-Leibler	$y$	$x \log(x)$
Rényi (ordem $\beta$ )	$\frac{1}{\beta-1} \log((\beta-1)y+2), 0 \leq y < \frac{1}{1-\beta}$	$\frac{x^\beta - \beta(x-1) - 2}{\beta-1}, 0 < \beta < 1$
Hellinger	$y/2, 0 \leq y < 2$	$(\sqrt{x}-1)^2$
Bhattacharyya	$-\log(-y+1), 0 \leq y < 1$	$-\sqrt{x} + \frac{x+1}{2}$
Jensen-Shannon	$y$	$x \log\left(\frac{2x}{x+1}\right)$
Aritmética-Geométrica	$y$	$\left(\frac{x+1}{2}\right) \log\left(\frac{x+1}{2x}\right)$
Triangular	$y, 0 \leq y < 2$	$\frac{(x-1)^2}{x+1}$
Média Harmônica	$-\log\left(-\frac{y}{2}+1\right), 0 \leq y < 2$	$\frac{(x-1)^2}{x+1}$

$$D_{\phi}^h(X, Y) = h\left(\int_I \phi\left(\frac{f_X(x; \theta_1)}{f_Y(x; \theta_2)}\right) f_Y(x; \theta_2) dx\right), \quad (6.6)$$

onde  $\phi : (0, \infty) \rightarrow [0, \infty)$  é uma função convexa e  $h : (0, \infty) \rightarrow [0, \infty)$  é uma função de incremento com  $h(0) = 0$ . A Tabela 6.1 indica as seleções das funções  $h$  e  $\phi$ .

Algumas destas divergências satisfazem a propriedade de simetria triangular, e podem ser consideradas distâncias. Porém, como nem todas as divergências seguem essa propriedade, é preciso calcular uma nova medida para assegurar a transformação das divergências em distâncias com a expressão 6.7.

$$d_{\phi}^h(X, Y) = \frac{D_{\phi}^h(X, Y) + D_{\phi}^h(Y, X)}{2} \quad (6.7)$$

Trabalhando com as funções da figura ?? em 6.6 e utilizando o resultado obtido em 6.7, os autores transformaram as divergências estocásticas em distâncias estocásticas e obteve as integrais abaixo. Estas integrais tiveram a supressão da dependência de  $x$  e do suporte de  $I$  nas suas notações.

#### Distância de Kullback-Leibler:

$$d_{KL}(X, Y) = \frac{1}{2} \int (f_X - f_Y) \log\left(\frac{f_X}{f_Y}\right) \quad (6.8)$$

#### Distância de Rényi de ordem $0 < \beta < 1$ :

$$d_R^{\beta}(X, Y) = \frac{1}{\beta-1} \log\left(\frac{\int f_X^{\beta} f_Y^{1-\beta} + \int f_X^{1-\beta} f_Y^{\beta}}{2}\right) \quad (6.9)$$

**Distância de Hellinger:**

$$d_H(X, Y) = 1 - \int \sqrt{f_X f_Y} = 1 - \exp\left(-\frac{1}{2}d_R^{1/2}(X, Y)\right) \quad (6.10)$$

**Distância de Bhattacharyya:**

$$d_B(X, Y) = -\log\left(\int \sqrt{f_X f_Y}\right) = -\log(1 - d_H(X, Y)) \quad (6.11)$$

**Distância de Jensen-Shannon:**

$$d_{JS}(X, Y) = \frac{1}{2} \left[ \int f_X \log\left(\frac{2f_X}{f_Y + f_X}\right) + \int f_Y \log\left(\frac{2f_Y}{f_Y + f_X}\right) \right] \quad (6.12)$$

**Distância aritmética-geométrica:**

$$d_{AG}(X, Y) = \frac{1}{2} \int (f_X + f_Y) \log\left(\frac{f_Y + f_X}{2\sqrt{f_Y f_X}}\right) \quad (6.13)$$

**Distância triangular:**

$$d_T(X, Y) = \int \frac{(f_X - f_Y)^2}{f_X + f_Y} \quad (6.14)$$

**Distância de média harmônica:**

$$d_{HM}(X, Y) = -\log\left(\int \frac{2f_X f_Y}{f_X + f_Y}\right) = -\log\left(1 - \frac{d_T(X, Y)}{2}\right) \quad (6.15)$$

A Figura 6.1 detalha, explicitamente, as fórmulas fechadas de quatro distâncias estocásticas através de matemática simbólica: Kullback-Leibler, Rényi, Hellinger e Bhattacharyya. Segundo Nascimento, Cintra e Frery (2010), as demais distâncias exigem cálculo numérico. A Figura 6.2 fornece a identidade das integrais da Figura 6.1.

(i) Distância de Kullback-Leibler:

$$d_{\text{KL}}(\boldsymbol{\theta}_1, \boldsymbol{\theta}_2) = \sum_{i=1}^2 (-1)^i k_i d \int_0^\infty \frac{x^{a_i}}{(b_i + L_i x)^{c_i}} dx + \sum_{i=1}^2 (-1)^i k_i d \int_0^\infty \frac{\log(b_i + L_i x) x^{a_i}}{(b_i + L_i x)^{c_i}} dx + \sum_{i=1}^2 (-1)^i k_i (L_2 - L_1) \int_0^\infty \frac{\log(x) x^{a_i}}{(b_i + L_i x)^{c_i}} dx - k_1 d \int_0^\infty \frac{x^{a_1} \log(b_2 + L_2 x)}{(b_1 + L_1 x)^{c_1}} dx + k_2 d \int_0^\infty \frac{x^{a_2} \log(b_1 + L_1 x)}{(b_2 + L_2 x)^{c_2}} dx,$$

onde  $k_i = \frac{L_i \Gamma(L_i - \alpha_i)}{(\frac{L_i}{2})^{\alpha_i} \Gamma(\alpha_i) \Gamma(L_i)}$ ,  $a_i = L_i - 1$ ,  $b_i = \frac{\gamma_i}{2}$ ,  $c_i = |\alpha_i| + L_i$  para  $i = 1, 2$  e  $d = \log(k_2/k_1)$ .

(ii) Distância de Rényi de ordem  $\beta$ :

$$d_{\text{R}}^\beta(\boldsymbol{\theta}_1, \boldsymbol{\theta}_2) = \frac{1}{\beta - 1} \left[ \log \left( h_1 \int_0^\infty x^{g_1} (b_1 + L_1 x)^{e_1} (b_2 + L_2 x)^{e_2} dx \right) + \log \left( h_2 \int_0^\infty x^{g_2} (b_1 + L_1 x)^{m_1} (b_2 + L_2 x)^{m_2} dx \right) \right],$$

onde  $h_1 = k_2^\beta k_1^{1-\beta}$ ,  $h_2 = k_1^\beta k_2^{1-\beta}$ ,  $g_1 = (L_1 - 1)(1 - \beta) + (L_2 - 1)\beta$ ,  $g_2 = (L_1 - 1)\beta + (L_2 - 1)(1 - \beta)$ ,  $e_1 = (\alpha_1 - L_1)(1 - \beta)$ ,  $e_2 = (\alpha_2 - L_2)\beta$ ,  $m_1 = (\alpha_1 - L_1)\beta$  e  $m_2 = (\alpha_2 - L_2)(1 - \beta)$ , e  $0 < \beta < 1$ .

(iii) Distância de Hellinger:  $d_{\text{H}}(\boldsymbol{\theta}_1, \boldsymbol{\theta}_2) = 2 \left( 1 - \sqrt{k_1 k_2} \int_0^\infty x^{(a_1 + a_2)/2} (b_1 + L_1 x)^{f_1} (b_2 + L_2 x)^{f_2} dx \right)$ , onde  $f_i = \frac{\alpha_i - L_i}{2}$ , para  $i = 1, 2$ .

(iv) Distância de Bhattacharyya:  $d_{\text{B}}(\boldsymbol{\theta}_1, \boldsymbol{\theta}_2) = -\log \left( \sqrt{k_1 k_2} \int_0^\infty x^{(a_1 + a_2)/2} (b_1 + L_1 x)^{f_1} (b_2 + L_2 x)^{f_2} dx \right)$ .

**Figura 6.1: Distâncias estocásticas para a distribuição  $G^0$ . Figura adaptada de (NASCIMENTO; CINTRA; FRERY, 2010).**

$$\int_0^\infty \frac{x^a}{(b + nx)^c} dx = \frac{b^{-c} \left(\frac{n}{b}\right)^{-1-a} \Gamma(1+a) \Gamma(-1-a+c)}{\Gamma(c)},$$

$$\int_0^\infty \frac{\log(b + nx) x^a}{(b + nx)^c} dx = \frac{1}{\Gamma(c)} \left( b^{-c} \left(\frac{n}{b}\right)^{-1-a} \Gamma(1+a) \Gamma(-1-a+c) (\log(b) + \psi^{(0)}(c) - \psi^{(0)}(-1-a-c)) \right),$$

$$\int_0^\infty \frac{\log(b_1 + n_1 x) x^a}{(b_2 + n_2 x)^c} dx = \frac{b_1 b_2^{-c} \pi \csc(a\pi)}{n_1} \left( \frac{n_2^2 (b_1/n_1)^{2-a} c {}_2F_1 \left( 2+a, 1+c; 3+a; \frac{b_1 n_2}{b_2 n_1} \right)}{2+3a+a^2} - \frac{2+a}{2+3a+a^2} \left( \frac{b_2 n_1 - b_1 n_2}{b_2 n_1} \right)^{-c} + \frac{(n_2/b_2)^{-a} \Gamma(-1-a+c) {}_3F_2 \left( 1, 1, -a+c; 2, 1-a; \frac{b_1 n_2}{b_2 n_1} \right)}{\Gamma(1-a)\Gamma(c)} + \frac{n_1 (b_2/n_2)^{1+a} \Gamma(-1-a+c)}{b_1 \Gamma(-a)\Gamma(c)} \left( \log \left( \frac{n_2}{n_1 b_2} \right) + \psi^{(0)}(-1-a+c) - \psi^{(0)}(-a) + \pi \cot(a\pi) \right) \right),$$

onde  ${}_2F_1(\cdot, \cdot; \cdot; \cdot)$  e  ${}_3F_2(\cdot, \cdot, \cdot; \cdot, \cdot; \cdot)$  são funções hipergeométricas,

$$\int_0^\infty \frac{\log(x) x^a}{(b + nx)^c} dx = -\frac{1}{\Gamma(c)} \left[ b^{-c} (n/b)^{-1-a} \Gamma(1+a) \Gamma(-1-a+c) (-H_{[a+1]} + H_{[-1-a+c]} + \log(n/b)) \right],$$

onde  $H_n$  é o  $n$ -ésimo número harmônico, e

$$\int_0^\infty x^a (b_1 + n_1 x)^{c_1} (b_2 + n_2 x)^{c_2} dx = b_1^{c_1} b_2^{c_2} \pi \csc((c_2 + a)\pi) \left[ -\frac{\left(\frac{n_1}{b_1}\right)^{-1-c_2-a} \left(\frac{n_2}{b_2}\right)^{c_2} \Gamma(-1-c_1-c_2-a) {}_2F_1 \left( -c_2, -1-c_1-c_2-a; -c_2-a; \frac{b_2 n_1}{b_1 n_2} \right)}{\Gamma(-c_1)} + \frac{\left(\frac{n_2}{b_2}\right)^{-1-a} \Gamma(1+a) {}_2F_1 \left( -c_1, 1+a; 2+c_2+a; \frac{b_2 n_1}{b_1 n_2} \right)}{\Gamma(-c_2)\Gamma(2+c_2+a)} \right].$$

**Figura 6.2: Identidades das integrais sob o modelo da  $G^0$ . Figura adaptada de (NASCIMENTO; CINTRA; FRERY, 2010).**

# Capítulo 7

## MEDIDAS PARA AVALIAÇÃO DOS FILTROS

---

---

*Neste capítulo serão descritos os tipos de métodos utilizados para avaliar os filtros. Basicamente eles são divididos em dois grupos: métodos com referência e métodos sem referência.*

O maior problema em avaliar os métodos propostos para filtrar imagens SAR, de acordo com Argenti et al. (2013), é que a refletividade livre de ruído, ou seja a imagem original, que se deseja estimar, é desconhecida. Logo, não é possível fazer uma comparação entre a imagem filtrada e a imagem original. A qualidade de uma imagem SAR filtrada, usualmente, é avaliada em termos do borramento de áreas homogêneas, ou seja, a supressão do “speckle”, e da preservação de detalhes em regiões heterogêneas. Segundo Argenti et al. (2013), a preservação radiométrica do sinal é um requerimento importante, pois um bom filtro do “speckle” não deve introduzir algum viés na refletividade.

Uma abordagem direta e subjetiva para avaliação da qualidade é a inspeção visual das imagens filtradas. Esta técnica permite detectar os principais traços e características visíveis: preservação de bordas, nível de borramento, preservação de pontos alvos, artefatos. Por outro lado, esta inspeção não permite comparações quantitativas entre as performances dos filtros ou ao viés introduzido.

Para contornar as limitações da inspeção visual, vários índices de performance foram propostos na literatura para avaliar a qualidade dos filtros do “speckle” e de outros ruídos. Estes índices podem ser divididos em duas classes: índices com referência e sem referência.

Métodos NR-IQA (“No-reference image quality assessment”) efetuam a avaliação da qualidade da imagem sem referência através de um algoritmo que tem como informação apenas a imagem filtrada para computar a qualidade da filtragem. Eles são baseados unicamente em hipóteses estatísticas específicas do modelo de sinal.

Já os métodos FR (“Full reference”) utilizam a informação da imagem original e da filtrada (MITTAL; MOORTHY; BOVIK, 2012). Eles são aplicados com muita frequência no campo de filtragem. Uma abordagem típica consiste em escolher uma imagem de referência (óptica ou sintética), que representará a refletividade original (“ground-thuth”), e criar uma versão degradada de acordo com um modelo de sinal. Estes índices permitem uma comparação quantitativa e objetiva entre a performance dos filtros. Apesar disto, resultados experimentais simulando imagens SAR nem sempre são suficientes para inferir na performance dos filtros em imagens SAR reais, pois a imagem sintética pode não ser consistente com a formação de imagens SAR reais ou nos processos de aquisição. Além disto, as propriedades estatísticas entre uma imagem SAR real e sintética podem se diferenciar fortemente. A seguir, serão descritos algumas medidas destes dois tipos de índices.

## 7.1 Índices com referências

### ISNR:

O ISNR (“Improvement in Signal-to-Noise Ratio” - melhora de relação sinal-ruído) definido pela equação 7.1 utiliza três imagens para a avaliação: a imagem original (ideal)  $f$ , a imagem ruidosa  $y$  e a filtrada (estimada)  $\hat{f}$ . Seu valor é dado em decibéis, quanto maior o valor obtido, maior será a aproximação da imagem estimada ser a ideal. O ISNR possuirá valor zero quando a imagem estimada for igual à ruidosa. O valor infinito indica uma imagem estimada igual à ideal.

$$ISNR = 10 \log \left( \frac{\sum_{i=1}^n (f_i - y_i)^2}{\sum_{i=1}^n (g_i - \hat{f}_i)^2} \right) \quad (7.1)$$

### PSNR:

O PSNR (“Peak Signal-to-Noise Ratio” - potência máxima na relação sinal-ruído) computa a razão entre a potência máxima possível de um sinal e o erro da sua estimação conforme a equação 7.2, onde  $\hat{f}$  é a imagem estimada e  $f$  a ideal.  $MAX_g$  indica o valor máximo observado na imagem ideal e o  $MSE(\hat{f}, f)$  dá o valor do erro médio quadrático (“mean square error”) através da equação 7.3 onde  $n$  é o número de pixels da imagem. Quanto maior o valor do PSNR, maior a qualidade da imagem estimada.

$$PSNR = 10 \log_{10} \left[ \frac{MAX_f^2}{MSE(\hat{f}, f)} \right] \quad (7.2)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{f}_i - f_i)^2 \quad (7.3)$$

**IDIV:**

A divergência de Csiszar (CSISZAR, 1991) utiliza a imagem ideal  $f$  e a filtrada  $\hat{f}$ . Quanto menor o valor obtido, mais próximas são as imagens. Quando elas são idênticas o valor do IDIV é zero. ele é calculado pela equação 7.4

$$IDIV = \sum_{i=1}^n \left[ \hat{f}_i \ln \left( \frac{\hat{f}_i}{f_i} \right) - (\hat{f}_i - f_i) \right] \quad (7.4)$$

**SSIM:**

O critério SSIM (“Structural Similarity Index” - índice de semelhança estrutural) de Wang et al. (2004) mede a semelhança entre a imagem ideal  $f$  e a filtrada  $\hat{f}$  a partir de três elementos:

- a similaridade da luminância  $l(\hat{f}, f)$
- a semelhança do contraste  $c(\hat{f}, f)$
- a semelhança das estruturas  $s(\hat{f}, f)$

Juntos eles formam o SSIM representado pela equação 7.5, onde  $\mu_{\hat{f}}$  e  $\sigma_{\hat{f}}$  são, respectivamente, a média e o desvio padrão de  $\hat{f}$ .  $\mu_f$  e  $\sigma_f$  são, respectivamente, a média e o desvio padrão de  $f$ .  $\sigma_{\hat{f}}\sigma_f$  indica a correlação entre  $\hat{f}$  e  $f$ . Os parâmetros  $C_1, C_2$  e  $C_3$  são constantes positivas que estabilizam cada termo. Este índice tem seu valor entre -1 e 1, o valor máximo 1 indica que as duas imagens são iguais.

$$SSIM = l(\hat{f}, f)c(\hat{f}, f)s(\hat{f}, f) = \left( \frac{2\mu_{\hat{f}}\mu_f + C_1}{\mu_{\hat{f}}^2 + \mu_f^2 + C_1} \right) \left( \frac{2\sigma_{\hat{f}}\sigma_f + C_2}{\sigma_{\hat{f}}^2 + \sigma_f^2 + C_2} \right) \left( \frac{2\sigma_{\hat{f}f} + C_3}{\sigma_{\hat{f}}\sigma_f + C_3} \right) \quad (7.5)$$

## 7.2 Índices sem referências

**ENL - "Equivalent Number of Looks":**

De acordo com (ARGENTI et al., 2013), nas imagens SAR, esta medida é adequada para avaliar o nível de suavização em áreas homogêneas. Quanto maior o ENL, maior a capacidade

de suavização do filtro. Ele é encontrado através da equação 7.6, na qual  $\mu$  e  $\sigma^2$  representam, respectivamente, a média e a variância da imagem.

$$ENL = \frac{\mu^2}{\sigma^2} \quad (7.6)$$

### **Razão $r$ da imagem:**

Esta medida é definida como a razão ponto a ponto entre a imagem ruidosa  $y(t)$  e filtrada  $\hat{f}(t)$  no pixel com a coordenada espacial  $t(x,y)$  através da equação 7.7 (ARGENTI et al., 2013). Ela é útil para regiões homogêneas e heterogêneas pois representa o padrão do ruído removido pelo filtro SAR que, segundo (ARGENTI et al., 2013), deve possuir uma distribuição Gama. Um filtro ideal deve resultar em um padrão do ruído aleatório puro, enquanto que um filtro mediano resulta em uma imagem com bordas e estruturas visíveis.

$$r(t) = \frac{y(t)}{\hat{f}(t)} \quad (7.7)$$

### **Índice B:**

Segundo (ARGENTI et al., 2013), este índice dado pela equação 7.8 é uma medida do viés adicionado na imagem filtrada  $\hat{f}$ .  $y$  representa a imagem ruidosa. Um valor próximo de zero indica uma estimativa sem viés.

$$B = E \left[ \frac{(\hat{f} - y)}{y} \right] \quad (7.8)$$

### **Índice $C_{\hat{f}}$ :**

Sob a hipótese da presença do “speckle”, Argenti et al. (2013) diz que uma medida de preservação da textura em regiões heterogêneas é dada pela comparação entre o coeficiente de variação calculado na imagem filtrada, nomeado de  $C_{\hat{f}}$ , e o valor teórico esperado de uma imagem ideal  $C_f$ . As equações 7.9 e 7.10 mostram os cálculos para os valores.  $C_Z$  e  $C_Y$  representam, respectivamente, os coeficientes de variação da imagem ruidosa observada  $Z$  e do ruído speckle  $Y$ . As equações 7.11 e 7.12 são utilizadas para calcular  $C_Z$  e  $C_Y$ . Em uma imagem SAR real, não é possível obter a média e o desvio padrão do “speckle”, por isso, nos experimentos da Seção 8.5, foi utilizado o cálculo teórico de  $C_Y = 1/\sqrt{L}$ , onde  $L$  indica o número de “looks”. Uma preservação fraca dos detalhes da imagem filtrada ocasiona  $C_f > C_{\hat{f}}$ , enquanto que a introdução de danos nas estruturas acarreta em  $C_f < C_{\hat{f}}$ .

$$C_{\hat{f}} = \frac{\sqrt{\text{Var}[\hat{f}]}}{E[\hat{f}]} \quad (7.9)$$

$$C_f = \sqrt{\frac{C_Z^2 - C_Y^2}{1 + C_Y^2}} \quad (7.10)$$

$$C_Z = \frac{\sqrt{\text{Var}[Z]}}{E[Z]} \quad (7.11)$$

$$C_Y = \frac{\sqrt{\text{Var}[Y]}}{E[Y]} \quad (7.12)$$

# Capítulo 8

## PROPOSTA E RESULTADOS

---

---

*Neste capítulo serão detalhadas as propostas de avaliação da filtragem NLM com as distâncias estocásticas. Foram feitos dois tipos de estimativas: estimativa pelo método da  $G_i^0$  e pelo método da inversa da distribuição Gama. Além disto, foram realizadas análises em imagens simuladas e na imagem SAR real.*

Dentre as distribuições propostas para o ruído multiplicativo na seção 3.1, este projeto tem o intuito de trabalhar com a distribuição  $G_i^0$ . No trabalho de Nascimento, Cintra e Frery (2010) foram computadas oito distâncias estocásticas baseadas na  $G_i^0$ . O objetivo é analisar a inclusão destas distâncias à filtragem “NL-means” para imagens SAR em intensidade ao considerar a substituição da distância euclidiana (já discutida na seção 5.4) com a transformação homomórfica na seção 5.6.1.

Utiliza-se como base a proposta de Deledalle, Denis e Tupin (2009), que define um “patch” probabilístico através da distribuição Rayleigh, aplicando-o à filtragem “NL-means” de imagens SAR em amplitude. Além disto, Torres, Cavalcante e Frery (2012) trabalharam com as distâncias estocásticas utilizando o filtro Nagao-Matsuyama para filtrar imagens SAR e, mais recentemente, em (TORRES et al., 2014) as distâncias estocásticas foram utilizadas na filtragem NLM para trabalhar com imagens SAR polarimétricas.

Para comparar o método proposto foram utilizados os seguintes filtros da seção 5.7, os quais possuem as implementações disponíveis: BM3D (DABOV et al., 2007), FANS (COZZOLINO et al., 2013), FNLM (DARBON et al., 2008), Frost (FROST et al., 1982), Lee (LEE, 1980), NLM (BUADES; COLL; MOREL, 2005), NLM-SAP (DELEDALLE; DUVAL; SALMON, 2012), OBNLM (COUPE et al., 2009), PNLN (WU et al., 2013), PPB (DELEDALLE; DENIS; TUPIN, 2009), SAIST (DONG; SHI; LI, 2013), SAR-BM3D (PARRILLI et al., 2012). E foram analisados dois tipos de testes: testes sintéticos simulando dez realizações do ruído “speckle” de cada variação do número de “looks”

e testes em uma imagem SAR real com o número de “looks”  $L = 4$ . O filtro PPB possui quatro tipos de execuções: método iterativo e não iterativo para o ruído gaussiano e também para o ruído multiplicativo.

## 8.1 Estimação pela inversa da Gama

Além de utilizar as distâncias estocásticas com os parâmetros estimados pela  $G_I^0$ , como mencionado no capítulo 1, o trabalho de Cheng et al. (2013) forneceu a motivação para elaborar a seguinte proposta:

Considerando o retorno do sinal sendo  $Z = X.Y$ , onde  $X$  representa o retroespalhamento e  $Y$  o “speckle”, é realizada uma pré-filtragem com o filtro NLM utilizando a transformação homomórfica, e assim obtém-se uma estimação a priori de  $X$ . Depois disto, os parâmetros de rugosidade e escala, respectivamente,  $\alpha$  e  $\gamma$  são estimados e, finalmente, é feita uma nova filtragem baseada no modelo do NLM substituindo a distância euclidiana pelas distâncias estocásticas com os parâmetros  $\alpha$ ,  $\gamma$  e  $L$ . Este último é considerado conhecido.

A vantagem desta estimação sobre a estimação pela  $G_I^0$  foi observada no custo computacional na estimação dos parâmetros e, como ela possui uma fórmula fechada, foi menos problemática do que processar a estimação pela  $G_I^0$  através do método numérico BFGS (FLETCHER, 2000). Além disto, os parâmetros não são embutidos em uma função digama como ocorre na estimação pela  $G_I^0$ .

Para estimar os parâmetros  $\alpha$  e  $\gamma$ , considerando que a imagem após a pré-filtragem possui uma distribuição da inversa da Gama de acordo com Witkovsky (2001) e que a média e a variância, representadas, respectivamente, por  $\mu$  e  $\sigma^2$ , desta distribuição são expressas por:

$$\mu = \frac{\gamma}{\alpha - 1} \quad \text{para } \alpha > 1 \quad (8.1)$$

$$\sigma^2 = \frac{\gamma^2}{(\alpha - 1)^2(\alpha - 2)} \quad \text{para } \alpha > 2, \quad (8.2)$$

é possível encontrar as seguintes equações através do Método do Momentos:

$$\alpha = 2 + \frac{\mu^2}{\sigma^2}, \quad (8.3)$$

$$\gamma = \mu \left( 1 + \frac{\mu^2}{\sigma^2} \right) \quad (8.4)$$

que satisfazem as equações 8.1 e 8.2. Considerando  $\mu$  e  $\sigma^2$  locais, basta substituí-los nas equações 8.3 e 8.4.

## 8.2 Implementação

Para estimar os parâmetros da  $G_\gamma^0$ , foi utilizada a plataforma R disponível em (R Core Team, 2013) e implementou-se um “script” através dos códigos das distâncias estocásticas disponíveis na linguagem Ox em (NASCIMENTO, 2008). Nascimento, Cintra e Frery (2010) estimaram os parâmetros  $\alpha$  e  $\gamma$  através da máxima verossimilhança utilizando o método BFGS (FLETCHER, 2000) disponível no pacote “maxLik” de Henningsen e Toomet (2011) desenvolvido para o R. Este trabalho de dissertação também seguiu esta proposta.

Já os parâmetros  $\alpha$  e  $\gamma$ , encontrados pelo Método dos Momentos na inversa da Gama na seção anterior, foram computados no Matlab. Os valores foram salvos em arquivos “.mat” para serem lidos no R pelo pacote “R.matlab”.

Por último, a filtragem do NLM com as distâncias estocásticas também foi implementada na linguagem R.

## 8.3 Configuração dos parâmetros do NLM

Em qualquer um dos filtros elaborados com a abordagem do NLM, existem três parâmetros básicos:

1. Tamanho da área de busca;
2. Tamanho dos “patches”;
3. Parâmetro de suavização  $h$ ;

Neste trabalho, para todos os filtros os tamanhos das áreas de busca e dos “patches” foram mantidos os mesmos: 11x11 e 5x5 pixels, respectivamente. Estes valores foram mantidos pois não era detectada alguma mudança drástica no desempenho das propostas. Já o parâmetro  $h$  é um parâmetro “problemático”, pois não existe uma fórmula até então conhecida e divulgada que ajude a computar um valor ideal. Em quase todos os artigos citados, este parâmetro foi configurado

empiricamente. Nesta proposta, foi adotado experimentalmente um valor  $h = 0.,000047\sigma^2$ , onde  $\sigma^2$  é a variância da imagem sintética ruidosa independente do número de “looks”  $L$ , e  $h = 1,32\sigma^2$  para a imagem SAR real.

Os parâmetros adicionais existentes nos demais filtros, os quais foram utilizados para a análise e comparação dos resultados, foram configurados com os valores padrões descritos pelos respectivos artigos.

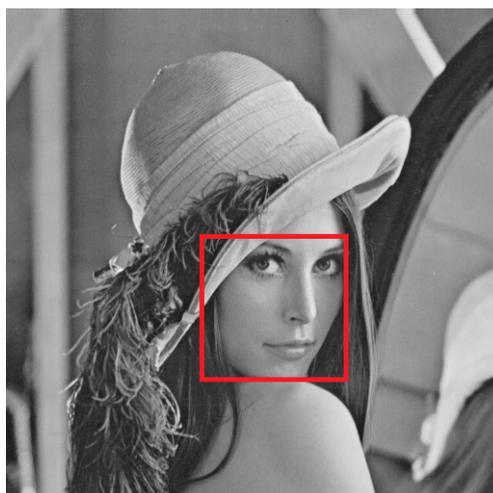
## 8.4 Análise em imagens sintéticas

Para avaliar a nossa proposta em imagens sintéticas, utilizou-se uma região com o tamanho 150x150 pixels extraída da Lena em escala de cinza. A imagem da Lena é ilustrada na Figura 8.1, o quadrado indica a região escolhida. O “speckle” com detecção quadrática foi incluído na imagem com os números de “looks”  $L = 1$ ,  $L = 3$  e  $L = 8$ . A Figura 8.2 ilustra as imagens contaminadas. Da Figura 8.3 até a Figura 8.11 são ilustrados os resultados das filtragens obtidas para as variações dos três “looks” do ruído “speckle” sintético. Para um resultado mais conciso, foram feitas dez realizações do “speckle” na imagem original. Logo, obtiveram-se dez estimações de cada variação do ruído e de cada método proposto e aplicou-se uma média no PSNR e no SSIM das imagens filtradas. Os valores encontram-se nas tabelas 8.1 até 8.9.

É possível perceber que, quanto mais agressivo o ruído, mais difícil torna-se a remoção do “speckle”. Quando  $L = 1$  e  $L = 3$ , as filtragens do NLM com as distâncias estocásticas pelos dois meios de estimções dos parâmetros tornam-se competitivas com os demais métodos, mesmo que os resultados obtidos pela estimação da inversa da gama apresentem artefatos ao redor das bordas das imagens.

Além disto, é importante notar que muitos dos filtros escolhidos para comparação suavizam excessivamente as imagens filtradas, como por exemplo o PPB (Gaussiano Iterativo) em que, para  $L = 8$ , quase não é possível identificar a boca da Lena. O BM3D conseguiu filtrar a imagem com o ruído fraco ( $L = 8$ ), como na Figura 8.4, mas conforme o ruído fica mais agressivo seu desempenho diminui.

O SAR-BM3D obteve excelentes performances e o FANS também garante ótimos resultados. É possível confirmar isto analisando as Tabelas 8.1 até 8.9, as quais comparam os valores do PSNR e SSIM de todos os filtros. Para todos os níveis de ruído o SAR-BM3D e o FANS ficam nas primeiras posições. Para  $L = 8$  a filtragem com a distância estocástica com a  $G^0$  e a Inversa da Gama que mais se aproximou do SAR-BM3D e FANS em termos de PSNR foi a Triangular, conforme mostra a Tabela 8.1 e a Tabela 8.2.



**Figura 8.1:** Lena em escala de cinza. O quadrado indica a região de tamanho  $150 \times 150$  pixels escolhida para os testes.

Com os parâmetros estimados pela  $G_i^0$ , houve problemas numéricos para computar a distância de Rényi de Nascimento, Cintra e Frery (2010) para  $L = 3$  e  $L = 8$ . Já para os parâmetros estimados pela Inversa da Gama os problemas numéricos foram encontrados para as três variações dos números de “looks” para as distâncias de Rényi e Bhattacharyya. Estes problemas numéricos ocasionaram em um resultado muito inferior às demais distâncias. Por isso, utilizando a  $G_i^0$ , decidiu-se computar as distâncias Rényi e Bhattacharyya utilizando as equações em Nascimento, Cintra e Frery (2010) que utilizam como base a distância de Hellinger. Então, o valor configurado para o parâmetro  $\beta$  da distância de Rényi foi  $\beta = 0.5$ . Outro valor que afetou a performance das distâncias foi o valor configurado no argumento “subdivisions” do método “integrate” da plataforma R. Quanto menor o valor, mais rápida é a filtragem trabalhando com as distâncias estocásticas nos dois métodos. Neste trabalho, o valor do argumento “subdivisions” foi dez. Quando  $L = 1$ , a distância Triangular e de Kullback-Leibler pela  $G^0$  (ver Tabelas 8.7 e 8.9) são as que mais se aproximam do PSNR do FANS e do SAR-BM3D.

A abordagem descrita no parágrafo acima não ocasionou alguma melhoria para o método com a Inversa da Gama nas distâncias de Rényi e Bhattacharyya. A maneira encontrada para contornar o problema do cálculo destas distâncias foi utilizar o valor padrão no argumento “subdivisions” (“subdivisions” = 100). Porém, isto ocasiona no aumento do custo computacional e estas duas distâncias tornam-se não competitivas.

O desempenho dos filtros com as distâncias estocásticas com as estimativas dos parâmetros, analisando os resultados nas Tabelas 8.1 até 8.9, se aproxima dos métodos dos vários filtros propostos na literatura para  $L = 8$  e  $L = 3$ . Para  $L = 1$ , o desempenho foi superior aos métodos e se aproxima do estado da arte (SAR-BM3D e FANS).

(a)  $L = 1$ (b)  $L = 3$ (c)  $L = 8$ 

Figura 8.2: Variação do número de “looks” na imagem sintética.



Figura 8.3: Resultado da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela  $G^0$ . Imagem contaminada com “speckle” de 8 “looks”. Da direita para esquerda e de cima para baixo: Aritmética Geométrica, Bhattacharyya, Hellinger, Média Harmônica, Jensen-Shannon, Kullback-Leibler, Rényi e Triangular.



**Figura 8.4:** Resultado da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela Inversa da Gama. Imagem contaminada com "speckle" de 8 "looks". Da direita para esquerda e de cima para baixo: Aritmética Geométrica, Bhattacharyya, Hellinger, Média Harmônica, Jensen-Shannon, Kullback-Leibler, Rényi e Triangular.



**Figura 8.5:** Resultado da filtragem com os demais filtros. Imagem contaminada com "speckle" de 8 "looks". Da esquerda para direita e de cima para baixo: BM3D, FANS, FNLM, FROST, LEE, NLM, NLM-SAP, OBNL, PNLN, PPB GAUSS IT, PPB GAUSS NIT, PPB NAKA IT, PPB NAKA NIT, SAIST, SAR-BM3D.



**Figura 8.6:** Resultado da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela  $G^0$ . Imagem contaminada com "speckle" de 3 "looks". Da direita para esquerda e de cima para baixo: Aritmética Geométrica, Bhattacharyya, Hellinger, Média Harmônica, Jensen-Shannon, Kullback-Leibler, Rényi e Triangular.

**Tabela 8.1:** Medidas do PSNR e SSIM da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela  $G^0$ . Imagem contaminada com "speckle" de 8 "looks".  $PSNR = 14,81$  e  $SSIM = 0,19$  baseados na média sobre 10 realizações do "speckle".

<b>Distâncias</b>	<b>PSNR</b>	<b>SSIM</b>
Aritmética Geométrica	24,63	0,63
Bhattacharyya	23,75	0,64
Hellinger	23,86	0,64
Média Harmônica	24,16	0,63
Jensen-Shannon	24,75	0,65
Kullback-Leibler	24,97	0,61
Rényi	22,92	0,59
Triangular	<b>25,06</b>	<b>0,62</b>

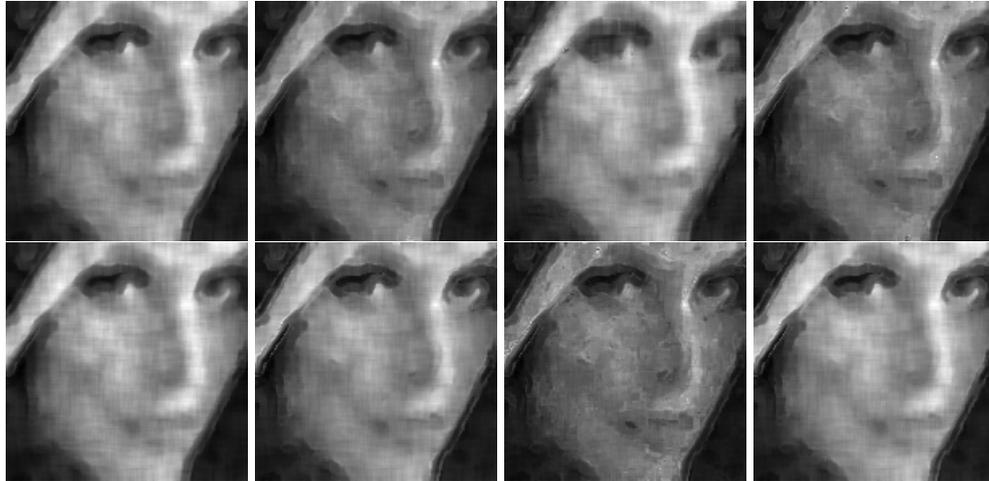
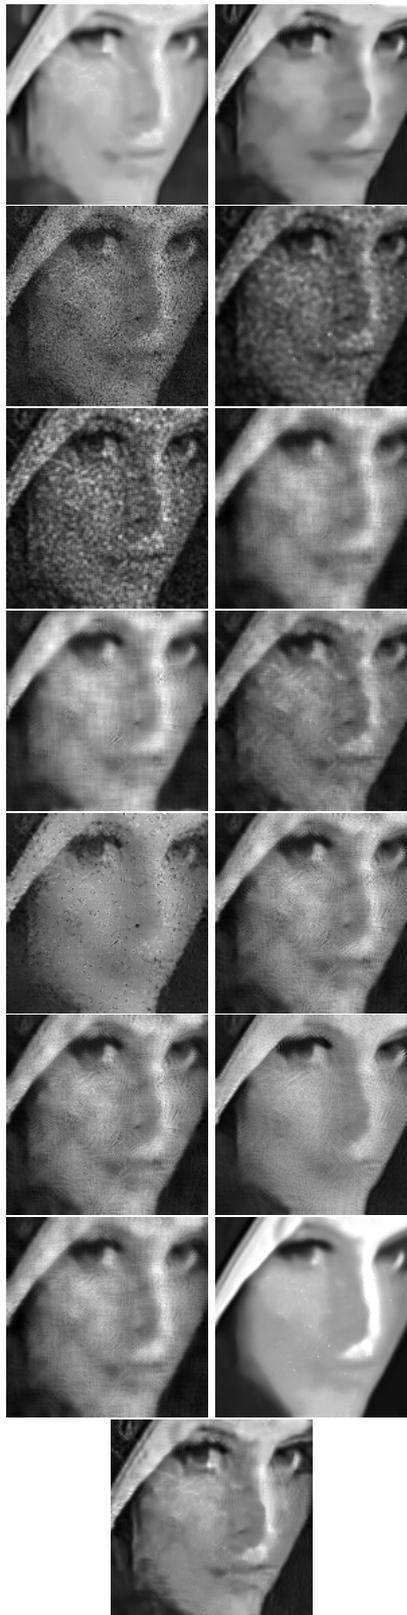


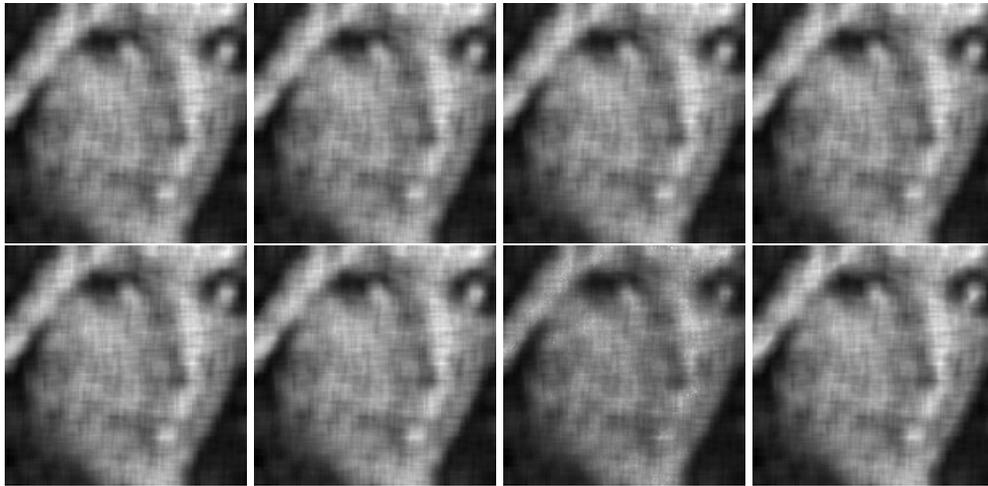
Figura 8.7: Resultado da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela inversa da Gama. Imagem contaminada com "speckle" de 3 "looks". Da direita para esquerda e de cima para baixo: Aritmética Geométrica, Bhattacharyya, Hellinger, Média Harmônica, Jensen-Shannon, Kullback-Leibler, Rényi e Triangular.

Tabela 8.2: Medidas do PSNR e SSIM da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela Inversa da Gama. Imagem contaminada com "speckle" de 8 "looks".  $PSNR = 14,81$  e  $SSIM = 0,19$  baseados na média sobre 10 realizações do "speckle".

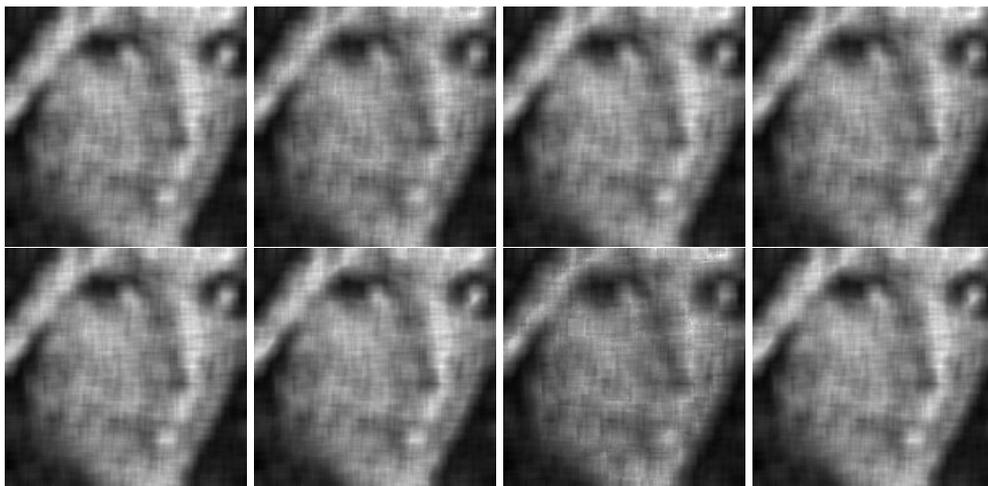
Distâncias	PSNR	SSIM
Aritmética Geométrica	24,67	0,67
Bhattacharyya	20,08	0,35
Hellinger	23,48	0,64
Média Harmônica	22,94	0,48
Jensen-Shannon	24,66	0,67
Kullback-Leibler	24,64	0,67
Rényi	19,56	0,34
Triangular	<b>24,70</b>	<b>0,67</b>



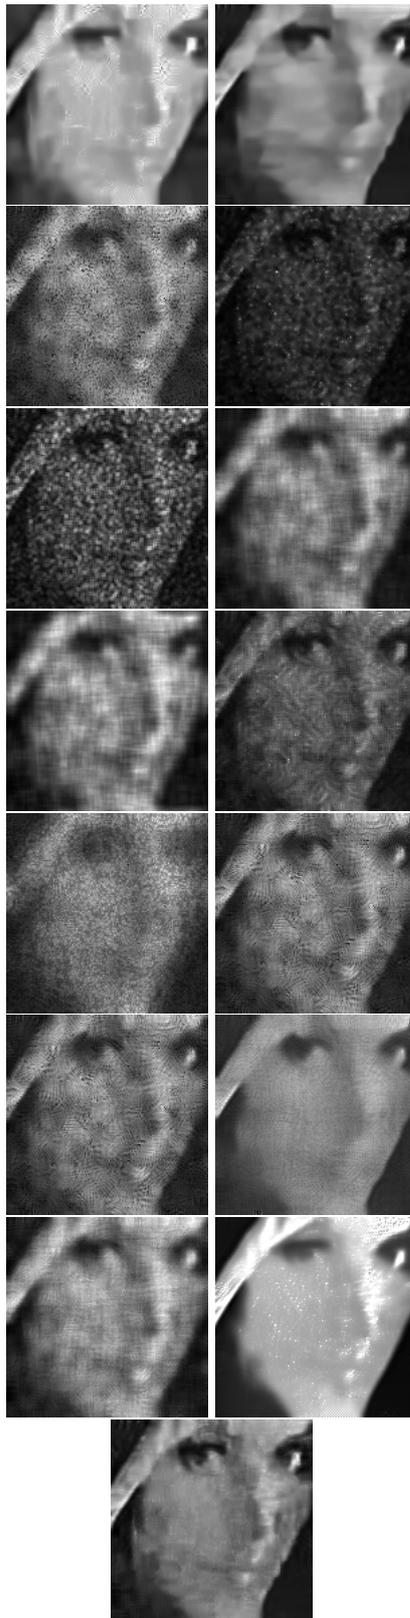
**Figura 8.8:** Resultado da filtragem com os demais filtros. Imagem contaminada com "speckle" de 3 "looks". Da esquerda para direita e de cima para baixo: BM3D, FANS, FNLM, FROST, LEE, NLM, NLM-SAP, OBNL, PNLN, PPB GAUSS IT, PPB GAUSS NIT, PPB NAKA IT, PPB NAKA NIT, SAIST, SAR-BM3D.



**Figura 8.9:** Resultado da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela  $G^0$ . Imagem contaminada com "speckle" de 1 "look". Da direita para esquerda e de cima para baixo: Aritmética Geométrica, Bhattacharyya, Hellinger, Média Harmônica, Jensen-Shannon, Kullback-Leibler, Rényi e Triangular.



**Figura 8.10:** Resultado da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela Inversa da Gama. Imagem contaminada com "speckle" de 1 "look". Da direita para esquerda e de cima para baixo: Aritmética Geométrica, Bhattacharyya, Hellinger, Média Harmônica, Jensen-Shannon, Kullback-Leibler, Rényi e Triangular.



**Figura 8.11: Resultado da filtragem com os demais filtros. Imagem contaminada com "speckle" de 1 "look". Da esquerda para direita e de cima para baixo: BM3D, FANS, FNLM, FROST, LEE, NLM, NLM-SAP, OBNL, PNLM, PPB GAUSS IT, PPB GAUSS NIT, PPB NAKA IT, PPB NAKA NIT, SAIST, SAR-BM3D.**

**Tabela 8.3: Medidas do PSNR e SSIM da filtragem do NLM com os demais filtros. Imagem contaminada com "speckle" de 8 "looks".**  $PSNR = 14,81$  e  $SSIM = 0,19$  baseados na média sobre 10 realizações do "speckle".

Filtros	PSNR	SSIM
BM3D	16,32	0,77
FANS	<b>28,80</b>	<b>0,82</b>
FNLM	22,83	0,43
FROST	26,30	0,68
LEE	23,79	0,50
NLM	26,93	0,71
NLM-SAP	27,24	0,75
OBNL	26,89	0,74
PNLM	25,93	0,65
PPB GAUSS IT	25,98	0,73
PB GAUSS NIT	26,78	0,73
PPB NAKA IT	27,17	0,74
PPB NAKA NIT	26,78	0,73
SAIST	26,30	0,76
SAR-BM3D	<b>28,63</b>	<b>0,80</b>

**Tabela 8.4: Medidas do PSNR e SSIM da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela  $G^0$ . Imagem contaminada com "speckle" de 3 "looks".**  $PSNR = 10,51$  e  $SSIM = 0,10$  baseados na média sobre 10 realizações do "speckle".

Distâncias	PSNR	SSIM
Aritmética Geométrica	23,67	0,61
Bhattacharyya	23,46	0,61
Hellinger	23,50	0,61
Média Harmônica	23,69	0,62
Jensen-Shannon	23,71	0,62
Kullback-Leibler	23,93	0,61
Rényi	23,42	0,61
Triangular	<b>24,03</b>	<b>0,62</b>

**Tabela 8.5: Medidas do PSNR e SSIM da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela Inversa da Gama. Imagem contaminada com "speckle" de 3 "looks".**  $PSNR = 10,51$  e  $SSIM = 0,10$  baseados na média sobre 10 realizações do "speckle".

Distâncias	PSNR	SSIM
Aritmética Geométrica	23,29	0,61
Bhattacharyya	23,35	0,58
Hellinger	22,38	0,57
Média Harmônica	23,21	0,56
Jensen-Shannon	23,61	0,61
Kullback-Leibler	23,60	0,61
Rényi	22,87	0,61
Triangular	<b>23,65</b>	<b>0,61</b>

**Tabela 8.6: Medidas do PSNR e SSIM da filtragem do NLM com os demais filtros. Imagem contaminada com "speckle" de 3 "looks".**  $PSNR = 10,51$  e  $SSIM = 0,10$  baseados na média sobre 10 realizações do "speckle".

Filtros	PSNR	SSIM
BM3D	17,52	0,72
FANS	<b>26,10</b>	<b>0,75</b>
FNLM	18,91	0,27
FROST	23,12	0,46
LEE	19,87	0,34
NLM	24,16	0,61
NLM-SAP	24,29	0,63
OBNL	24,75	0,60
PNLM	23,10	0,49
PPB GAUSS IT	24,29	0,63
PB GAUSS NIT	24,26	0,55
PPB NAKA IT	24,66	0,61
PPB NAKA NIT	24,26	0,55
SAIST	24,52	0,71
SAR-BM3D	<b>26,03</b>	<b>0,71</b>

**Tabela 8.7: Medidas do PSNR e SSIM da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela  $G^0$ . Imagem contaminada com "speckle" de 1 "look".**  $PSNR = 5,78$  e  $SSIM = 0,04$  baseados na média sobre 10 realizações do "speckle".

Distâncias	PSNR	SSIM
Aritmética Geométrica	22,19	0,52
Bhattacharyya	22,20	0,52
Hellinger	22,20	0,52
Média Harmônica	22,23	0,52
Jensen-Shannon	22,18	0,52
Kullback-Leibler	<b>22,28</b>	<b>0,52</b>
Rényi	21,78	0,51
Triangular	<b>22,28</b>	<b>0,52</b>

**Tabela 8.8: Medidas do PSNR e SSIM da filtragem do NLM com as distâncias estocásticas com os parâmetros estimados pela Inversa da Gama. Imagem contaminada com "speckle" de 1 "look".**  $PSNR = 5,78$  e  $SSIM = 0,04$  baseados na média sobre 10 realizações do "speckle".

Distâncias	PSNR	SSIM
Aritmética Geométrica	22,17	0,52
Bhattacharyya	21,92	0,50
Hellinger	22,08	0,51
Média Harmônica	21,95	0,50
Jensen-Shannon	22,16	0,52
Kullback-Leibler	<b>22,18</b>	<b>0,52</b>
Rényi	21,39	0,46
Triangular	<b>22,18</b>	<b>0,52</b>

**Tabela 8.9:** Medidas do PSNR e SSIM da filtragem do NLM com os demais filtros. Imagem contaminada com "speckle" de 1 "look".  $PSNR = 5,78$  e  $SSIM = 0,04$  baseados na média sobre 10 realizações do "speckle".

<b>Filtros</b>	<b>PSNR</b>	<b>SSIM</b>
BM3D	17,86	0,58
FANS	<b>22,83</b>	<b>0,65</b>
FNLM	17,18	0,21
FROST	16,76	0,25
LEE	15,26	0,20
NLM	20,97	0,44
NLM-SAP	20,71	0,45
OBNL	20,67	0,38
PNLM	17,75	0,16
PPB GAUSS IT	21,11	0,38
PB GAUSS NIT	18,76	0,27
PPB NAKA IT	22,16	0,47
PPB NAKA NIT	18,76	0,27
SAIST	18,45	0,55
SAR-BM3D	<b>23,02</b>	<b>0,60</b>

## 8.5 Análise em imagem SAR real

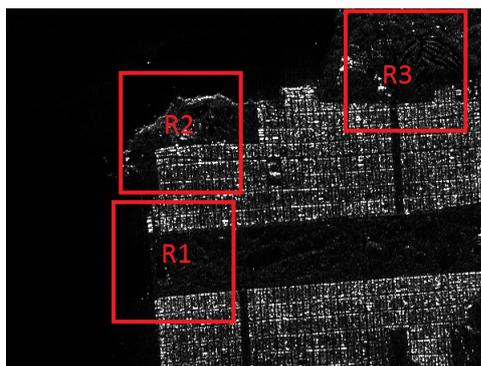
As imagens SAR em intensidade escolhidas para avaliar nossa proposta foram as imagens de São Francisco em três polarizações com  $L = 4$ . Decidiu-se trabalhar com três tipos de polarizações da antena: horizontal-horizontal (HH), horizontal-vertical (HV) e vertical-vertical (VV). O objetivo disto é identificar se existe alguma polarização que forneça um melhor resultado da suavização do “speckle” utilizando os filtros propostos e os demais filtros. As três imagens possuem dimensão 450x600 pixels, mas foram escolhidas três regiões iguais de dimensão 150x150 pixels, por razões de custo computacional, de cada imagem para analisar os filtros conforme mostram as Figuras 8.12, 8.13 e 8.14. A figura com a polarização HH indica as regiões escolhidas e as figuras com as polarizações HV e VV foram transladadas e comprimidas para serem melhor visualizadas. Nesta seção não foi possível comparar os resultados dos filtros BM3D e SAIST, pois estes filtros possuem como parâmetro a imagem original livre do ruído, logo, por ser uma imagem SAR real, esta imagem não está acessível. A Figura 8.15 mostra as regiões selecionadas.

Para a imagem HH nas três regiões, a estimação pela Inversa da Gama mostrou-se competitiva com a estimação pela  $G^0$ . Já na imagem HV, observando as regiões nota-se uma dificuldade nos dois métodos para diferenciar uma região heterogênea (casas) de uma homogênea (floresta). As regiões 1 e 2 nas três polarizações ficam com um forte aspecto de “cartoon” pela estimação da inversa da Gama, e na polarização VV as regiões dois e três ficaram bastante borradas. A região três na polarização HH foi a que obteve melhor resultado. Os resultados descritos das filtragens com os métodos propostos podem ser visualizados nas Figuras 8.16 a 8.18

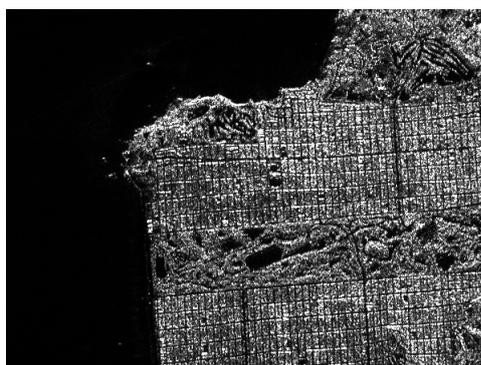
Nas Figuras 8.19 até a 8.22 nota-se a eficiência dos filtros SAR-BM3D, FANS e OBNL. Da Figura 8.23 até a Figura 8.31 são ilustrados os valores da razão  $r$  de todos os filtros. O SAR-BM3D e o FANS são os filtros que possuem menos presença de estruturas e bordas nesta razão. Já o NLM com os parâmetros estimados pela inversa da Gama possui mais resíduos do que o NLM com os parâmetros pela  $G_I^0$ .

Houve a idéia de calcular o valor  $ENL$  dos filtros, mas, conforme é mostrado nas Tabelas A.1 até a A.27 do Apêndice A, este valor não é de grande eficácia, pois seu cálculo favorece imagens que foram super suavizadas ocasionando um resultado superior ao SAR-BM3D e até mesmo ao FANS. Então, foi utilizado a razão  $r$ , discutida da seção 7.2, a qual é uma razão entre a imagem ruidosa e a filtrada e o resultado que apresentar menos estruturas significa que teve uma boa performance.

As Tabelas A.28 até A.54 do Apêndice A mostram os valores dos índices B de todas as



**Figura 8.12:** Imagem SAR em Intensidade com polarização HH e  $L = 4$ , com 3 regiões realçadas.



**Figura 8.13:** Imagem SAR em Intensidade com polarização HV e  $L = 4$ .

imagens reais com os métodos propostos e com os demais métodos. Analisando-as é possível perceber que o método com a Inversa da Gama introduz um viés maior que o método com a  $G_f^0$ . Além disto, pode-se identificar novamente o bom desempenho do SAR-BM3D e do FANS. Todos os filtros resultaram em imagens com algum viés. Os métodos propostos superaram alguns métodos da literatura na polarização HV. Porém, o viés foi maior para as polarizações HH e VV.

A seção A.3 contém as tabelas com os valores do índice  $C_{\hat{f}}$  dos métodos propostos e dos demais filtros. Pelas Tabelas A.55 até A.81 pode-se identificar que os filtros SAR-BM3D e o FANS resultaram em um  $C_{\hat{f}} > C_f$ , o que significa que estes dois métodos realizaram uma boa filtragem, mas adicionaram alguns danos e artefatos na imagem filtrada. Além disto, também pode-se perceber que a maioria dos filtros ocasionaram em um  $C_{\hat{f}} < C_f$ , ou seja, foram feitas filtragens abaixo das ideais. Por fim, as tabelas também indicam que existem situações nos quais os métodos propostos conseguem se aproximar do índice  $C_f$  e que eles são superiores a alguns filtros já propostos.



Figura 8.14: Imagem SAR em Intensidade com polarização VV e  $L = 4$ .

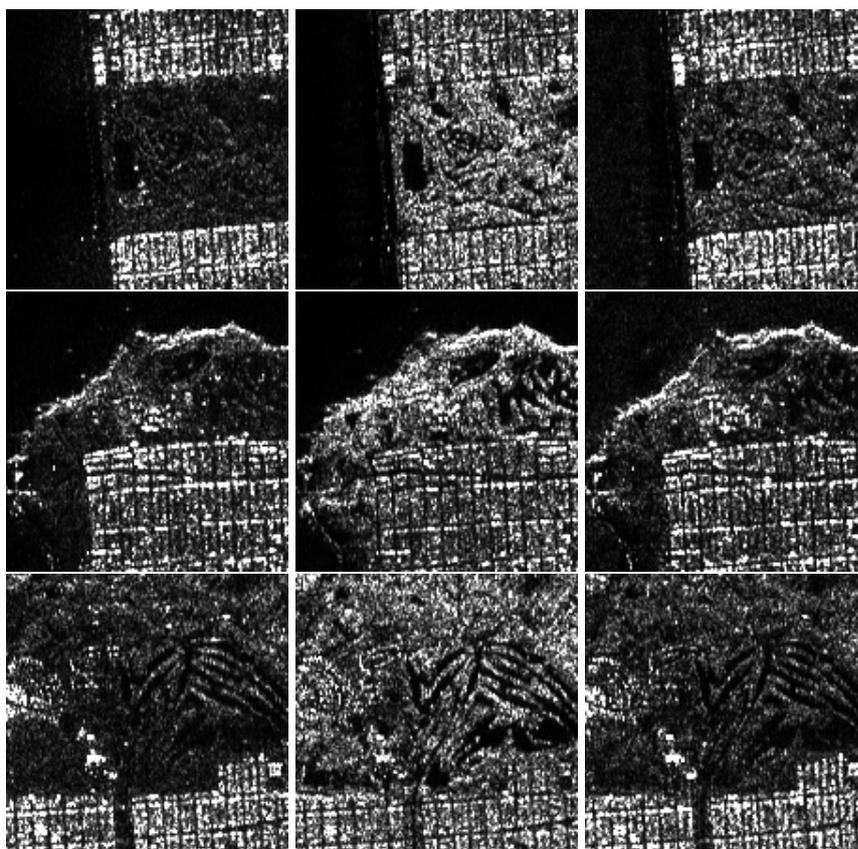


Figura 8.15: Regiões ruidosas. Da esquerda para a direita: polarização HH, HV, VV. De cima para baixo: R1, R2, R3.

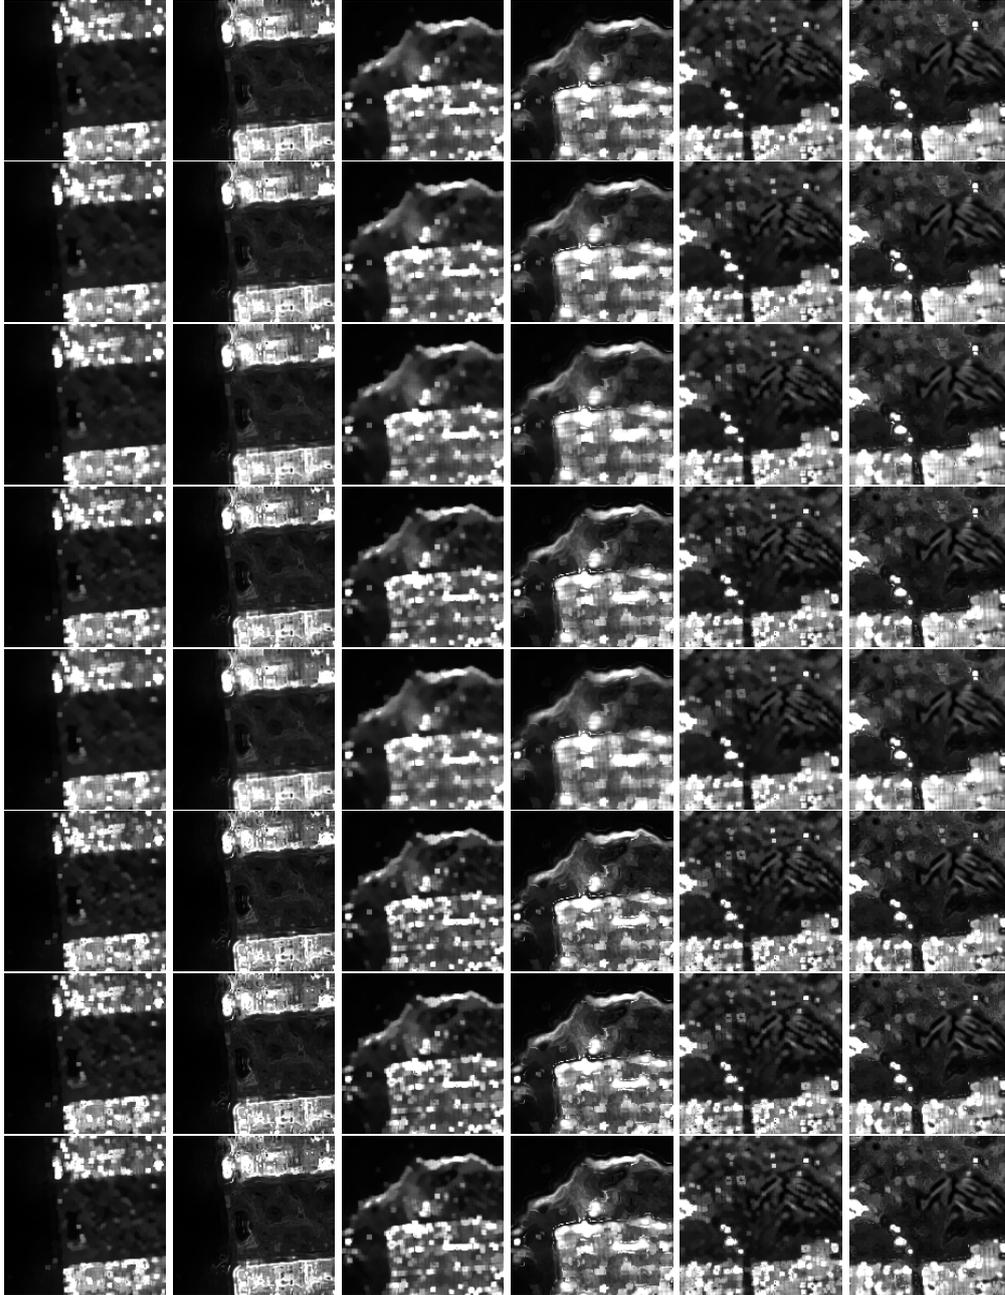


Figura 8.16: Comparação das filtragens do filtro NLM com as distâncias estocásticas nas regiões HH com as estimações pela  $G^0$  e Inversa da Gama. De cima para baixo são as distâncias Aritmética Geométrica, Bhattacharyya, Hellinger, Média Harmônica, Jensen-Shannon, Kullback-Leibler, Rényi e Triangular. As colunas ímpares são estimações pela  $G^0$  e as colunas pares pela inversa da Gama.

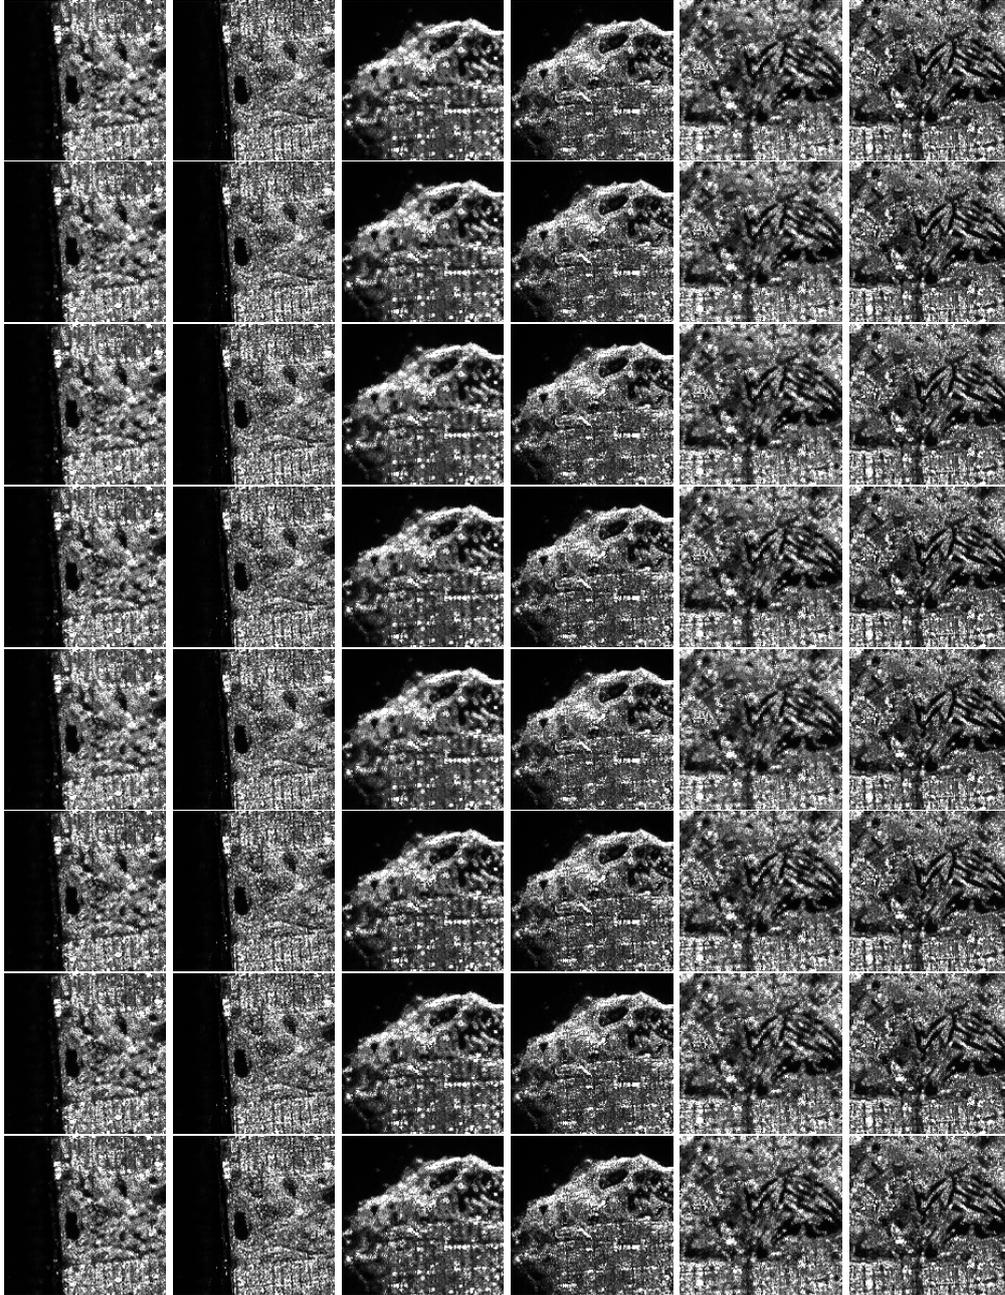


Figura 8.17: Comparação das filtragens do filtro NLM com as distâncias estocásticas nas regiões HV com as estimações pela  $G^0$  e Inversa da Gama. De cima para baixo são as distâncias Aritmética Geométrica, Bhattacharyya, Hellinger, Média Harmônica, Jensen-Shannon, Kullback-Leibler, Rényi e Triangular. As colunas ímpares são estimações pela  $G^0$  e as colunas pares pela inversa da Gama.

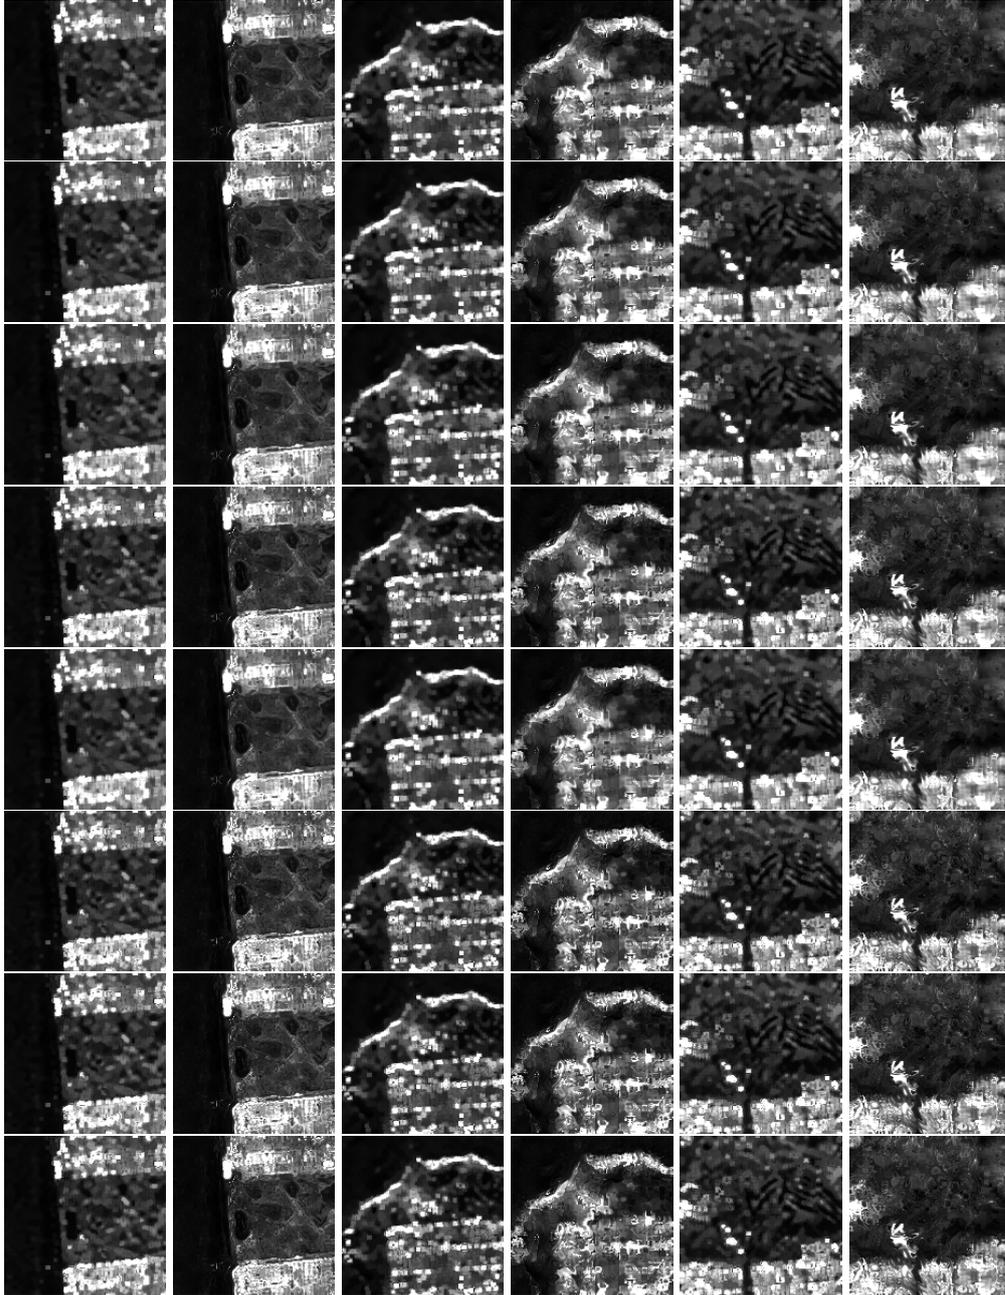
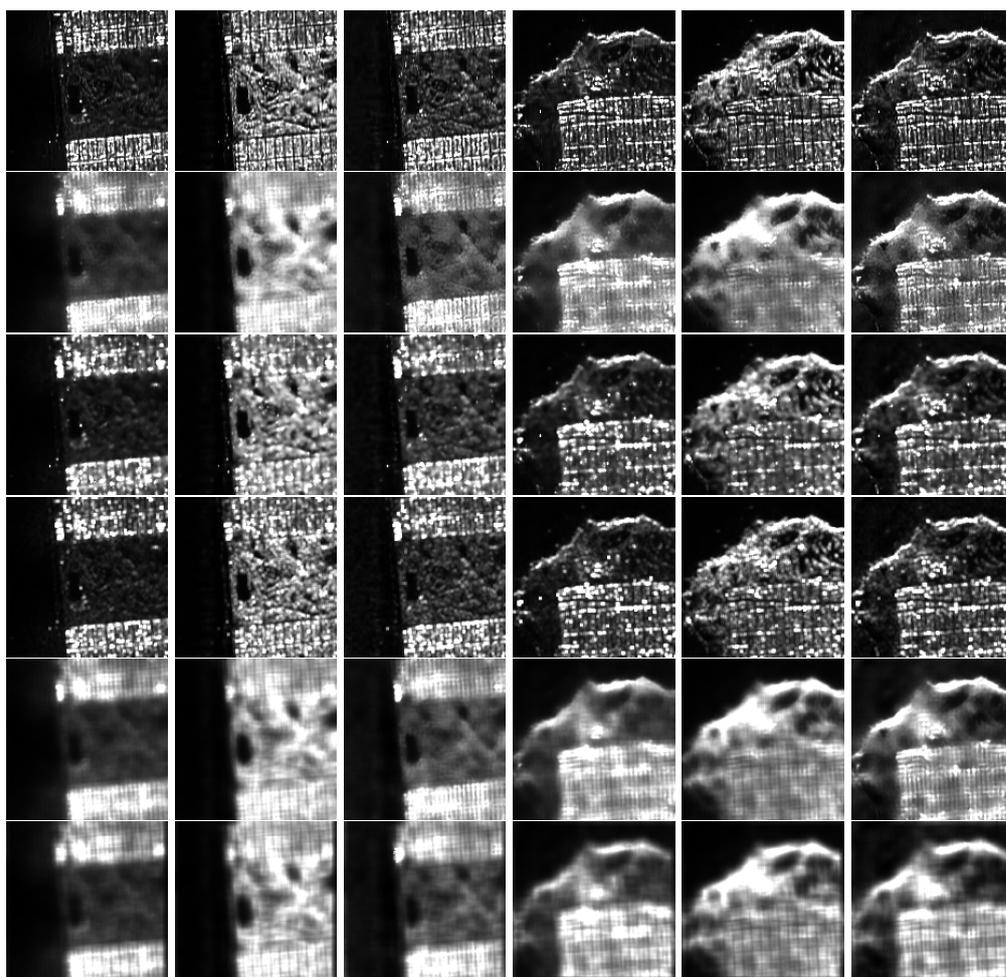
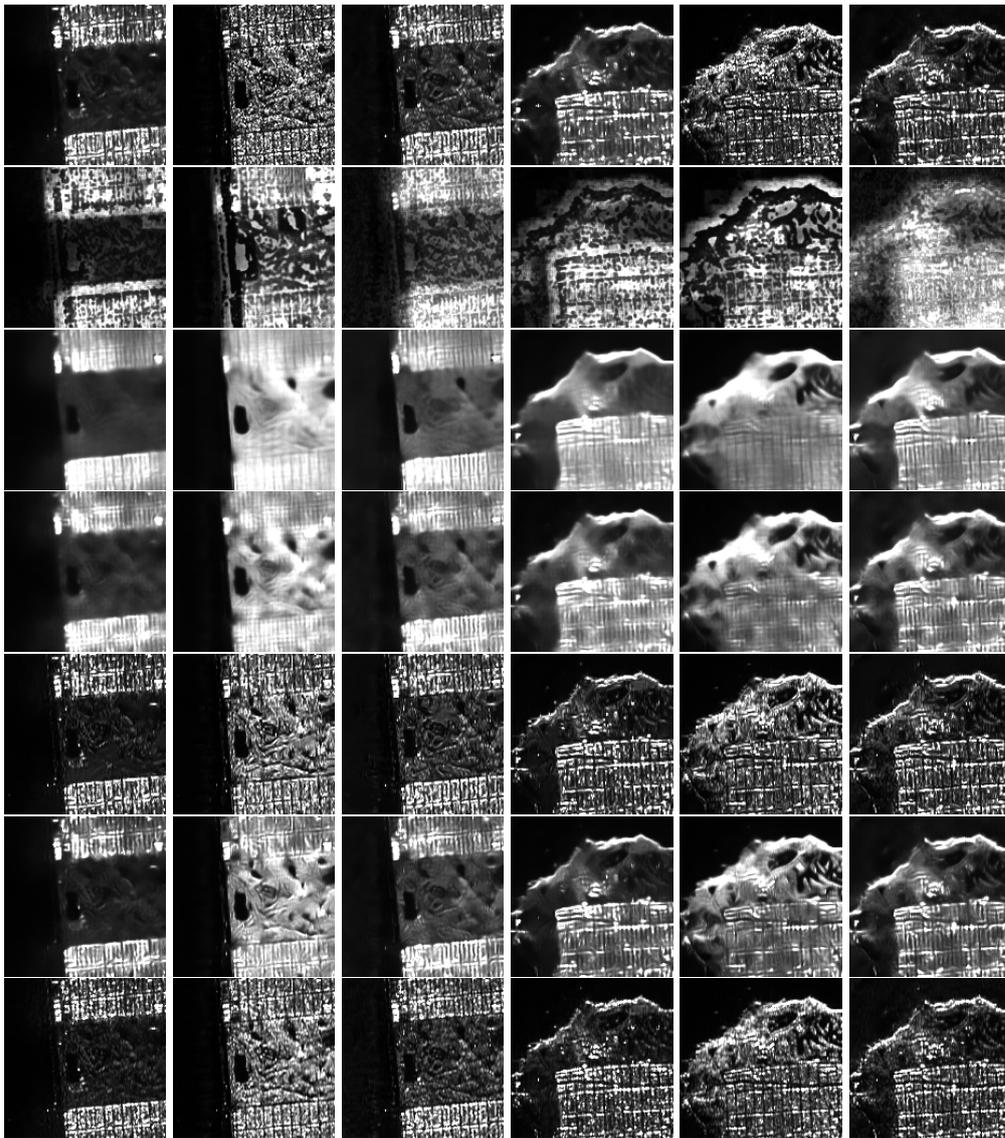


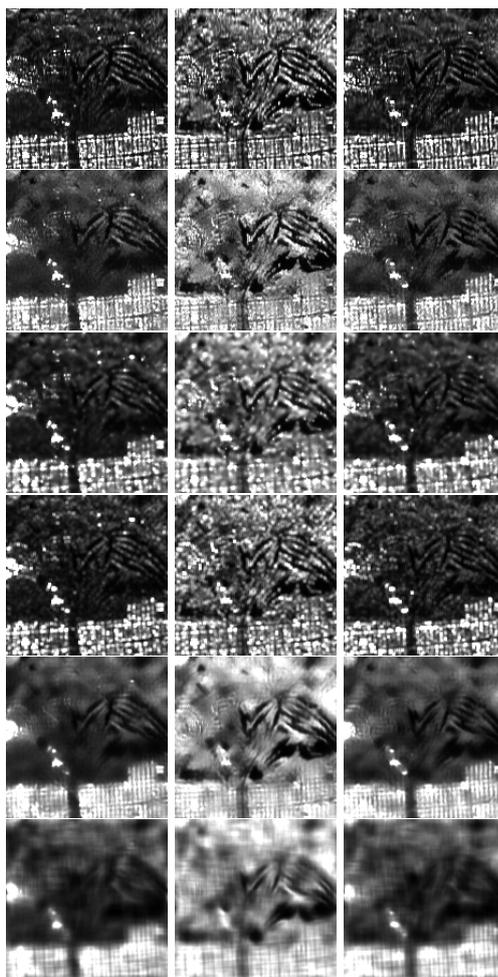
Figura 8.18: Comparação das filtragens do filtro NLM com as distâncias estocásticas nas regiões VV com as estimações pela  $G^0$  e Inversa da Gama. De cima para baixo são as distâncias Aritmética Geométrica, Bhattacharyya, Hellinger, Média Harmônica, Jensen-Shannon, Kullback-Leibler, Rényi e Triangular. As colunas ímpares são estimações pela  $G^0$  e as colunas pares pela inversa da Gama.



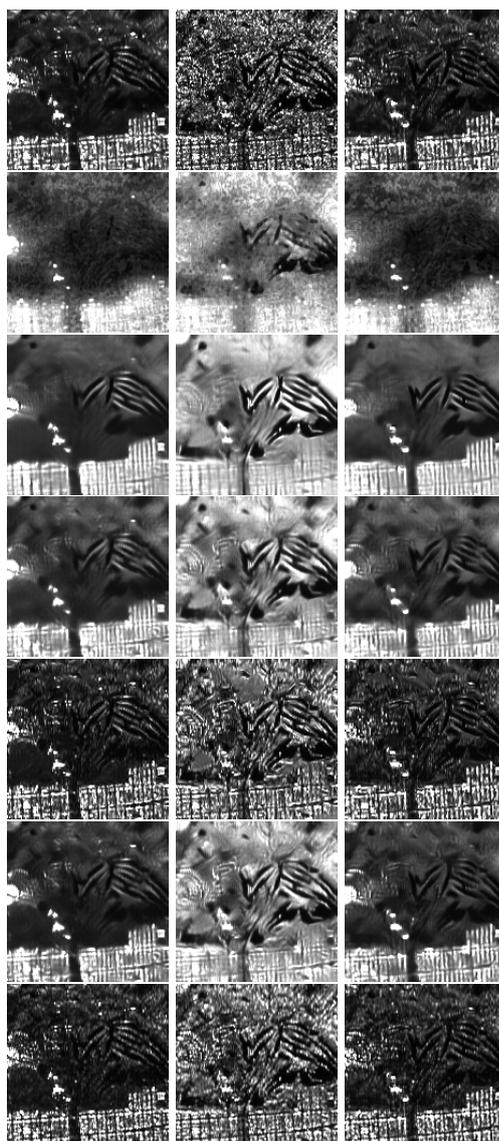
**Figura 8.19:** Comparação das filtragens com os demais filtros nas regiões 1 e 2. De cima para baixo: FANS, FNLM, FROST, LEE, NLM, NLM-SAP. As regiões alternam-se de três em três colunas.



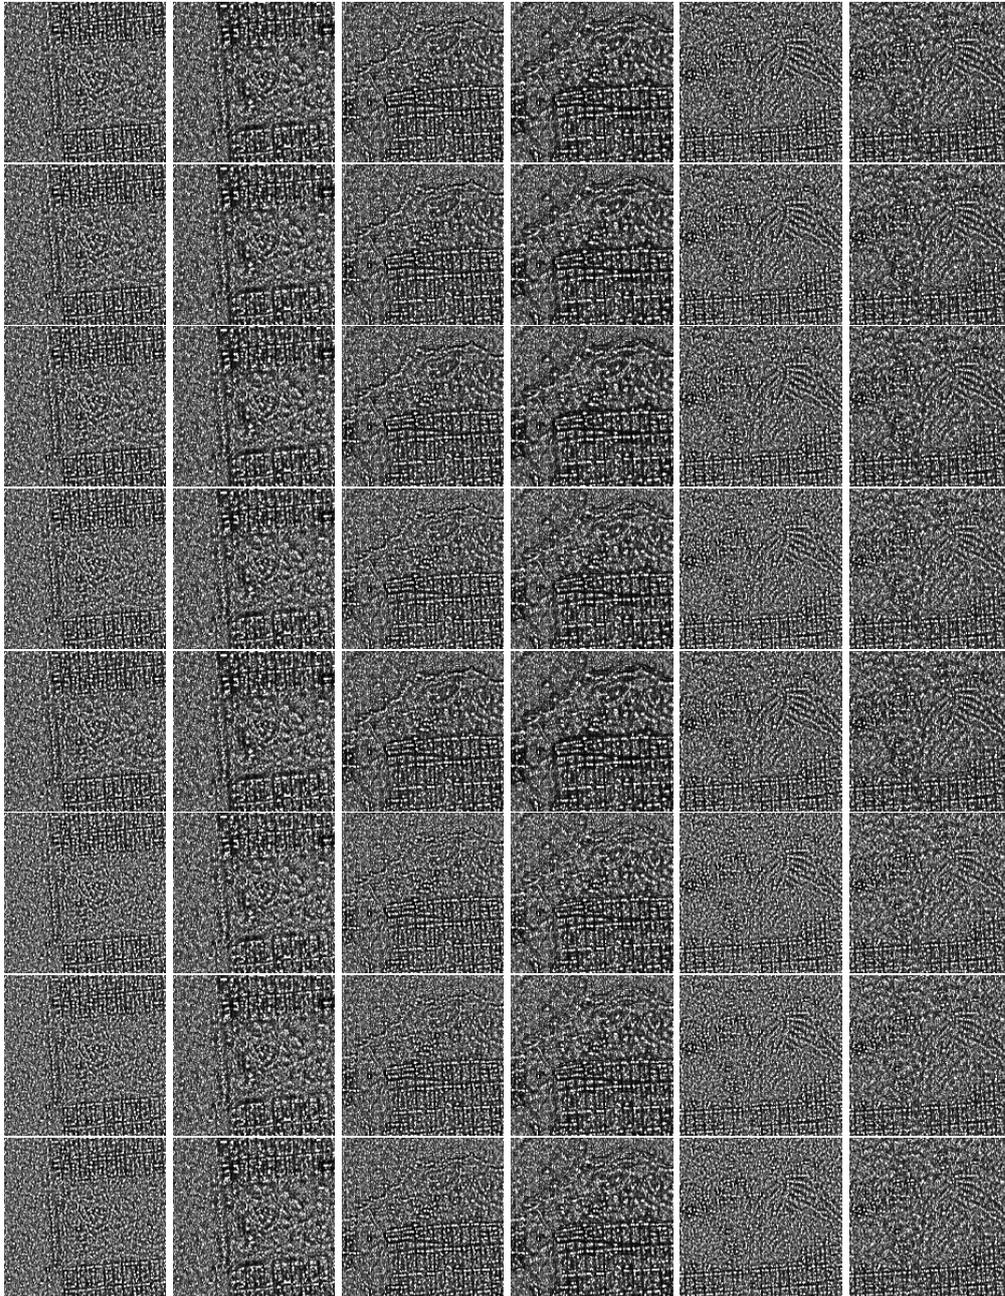
**Figura 8.20:** Comparação das filtragens com os demais filtros nas regiões 1 e 2. De cima para baixo: OBNL, PNLM, PPB GAUSS IT, PPB GAUSS NIT, PPB NAKA IT, PPB NAKA NIT, SAR-BM3D. As regiões alternam-se de três em três colunas.



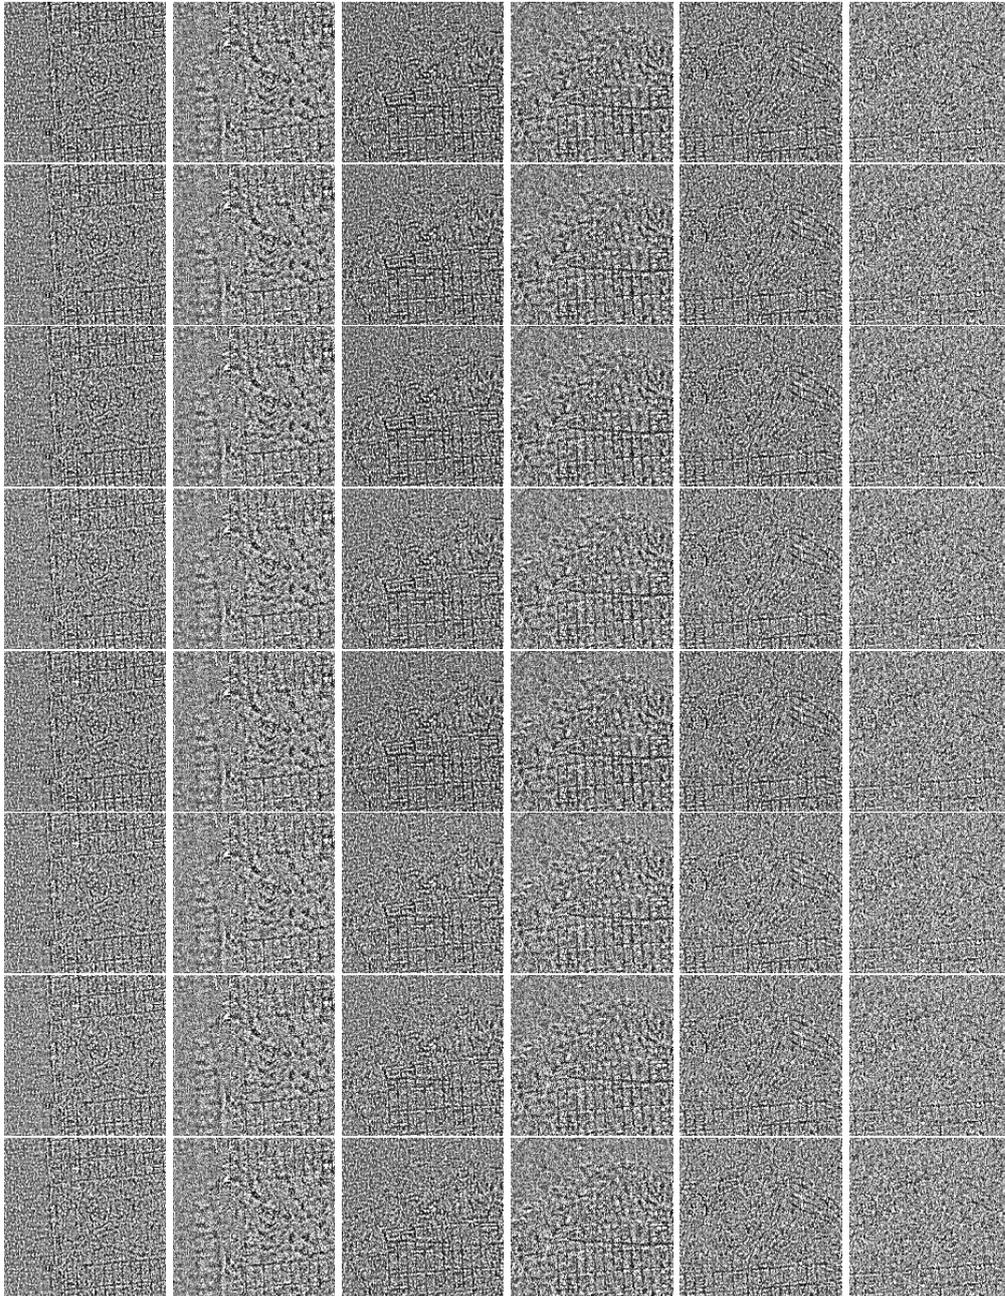
**Figura 8.21:** Comparação das filtragens com os demais filtros na região 3. De cima para baixo: FANS, FNLM, FROST, LEE, NLM, NLM-SAP.



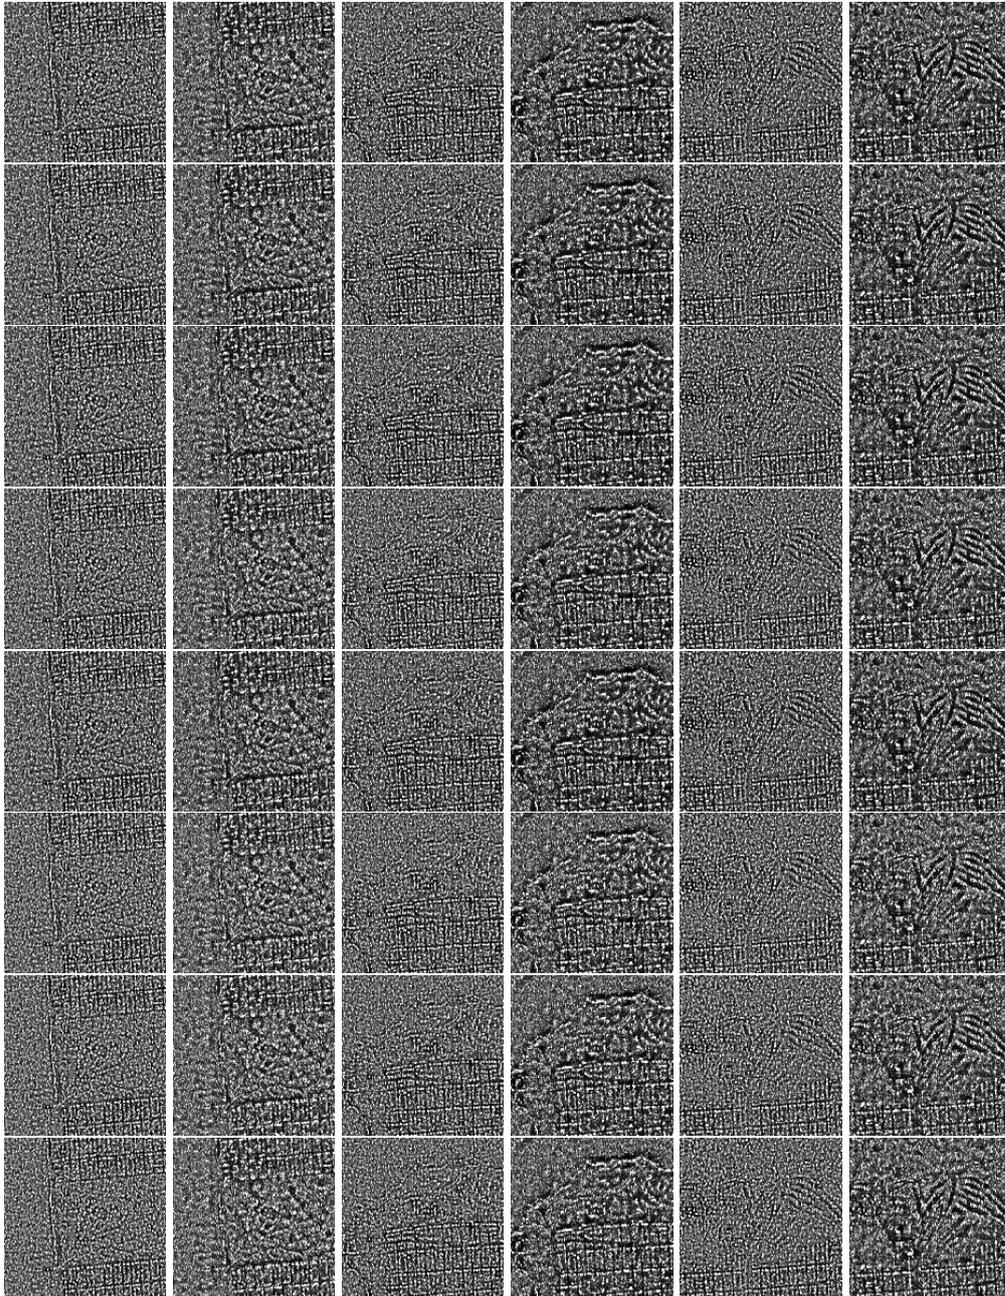
**Figura 8.22:** Comparação das filtragens com os demais filtros na região 3. De cima para baixo: OBNL, PNLM, PPB GAUSS IT, PPB GAUSS NIT, PPB NAKA IT, PPB NAKA NIT, SAR-BM3D.



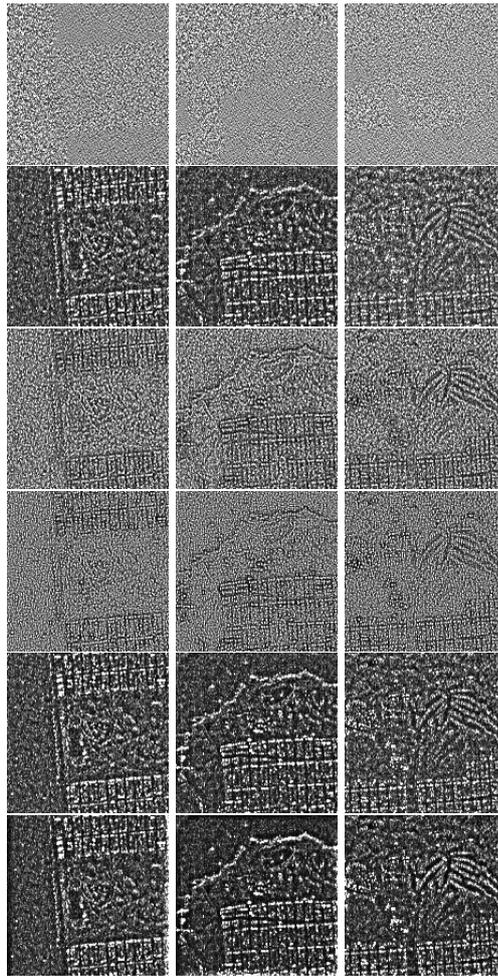
**Figura 8.23:** Razão  $r$  das regiões com a polarização HH para o NLM com as distâncias estocásticas. Quanto menor a presença de bordas e artefatos, maior o desempenho do filtro. Nas colunas ímpares foram utilizados os parâmetros estimados pela  $G^0$ , nas pares, pela inversa da Gama.



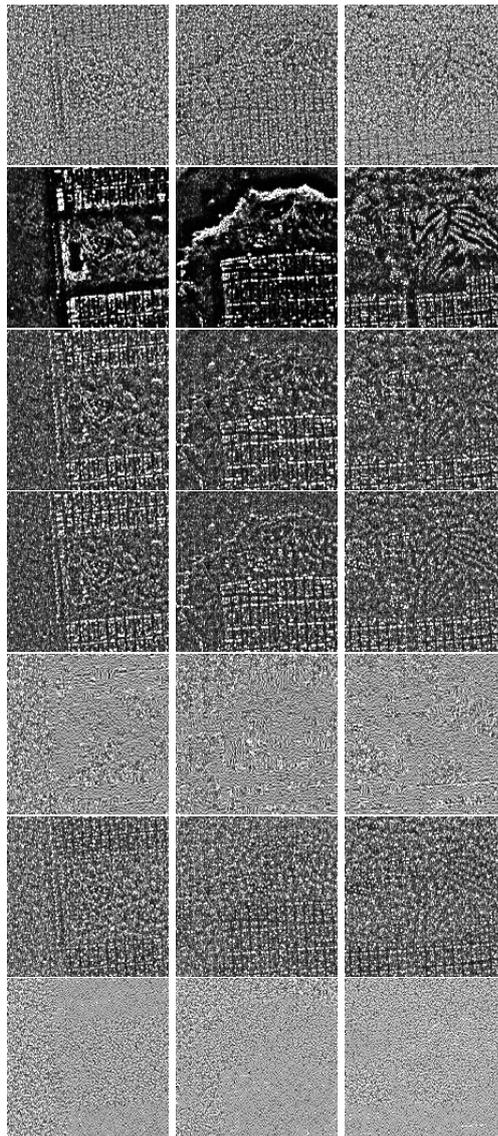
**Figura 8.24:** Razão  $r$  das regiões com a polarização HV para o NLM com as distâncias estocásticas. Quanto menor a presença de bordas e artefatos, maior o desempenho do filtro. Nas colunas ímpares foram utilizados os parâmetros estimados pela  $G^0$ , nas pares, pela inversa da Gama.



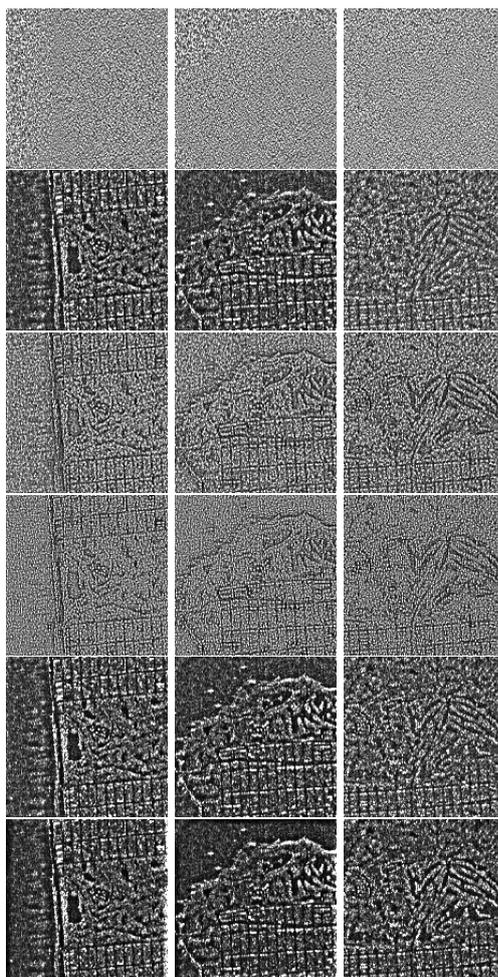
**Figura 8.25:** Razão  $r$  das regiões com a polarização VV para o NLM com as distâncias estocásticas. Quanto menor a presença de bordas e artefatos, maior o desempenho do filtro. Nas colunas ímpares foram utilizados os parâmetros estimados pela  $G^0$ , nas pares, pela inversa da Gama.



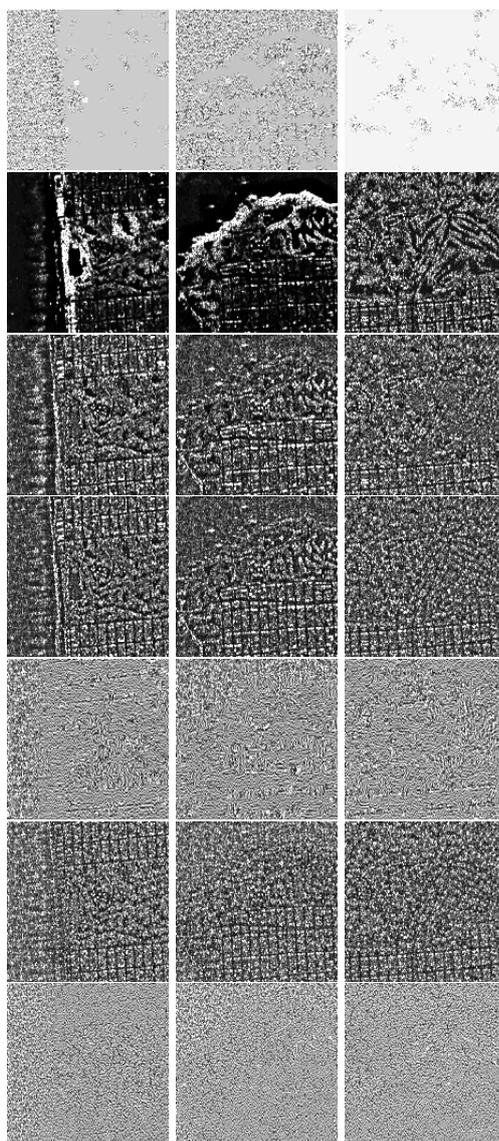
**Figura 8.26:** Razão  $r$  das regiões com a polarização HH para os demais filtros. Quanto menor a presença de bordas e artefatos, maior o desempenho do filtro. De cima para baixo: FANS, FNLM, FROST, LEE, NLM, NLM-SAP.



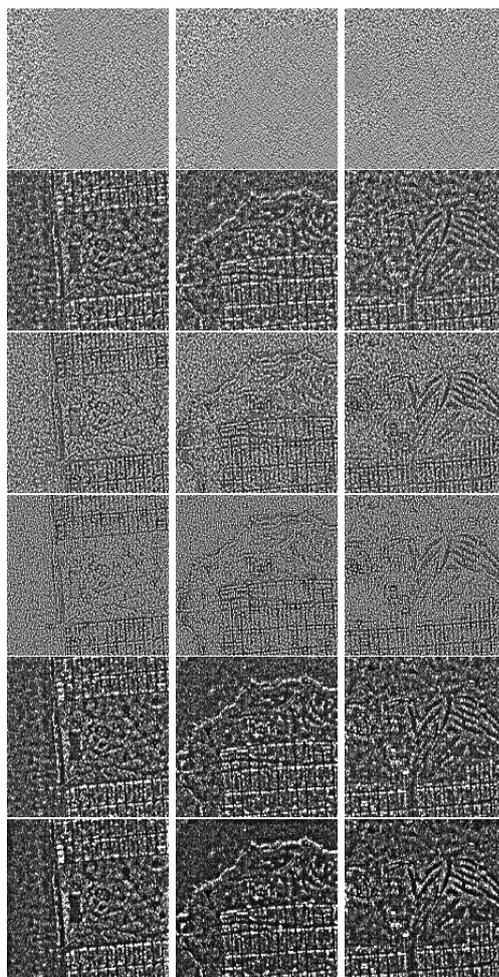
**Figura 8.27:** Razão  $r$  das regiões com a polarização HH para os demais filtros. Quanto menor a presença de bordas e artefatos, maior o desempenho do filtro. De cima para baixo: OBNL, PNL, PPB GAUSS IT, PPB GAUSS NIT, PPB NAKA IT, PPB NAKA NIT, SAR-BM3D.



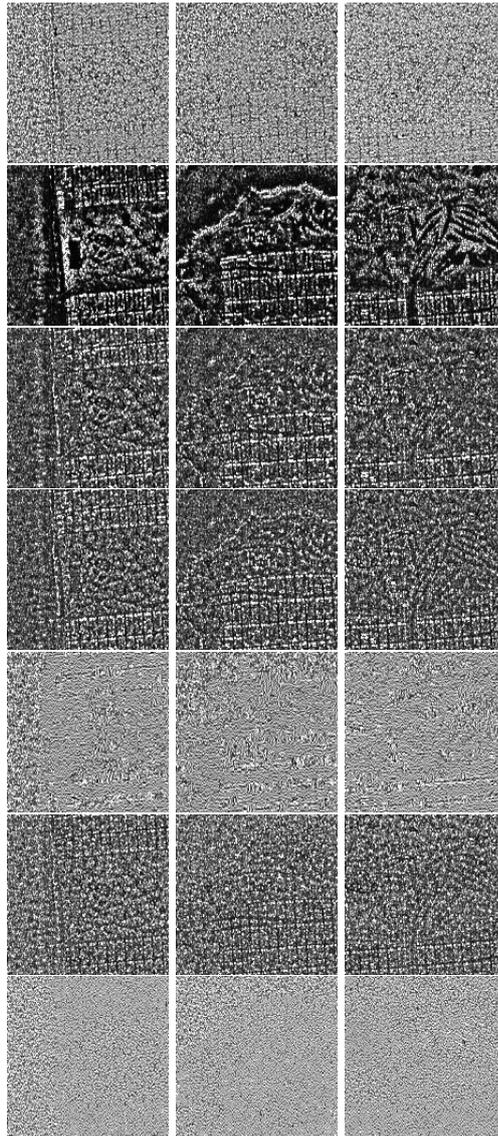
**Figura 8.28:** Razão  $r$  das regiões com a polarização HV para os demais filtros. Quanto menor a presença de bordas e artefatos, maior o desempenho do filtro. De cima para baixo: FANS, FNLM, FROST, LEE, NLM, NLM-SAP.



**Figura 8.29:** Razão  $r$  das regiões com a polarização HV para os demais filtros. Quanto menor a presença de bordas e artefatos, maior o desempenho do filtro. De cima para baixo: OBNL, PNLN, PPB GAUSS IT, PPB GAUSS NIT, PPB NAKA IT, PPB NAKA NIT, SAR-BM3D.



**Figura 8.30:** Razão  $r$  das regiões com a polarização VV para os demais filtros. Quanto menor a presença de bordas e artefatos, maior o desempenho do filtro. De cima para baixo: FANS, FNLM, FROST, LEE, NLM, NLM-SAP.



**Figura 8.31:** Razão  $r$  das regiões com a polarização VV para os demais filtros. Quanto menor a presença de bordas e artefatos, maior o desempenho do filtro. De cima para baixo: OBNL, PNL, PPB GAUSS IT, PPB GAUSS NIT, PPB NAKA IT, PPB NAKA NIT, SAR-BM3D.

# Capítulo 9

## CONCLUSÃO

---

---

*Neste último capítulo apresentam-se as considerações finais sobre a proposta desta dissertação e discutem-se brevemente os resultados obtidos. Também são considerados trabalhos futuros que possam melhorar a proposta.*

Esta dissertação surgiu através da inspiração dos trabalhos de Buades, Coll e Morel (2005), Nascimento, Cintra e Frery (2010) e de Cheng et al. (2013). Ela possui o objetivo de analisar a filtragem do NLM utilizando a transformação homomórfica e a estimação dos parâmetros pela distribuição  $G^0$  e comparar esta estimação com vários métodos propostos na literatura.

Além disto, surgiu a ideia para trabalhar com a distribuição da inversa da Gama na transformação homomórfica para estimar os parâmetros do “backscatter”, após uma pré-filtragem com o NLM. Esta pré-filtragem é utilizada com o intuito de obter os parâmetros mais próximos de uma imagem livre de ruído. Logo em seguida, estes parâmetros são adicionados nas distâncias estocásticas. Esta proposta é uma nova proposta na literatura, pois não foram encontrados, até então, artigos que filtram desta maneira. Outro fator que levou a esta motivação foi a facilidade de estimar os parâmetros, os quais não são embutidos na função digama, o que ocorre na estimação pela  $G_I^0$ .

Analisando os resultados sintéticos e reais, torna-se evidente o excelente desempenho dos filtros SAR-BM3D e FANS, que são o estado da arte. Também fica claro que, as estimações pela inversa da Gama ainda precisam ser mais ajustadas para chegar ao mesmo nível de remoção do “speckle” como destes dois filtros. Mas, mesmo com esta necessidade de ajuste, as nossas duas propostas são superiores a vários filtros propostos na literatura tanto com imagens sintéticas como reais.

Tanto a estimação pela  $G^0$ , quanto a estimação pela inversa da Gama computam parâmetros que, ao serem utilizados nas distâncias estocásticas dentro do NLM, conseguem suavizar o

“speckle”, mas ao mesmo tempo borram as imagens e perdem as bordas. Logo, mais análises precisam ser feitas, além de testes com outros tipos de distâncias dentro do NLM, e, em um futuro, no BM3D.

Através dos resultados, nota-se também que muitas filtragens baseadas no NLM e com a transformação homomórfica borram fortemente as imagens.

Foi observado também que, utilizar imagens SAR de diferentes polarizações, influencia no processo de remoção de “speckle” utilizando os parâmetros estimados pela inversa da Gama. Nas imagens SAR da região 2 com a polarização VV fica evidente o super borramento. Já as imagens com as polarizações HV, não é trivial identificar regiões homogêneas de heterogêneas.

Pelos resultados sintéticos e reais obtidos no capítulo 8, e a análise o PSNR e SSIM das tabelas 8.1 a 8.9 juntamente com os índices  $B$  e  $C_f$  do apêndice A, percebe-se que a diferença entre os valores obtidos com as oito distâncias estocásticas para os dois métodos propostos é mínima, e que a melhor distância para ser utilizada em trabalhos futuros é a distância Triangular.

E por último, um ponto importante, que precisa ser melhorado nas duas propostas em comparação com os demais métodos, é o custo computacional. Como utilizou-se a implementação “crua”, ou seja, sem nenhuma variação do filtro NLM, seu custo é bastante superior aos outros métodos. Além disto, no método “integrate” da plataforma R, existe um argumento chamado “subdivisions” que define o número de subintervalos na integração. Quanto menor o seu valor, mais rápida é a filtragem. Seu valor padrão (“subdivisions” = 100) foi configurado para “subdivisions” = 10, valor utilizado nos resultados sintéticos e reais. A alteração deste argumento influencia o cálculo do PSNR e SSIM dos métodos propostos. As Tabelas 9.1 a 9.6 indicam o tempo de filtragem das distâncias com os métodos propostos executados na imagem sintética. A distância em negrito de cada tabela indica a filtragem mais rápida. As distâncias de Rényi e Bhattacharyya tornaram-se não competitivas devido as dificuldades citadas na seção anterior para o método proposto com a Inversa da Gama para  $L = 3$  e  $L = 8$ . Já as Tabelas 9.7 a 9.9 mostram o tempo dos demais filtros. Decidiu-se não destacar o menor tempo nestas últimas tabelas, pois, embora alguns métodos sejam mais rápidos que o SAR-BM3D e o FANS, não foram mais eficazes. Todos os testes foram executados em uma máquina com processador Intel Core i7-4770 - 3.40GHz com 24GB de memória.

## 9.1 **Trabalhos futuros**

Como trabalhos futuros, pode-se identificar algumas etapas:

**Tabela 9.1:** Tempo de execução da filtragem com o método proposto pela  $G^0$  com as oito distâncias estocásticas de uma realização do "speckle" para  $L = 1$ .

Distâncias	Tempo em segundos
Aritmética Geométrica	95,20
Bhattacharyya	95,66
<b>Hellinger</b>	<b>90,31</b>
Média Harmônica	96,71
Jensen-Shannon	169,29
Kullback-Leibler	95,53
Rényi	96,36
Triangular	90,65

**Tabela 9.2:** Tempo de execução da filtragem com o método proposto pela  $G^0$  com as oito distâncias estocásticas de uma realização do "speckle" para  $L = 3$ .

Distâncias	Tempo em segundos
Aritmética Geométrica	98,71
Bhattacharyya	98,67
<b>Hellinger</b>	<b>95,15</b>
Média Harmônica	101,57
Jensen-Shannon	176,34
Kullback-Leibler	97,59
Rényi	100,62
Triangular	97,89

- Avaliar os parâmetros estimados pela inversa da Gama com outras distâncias dentro do conceito do NLM e do BM3D;
- Elaborar ou identificar outras maneiras de estimar os parâmetros pela inversa da Gama;
- Analisar e realizar um melhor ajuste destes parâmetros;
- Melhorar a eficácia nas bordas com a filtragem utilizando os parâmetros obtidos pela inversa da Gama;
- Estimar o parâmetro  $h$  do NLM;
- Melhorar o custo computacional;
- Comparar o uso da distribuição Fisher-Tippet para modelar o "speckle" com detecção quadrática no domínio do logaritmo, para um "look", com a aproximação gaussiana.

**Tabela 9.3:** Tempo de execução da filtragem com o método proposto pela  $G^0$  com as oito distâncias estocásticas de uma realização do "speckle" para  $L = 8$ .

<b>Distâncias</b>	<b>Tempo em segundos</b>
Aritmética Geométrica	104,50
Bhattacharyya	108,87
Hellinger	101,67
Média Harmônica	103,25
Jensen-Shannon	186,63
Kullback-Leibler	104,26
Rényi	104,91
<b>Triangular</b>	<b>98,09</b>

**Tabela 9.4:** Tempo de execução da filtragem com o método proposto pela Inversa da Gama com as oito distâncias estocásticas de uma realização do "speckle" para  $L = 1$ .

<b>Distâncias</b>	<b>Tempo em segundos</b>
Aritmética Geométrica	96,66
Bhattacharyya	96,05
Hellinger	92,45
Média Harmônica	95,61
Jensen-Shannon	168,52
Kullback-Leibler	96,70
Rényi	98,65
<b>Triangular</b>	<b>90,28</b>

**Tabela 9.5:** Tempo de execução da filtragem com o método proposto pela Inversa da Gama com as oito distâncias estocásticas de uma realização do "speckle" para  $L = 3$ .

<b>Distâncias</b>	<b>Tempo em segundos</b>
Aritmética Geométrica	98,18
Bhattacharyya	601,76
Hellinger	92,20
Média Harmônica	98,30
Jensen-Shannon	170,25
Kullback-Leibler	93,55
Rényi	1481,27
<b>Triangular</b>	<b>92,19</b>

**Tabela 9.6:** Tempo de execução da filtragem com o método proposto pela Inversa da Gama com as oito distâncias estocásticas de uma realização do "speckle" para  $L = 8$ .

<b>Distâncias</b>	<b>Tempo em segundos</b>
Aritmética Geométrica	103,83
Bhattacharyya	474,54
<b>Hellinger</b>	<b>98,23</b>
Média Harmônica	105,22
Jensen-Shannon	184,81
Kullback-Leibler	100,94
Rényi	1104,98
Triangular	98,27

**Tabela 9.7:** Tempo de execução da filtragem com os demais filtros de uma realização do "speckle" para  $L = 1$ .

<b>Filtros</b>	<b>Tempo em segundos</b>
BM3D	0,23
FANS	0,64
FNLM	0,06
FROST	1,19
LEE	0,03
NLM	7,37
NLM-SAP	3,91
OBNL	0,05
PNLM	2,82
PPB GAUSS IT	4,92
PB GAUSS NIT	0,95
PPB NAKA IT	7,45
PPB NAKA NIT	1,12
SAIST	18,30
SAR-BM3D	5,67

**Tabela 9.8:** Tempo de execução da filtragem com os demais filtros de uma realização do "speckle" para  $L = 3$ .

<b>Filtros</b>	<b>Tempo em segundos</b>
BM3D	0,23
FANS	0,76
FNLM	0,07
FROST	1,20
LEE	0,03
NLM	7,42
NLM-SAP	4,16
OBNL	0,07
PNLM	2,92
PPB GAUSS IT	5,31
PB GAUSS NIT	1,05
PPB NAKA IT	9,50
PPB NAKA NIT	1,74
SAIST	21,51
SAR-BM3D	5,67

**Tabela 9.9:** Tempo de execução da filtragem com os demais filtros de uma realização do "speckle" para  $L = 8$ .

<b>Filtros</b>	<b>Tempo em segundos</b>
BM3D	0,22
FANS	0,81
FNLM	0,06
FROST	1,24
LEE	0,03
NLM	7,42
NLM-SAP	4,13
OBNL	0,09
PNLM	2,75
PPB GAUSS IT	5,33
PB GAUSS NIT	1,03
PPB NAKA IT	12,95
PPB NAKA NIT	2,82
SAIST	21,45
SAR-BM3D	5,58

## REFERÊNCIAS

---

---

- ACHIM, A. Sar image filtering based on the heavy-tailed rayleigh model. *IEEE Transactions on Image Processing*, v. 15, n. 9, p. 2686–2692, Sep. 2006.
- AHARON, M.; ELAD, M.; BRUCKSTEIN, A. K-svd: An algorithm for designing overcomplete dictionaries for sparse representation. *Signal Processing, IEEE Transactions on*, v. 54, n. 11, p. 4311–4322, 2006.
- AIAZZI, B.; ALPARONE, L.; BARONTI, S. Multiresolution local-statistics speckle filtering based on a ratio laplacian pyramid. *IEEE Transactions on Geoscience and Remote Sensing*, v. 36, n. 5, p. 1466–1476, 1998.
- AIAZZI, B. et al. Pyramid-based multiresolution adaptive filters for additive and multiplicative image noise. *IEEE Transactions on Circuits and Systems II: Analog and Digital Signal Processing*, v. 45, n. 8, p. 1092–1097, 1998.
- ALPARONE, L.; BARONTI, S.; CARLA, R. Two-dimensional rank-conditioned median filter. *IEEE Transactions on Circuits and Systems II: Analog and Digital Signal Processing*, v. 42, n. 2, p. 130–132, 1995.
- ALPARONE, L. et al. An adaptive order-statistics filter for sar images. *International Journal of Remote Sensing*, v. 17, n. 7, p. 1357–1365, 1996.
- ALPARONE, L.; BARONTI, S.; GARZELLI, A. A hybrid sigma filter for unbiased and edge-preserving speckle reduction. In: *International Geoscience and Remote Sensing Symposium, 1995. IGARSS '95. 'Quantitative Remote Sensing for Science and Applications'*. [S.l.: s.n.], 1995. v. 2, p. 1409–1411.
- ALPARONE, L.; GARZELLI, A. Decimated geometric filter for edge-preserving smoothing of non-white image noise. *Pattern Recognition Letters*, v. 19, n. 1, p. 89 – 96, 1998.
- ARGENTI, F. et al. Fast map despeckling based on laplacian-gaussian modeling of wavelet coefficients. *IEEE Geoscience and Remote Sensing Letters*, v. 9, n. 1, p. 13–17, 2012.
- ARGENTI, F. et al. A tutorial on speckle reduction in synthetic aperture radar images. *IEEE Geoscience and Remote Sensing Magazine*, v. 1, n. 3, p. 6–35, 2013.
- ARSENAUL, H. H.; APRIL, G. Properties of speckle integrated with a finite aperture and logarithmically transformed. *Journal of the Optical Society of America*, v. 6, n. 11, p. 1160–1163, Nov. 1976.

- BARALDI, A.; PARMIGGIANI, F. A refined gamma map sar speckle filter with improved geometrical adaptivity. *IEEE Transactions on Geoscience and Remote Sensing*, v. 33, n. 5, p. 1245–1257, 1995.
- BIBO, L.; ZHANG, L.; FUQIANG, X. Sar speckle reduction based on nonlocal means method. *Second International Conference on Computer Modeling and Simulation, 2010. ICCMS '10.*, v. 2, p. 156–159, Jan. 2012.
- BOULANGER, J. et al. Non-parametric regression for patch-based fluorescence microscopy image sequence denoising. In: *5th IEEE International Symposium on Biomedical Imaging: From Nano to Macro, 2008. ISBI 2008*. [S.l.: s.n.], 2008. p. 748–751.
- BUADES, A.; COLL, B.; MOREL, J. M. A review of image denoising algorithm, with a new one. *Multiscale Modeling and Simulation*, v. 4, n. 2, p. 490–530, 2005.
- CANDÉS, E.; ROMBERG, J.; TAO, T. Robust uncertainty principles: exact signal reconstruction from highly incomplete frequency information. *IEEE Transactions on Information Theory*, v. 52, n. 2, p. 489–509, 2006.
- CHAN, Y. K.; KOO, V. C. An introduction to synthetic aperture radar (sar). *Progress In Electromagnetics Research B*, v. 2, p. 27–60, 2008.
- CHANG, S.; YU, B.; VETTERLI, M. Adaptive wavelet thresholding for image denoising and compression. *IEEE Transactions on Image Processing*, v. 9, n. 9, p. 1532–1546, 2000.
- CHATTERJEE, P.; MILANFAR, P. Is denoising dead? *IEEE Transactions on Image Processing*, v. 19, n. 4, p. 895–911, Apr. 2010.
- CHENG, J. et al. An improved scheme for parameter estimation of g0 distribution model in high-resolution sar images. *Progress In Electromagnetics Research*, v. 134, p. 23–46, 2013.
- COUPE, P. et al. Nonlocal means-based speckle filtering for ultrasound images. *IEEE Transactions on Image Processing*, v. 18, n. 10, p. 2221–2229, 2009.
- COZZOLINO, D. et al. Fast adaptive nonlocal sar despeckling. *IEEE Geoscience and Remote Sensing Letters*, v. 11, n. 99, p. 1–5, 2013.
- CRIMMINS, T. R. Geometric filter for speckle reduction. *Applied Optics*, Optical Society of America, v. 24, n. 10, p. 1438–1443, May 1985.
- CSISZAR, I. Why least squares and maximum entropy an axiomatic approach to inference for linear inverse problems. *Annals of Statistics*, v. 19, n. 4, p. 2032–2066, 1991.
- 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, Aug. 2007.
- DAI, M. et al. Bayesian wavelet shrinkage with edge detection for sar image despeckling. *IEEE Transactions on Geoscience and Remote Sensing*, v. 42, n. 8, p. 1642–1648, 2004.
- DARBON, J. et al. Fast nonlocal filtering applied to electron cryomicroscopy. In: *5th IEEE International Symposium on Biomedical Imaging: From Nano to Macro, 2008. ISBI 2008*. [S.l.: s.n.], 2008. p. 1331–1334.

- DELEDALLE, C.; DENIS, L.; TUPIN, F. Iterative weighted maximum likelihood denoising with probabilistic patch-based weights. *IEEE Transactions on Image Processing*, v. 18, n. 12, p. 2661–2672, Dec 2009.
- DELEDALLE, C.; DUVAL, V.; SALMON, J. Non-local methods with shape-adaptive patches (nlm-sap). *Journal of Mathematical Imaging and Vision*, v. 43, n. 2, p. 103–120, 2012.
- DONG, W.; SHI, G.; LI, X. Nonlocal image restoration with bilateral variance estimation: A low-rank approach. *IEEE Transactions on Image Processing*, v. 22, n. 2, p. 700–711, 2013.
- DONOHO, D. De-noising by soft-thresholding. *IEEE Transactions on Information Theory*, v. 41, n. 3, p. 613–627, 1995.
- DONOHO, D. Compressed sensing. *IEEE Transactions on Information Theory*, v. 52, n. 4, p. 1289–1306, 2006.
- EFROS, A.; LEUNG, T. Texture synthesis by non parametric sampling. *Proceedings of the IEEE International Conference on Computer Vision*, v. 2, p. 1033–1038, 1999.
- FLETCHER, R. *Practical Methods of Optimization*. 2. ed. [S.l.]: Wiley, 2000.
- FOUCHER, S. Sar image filtering via learned dictionaries and sparse representations. In: *IEEE International Geoscience and Remote Sensing Symposium, 2008. IGARSS 2008*. [S.l.: s.n.], 2008. v. 1, p. I-229–I-232.
- FOUCHER, S.; BENIE, G.; BOUCHER, J.-M. Multiscale map filtering of sar images. *IEEE Transactions on Image Processing*, v. 10, n. 1, p. 49–60, 2001.
- FRERY, A. et al. A model for extremely heterogeneous clutter. *IEEE Transactions on Geoscience and Remote Sensing*, v. 35, n. 3, p. 648–659, May 1997.
- FROST, V. S. et al. A model for radar images and its application to adaptive digital filtering of multiplicative noise. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-4, n. 2, p. 157–166, Mar. 1982.
- FUKUDA, S.; HIROSAWA, H. Smoothing effect of wavelet-based speckle filtering: the haar basis case. *IEEE Transactions on Geoscience and Remote Sensing*, v. 37, n. 2, p. 1168–1172, 1999.
- GOMEZ, L. et al. Supervised constrained optimization of bayesian nonlocal means filter with sigma preselection for despeckling sar images. *IEEE Transactions on Geoscience and Remote Sensing*, v. 51, n. 8, p. 4563–4575, 2013.
- GONZALEZ, R. C.; WOODS, R. C. *Digital Image Processing*. 3. ed. [S.l.]: Pearson Education, 2010.
- GUO, H. et al. Wavelet based speckle reduction with application to sar based atd/r. In: *IEEE International Conference Image Processing, 1994. Proceedings. ICIP-94*. [S.l.: s.n.], 1994. v. 1, p. 75–79.
- GUO, Y.; WANG, Y.; HOU, T. Speckle filtering of ultrasonic images using a modified non local-based algorithm. *Biomedical Signal Processing and Control*, v. 6, n. 2, p. 129–138, 2011.

- HAO, Y.; FENG, X.; XU, J. Multiplicative noise removal via sparse and redundant representations over learned dictionaries and total variation. *Signal Processing*, v. 92, n. 6, p. 1536 – 1549, 2012.
- HAWWAR, Y.; REZA, A. Spatially adaptive multiplicative noise image denoising technique. *IEEE Transactions on Image Processing*, v. 11, n. 12, p. 1397–1404, 2002.
- HENNINGSSEN, A.; TOOMET, O. maxlik: A package for maximum likelihood estimation in R. *Computational Statistics*, v. 26, n. 3, p. 443–458, 2011. Disponível em: <<http://dx.doi.org/10.1007/s00180-010-0217-1>>.
- HONGZHEN, C. et al. Stationary-wavelet-based despeckling of sar images using two-sided generalized gamma models. *IEEE Geoscience and Remote Sensing Letters*, v. 9, n. 6, p. 1061–1065, 2012.
- HORTA, M. M. *Modelos de mistura de distribuições na segmentação de imagens SAR polarimétricas multi-look*. Dissertação (Mestrado) — Universidade de São Paulo - Instituto de Física de São Carlos - Departamento de Física e Informática, 2009.
- JIANG, J.; JIANG, L.; SANG, N. Non-local sparse models for sar image despeckling. In: *2012 International Conference on Computer Vision in Remote Sensing (CVRS)*. [S.l.: s.n.], 2012. p. 230–236.
- JOJY, C. et al. Discontinuity adaptive non-local means with importance sampling unscented kalman filter for de-speckling sar images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 6, n. 4, p. 1964–1970, 2013.
- KARNATI, V.; ULIYAR, M.; DEY, S. Fast non-local algorithm for image denoising. In: *16th IEEE International Conference on Image Processing (ICIP), 2009*. [S.l.: s.n.], 2009. p. 3873–3876.
- KUAN, D. T. et al. Adaptive restoration of images with speckle. *IEEE Transactions on Acoustics, Speech and Signal Processing*, v. 35, n. 3, p. 373–383, 1987.
- KUAN, D. T. et al. Adaptive noise smoothing filter for images with signal-dependent noise. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-7, n. 2, p. 165–177, Mar 1985.
- LEBRUN, M. An analysis and implementation of the bm3d image denoising method. *Image Processing On Line*, v. 2012, p. 175–213, 2012.
- LEBRUN, M.; BUADES, A.; MOREL, J. Implementation of the non-local bayes (nl-bayes) image denoising algorithm. *Image Processing On Line*, v. 2013, p. 1–42, 2013.
- LEBRUN, M.; BUADES, A.; MOREL, J. A nonlocal bayesian image denoising algorithm. *SIAM Journal on Imaging Sciences*, v. 6, n. 3, p. 1665–1688, 2013.
- LEE, J.-S. Digital image enhancement and noise filtering by use of local statistics. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-2, n. 2, p. 165–168, Mar. 1980.
- LEE, J.-S. Refined filtering of image noise using local statistics. *Computer Graphics and Image Processing*, v. 15, n. 2, p. 380–389, Apr. 1981.

- LEE, J.-S. Digital image smoothing and the sigma filter. *Computer Vision, Graphics, and Image Processing*, v. 24, n. 2, p. 255–269, 1983.
- LEE, J.-S. A simple speckle smoothing algorithm for synthetic aperture radar images. *IEEE Transactions on Systems, Man and Cybernetics*, SMC-13, n. 1, p. 85–89, 1983.
- LEE, J.-S. et al. Improved sigma filter for speckle filtering of sar imagery. *IEEE Transactions on Geoscience and Remote Sensing*, v. 47, n. 1, p. 202–213, 2009.
- LI, G.-T. et al. Sar image despeckling using a space-domain filter with alterable window. *IEEE Geoscience and Remote Sensing Letters*, v. 10, n. 2, p. 263–267, 2013.
- LI, H.-C. et al. Bayesian wavelet shrinkage with heterogeneity-adaptive threshold for sar image despeckling based on generalized gamma distribution. *IEEE Transactions on Geoscience and Remote Sensing*, v. 51, n. 4, p. 2388–2402, 2013.
- LOPES, A. et al. Maximum a posteriori speckle filtering and first order texture models in sar images. In: *10th Annual International Geoscience and Remote Sensing Symposium, 1990. IGARSS '90. 'Remote Sensing Science for the Nineties'*. [S.l.: s.n.], 1990. p. 2409–2412.
- LUO, E.; PAN, S.; NGUYEN, T. Generalized non-local means for iterative denoising. In: *2012 Proceedings of the 20th European Signal Processing Conference (EUSIPCO)*. [S.l.: s.n.], 2012. p. 260–264.
- MALLADI, R.; KASILINGAM, D.; COSTA, A. Speckle filtering of sar images using hollder regularity analysis of the sparse code. In: *2003 IEEE International Geoscience and Remote Sensing Symposium, 2003. IGARSS '03. Proceedings*. [S.l.: s.n.], 2003. v. 6, p. 3998–4000.
- MEER, P.; PARK, R.-H.; CHO, K. Multiresolution adaptive image smoothing. *Computer Graphics and Image Processing*, v. 56, n. 2, p. 140–148, Mar 1994.
- MEJAIL, M. E. et al. Classification of sar images using a general and tractable multiplicative model. *International Journal of Remote Sensing*, v. 24, n. 18, p. 3565–3582, 2003.
- MITTAL, A.; MOORTHY, A.; BOVIK, A. No-reference image quality assessment in the spatial domain. *IEEE Transactions on Image Processing*, v. 21, n. 12, p. 4695–4708, 2012.
- MOREIRA, A. et al. A tutorial on synthetic aperture radar. *IEEE Geoscience and Remote Sensing Magazine*, v. 1, n. 1, p. 6–43, 2013.
- NASCIMENTO, A. D. C. *Contrast measures and stochastic distances in a model for speckled data*. Dissertação (Mestrado) — Universidade Federal de Pernambuco - Departamento de Estatística, 2008.
- NASCIMENTO, A. D. C.; CINTRA, R. J.; FRERY, A. C. Hypothesis testing in speckled data with stochastic distances. *IEEE Transactions on Geoscience and Remote Sensing*, v. 48, n. 1, p. 373–385, Jan. 2010.
- NATH, A. Image denoising algorithms: A comparative study of different filtration approaches used in image restoration. In: *2013 International Conference on Communication Systems and Network Technologies (CSNT)*. [S.l.: s.n.], 2013. p. 157–163.

- PARRILLI, S. et al. A nonlocal sar image denoising algorithm based on lmmse wavelet shrinkage. *IEEE Transactions on Geoscience and Remote Sensing*, v. 50, n. 2, p. 606–616, Feb 2012.
- PERONA, P.; MALIK, J. Scale-space and edge detection using anisotropic diffusion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 12, n. 7, p. 629–639, 1990.
- R Core Team. *R: A Language and Environment for Statistical Computing*. Vienna, Austria, 2013. Disponível em: <<http://www.R-project.org/>>.
- RAMACHANDRAN, S.; NAIR, M. G. Ultrasound speckle reduction using nonlinear gaussian filters and nonlocal neighbourhoods. *Proc. SPIE*, v. 8320, p. 83201J–83201J–8, 2012.
- RUDIN, L. I.; OSHER, S.; FATEMI, E. Nonlinear total variation based noise removal algorithms. *Physica D Nonlinear Phenomena*, v. 60, n. 4, p. 259–268, 1992.
- STARCK, J. L.; MURTAGH, F.; FADILI, J. M. *Sparse image and signal processing: wavelets, curvelets, morphological diversity*. 1. ed. [S.l.]: Cambridge University Press, 2010.
- STEIN, C. M. Estimation of the mean of a multivariate normal distribution. *The Annals of Statistics*, v. 9, n. 6, p. 1135–1151, 1981.
- SUBRAHMANYAM, G. R. K. S.; RAJAGOPALAN, A. N.; ARAVIND, R. A recursive filter for despeckling sar images. *IEEE Transactions on Image Processing*, v. 17, n. 10, p. 1969–1974, 2008.
- SVEINSSON, J.; BENEDIKTSSON, J. Almost translation invariant wavelet transformations for speckle reduction of sar images. *IEEE Transactions on Geoscience and Remote Sensing*, v. 41, n. 10, p. 2404–2408, 2003.
- TAKAGI, H. Interactive evolutionary computation: fusion of the capabilities of ec optimization and human evaluation. *Proceedings of the IEEE*, v. 89, n. 9, p. 1275–1296, 2001.
- TEUBER, T.; LANG, A. A new similarity measure for nonlocal filtering in the presence of multiplicative noise. *Computational Statistics And Data Analysis*, v. 56, n. 12, p. 3821–3842, 2012.
- TOMASI, C.; MANDUCHI, R. Bilateral filtering for gray and color images. In: *Sixth International Conference on Computer Vision, 1998*. [S.l.: s.n.], 1998. p. 839–846.
- TORRES, L.; CAVALCANTE, T.; FRERY, A. Speckle reduction using stochastic distances. In: ALVAREZ, L. et al. (Ed.). *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications*. [S.l.]: Springer Berlin Heidelberg, 2012. (Lecture Notes in Computer Science, v. 7441), p. 632–639.
- TORRES, L. et al. Speckle reduction in polarimetric sar imagery with stochastic distances and nonlocal means. *Pattern Recognition*, v. 47, n. 1, p. 141–157, jan. 2014.
- TOUZI, R. Multiplicative and product model constraints upon speckle filtering of sar images. In: *IEEE 2001 International Geoscience and Remote Sensing Symposium, 2001. IGARSS '01*. [S.l.: s.n.], 2001. v. 3, p. 1161–1163 vol.3.

- TOUZI, R. A review of speckle filtering in the context of estimation theory. *IEEE Transactions on Geoscience and Remote Sensing*, v. 40, n. 11, p. 2392–2404, Nov. 2002.
- TOUZI, R.; LOPES, A.; BOUSQUET, P. A statistical and geometrical edge detector for sar images. *IEEE Transactions on Geoscience and Remote Sensing*, v. 26, n. 6, p. 764–773, 1988.
- VILLE, D. V. D.; KOCHER, M. Nonlocal means with dimensionality reduction and sure-based parameter selection. *IEEE Transactions on Image Processing*, v. 20, n. 9, p. 2683–2690, 2011.
- WALESSA, M.; DATCU, M. Model-based despeckling and information extraction from sar images. *IEEE Transactions on Geoscience and Remote Sensing*, v. 38, n. 5, p. 2258–2269, 2000.
- WANG, Z. et al. Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing*, v. 13, n. 4, p. 600–612, 2004.
- Carl A. Wiley. *Pulsed doppler radar methods and apparatus*. 1965. 3196436. Disponível em: <<http://www.freepatentsonline.com/3196436.html>>.
- WITKOVSKY, V. Computing the distribution of a linear combination of inverted gamma variables. *Kybernetika*, v. 37, n. 1, p. 79–90, 2001.
- WU, Y. et al. Probabilistic non-local means. *IEEE Signal Processing Letters*, v. 20, n. 8, p. 763–766, 2013.
- XIE, H.; PIERCE, L.; ULABY, F. Sar speckle reduction using wavelet denoising and markov random field modeling. *IEEE Transactions on Geoscience and Remote Sensing*, v. 40, n. 10, p. 2196–2212, 2002.
- XUE, B. et al. Fast nonlocal remote sensing image denoising using cosine integral images. *IEEE Geoscience and Remote Sensing Letters*, v. 10, n. 6, p. 1309–1313, 2013.
- YANG, M.; ZHANG, G. Sar image despeckling using over-complete dictionary. *Electronics Letters*, v. 48, n. 10, p. 596–597, 2012.
- YANG, X.; CLAUSI, D. A. Structure-preserving speckle reduction of sar images using nonlocal means filters. *16th IEEE International Conference on Image Processing (ICIP), 2009.*, p. 2985–2988, Nov. 2009.
- YONGJIAN, Y.; ACTON, S. T. Speckle reducing anisotropic diffusion. *IEEE Transactions on Image Processing*, v. 11, n. 11, p. 1260–1270, 2002.
- ZENG, Z.; CUMMING, I. Bayesian speckle noise reduction using the discrete wavelet transform. In: *1998 IEEE International Geoscience and Remote Sensing Symposium Proceedings, 1998. IGARSS '98*. [S.l.: s.n.], 1998. v. 1, p. 7–9.
- ZHAN, Y.; ZHANG, X.; DING, M. A novel iterative non-local means algorithm for speckle reduction. In: *Proceedings of SPIE*. [S.l.: s.n.], 2012. v. 8314, p. 831442–831442–9.
- ZHAN, Y.; ZHANG, X.; DING, M. Susan controlled decay parameter adaption for non-local means image denoising. *Electronics Letters*, v. 49, n. 13, p. 807–808, 2013.
- ZHANG, L. et al. Two-stage image denoising by principal component analysis with local pixel grouping. *Pattern Recognition*, v. 43, n. 4, p. 1531–1549, 2010.

- ZHANG, W.; ZHANG, Q.; YANG, C. Improved bilateral filtering for sar image despeckling. *Electronics Letters*, v. 47, n. 4, p. 286–288, 2011.
- ZHONG, H.; LI, Y.; JIAO, L. Bayesian nonlocal means filter for sar image despeckling. *2nd Asian-Pacific Conference on Synthetic Aperture Radar, 2009. APSAR 2009.*, p. 1096–1099, Jan. 2010.
- ZHONG, H.; LI, Y.; JIAO, L. Sar image despeckling using bayesian nonlocal means filter with sigma preselection. *IEEE Geoscience and Remote Sensing Letters*, v. 8, n. 4, p. 809–813, 2011.
- ZHONG, H. et al. Nonlocal-lee filter for sar image despeckling based on hybrid patch similarity. In: *2013 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. [S.l.: s.n.], 2013. p. 1987–1990.

# GLOSSÁRIO

---

---

**ASI** – *Italian Space Agency - Agência Espacial Italiana*

**AWGN** – *Additive White Gaussian Noise - Ruído Branco Aditivo Gaussiano*

**BFGS** – *Broyden-Fletcher-Goldfarb-Shanno*

**BM3D** – *Block Matching 3D*

**CS** – *Compressive Sensing*

**DRI** – *German Space Agency - Agência Espacial Alemã*

**ENL** – *Equivalent Number of Looks*

**ESA** – *European Space Agency - Agência Espacial Européia*

**F.D.P** – *Função densidade de probabilidade*

**FFT** – *Fast Fourier Transform*

**FNLM** – *Fast Non Local Means*

**GF** – *Geometric Filter*

**GG** – *Gaussian Generalizada*

**GMRF** – *Gaussian Markov Random Fields - campos marcovianos aleatórios gaussianos*

**GNLM** – *Generalized Non-Local Means*

**I.I.D** – *Independente e Identicamente Distribuído*

**IANLM** – *Iterative Adaptive Non-Local Means*

**IGA** – *Interactive Genetic Algorithm*

**ISNR** – *Improvement in Signal-to-Noise Ratio*

**ISUKF** – *Importance Sampling Unscented Kalman Filter*

**LLMMSE** – *Local Linear Minimum Mean Square Error*

**MAP** – *Maximum A Posteriori*

**MLE** – *Maximum Likelihood Estimator*

**MMSE** – *Minimum Mean-Square Error - mínimo erro quadrático médio*

**MSE** – *Mean Square Error - Erro Médio Quadrático*

**NLM** – *Nonlocal Means - Média Não Local*

**NR-IQA** – *No-reference image quality assessment*

**NRL** – *Naval Research Laboratory*

**PNLM** – *Probabilistic Non-Local Means*

**PPB** – *Probabilistic Patch Based*

**PPPWE** – *PPB Weights Estimator*

**PSNR** – *Peak Signal-to-Noise Ratio*

**RGB** – *Red, Green and Blue - Vermelho, Verde e Azul*

**RLP** – *Relational Laplacian Pyramid*

**ROF** – *Rudin-Osher-Fatemi*

**SAR** – *Synthetic Aperture Radar - Radar de Abertura Sintética*

**SFAW** – *Space-domain filter with alterable window*

**SLAR** – *Side-Looking Airbone Radar*

**SNLM** – *SUSAN Non-Local Means*

**SNR** – *Signal to Noise Ration*

**SRAD** – *Speckle Reducing Anisotropic Diffusion*

**SSIM** – *Structural Similarity Index*

**SURE** – *Stein's Unbiased Risk Estimate*

**UDWT** – *Undacimated Discrete Wavelet Transform*

**WA** – *Weighted Average - média ponderada*

**WMLE** – *Weighted Maximum Likelihood Estimation*

**WT** – *Wavelet Transform*

# Apêndice A

## TABELAS DOS RESULTADOS

---

---

### A.1 ENL

Tabela A.1: Valores ENL da região 1 HH do filtro proposto com as distâncias estocásticas e estimadores da  $G_I^0$ .

Distâncias	ENL
Aritmética Geométrica	1,56
Bhattacharyya	1,57
Hellinger	1,58
Média Harmônica	1,50
Jensen-Shannon	1,59
Kullback-Leibler	1,41
Rényi	1,42
Triangular	1,42

Tabela A.2: Valores ENL da região 1 HH do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama.

Distâncias	ENL
Aritmética Geométrica	1,67
Bhattacharyya	1,68
Hellinger	1,68
Média Harmônica	1,62
Jensen-Shannon	1,57
Kullback-Leibler	1,57
Rényi	1,57
Triangular	1,57

**Tabela A.3: Valores ENL da região 1 HH dos demais filtros.**

<b>Filtros</b>	<b>ENL</b>
FANS	1,60
FNLM	2,00
FROST	1,67
LEE	1,16
NLM	1,99
NLM-SAP	2,26
OBNL	1,82
PNLM	0,24
PPB GAUSS IT	2,15
PB GAUSS NIT	2,00
PPB NAKA IT	1,56
PPB NAKA NIT	1,88
SAR-BM3D	1,43

**Tabela A.4: Valores ENL da região 2 HH do filtro proposto com as distâncias estocásticas e estimadores da  $G_I^0$ .**

<b>Distâncias</b>	<b>ENL</b>
Aritmética Geométrica	0,17
Bhattacharyya	0,17
Hellinger	0,17
Média Harmônica	0,16
Jensen-Shannon	0,17
Kullback-Leibler	0,15
Rényi	0,15
Triangular	0,15

**Tabela A.5: Valores ENL da região 2 HH do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama.**

<b>Distâncias</b>	<b>ENL</b>
Aritmética Geométrica	0,17
Bhattacharyya	0,17
Hellinger	0,17
Média Harmônica	0,16
Jensen-Shannon	0,18
Kullback-Leibler	0,14
Rényi	0,14
Triangular	0,15

**Tabela A.6: Valores ENL da região 2 HH dos demais filtros.**

<b>Filtros</b>	<b>ENL</b>
FANS	0,09
FNLM	0,25
FROST	0,14
LEE	0,12
NLM	0,28
NLM-SAP	0,42
OBNL	0,13
PNLM	0,24
PPB GAUSS IT	0,22
PB GAUSS NIT	0,22
PPB NAKA IT	0,10
PPB NAKA NIT	0,15
SAR-BM3D	0,09

**Tabela A.7: Valores ENL da região 3 HH do filtro proposto com as distâncias estocásticas e estimadores da  $G_I^0$ .**

<b>Distâncias</b>	<b>ENL</b>
Aritmética Geométrica	2,80
Bhattacharyya	2,82
Hellinger	2,84
Média Harmônica	2,57
Jensen-Shannon	2,86
Kullback-Leibler	2,38
Rényi	2,39
Triangular	2,39

**Tabela A.8: Valores ENL da região 3 HH do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama.**

<b>Distâncias</b>	<b>ENL</b>
Aritmética Geométrica	2,79
Bhattacharyya	2,79
Hellinger	2,81
Média Harmônica	2,63
Jensen-Shannon	2,82
Kullback-Leibler	2,53
Rényi	2,53
Triangular	2,52

**Tabela A.9: Valores ENL da região 3 HH dos demais filtros.**

<b>Filtros</b>	<b>ENL</b>
FANS	1,68
FNLM	3,46
FROST	2,62
LEE	2,08
NLM	5,09
NLM-SAP	7,03
OBNL	2,49
PNLM	11,38
PPB GAUSS IT	2,86
PB GAUSS NIT	3,79
PPB NAKA IT	1,41
PPB NAKA NIT	3,05
SAR-BM3D	1,47

**Tabela A.10: Valores ENL da região 1 HV do filtro proposto com as distâncias estocásticas e estimadores da  $G_I^0$ .**

<b>Distâncias</b>	<b>ENL</b>
Aritmética Geométrica	1,73
Bhattacharyya	1,62
Hellinger	1,62
Média Harmônica	1,56
Jensen-Shannon	1,61
Kullback-Leibler	1,56
Rényi	1,54
Triangular	1,60

**Tabela A.11: Valores ENL da região 1 HV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama.**

<b>Distâncias</b>	<b>ENL</b>
Aritmética Geométrica	1,23
Bhattacharyya	1,23
Hellinger	1,23
Média Harmônica	1,20
Jensen-Shannon	1,23
Kullback-Leibler	1,19
Rényi	1,18
Triangular	1,19

**Tabela A.12: Valores ENL da região 1 HV dos demais filtros.**

<b>Filtros</b>	<b>ENL</b>
FANS	1,70
FNLM	6,27
FROST	2,42
LEE	1,88
NLM	6,41
NLM-SAP	2,84
OBNL	1,32
PNLM	0,25
PPB GAUSS IT	10,60
PB GAUSS NIT	5,98
PPB NAKA IT	1,41
PPB NAKA NIT	3,30
SAR-BM3D	1,49

**Tabela A.13: Valores ENL da região 2 HV do filtro proposto com as distâncias estocásticas e estimadores da  $G_I^0$ .**

<b>Distâncias</b>	<b>ENL</b>
Aritmética Geométrica	0,06
Bhattacharyya	0,06
Hellinger	0,06
Média Harmônica	0,06
Jensen-Shannon	0,06
Kullback-Leibler	0,06
Rényi	0,06
Triangular	0,06

**Tabela A.14: Valores ENL da região 2 HV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama.**

<b>Distâncias</b>	<b>ENL</b>
Aritmética Geométrica	0,06
Bhattacharyya	0,06
Hellinger	0,06
Média Harmônica	0,06
Jensen-Shannon	0,06
Kullback-Leibler	0,06
Rényi	0,06
Triangular	0,06

**Tabela A.15: Valores ENL da região 2 HV dos demais filtros.**

<b>Filtros</b>	<b>ENL</b>
FANS	0,06
FNLM	0,09
FROST	0,07
LEE	0,06
NLM	0,11
NLM-SAP	0,14
OBNL	0,05
PNLM	0,27
PPB GAUSS IT	0,07
PB GAUSS NIT	0,08
PPB NAKA IT	0,06
PPB NAKA NIT	0,07
SAR-BM3D	0,06

**Tabela A.16: Valores ENL da região 3 HV do filtro proposto com as distâncias estocásticas e estimadores da  $G_I^0$ .**

<b>Distâncias</b>	<b>ENL</b>
Aritmética Geométrica	1,04
Bhattacharyya	1,04
Hellinger	1,04
Média Harmônica	1,02
Jensen-Shannon	1,04
Kullback-Leibler	1,00
Rényi	1,00
Triangular	1,00

**Tabela A.17: Valores ENL da região 3 HV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama.**

<b>Distâncias</b>	<b>ENL</b>
Aritmética Geométrica	0,97
Bhattacharyya	0,97
Hellinger	0,97
Média Harmônica	0,95
Jensen-Shannon	0,97
Kullback-Leibler	0,93
Rényi	0,94
Triangular	0,94

**Tabela A.18: Valores ENL da região 3 HV dos demais filtros.**

<b>Filtros</b>	<b>ENL</b>
FANS	1,05
FNLM	1,59
FROST	1,69
LEE	1,47
NLM	1,92
NLM-SAP	2,34
OBNL	0,66
PNLM	3,07
PPB GAUSS IT	1,65
PB GAUSS NIT	1,73
PPB NAKA IT	1,01
PPB NAKA NIT	1,81
SAR-BM3D	0,98

**Tabela A.19: Valores ENL da região 1 VV do filtro proposto com as distâncias estocásticas e estimadores da  $G_I^0$ .**

<b>Distâncias</b>	<b>ENL</b>
Aritmética Geométrica	8,36
Bhattacharyya	8,40
Hellinger	8,43
Média Harmônica	7,67
Jensen-Shannon	8,45
Kullback-Leibler	7,31
Rényi	7,36
Triangular	7,32

**Tabela A.20: Valores ENL da região 1 VV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama.**

<b>Distâncias</b>	<b>ENL</b>
Aritmética Geométrica	9,77
Bhattacharyya	9,84
Hellinger	9,88
Média Harmônica	8,63
Jensen-Shannon	9,92
Kullback-Leibler	7,26
Rényi	7,37
Triangular	7,30

**Tabela A.21: Valores ENL da região 1 VV dos demais filtros.**

<b>Filtros</b>	<b>ENL</b>
FANS	8,54
FNLM	24,83
FROST	10,13
LEE	4,78
NLM	27,87
NLM-SAP	8,02
OBNL	12,09
PNLM	7,63
PPB GAUSS IT	44,04
PB GAUSS NIT	25,66
PPB NAKA IT	8,12
PPB NAKA NIT	20,54
SAR-BM3D	6,07

**Tabela A.22: Valores ENL da região 2 VV do filtro proposto com as distâncias estocásticas e estimadores da  $G_I^0$ .**

<b>Distâncias</b>	<b>ENL</b>
Aritmética Geométrica	0,24
Bhattacharyya	0,24
Hellinger	0,24
Média Harmônica	0,23
Jensen-Shannon	0,24
Kullback-Leibler	0,22
Rényi	0,22
Triangular	0,22

**Tabela A.23: Valores ENL da região 2 VV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama.**

<b>Distâncias</b>	<b>ENL</b>
Aritmética Geométrica	0,39
Bhattacharyya	0,39
Hellinger	0,39
Média Harmônica	0,38
Jensen-Shannon	0,39
Kullback-Leibler	0,37
Rényi	0,37
Triangular	0,37

**Tabela A.24: Valores ENL da região 2 VV dos demais filtros.**

<b>Filtros</b>	<b>ENL</b>
FANS	0,17
FNLM	0,59
FROST	0,26
LEE	0,23
NLM	0,79
NLM-SAP	0,97
OBNL	0,17
PNLM	1,49
PPB GAUSS IT	0,06
PB GAUSS NIT	0,58
PPB NAKA IT	0,19
PPB NAKA NIT	0,30
SAR-BM3D	0,17

**Tabela A.25: Valores ENL da região 3 VV do filtro proposto com as distâncias estocásticas e estimadores da  $G_I^0$ .**

<b>Distâncias</b>	<b>ENL</b>
Aritmética Geométrica	2,13
Bhattacharyya	2,13
Hellinger	2,14
Média Harmônica	2,02
Jensen-Shannon	2,14
Kullback-Leibler	1,93
Rényi	1,94
Triangular	1,93

**Tabela A.26: Valores ENL da região 3 VV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama.**

<b>Distâncias</b>	<b>ENL</b>
Aritmética Geométrica	4,13
Bhattacharyya	4,16
Hellinger	4,16
Média Harmônica	3,88
Jensen-Shannon	4,17
Kullback-Leibler	3,46
Rényi	3,49
Triangular	3,49

**Tabela A.27: Valores ENL da região 3 VV dos demais filtros.**

<b>Filtros</b>	<b>ENL</b>
FANS	1,56
FNLM	2,71
FROST	2,36
LEE	2,03
NLM	3,58
NLM-SAP	4,73
OBNL	1,61
PNLM	9,26
PPB GAUSS IT	2,42
PB GAUSS NIT	2,81
PPB NAKA IT	1,35
PPB NAKA NIT	2,63
SAR-BM3D	1,41

## A.2 Índice B

**Tabela A.28:** Valores do índice B da região 1 HH do filtro proposto com as distâncias estocásticas e estimadores da  $G_I^0$ .

<b>Distâncias</b>	<b>B</b>
Aritmética Geométrica	1,00
Bhattacharyya	1,01
Hellinger	1,02
Média Harmônica	0,97
Jensen-Shannon	1,02
Kullback-Leibler	0,93
Rényi	0,93
Triangular	0,93

**Tabela A.29:** Valores do índice B da região 1 HH do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama.

<b>Distâncias</b>	<b>B</b>
Aritmética Geométrica	1,16
Bhattacharyya	1,16
Hellinger	1,17
Média Harmônica	1,13
Jensen-Shannon	1,17
Kullback-Leibler	1,09
Rényi	1,09
Triangular	1,09

**Tabela A.30: Valores do índice B da região 1 HH dos demais filtros.**

<b>Filtros</b>	<b>B</b>
FANS	0,26
FNLM	0,47
FROST	0,64
LEE	0,67
NLM	0,55
NLMSAP	0,64
OBNL	0,51
PNLM	2,44
PPB GAUSS IT	0,51
PPB GAUSS NIT	0,48
PPB NAKA IT	0,29
PPB NAKA NIT	0,61
SAR-BM3D	0,22

**Tabela A.31: Valores do índice B da região 2 HH do filtro proposto com as distâncias estocásticas e estimadores da  $G_I^0$ .**

<b>Distâncias</b>	<b>B</b>
Aritmética Geométrica	1,25
Bhattacharyya	1,28
Hellinger	1,30
Média Harmônica	1,21
Jensen-Shannon	1,32
Kullback-Leibler	1,13
Rényi	1,14
Triangular	1,15

**Tabela A.32: Valores do índice B da região 2 HH do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama.**

<b>Distâncias</b>	<b>B</b>
Aritmética Geométrica	1,54
Bhattacharyya	1,57
Hellinger	1,59
Média Harmônica	1,50
Jensen-Shannon	1,61
Kullback-Leibler	1,40
Rényi	1,40
Triangular	1,42

**Tabela A.33: Valores do índice B da região 2 HH dos demais filtros.**

<b>Filtros</b>	<b>B</b>
FANS	0,26
FNLM	0,47
FROST	0,71
LEE	0,76
NLM	0,59
NLMSAP	0,73
OBNL	0,65
PNLM	3,12
PPB GAUSS IT	0,52
PPB GAUSS NIT	0,48
PPB NAKA IT	0,31
PPB NAKA NIT	0,64
SAR-BM3D	0,22

**Tabela A.34: Valores do índice B da região 3 HH do filtro proposto com as distâncias estocásticas e estimadores da  $G_I^0$ .**

<b>Distâncias</b>	<b>B</b>
Aritmética Geométrica	1,06
Bhattacharyya	1,07
Hellinger	1,07
Média Harmônica	1,02
Jensen-Shannon	1,08
Kullback-Leibler	0,98
Rényi	0,98
Triangular	0,98

**Tabela A.35: Valores do índice B da região 3 HH do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama.**

<b>Distâncias</b>	<b>B</b>
Aritmética Geométrica	1,13
Bhattacharyya	1,14
Hellinger	1,15
Média Harmônica	1,08
Jensen-Shannon	1,15
Kullback-Leibler	1,01
Rényi	1,01
Triangular	1,01

**Tabela A.36: Valores do índice B da região 3 HH dos demais filtros.**

<b>Filtros</b>	<b>B</b>
FANS	0,26
FNLM	0,37
FROST	0,73
LEE	0,74
NLM	0,54
NLMSAP	0,69
OBNL	0,47
PNLM	0,85
PPB GAUSS IT	0,50
PPB GAUSS NIT	0,47
PPB NAKA IT	0,28
PPB NAKA NIT	0,69
SAR-BM3D	0,21

**Tabela A.37: Valores do índice B da região 1 HV do filtro proposto com as distâncias estocásticas e estimadores da  $G_7^0$ .**

<b>Distâncias</b>	<b>B</b>
Aritmética Geométrica	0,61
Bhattacharyya	0,59
Hellinger	0,59
Média Harmônica	0,55
Jensen-Shannon	0,59
Kullback-Leibler	0,54
Rényi	0,53
Triangular	0,54

**Tabela A.38: Valores do índice B da região 1 HV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama.**

<b>Distâncias</b>	<b>B</b>
Aritmética Geométrica	0,59
Bhattacharyya	0,59
Hellinger	0,59
Média Harmônica	0,57
Jensen-Shannon	0,59
Kullback-Leibler	0,55
Rényi	0,55
Triangular	0,55

**Tabela A.39: Valores do índice B da região 1 HV dos demais filtros.**

<b>Filtros</b>	<b>B</b>
FANS	0,26
FNLM	0,61
FROST	0,69
LEE	0,69
NLM	0,68
NLMSAP	0,78
OBNL	0,04
PNLM	3,09
PPB GAUSS IT	0,65
PPB GAUSS NIT	0,58
PPB NAKA IT	0,27
PPB NAKA NIT	0,66
SAR-BM3D	0,22

**Tabela A.40: Valores do índice B da região 2 HV do filtro proposto com as distâncias estocásticas e estimadores da  $G_7^0$ .**

<b>Distâncias</b>	<b>B</b>
Aritmética Geométrica	0,65
Bhattacharyya	0,54
Hellinger	0,64
Média Harmônica	0,59
Jensen-Shannon	0,64
Kullback-Leibler	0,56
Rényi	0,56
Triangular	0,56

**Tabela A.41: Valores do índice B da região 2 HV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama.**

<b>Distâncias</b>	<b>B</b>
Aritmética Geométrica	0,68
Bhattacharyya	0,68
Hellinger	0,68
Média Harmônica	0,65
Jensen-Shannon	0,68
Kullback-Leibler	0,63
Rényi	0,63
Triangular	0,63

**Tabela A.42: Valores do índice B da região 2 HV dos demais filtros.**

<b>Filtros</b>	<b>B</b>
FANS	0,26
FNLM	0,58
FROST	0,73
LEE	0,72
NLM	0,69
NLMSAP	0,82
OBNL	0,10
PNLM	4,52
PPB GAUSS IT	0,64
PPB GAUSS NIT	0,57
PPB NAKA IT	0,28
PPB NAKA NIT	0,69
SAR-BM3D	0,22

**Tabela A.43: Valores do índice B da região 3 HV do filtro proposto com as distâncias estocásticas e estimadores da  $G_7^0$ .**

<b>Distâncias</b>	<b>B</b>
Aritmética Geométrica	0,61
Bhattacharyya	0,61
Hellinger	0,61
Média Harmônica	0,57
Jensen-Shannon	0,61
Kullback-Leibler	0,55
Rényi	0,55
Triangular	0,55

**Tabela A.44: Valores do índice B da região 3 HV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama.**

<b>Distâncias</b>	<b>B</b>
Aritmética Geométrica	0,49
Bhattacharyya	0,49
Hellinger	0,49
Média Harmônica	0,48
Jensen-Shannon	0,49
Kullback-Leibler	0,47
Rényi	0,47
Triangular	0,47

**Tabela A.45: Valores do índice B da região 3 HV dos demais filtros.**

<b>Filtros</b>	<b>B</b>
FANS	0,27
FNLM	0,38
FROST	0,77
LEE	0,72
NLM	0,58
NLMSAP	0,75
OBNL	0,00
PNLM	0,74
PPB GAUSS IT	0,56
PPB GAUSS NIT	0,52
PPB NAKA IT	0,30
PPB NAKA NIT	0,76
SAR-BM3D	0,24

**Tabela A.46: Valores do índice B da região 1 VV do filtro proposto com as distâncias estocásticas e estimadores da  $G_1^0$ .**

<b>Distâncias</b>	<b>B</b>
Aritmética Geométrica	0,97
Bhattacharyya	0,97
Hellinger	0,97
Média Harmônica	0,94
Jensen-Shannon	0,97
Kullback-Leibler	0,90
Rényi	0,91
Triangular	0,90

**Tabela A.47: Valores do índice B da região 1 VV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama.**

<b>Distâncias</b>	<b>B</b>
Aritmética Geométrica	1,16
Bhattacharyya	1,16
Hellinger	1,16
Média Harmônica	1,12
Jensen-Shannon	1,16
Kullback-Leibler	1,08
Rényi	1,08
Triangular	1,08

**Tabela A.48: Valores do índice B da região 1 VV dos demais filtros.**

<b>Filtros</b>	<b>B</b>
FANS	0,27
FNLM	0,46
FROST	0,70
LEE	0,71
NLM	0,58
NLMSAP	0,68
OBNL	0,41
PNLM	0,74
PPB GAUSS IT	0,55
PPB GAUSS NIT	0,50
PPB NAKA IT	0,29
PPB NAKA NIT	0,66
SAR-BM3D	0,23

**Tabela A.49: Valores do índice B da região 2 VV do filtro proposto com as distâncias estocásticas e estimadores da  $G_7^0$ .**

<b>Distâncias</b>	<b>B</b>
Aritmética Geométrica	1,14
Bhattacharyya	1,14
Hellinger	1,14
Média Harmônica	1,10
Jensen-Shannon	1,15
Kullback-Leibler	1,06
Rényi	1,06
Triangular	1,06

**Tabela A.50: Valores do índice B da região 2 VV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama.**

<b>Distâncias</b>	<b>B</b>
Aritmética Geométrica	1,56
Bhattacharyya	1,57
Hellinger	1,57
Média Harmônica	1,51
Jensen-Shannon	1,57
Kullback-Leibler	1,44
Rényi	1,44
Triangular	1,44

**Tabela A.51: Valores do índice B da região 2 VV dos demais filtros.**

<b>Filtros</b>	<b>B</b>
FANS	0,26
FNLM	0,41
FROST	0,77
LEE	0,80
NLM	0,56
NLMSAP	0,72
OBNL	0,40
PNLM	1,19
PPB GAUSS IT	0,52
PPB GAUSS NIT	0,48
PPB NAKA IT	0,31
PPB NAKA NIT	0,69
SAR-BM3D	0,22

**Tabela A.52: Valores do índice B da região 3 VV do filtro proposto com as distâncias estocásticas e estimadores da  $G_7^0$ .**

<b>Distâncias</b>	<b>B</b>
Aritmética Geométrica	1,06
Bhattacharyya	1,07
Hellinger	1,07
Média Harmônica	1,02
Jensen-Shannon	1,07
Kullback-Leibler	0,99
Rényi	0,99
Triangular	0,99

**Tabela A.53: Valores do índice B da região 3 VV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama.**

<b>Distâncias</b>	<b>B</b>
Aritmética Geométrica	1,46
Bhattacharyya	1,46
Hellinger	1,47
Média Harmônica	1,41
Jensen-Shannon	1,47
Kullback-Leibler	1,34
Rényi	1,35
Triangular	1,34

**Tabela A.54: Valores do índice B da região 3 VV dos demais filtros.**

<b>Filtros</b>	<b>B</b>
FANS	0,27
FNLM	0,40
FROST	0,80
LEE	0,79
NLM	0,58
NLMSAP	0,75
OBNL	0,37
PNLM	0,91
PPB GAUSS IT	0,54
PPB GAUSS NIT	0,50
PPB NAKA IT	0,29
PPB NAKA NIT	0,74
SAR-BM3D	0,23

### A.3 Índice $C_{\hat{f}}$

**Tabela A.55: Valores do índice  $C_{\hat{f}}$  da região 1 HH do filtro proposto com as distâncias estocásticas e estimadores da  $G_I^0$ . Valor  $C_f = 3, 12$ .**

Distâncias	$C_{\hat{f}}$
Aritmética Geométrica	1,86
Bhattacharyya	1,80
Hellinger	1,78
Média Harmônica	1,90
Jensen-Shannon	1,75
Kullback-Leibler	2,04
Rényi	2,03
Triangular	2,01

**Tabela A.56: Valores do índice  $C_{\hat{f}}$  da região 1 HH do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. Valor  $C_f = 3, 12$ .**

Distâncias	$C_{\hat{f}}$
Aritmética Geométrica	1,52
Bhattacharyya	1,51
Hellinger	1,50
Média Harmônica	1,58
Jensen-Shannon	1,50
Kullback-Leibler	1,65
Rényi	1,65
Triangular	1,65

**Tabela A.57: Valores do índice  $C_{\hat{f}}$  da região 1 HH com os demais filtros. Valor  $C_f = 3,12$ .**

<b>Filtros</b>	$C_{\hat{f}}$
FANS	3,04
FNLM	1,16
FROST	2,39
LEE	2,22
NLM	1,05
NLMSAP	1,04
OBNL	2,82
PNLM	1,19
PPB GAUSS IT	2,03
PPB GAUSS NIT	1,24
PPB NAKA IT	3,07
PPB NAKA NIT	2,25
SAR-BM3D	3,32

**Tabela A.58: Valores do índice  $C_{\hat{f}}$  da região 2 HH do filtro proposto com as distâncias estocásticas e estimadores da  $G_l^0$ . Valor  $C_f = 3,35$ .**

<b>Distâncias</b>	$C_{\hat{f}}$
Aritmética Geométrica	1,62
Bhattacharyya	1,55
Hellinger	1,48
Média Harmônica	1,68
Jensen-Shannon	1,42
Kullback-Leibler	1,86
Rényi	1,85
Triangular	1,80

**Tabela A.59: Valores do índice  $C_{\hat{f}}$  da região 2 HH do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. Valor  $C_f = 3,35$ .**

<b>Distâncias</b>	$C_{\hat{f}}$
Aritmética Geométrica	1,21
Bhattacharyya	1,19
Hellinger	1,17
Média Harmônica	1,25
Jensen-Shannon	1,16
Kullback-Leibler	1,39
Rényi	1,37
Triangular	1,34

**Tabela A.60: Valores do índice  $C_{\hat{f}}$  da região 2 HH com os demais filtros. Valor  $C_f = 3,35$ .**

<b>Filtros</b>	$C_{\hat{f}}$
FANS	3,38
FNLM	0,95
FROST	2,78
LEE	2,10
NLM	0,82
NLMSAP	0,80
OBNL	2,77
PNLM	0,95
PPB GAUSS IT	0,96
PPB GAUSS NIT	0,98
PPB NAKA IT	2,79
PPB NAKA NIT	2,16
SAR-BM3D	3,60

**Tabela A.61: Valores do índice  $C_{\hat{f}}$  da região 3 HH do filtro proposto com as distâncias estocásticas e estimadores da  $G_I^0$ . Valor  $C_f = 2,35$ .**

<b>Distâncias</b>	$C_{\hat{f}}$
Aritmética Geométrica	1,42
Bhattacharyya	1,40
Hellinger	1,40
Média Harmônica	1,46
Jensen-Shannon	1,39
Kullback-Leibler	1,52
Rényi	1,52
Triangular	1,52

**Tabela A.62: Valores do índice  $C_{\hat{f}}$  da região 3 HH do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. Valor  $C_f = 2,35$ .**

<b>Distâncias</b>	$C_{\hat{f}}$
Aritmética Geométrica	1,31
Bhattacharyya	1,30
Hellinger	1,30
Média Harmônica	1,36
Jensen-Shannon	1,29
Kullback-Leibler	1,42
Rényi	1,42
Triangular	1,41

**Tabela A.63: Valores do índice  $C_{\hat{f}}$  da região 3 HH com os demais filtros. Valor  $C_f = 2,35$ .**

<b>Filtros</b>	$C_{\hat{f}}$
FANS	2,33
FNLM	1,28
FROST	1,78
LEE	1,61
NLM	0,85
NLMSAP	0,74
OBNL	2,10
PNLM	0,81
PPB GAUSS IT	1,48
PPB GAUSS NIT	1,05
PPB NAKA IT	2,23
PPB NAKA NIT	1,49
SAR-BM3D	2,48

**Tabela A.64: Valores do índice  $C_{\hat{f}}$  da região 1 HV do filtro proposto com as distâncias estocásticas e estimadores da  $G_I^0$ . Valor  $C_f = 1,80$ .**

<b>Distâncias</b>	$C_{\hat{f}}$
Aritmética Geométrica	1,55
Bhattacharyya	1,55
Hellinger	1,55
Média Harmônica	1,59
Jensen-Shannon	1,55
Kullback-Leibler	1,61
Rényi	1,61
Triangular	1,61

**Tabela A.65: Valores do índice  $C_{\hat{f}}$  da região 1 HV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. Valor  $C_f = 1,80$ .**

<b>Distâncias</b>	$C_{\hat{f}}$
Aritmética Geométrica	1,53
Bhattacharyya	1,53
Hellinger	1,53
Média Harmônica	1,54
Jensen-Shannon	1,53
Kullback-Leibler	1,56
Rényi	1,55
Triangular	1,56

**Tabela A.66: Valores do índice  $C_{\hat{f}}$  da região 1 HV com os demais filtros. Valor  $C_f = 1,80$ .**

<b>Filtros</b>	$C_{\hat{f}}$
FANS	1,49
FNLM	0,79
FROST	1,37
LEE	1,34
NLM	0,78
NLMSAP	0,79
OBNL	2,07
PNLM	1,44
PPB GAUSS IT	0,74
PPB GAUSS NIT	0,79
PPB NAKA IT	1,76
PPB NAKA NIT	1,35
SAR-BM3D	1,89

**Tabela A.67: Valores do índice  $C_{\hat{f}}$  da região 2 HV do filtro proposto com as distâncias estocásticas e estimadores da  $G_I^0$ . Valor  $C_f = 1,80$ .**

<b>Distâncias</b>	$C_{\hat{f}}$
Aritmética Geométrica	1,49
Bhattacharyya	1,49
Hellinger	1,49
Média Harmônica	1,53
Jensen-Shannon	1,49
Kullback-Leibler	1,57
Rényi	1,57
Triangular	1,57

**Tabela A.68: Valores do índice  $C_{\hat{f}}$  da região 2 HV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. Valor  $C_f = 1,80$ .**

<b>Distâncias</b>	$C_{\hat{f}}$
Aritmética Geométrica	1,54
Bhattacharyya	1,54
Hellinger	1,54
Média Harmônica	1,59
Jensen-Shannon	1,54
Kullback-Leibler	1,63
Rényi	1,63
Triangular	1,63

**Tabela A.69: Valores do índice  $C_{\hat{f}}$  da região 2 HV com os demais filtros. Valor  $C_f = 1,80$ .**

<b>Filtros</b>	$C_{\hat{f}}$
FANS	1,60
FNLM	0,81
FROST	1,39
LEE	1,29
NLM	0,78
NLMSAP	0,78
OBNL	2,06
PNLM	0,95
PPB GAUSS IT	0,86
PPB GAUSS NIT	0,85
PPB NAKA IT	1,64
PPB NAKA NIT	1,10
SAR-BM3D	1,88

**Tabela A.70: Valores do índice  $C_{\hat{f}}$  da região 3 HV do filtro proposto com as distâncias estocásticas e estimadores da  $G_I^0$ . Valor  $C_f = 1,02$ .**

<b>Distâncias</b>	$C_{\hat{f}}$
Aritmética Geométrica	0,89
Bhattacharyya	0,89
Hellinger	0,89
Média Harmônica	0,92
Jensen-Shannon	0,89
Kullback-Leibler	0,94
Rényi	0,94
Triangular	0,93

**Tabela A.71: Valores do índice  $C_{\hat{f}}$  da região 3 HV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. Valor  $C_f = 1,02$ .**

<b>Distâncias</b>	$C_{\hat{f}}$
Aritmética Geométrica	0,98
Bhattacharyya	0,98
Hellinger	0,98
Média Harmônica	1,00
Jensen-Shannon	0,98
Kullback-Leibler	1,01
Rényi	1,01
Triangular	1,01

**Tabela A.72: Valores do índice  $C_{\hat{f}}$  da região 3 HV com os demais filtros. Valor  $C_f = 1,02$ .**

<b>Filtros</b>	$C_{\hat{f}}$
FANS	0,96
FNLM	0,55
FROST	0,70
LEE	0,72
NLM	0,45
NLMSAP	0,41
OBNL	1,25
PNLM	0,40
PPB GAUSS IT	0,46
PPB GAUSS NIT	0,49
PPB NAKA IT	0,98
PPB NAKA NIT	0,56
SAR-BM3D	1,04

**Tabela A.73: Valores do índice  $C_{\hat{f}}$  da região 1 VV do filtro proposto com as distâncias estocásticas e estimadores da  $G_I^0$ . Valor  $C_f = 2,67$ .**

<b>Distâncias</b>	<b><math>C_{\hat{f}}</math></b>
Aritmética Geométrica	1,76
Bhattacharyya	1,76
Hellinger	1,76
Média Harmônica	1,81
Jensen-Shannon	1,75
Kullback-Leibler	1,87
Rényi	1,87
Triangular	1,87

**Tabela A.74: Valores do índice  $C_{\hat{f}}$  da região 1 VV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. Valor  $C_f = 2,67$ .**

<b>Distâncias</b>	<b><math>C_{\hat{f}}</math></b>
Aritmética Geométrica	1,35
Bhattacharyya	1,35
Hellinger	1,35
Média Harmônica	1,41
Jensen-Shannon	1,34
Kullback-Leibler	1,47
Rényi	1,47
Triangular	1,47

**Tabela A.75: Valores do índice  $C_{\hat{f}}$  da região 1 VV com os demais filtros. Valor  $C_f = 2,67$ .**

<b>Filtros</b>	$C_{\hat{f}}$
FANS	2,90
FNLM	1,11
FROST	2,12
LEE	1,86
NLM	0,90
NLMSAP	0,86
OBNL	2,35
PNLM	0,92
PPB GAUSS IT	1,85
PPB GAUSS NIT	1,12
PPB NAKA IT	2,41
PPB NAKA NIT	1,77
SAR-BM3D	2,84

**Tabela A.76: Valores do índice  $C_{\hat{f}}$  da região 2 VV do filtro proposto com as distâncias estocásticas e estimadores da  $G_l^0$ . Valor  $C_f = 2,22$ .**

<b>Distâncias</b>	$C_{\hat{f}}$
Aritmética Geométrica	1,46
Bhattacharyya	1,45
Hellinger	1,45
Média Harmônica	1,50
Jensen-Shannon	1,44
Kullback-Leibler	1,55
Rényi	1,55
Triangular	1,55

**Tabela A.77: Valores do índice  $C_{\hat{f}}$  da região 2 VV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. Valor  $C_f = 2,22$ .**

<b>Distâncias</b>	$C_{\hat{f}}$
Aritmética Geométrica	1,00
Bhattacharyya	0,99
Hellinger	0,99
Média Harmônica	1,05
Jensen-Shannon	0,99
Kullback-Leibler	1,13
Rényi	1,12
Triangular	1,12

**Tabela A.78: Valores do índice  $C_{\hat{f}}$  da região 2 VV com os demais filtros. Valor  $C_f = 2,22$ .**

<b>Filtros</b>	$C_{\hat{f}}$
FANS	2,32
FNLM	1,06
FROST	1,68
LEE	1,55
NLM	0,75
NLMSAP	0,67
OBNL	2,03
PNLM	0,64
PPB GAUSS IT	1,18
PPB GAUSS NIT	0,96
PPB NAKA IT	2,06
PPB NAKA NIT	1,44
SAR-BM3D	2,35

**Tabela A.79: Valores do índice  $C_{\hat{f}}$  da região 3 VV do filtro proposto com as distâncias estocásticas e estimadores da  $G_I^0$ . Valor  $C_f = 2,07$ .**

<b>Distâncias</b>	$C_{\hat{f}}$
Aritmética Geométrica	1,38
Bhattacharyya	1,38
Hellinger	1,37
Média Harmônica	1,44
Jensen-Shannon	1,37
Kullback-Leibler	1,51
Rényi	1,51
Triangular	1,51

**Tabela A.80: Valores do índice  $C_{\hat{f}}$  da região 3 VV do filtro proposto com as distâncias estocásticas e estimadores da Inversa da Gama. Valor  $C_f = 2,07$ .**

<b>Distâncias</b>	$C_{\hat{f}}$
Aritmética Geométrica	1,08
Bhattacharyya	1,08
Hellinger	1,08
Média Harmônica	1,13
Jensen-Shannon	1,08
Kullback-Leibler	1,19
Rényi	1,18
Triangular	1,18

**Tabela A.81: Valores do índice  $C_{\hat{f}}$  da região 3 VV com os demais filtros. Valor  $C_f = 2,07$ .**

<b>Filtros</b>	$C_{\hat{f}}$
FANS	2,17
FNLM	1,14
FROST	1,53
LEE	1,48
NLM	0,75
NLMSAP	0,67
OBNL	1,93
PNLM	0,74
PPB GAUSS IT	1,18
PPB GAUSS NIT	0,92
PPB NAKA IT	1,96
PPB NAKA NIT	1,38
SAR-BM3D	2,18