

UNIVERSIDADE FEDERAL DE SÃO CARLOS

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**FILTRAGEM NÃO-LOCAL DO RUÍDO
SPECKLE EM IMAGENS SAR COM
MODELAGEM ESTATÍSTICA DOS
COEFICIENTES DA WAVELET DE HAAR E
DISTÂNCIAS ESTOCÁSTICAS**

PEDRO AUGUSTO DE ALAGÃO PENNA

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

São Carlos – SP

Junho/2018

UNIVERSIDADE FEDERAL DE SÃO CARLOS

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**FILTRAGEM NÃO-LOCAL DO RUÍDO
SPECKLE EM IMAGENS SAR COM
MODELAGEM ESTATÍSTICA DOS
COEFICIENTES DA WAVELET DE HAAR E
DISTÂNCIAS ESTOCÁSTICAS**

PEDRO AUGUSTO DE ALAGÃO PENNA

Tese apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Doutor em Ciência da Computação, área de concentração: Processamento de Imagens e Sinais

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

São Carlos – SP

Junho/2018



UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências Exatas e de Tecnologia
Programa de Pós-Graduação em Ciência da Computação

Folha de Aprovação

Assinaturas dos membros da comissão examinadora que avaliou e aprovou a Defesa de Tese de Doutorado do candidato Pedro Augusto de Alagão Penna, realizada em 04/06/2018:

Prof. Dr. Nelson Delfino D'Avila Mascarenhas
UFSCar

Prof. Dr. José Hiroki Saito
UFSCar

Prof. Dr. Sidnei João Siqueira Sant'Anna
INPE

Prof. Dr. Murillo Rodrigo Petrucelli Homem
UFSCar

Prof. Dr. Sergio Shiguemi Furuie
USP

Para Taise, Marco, Maria e Ana.

AGRADECIMENTOS

Primeiramente agradeço a Deus por ter me dado forças para enfrentar todos os desafios que apareceram durante o desenvolvimento deste trabalho.

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

Agradeço aos meus pais: Marco e Maria pelo apoio e por acreditarem em mim. E à minha irmã Ana.

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

Agradeço à CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) pela concessão da bolsa durante todo o período de realização deste doutorado.

Agradeço ao Professor Alejandro Frery por ter fornecido a imagem SAR real da região de Munique para a realização de testes e avaliação dos resultados.

Agradeço também aos amigos, colegas e ex-colegas do GAPIS: Andre, Cid, Arthur, Bruno, Paulo, Amandia e Kathiani. E por fim, agradeço ao empenho do Ivan da secretaria do PPG-CC.

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

Friedrich Nietzsche

RESUMO

Devido ao processamento coerente dos sistemas de radar de abertura sintética (SAR - “Synthetic Aperture Radar”), o ruído multiplicativo “speckle” surge fornecendo uma aparência granulosa às imagens SAR. Este tipo de ruído dificulta a análise e interpretação das imagens da superfície terrestre. Portanto, a pesquisa por novas técnicas de filtragem do “speckle” é uma tarefa constante na literatura de Processamento de Imagens e Sinais.

Os atuais filtros do estado da arte na área de sensoriamento remoto exploram a filosofia da similaridade entre “patches” (janelas ou vizinhanças). O método apresentado nesta tese tem o propósito de melhorar um algoritmo de filtragem recentemente proposto: o “Non-Local Means” (NLM), o qual representou um novo paradigma para filtragem de imagens, e analisar e comparar sua capacidade de redução do “speckle” em imagens SAR de intensidade, técnica conhecida na literatura como “despeckling”. O filtro NLM foi originalmente desenvolvido para o ruído branco aditivo gaussiano (AWGN - “Additive White Gaussian Noise”).

O método proposto, que é uma extensão do filtro NLM, considera um cenário com o ruído mais forte, isto é, o “single look speckle”, e é possível atenuar o ruído substituindo a distância original utilizada para medir a similaridade entre “patches” (vizinhanças), a distância Euclidiana, pelas distâncias estocásticas e aplicar o filtro proposto no domínio da “wavelet” de Haar. Para alcançar este objetivo, os coeficientes da “wavelet” de Haar foram descritos pelas distribuições EP (“Exponential-Polynomial”) e Gama.

A principal contribuição desta proposta é trabalhar com o NLM, originalmente desenvolvido para o domínio espacial da imagem, diretamente no domínio das “wavelets”, ao computar as distâncias estocásticas baseando-se nas distribuições EP e Gama. Além disto, este trabalho mostra que é vantajoso utilizar métodos elaborados para o processamento pós-filtragem, como o “Dual Domain Filtering”(DDF) e “Data Adaptive Dual Domain Denoising”(DA3D), pois eles podem melhorar a qualidade da imagem filtrada tanto do método proposto quanto do algoritmo do estado da arte.

Por fim, é feita uma análise e comparação dos resultados do filtro proposto mostrando que essa nova abordagem foi capaz de atenuar o “speckle” para o caso mais agressivo, com alguns dos filtros recentes da literatura. Os resultados obtidos mostram que a abordagem proposta é competitiva.

Palavras-chave: SAR, “speckle”, “despeckling”, NLM, “wavelets”, distribuição EP, distâncias estocásticas

ABSTRACT

Due to the coherent processing of synthetic aperture radar (SAR) systems, multiplicative speckle noise arises providing a granular appearance in SAR images. This kind of noise makes it difficult to analyse and interpret Earth surface images. Therefore, the search for new techniques to mitigate the speckle is a constant task in the image processing literature. Current state-of-the-art filters in remote sensing area explore the philosophy of similarity between patches (neighborhoods). This thesis aims to expand a recently proposed filtering algorithm: the Non-Local Means (NLM), which represents a new paradigm for filtering images, and analyses and compares its capacity of speckle reduction in intensity SAR images, technique known in the literature as despeckling. This filter was originally proposed for the additive white Gaussian noise (AWGN).

The NLM filter extension considers a scenario with the more aggressive noise, i.e., the single-look speckle, and it is possible to attenuate the noise by replacing the original distance used to measure the similarity between patches, the Euclidean distance, with the stochastic distances and apply the proposed filter in the Haar wavelets domain. To achieve this goal, the Haar wavelet coefficients were described by the Exponential-Polynomial (EP) and Gamma distributions.

The main contribution of this proposal is to work with the NLM, originally developed for the image space domain, directly in the wavelets domain, by computing the stochastic distances based on the EP and Gamma distributions. In addition, this proposal shows that it is advantageous to use elaborate methods for post-filtering processing, such as Dual Domain Filtering (DDF) and Data Adaptive Dual Domain Denoising (DA3D), as they can improve the quality of the filtered image both of the proposed method and the state-of-the-art algorithm.

Finally, an analysis and comparison of the results of the proposed method are made, which show that this new approach was able to attenuate the presence of speckle in the more aggressive case, with some of the recent filters in the literature. The obtained results show that the proposed filter is competitive.

Keywords: SAR, speckle, despeckling, NLM, wavelets, EP distribution, stochastic distances

LISTA DE FIGURAS

| | | |
|-----|--|----|
| 2.1 | Região sendo imageada. O radar envia pulsos eletromagnéticos em direção à superfície e analisa o retorno do sinal. | 24 |
| 2.2 | Efeito granular do “speckle” após o imageamento. O ruído dificulta a análise e interpretação das imagens. | 24 |
| 2.3 | O retorno do eco na superfície é a somatória de várias ondas retroespalhadas. Há também ondas espalhadas, que não retornam ao radar (ARGENTI et al., 2013). | 25 |
| 2.4 | Exemplo de uma imagem SAR utilizada para a classificação de regiões que possuem diferentes graus de homogeneidade. Normalmente, área urbana é mais heterogênea. Já uma região de pasto é mais homogênea e possui sinais mais espalhados (NASCIMENTO; CINTRA; FRERY, 2010). | 25 |
| 2.5 | Gráficos das funções densidade de probabilidade comumente utilizadas para modelar o “speckle” (GONZALEZ; WOODS, 2007). | 26 |
| 3.1 | Representação dos subespaços de aproximação gerados pela MRA com a função de escala ρ | 33 |
| 3.2 | Representação dos subespaços V e W , que é o complemento ortogonal de V . . . | 33 |
| 3.3 | “Wavelet” de Haar. Ela é considerada a “wavelet” mais simples. Seu gráfico é um pulso retangular. | 35 |
| 3.4 | Representação das funções de limiarização. (a) sinal original. (b) “hard thresholding”. (c) “soft thresholding”. | 36 |
| 3.5 | FDP EP para diferentes “looks” considerando um nível de decomposição da “wavelet” de Haar (CHAN; PENG, 2003). Notar que o primeiro gráfico segue uma distribuição de Laplace, que é a diferença entre duas distribuições Exponenciais. | 39 |

| | | |
|------|---|----|
| 4.1 | Gráficos 3-D das distâncias estocásticas para a distribuição EP no caso “single look”. Os gráficos indicam que as distâncias obedecem as propriedades: homogênea, simétrica e não-negativa. O intervalo foi escolhido empiricamente. | 45 |
| 4.2 | Gráficos 3-D das distâncias estocásticas para a distribuição Gama no caso “single look”. Os gráficos indicam que as distâncias obedecem as propriedades: homogênea, simétrica e não-negativa. O intervalo foi escolhido empiricamente. | 46 |
| 5.1 | “Kernel” centralizado em um ponto (x,y) em uma imagem no domínio espacial. | 48 |
| 5.2 | Esquema do algoritmo BM3D. Adaptada de (LEBRUN, 2012). | 49 |
| 5.3 | Representação das janelas do NLM. 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. | 50 |
| 5.4 | Exemplo de atribuição de pesos no NLM: 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). | 52 |
| 7.1 | Decomposição de uma imagem pela Transformada “wavelet”. | 59 |
| 7.2 | Gráfico da fdp do “speckle”. L representa o número de “looks”. Quanto maior o L , a função se aproxima mais de uma Gaussiana no gráfico (b). | 60 |
| 7.3 | Diagrama do método proposto com 1 nível de decomposição utilizando a “wavelet” de Haar. | 62 |
| 7.4 | Diagrama do pós-processamento. | 62 |
| 7.5 | Código para gerar o “speckle”. | 62 |
| 7.6 | Ruído “speckle single look” para os experimentos sintéticos. | 63 |
| 7.7 | Resultados para Barbara com a distância Aritmética-Geométrica. | 65 |
| 7.8 | Resultados para Cameraman com a distância de Rényi. | 66 |
| 7.9 | Resultados para Concord com a distância de Rényi. | 67 |
| 7.10 | Resultados para Lena com a distância de Kullback-Leibler. | 68 |
| 7.11 | Histogramas das imagens da Lena. | 71 |

| | | |
|------|--|----|
| 7.12 | Histogramas dos coeficientes ruidosos. | 71 |
| 7.13 | Histogramas dos coeficientes filtrados. | 72 |
| 7.14 | Histogramas dos coeficientes filtrados limiarizados. | 72 |
| 7.15 | Imagem SAR “single look” HH de Oberpfaffenhofen. | 73 |
| 7.16 | Regiões de dimensão 512×512 escolhidas. | 73 |
| 7.17 | Resultados para a região 1 (R1). | 75 |
| 7.18 | Resultados para a região 2 (R2). | 76 |
| 7.19 | Resultados para a região 3 (R3). | 77 |
| 7.20 | Razão da região 1 (R1). | 79 |
| 7.21 | Razão da região 2 (R2). | 80 |
| 7.22 | Razão da região 3 (R3). | 81 |

LISTA DE TABELAS

| | | |
|-----|---|----|
| 4.1 | Funções h e ϕ utilizadas para desenvolver as distâncias estocásticas. Tabela adaptada de (NASCIMENTO; CINTRA; FRERY, 2010). | 41 |
| 7.1 | Configuração dos parâmetros para os experimentos sintéticos. | 64 |
| 7.2 | Valores do PSNR, SSIM e tempo de processamento para a imagem da Barbara. Os valores são médias sobre dez realizações do “speckle” (distância da Aritmética-Geométrica). | 69 |
| 7.3 | Valores do PSNR, SSIM e tempo de processamento para a imagem do Cameraman. Os valores são médias sobre dez realizações do “speckle” (distância de Rényi). | 69 |
| 7.4 | Valores do PSNR, SSIM e tempo de processamento para a imagem de Concord. Os valores são médias sobre dez realizações do “speckle” (distância de Rényi). | 69 |
| 7.5 | Valores do PSNR, SSIM e tempo de processamento para a imagem da Lena. Os valores são médias sobre dez realizações do “speckle” (distância de Kullback-Leibler). | 70 |
| 7.6 | Valores da média, desvio padrão, PSNR, SSIM do filtro proposto com e sem limiarização para a imagem da Lena. Os valores são médias sobre dez realizações do “speckle” com a distância de Kullback-Leibler. PSNR da imagem ruidosa: 5,65 | 72 |
| 7.7 | Média (μ_r) e desvio padrão (σ_r) da razão da região 1 com a distância de Jensen-Shannon. Os melhores valores estão marcados em negrito. | 78 |
| 7.8 | Média (μ_r) e desvio padrão (σ_r) da razão da região 2 com a distância Aritmética-Geométrica. Os melhores valores estão marcados em negrito. | 78 |
| 7.9 | Média (μ_r) e desvio padrão (σ_r) da razão da região 3 com a distância da Média-Harmônica. Os melhores valores estão marcados em negrito. | 82 |

| | | |
|------|---|-----|
| A.1 | Barbara: Aritmética-Geométrica. | 95 |
| A.2 | Barbara: Bhattacharyya. | 95 |
| A.3 | Barbara: Hellinger. | 96 |
| A.4 | Barbara: Jensen-Shannon. | 96 |
| A.5 | Barbara: Kullback-Leibler. | 97 |
| A.6 | Barbara: Média-Harmônica. | 97 |
| A.7 | Barbara: Rényi. | 98 |
| A.8 | Barbara: Triangular. | 98 |
| A.9 | Cameraman: Aritmética-Geométrica. | 99 |
| A.10 | Cameraman: Bhattacharyya. | 99 |
| A.11 | Cameraman: Hellinger. | 100 |
| A.12 | Cameraman: Jensen-Shannon. | 100 |
| A.13 | Cameraman: Kullback-Leibler. | 101 |
| A.14 | Cameraman: Média-Harmônica. | 101 |
| A.15 | Cameraman: Rényi. | 102 |
| A.16 | Cameraman: Triangular. | 102 |
| A.17 | Concord: Aritmética-Geométrica. | 103 |
| A.18 | Concord: Bhattacharyya. | 103 |
| A.19 | Concord: Hellinger. | 104 |
| A.20 | Concord: Jensen-Shannon. | 104 |
| A.21 | Concord: Kullback-Leibler. | 105 |
| A.22 | Concord: Média-Harmônica. | 105 |
| A.23 | Concord: Rényi. | 106 |
| A.24 | Concord: Triangular. | 106 |
| A.25 | Lena: Aritmética-Geométrica. | 107 |
| A.26 | Lena: Bhattacharyya. | 107 |

| | |
|---|-----|
| A.27 Lena: Hellinger. | 108 |
| A.28 Lena: Jensen-Shannon. | 108 |
| A.29 Lena: Kullback-Leibler. | 109 |
| A.30 Lena: Média-Harmônica. | 109 |
| A.31 Lena: Rényi. | 110 |
| A.32 Lena: Triangular. | 110 |
| A.33 R1: Aritmética-Geométrica. | 111 |
| A.34 R1: Bhattacharyya. | 111 |
| A.35 R1: Hellinger. | 112 |
| A.36 R1: Jensen-Shannon. | 112 |
| A.37 R1: Kullback-Leibler. | 113 |
| A.38 R1: Média-Harmônica. | 113 |
| A.39 R1: Rényi. | 114 |
| A.40 R1: Triangular. | 114 |
| A.41 R2: Aritmética-Geométrica. | 115 |
| A.42 R2: Bhattacharyya. | 115 |
| A.43 R2: Hellinger. | 116 |
| A.44 R2: Jensen-Shannon. | 116 |
| A.45 R2: Kullback-Leibler. | 117 |
| A.46 R2: Média-Harmônica. | 117 |
| A.47 R2: Rényi. | 118 |
| A.48 R2: Triangular. | 118 |
| A.49 R3: Aritmética-Geométrica. | 119 |
| A.50 R3: Bhattacharyya. | 119 |
| A.51 R3: Hellinger. | 120 |
| A.52 R3: Jensen-Shannon. | 120 |

| | |
|------------------------------------|-----|
| A.53 R3: Kullback-Leibler. | 121 |
| A.54 R3: Média-Harmônica. | 121 |
| A.55 R3: Rényi. | 122 |
| A.56 R3: Triangular. | 122 |

SUMÁRIO

| | |
|---|-----------|
| CAPÍTULO 1 – INTRODUÇÃO | 18 |
| 1.1 Motivação e objetivo | 21 |
| 1.2 Organização | 21 |
| CAPÍTULO 2 – IMAGENS SAR E “SPECKLE” | 23 |
| CAPÍTULO 3 – DOMÍNIO DA “WAVELET” DE HAAR: A DISTRIBUIÇÃO EP | 28 |
| 3.1 Análise de Fourier | 29 |
| 3.1.1 Séries de Fourier | 29 |
| 3.1.2 Transformada de Fourier | 29 |
| 3.1.3 “Short Time Fourier Transform” (STFT) | 30 |
| 3.2 “Wavelets” | 31 |
| 3.2.1 Transformada de Wavelet Contínua (CWT) | 32 |
| 3.2.2 Análise por Multiresolução (MRA) | 32 |
| 3.2.2.1 Subespaço de Aproximação | 33 |
| 3.2.2.2 Subespaço da Wavelet | 33 |
| 3.2.3 Transformada Wavelet Discreta (DWT) | 34 |
| 3.2.4 A “wavelet” de Haar | 35 |
| 3.2.5 Limiarização | 36 |
| 3.3 Distribuição Exponencial-Polinomial (EP) | 38 |

| | |
|---|-----------|
| CAPÍTULO 4 – DISTÂNCIAS ESTOCÁSTICAS | 40 |
| 4.1 Propriedades das distâncias | 43 |
| CAPÍTULO 5 – FILTROS | 47 |
| 5.1 “Non Local Means” (NLM) | 50 |
| 5.2 “Probabilistic Patch-Based” (PPB) | 51 |
| 5.3 SAR-BM3D | 53 |
| 5.4 Filtros de pós-processamento | 54 |
| CAPÍTULO 6 – MEDIDAS DE AVALIAÇÃO | 55 |
| 6.1 Índices com referência | 55 |
| 6.1.1 PSNR | 56 |
| 6.1.2 SSIM | 56 |
| 6.2 Índices sem referência | 57 |
| 6.2.1 ENL | 57 |
| 6.2.2 Razão r da imagem | 57 |
| CAPÍTULO 7 – PROPOSTA E RESULTADOS | 59 |
| 7.1 Resultados sintéticos | 61 |
| 7.1.1 Análise dos histogramas | 70 |
| 7.2 Resultados reais | 73 |
| CAPÍTULO 8 – CONCLUSÃO | 83 |
| 8.1 Trabalhos futuros | 84 |
| REFERÊNCIAS | 86 |
| GLOSSÁRIO | 92 |
| APÊNDICE A – TABELAS DOS DEMAIS RESULTADOS | 94 |

| | | |
|-------|-----------------------------------|-----|
| A.1 | Experimentos sintéticos | 95 |
| A.1.1 | Barbara | 95 |
| A.1.2 | Camerman | 99 |
| A.1.3 | Concord | 103 |
| A.1.4 | Lena | 107 |
| A.2 | Experimentos reais | 111 |
| A.2.1 | Região 1 | 111 |
| A.2.2 | Região 2 | 115 |
| A.2.3 | Região 3 | 119 |

Capítulo 1

INTRODUÇÃO

A filtragem de imagens está presente no cotidiano de diversas áreas e atividades como na Astronomia, Medicina, Ciência Forense, Engenharias, Biologia, etc (NATH, 2013). Por esta razão, o avanço nas técnicas para a remoção de ruídos nas imagens é um problema continuamente estudado na área de Processamento de Imagens e Sinais e ainda atrai pesquisadores que buscam desenvolver melhores métodos para a atenuação de ruído (CHATTERJEE; MILANFAR, 2010).

Os filtros são aplicados para recuperar imagens corrompidas com base, em alguns casos, em um conhecimento a priori do fenômeno de degradação do sinal e podem conter: critérios para definir estimativas do resultado desejado e medidas para avaliar a qualidade da imagem filtrada (GONZALEZ; WOODS, 2007). Isto significa que muitos dos algoritmos não atingiram um nível de superioridade e aplicabilidade desejada, ou seja, embora eles suavizem o ruído, eles necessitam de um aperfeiçoamento. Além disto, muitos filtros podem mostrar um bom desempenho em uma imagem que corresponda ao algoritmo, isto é, uma imagem que tenha resultado superior às demais utilizadas com o mesmo ajuste de parâmetros do filtro, como o tamanho da janela, número de iterações, entre outros. 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. Segundo Knaus e Zwicker (2014), os algoritmos dos métodos atuais também tornam-se complexos, dificultando sua análise e implementação.

Os sistemas de radar de abertura sintética (SAR) são muito úteis para monitorar e estudar a superfície da Terra (HORTA, 2009) como vazamentos de óleo nos oceanos, geleiras derretidas, análise de fronteiras, etc. A principal vantagem deste tipo de sistema é a sua aplicabilidade em variadas condições climáticas (DELEDALLE et al., 2017), pois ele atua na faixa de micro-ondas tornando-o menos afetado que os sensores ópticos.

Um sistema SAR envia pulsos eletromagnéticos em direção a um alvo e analisa o eco de retorno. As imagens resultantes do processamento coerente são contaminadas com ruído multiplicativo “speckle”, que surge devido às interferências no sinal pelos retroespalhadores presentes na superfície (PENNA; MASCARENHAS, 2018). Este ruído causa um aspecto granuloso na imagem tornando as análises e interpretações das cenas em tarefas árduas com altas chances de erros.

No entanto, o “speckle” não é apenas ruído devido ao fato de que ele carrega informações sobre o alvo processado (PARRILLI et al., 2012). Portanto, para um método de redução do “speckle” ser ótimo, o “speckle” deve ser removido e os detalhes (bordas, linhas, pontos) devem ser bem preservados (WU et al., 2016). Além disso, as imagens SAR com “speckle” não devem ser processadas com filtros fundamentados no conceito do ruído aditivo branco Gaussiano (AWGN) porque o “speckle” corrompe o sinal de retorno de uma maneira multiplicativa, ou seja, a distribuição de ruído não é Gaussiana.

A abordagem do “Non-Local Means” (NLM) (BUADES; COLL; MOREL, 2005) foi um divisor de águas na área de atenuação de ruídos das imagens. Ela forneceu a base para as técnicas de filtragem colaborativa como o “Block-matching 3D” (BM3D) (DABOV et al., 2007) e métodos baseados em sinais esparsos como o “K-means Singular Value Decomposition” (K-SVD) (AHARON; ELAD; BRUCKSTEIN, 2006). A idéia principal dessas técnicas é a suposição de semelhança entre “patches”, janelas na maioria das vezes quadradas com dimensões $n \times n$, da imagem (PENNA; MASCARENHAS, 2018) primeiramente proposta em (EFROS; LEUNG, 1999). A semelhança entre dois “patches” é fornecida por uma métrica que relaciona os valores dos pixels dentro de cada “patch”.

Como grande parte dos métodos elaborados na literatura são baseados primeiramente no modelo do ruído aditivo branco Gaussiano (AWGN), alguns pesquisadores dedicam-se a aprimorar a capacidade de um filtro e poder tratar imagens com outros modelos de ruído, como por exemplo o ruído Poisson e o ruído multiplicativo “speckle” independente do sinal. Pode-se citar, como exemplo, o filtro BM3D (DABOV et al., 2007), que foi baseado nos princípios do NLM (BUADES; COLL; MOREL, 2005), originalmente desenvolvido para o ruído branco aditivo Gaussiano (AWGN) e que foi estendido para o SAR-BM3D (PARRILLI et al., 2012) para poder filtrar imagens SAR.

Também é possível usar a técnica de “multilook”, que faz uma média de L “looks” durante a geração da imagem SAR e reduz a variância do “speckle” por um fator L (PENG; ZHAO, 2014), mas ela reduz o ruído ao custo da perda de resolução em azimuth mesmo levando em consideração que todo processo de filtragem também ocasiona tal perda. Portanto, é de grande

importância estudar alternativas para mitigar o ruído “speckle” (ARGENTI et al., 2013).

O filtro “Probabilistic Patch-Based” (PPB) (DELEDALLE; DENIS; TUPIN, 2009) funciona com ruído aditivo e multiplicativo. Além disso, é possível aplicar diferentes medidas de similaridade que substituem a distância Euclidiana do algoritmo NLM como em (TEUBER; LANG, 2012). Na literatura de processamento de imagens, algumas técnicas, por exemplo, transformação homomórfica (ARSENAULT; APRIL, 1976), tornam os filtros AWGN capazes de filtrar o “speckle”, um ruído presente não só nas imagens SAR, mas também em imagens médicas de ultrassom, sonares e laser. Com relação à imagem SAR, SAR-BM3D (PARRILLI et al., 2012) e FANS (COZZOLINO et al., 2013) são considerados o estado da arte com excelentes resultados (PENNA; MASCARENHAS, 2018).

Existe uma outra linha de estudo que adapta medidas de divergências para lidar com tarefas de processamento de imagens (NASCIMENTO; CINTRA; FRERY, 2010). O conceito das distâncias estocásticas foi estudado e aplicado para diferentes tipos de ruídos e imagens. Estas distâncias já foram usadas para remover o “speckle” em imagens SAR (PENNA; MASCARENHAS, 2018; TORRES; CAVALCANTE; FRERY, 2012; TORRES; FRERY, 2013; TORRES et al., 2014) e imagens de ultra-som (SANTOS; MARTINS; MASCARENHAS, 2017). Além disso, Bindilatti, Vieira e Mascarenhas (2018) empregaram as distâncias para filtrar o ruído “Poisson”.

Alguns pesquisadores trabalham com filtros que são aplicadas como um “passo final” da filtragem, isto é, o método será aplicado em uma imagem filtrada utilizando uma outra imagem estimada de qualquer filtro do estado da arte, a qual servirá como guia para aprimorar o resultado da imagem final. Neste grupo, existem dois métodos: “Dual Domain Filtering” (DDF) (KNAUS; ZWICKER, 2015) e “Data Adaptive Dual Domain Denoising” (DA3D) (PIERAZZO et al., 2015). O algoritmo DDF atua no domínio espacial e de frequência, enquanto o DA3D atua apenas no domínio de frequência.

Sob o conceito das “wavelets” (MALLAT, 1989), pode-se dizer que a “wavelet” de Haar é o caso mais simples (STANKOVIC; FALKOWSKI, 2003). O paradigma das transformadas de “wavelets” foi adotado por um grande número de aplicações em muitas áreas como a Astrofísica, Geofísica, Geoprocessamento, Medicina, etc (MISRA; KARTIKEYAN; GARG, 2014). Por isso, este trabalho está fundamentado nas “wavelets” de Haar.

1.1 Motivação e objetivo

Visto que um dos desafios da área de Processamento de Imagens e Sinais é desenvolver ou melhorar uma técnica para que seja possível atenuar vários tipos de ruídos, este trabalho tem o objetivo de tornar o filtro NLM capaz de filtrar imagens SAR de intensidade diretamente no domínio das “wavelets” de Haar calculando novas distâncias estocásticas baseadas nas distribuições Exponencial-Polinomial (EP) (CHAN; PENG, 2003) e Gama. Uma das vantagens de se trabalhar com essa distribuição está no baixo custo computacional em relação ao método de Penna (2014), uma vez que não é necessário calcular parâmetros como na distribuição G^0 (FRERY et al., 1997).

Este trabalho expõe os resultados de cenários sintéticos e reais para mostrar que o método proposto e as distâncias estocásticas geram bons resultados, os quais são competitivos com os filtros do estado da arte. Além disto, este trabalho também apresenta os resultados com as técnicas DA3D e DDF, que fornecem uma otimização da imagem estimada recuperando estruturas retidas no processo de filtragem anterior.

Por fim, pode-se dizer que as principais contribuições deste trabalho são: aplicar um algoritmo originalmente desenvolvido para o ruído aditivo na filtragem do ruído “speckle” multiplicativo, apresentar novas distâncias estocásticas e, através da união do NLM e das distâncias, atenuar o “speckle” no domínio das “wavelets”.

1.2 Organização

O restante deste documento está organizado da seguinte forma:

- *Capítulo 2:* São apresentados a imagem SAR e o modelo do ruído “speckle”.
- *Capítulo 3:* Aborda-se a teoria das “wavelets” e a distribuição EP.
- *Capítulo 4:* Apresentam-se as distâncias estocásticas computadas para a distribuição EP para o ruído “speckle single look”.
- *Capítulo 5:* Faz-se uma breve revisão bibliográfica dos filtros na literatura e expõe-se o filtro “Non-local Means”.
- *Capítulo 6:* Indicam-se algumas medidas utilizadas para avaliar a qualidade da imagem filtrada.

-
- *Capítulo 7*: Define-se o método proposto fundamentado com o NLM e as distâncias estocásticas no domínio das “wavelets” de Haar. Além disso, discutem-se os resultados sintéticos e reais.
 - *Capítulo 8*: No último capítulo deste trabalho conclui-se a abordagem proposta apresentando também possíveis trabalhos futuros.

Capítulo 2

IMAGENS SAR E “SPECKLE”

Imagem pode ser definida como a preservação de uma evidência visual. Uma imagem digital pode ser representada por uma matriz de intensidade, na qual cada elemento dessa matriz corresponde ao valor da intensidade do pixel naquela posição (MAITY et al., 2015). Dada uma imagem em tons de cinza, os valores dos “pixels”, os quais são os elementos fundamentais da imagem digital, variam usualmente entre 0 (preto) e 255 (branco) no formato “byte”.

O ruído pode surgir durante a aquisição e/ou transmissão das imagens. Ele degrada a qualidade da imagem causando um distúrbio aleatório no valor de intensidade do pixel. Além da qualidade dos elementos dos sensores como fator para a criação de ruído, estes são afetados por condições ambientais ou atmosféricas (iluminação, temperatura, umidade, descargas atmosféricas, etc) (GONZALEZ; WOODS, 2007).

Imageamento por SAR é uma técnica aeroespacial que gera imagens das superfícies terrestres com altas resoluções espaciais em várias condições de tempo (BIBO; ZHANG; FUQIANG, 2012). Para o imageamento das áreas da superfície terrestre, existe um processamento coerente, o qual gera um ruído dependente do sinal chamado “speckle” que fornece à imagem SAR uma característica granular (MALLADI; KASILINGAM; COSTA, 2003). As Figuras 2.1 e 2.2 ilustram o processo de imageamento de uma área e o efeito granular ocasionado pelo ruído.

Um sistema SAR produz uma radiação de pulsos eletromagnéticos e captura os sinais retroespalhados pelos elementos de uma determinada área (“resolution-cell”). O sinal de retorno, chamado de eco, é complexo e pode ser visto como uma somatória do retorno de vários objetos retroespalhadores (ARGENTI et al., 2013). Quando uma onda eletromagnética é refletida de um objeto em direção ao sistema SAR, ambas a fase ϕ e a amplitude A da onda são modificadas devido às diferenças físicas dos diferentes terrenos da área sendo imageada (CHAN; PENG, 2003). Entretanto, costuma-se trabalhar apenas com o valor da amplitude devido ao fato dos




Figura 2.1: Região sendo imageada. O radar envia pulsos eletromagnéticos em direção à superfície e analisa o retorno do sinal.



Figura 2.2: Efeito granular do “speckle” após o imageamento. O ruído dificulta a análise e interpretação das imagens.

modelos estatísticos serem bem conhecidos (CHAN; PENG, 2003). A fase fornece informações sobre a aquisição geométrica (DELEDALLE et al., 2017).

Assumindo que a área contém diversos “scatterers” e que nenhum deles leva a um sinal refletido mais forte que os demais, então o sinal recebido pode ser visto como a soma de várias ondas retroespalhadas, ou seja, $Ae^{j\phi} = \sum_i A_i e^{j\phi_i}$ (ARGENTI et al., 2013). A Figura 2.3 ilustra o retorno do eco. A_i representa a amplitude e ϕ_i a fase dos sinais, que são dadas de acordo com alguns fatores: atenuação da propagação, “scatterers” (espalhadores) dos alvos imageados, diretividade da antena. Se for considerado que as fases de cada sinal dos “scatterers” são muito distintas e que elas podem ser somadas de uma maneira construtiva ou destrutiva, então a amplitude do eco varia aleatoriamente. Logo, mesmo que a refletividade subjacente seja uniforme, ela aparece afetada por um ruído granular após o imageamento (ARGENTI et al., 2013).

No modelo multiplicativo, admite-se que o eco de retorno Z pode ser tratado como o produto entre duas variáveis aleatórias independentes: o “speckle” Y e o retroespalhamento do terreno X . Várias distribuições podem ser utilizadas para modelar o retroespalhamento de diferentes tipos de classes de uso da terra levando-se em conta as suas características do grau de homogeneidade. Por exemplo, para uma dada característica de imageamento, de 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 (MEJAIL et al.,




Figura 2.3: O retorno do eco na superfície é a somatória de várias ondas retroespalhadas. Há também ondas espalhadas, que não retornam ao radar (ARGENTI et al., 2013).

2003). A Figura 2.4 mostra algumas regiões com diferentes graus de homogeneidade.




Figura 2.4: Exemplo de uma imagem SAR utilizada para a classificação de regiões que possuem diferentes graus de homogeneidade. Normalmente, área urbana é mais heterogênea. Já uma região de pasto é mais homogênea e possui sinais mais espalhados (NASCIMENTO; CINTRA; FRERY, 2010).

Existem várias funções densidade de probabilidade (FDP) para modelar as variáveis X e Y . As FDP's mais comuns para modelar o “speckle” Y com 1 “look” (“single look”) são a

Exponencial, que é um caso particular da função Gama para imagens SAR “single look” de intensidade, e a Rayleigh para detecções quadráticas (imagens SAR em intensidade: $I = |A|^2$) e lineares (imagens SAR em amplitude: $A = \sqrt{I}$), respectivamente (FRERY et al., 1997). Já para imagens SAR de intensidade com vários “looks” (“multi-look”), estas podem ser modeladas por uma função Gama para dados no formato em intensidade ou Raiz Quadrada da Gama para dados no formato em amplitude. A Figura 2.5 mostra o formato das distribuições descritas até aqui.

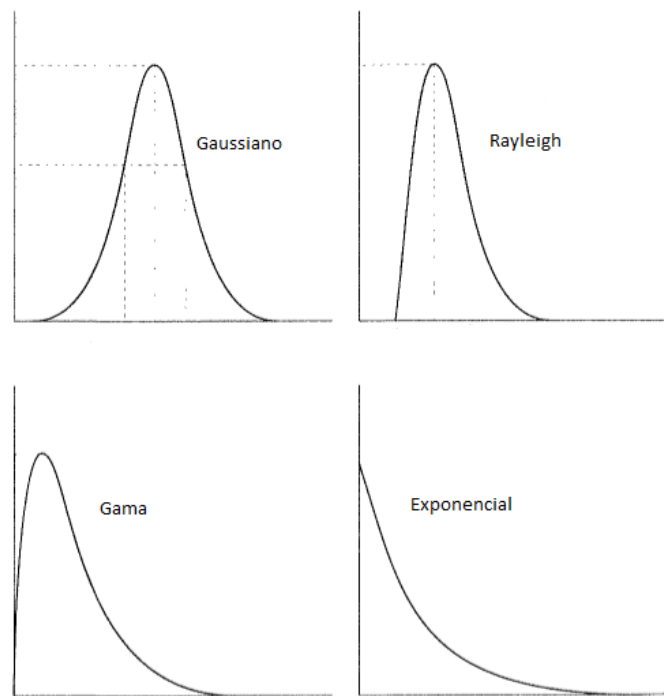


Figura 2.5: Gráficos das funções densidade de probabilidade comumente utilizadas para modelar o “speckle” (GONZALEZ; WOODS, 2007).

O “speckle” não é apenas ruído, pois ele carrega informações sobre a área iluminada. Todavia, ele degrada a aparência da imagem e piora a performance das análises e interpretações. Uma maneira de contornar e atenuar este ruído é fazer uso da técnica de “multilook”, a qual reduz o ruído, mas ao custo da perda de resolução em azimute (direção de vôo do radar) (PARRILLI et al., 2012), ou seja, a imagem tende a ficar mais suavizada. Por isso, este trabalho foi elaborado para uma imagem SAR “single look” ($L = 1$) de intensidade, a qual, como citado, é descrito pela distribuição Gama $f_Y(y, L) \sim \Gamma(L, L)$ (GOODMAN, 1976; ARSENAULT; APRIL, 1976) com a FDP expressa por

$$f_Y(y, L) = \frac{L^L}{\Gamma(L)} y^{L-1} \exp(-Ly), \quad y > 0, L \geq 1 \quad (2.1)$$

onde $L > 0$ representa o número de "looks".

Capítulo 3

DOMÍNIO DA “WAVELET” DE HAAR: A DISTRIBUIÇÃO EP

As transformadas “wavelets” estão sendo adotadas por um grande número de aplicações, com alguns casos substituindo a Transformada de Fourier. Alguns campos de pesquisa, como Astrofísica, Geofísica, Ótica, imagens médicas e Geoprocessamento, adotam a teoria das “wavelets” (MISRA; KARTIKEYAN; GARG, 2014).

Dentro da área de Processamento de Imagens, a teoria das “wavelets” tem sido amplamente utilizada devido à vantagem das análises do tempo-frequência e da multi-escala (ZHANG et al., 2015b). Um método de filtragem com “wavelets” tende a ser superior que outros quando o ruído tratado é AWGN. Entretanto, usar as “wavelets” para suavizar o “speckle” ainda não gera resultados desejáveis, pois observa-se no componente de passa-baixa, isto é, o coeficiente de aproximação obtido com a função de escala da “wavelet”, que não houve uma atenuação do “speckle” (ZHANG et al., 2015b). Por isso, há um grande interesse por pesquisas envolvendo filtragem de imagens SAR com “wavelets”.

Um sinal contínuo no tempo (sinal analógico) representado por $x(t) = \sum_k c_k \varphi_k(t)$, onde $\varphi_k(t), k \in \mathbf{Z}$ é o conjunto de funções base, \mathbf{Z} é o conjunto dos números inteiros e c_k é o coeficiente, pode existir num intervalo de tempo $-\infty < t < \infty$. Na maioria das aplicações, o sinal considerado é um sinal causal, ou seja, existe para $t > 0$. Estes sinais podem ter uma duração finita: $x(t) = 0$ fora de um intervalo $t_0 \leq t \leq t_1$. Além disso, esses sinais podem ser representados por uma combinação linear de funções base e cada componente associado com uma determinada base pode ser escolhido para uma análise e processamento (CHAN; PENG, 2003).

3.1 Análise de Fourier

Segundo Chan e Peng (2003), desde o seu desenvolvimento nos anos de 1800, a análise de Fourier foi amplamente utilizada em muitos ramos de Engenharia e Matemática e foi o alicerce para todas as análises no domínio da frequência.

Na análise de Fourier converte-se um sinal representado no domínio do tempo, ou domínio espacial, para o domínio da frequência. A representação no domínio da frequência pode revelar informações do sinal que não são perceptíveis no domínio do tempo-espaço.

3.1.1 Séries de Fourier

Seja o sinal periódico $x(t) = x(t + kT), k \in \mathbf{Z}$. A representação da série de Fourier é uma soma infinita de exponenciais dada por

$$x(t) = \sum_{k=-\infty}^{\infty} c_k e^{jk\omega_0 t}, \quad (3.1)$$

onde $\omega_0 = 2\pi f_0 = 2\pi/T$ é a frequência angular do sinal, T é o período e $j = \sqrt{-1}$ o imaginário puro. Os coeficientes são obtidos pela ortogonalidade entre as funções bases exponenciais. Seja $\langle f, g \rangle = \int_{-\infty}^{\infty} f(t)\overline{g(t)}dt$ a expressão para produto interno, onde a barra denota o complexo conjugado. A ortogonalidade entre as exponenciais implica que

$$\langle e^{jk\omega_0 t}, e^{jl\omega_0 t} \rangle = \int_{-T/2}^{T/2} e^{jk\omega_0 t} e^{-jl\omega_0 t} dt = 0, \quad \text{se } k \neq l. \quad (3.2)$$

Os coeficientes são determinados pela expressão:

$$c_k = \frac{1}{T} \langle x(t), e^{jk\omega_0 t} \rangle = 1/T \int_{-T/2}^{T/2} x(t) e^{-jk\omega_0 t} dt \quad (3.3)$$

3.1.2 Transformada de Fourier

Como a maioria dos sinais naturais ou processados não são periódicos, torna-se difícil trabalhar com a expansão em séries para acessar a frequência desses sinais. Segundo Chan e Peng (2003), é possível remover a limitação da periodicidade do sinal estendendo o período para o infinito. Através da equação 3.1, substitui-se o coeficiente c_k pela equação 3.3. Chan e Peng (2003) mostram, por meio de algumas manipulações matemáticas, a expressão

$$\hat{x}(\omega) = \int_{-\infty}^{\infty} x(t)e^{-j\omega t} dt. \quad (3.4)$$

A equação 3.4 é chamada de Transformada de Fourier (TF) e é responsável por converter o sinal para o domínio da frequência. Já a expressão 3.5 é denominada Transformada Inversa e converte o sinal para seu domínio original.

$$x(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \hat{x}(\omega)e^{j\omega t} d\omega \quad (3.5)$$

3.1.3 “Short Time Fourier Transform” (STFT)

A TF mostrou-se ser uma boa ferramenta para analisar sinais periódicos infinitos. Entretanto, para sinais transientes, ou seja, não periódicos, como músicas, imagens, voz, ruído acústico, sinais sísmicos, trovões, entre outros, a representação pela Transformada de Fourier torna-se pesada e trabalhosa. A TF não mostra onde no tempo as diversas frequências desses sinais aparecem, apenas informa se uma certa frequência existe. Uma desvantagem também notada é que a TF não pode fornecer informações no domínio do tempo e frequência simultaneamente.

Para obter informação temporal a partir do espectro da frequência, surgiu na literatura a STFT, com o objetivo de investigar o espectro em um intervalo de tempo particular do sinal. O sinal é dividido em pequenos segmentos que podem ser considerados estacionários. A STFT é formalmente definida por

$$W_{\gamma}x(\omega, t) = \int_{-\infty}^{\infty} x(\tau)\overline{\gamma(\tau-t)}e^{-j\omega\tau}d\tau, \quad (3.6)$$

onde $\gamma(t)$ é uma função de janela e seu traço superior denota o complexo conjugado. As janelas mais utilizadas são: “Boxcar” (retangular), Gaussiana, Cosseno, Hamming e Hanning (CHAN; PENG, 2003). O par frequência-tempo (ω, t) é o resultado da transformada no tempo τ . A STFT transforma uma função de uma variável em uma função de duas variáveis. O espectro complexo $W_{\gamma}x(\omega, t)$ fornece um espectro do sinal ao redor da localização no tempo t .

É importante ressaltar que as resoluções dos domínios do tempo e da frequência são governadas pelo princípio da incerteza. Isto causa um dilema. Trabalhar com uma janela estreita garante uma boa resolução no tempo ao capturar componentes de alta frequência do sinal, mas gera uma resolução pobre no espectro da frequência. Uma janela larga captura componentes de baixa frequência, garantindo uma boa resolução no espectro da frequência ao custo de uma má

resolução no tempo. Resumindo, o problema está relacionado com a largura/comprimento da janela. Como é um valor finito, a janela “cobrirá” apenas uma porção do sinal, ocasionando um empobrecimento.

A STFT é uma transformação linear que permite recuperar o sinal original $x(t)$ aplicando a fórmula inversa expressa por

$$x(t) = \frac{1}{2\pi\|\gamma\|} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} W_{\gamma x}(\omega, \tau) \gamma(\tau - t) e^{j\omega\tau} d\omega d\tau, \quad (3.7)$$

onde $\|\gamma\|$ é a norma da função de janela definida por

$$\|\gamma\| = \left(\int_{-\infty}^{\infty} |\gamma(t)|^2 dt \right)^{\frac{1}{2}}. \quad (3.8)$$

3.2 “Wavelets”

Utilizar “wavelets” como funções bases para representar um sinal transiente é muito efetivo, pois um componente de um determinado local do sinal pode ser decomposto e analisado em diferentes níveis de escalas e pode ser reconstruído, o que favorece as necessidades de um determinado processamento para obter informações do sinal. A palavra “wavelet” surgiu do termo em inglês “small wave” com o termo em francês “Ondelette”.

Funções “wavelets”, que têm duração finita, são bem diferentes das funções senoidais de duração infinita utilizadas na TF. Uma “wavelet” pode ser representada por

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right), \quad (3.9)$$

onde o parâmetro a corresponde ao tamanho da escala (contração/dilatação), enquanto que b é responsável pela translação (deslocamento). A “wavelet” $\psi(t) = \psi_{0,1}(t)$, i.e., $a = 0$ e $b = 1$, é a função base, chamada de “Mother Wavelet”. O formato da “wavelet” permanecerá o mesmo sob o processo de translação e de escala. Os coeficientes da “wavelet” são componentes do sinal $x(t)$ com a “wavelet” em diferentes escalas e diferentes localizações ao longo do eixo do tempo (CHAN; PENG, 2003).

3.2.1 Transformada de Wavelet Contínua (CWT)

É interessante conhecer a CWT (“Continuous Wavelet Transform”), pois suas propriedades são similares ao analisar o caso discreto (DWT). A CWT de um sinal $x(t)$ é uma transformação linear definida por uma integral com a “wavelet” escolhida expressa por

$$CWT_{\psi}x(a,b) = \int_{-\infty}^{\infty} x(t)\overline{\psi_{a,b}(t)}dt = \langle x(t), \psi_{a,b}(t) \rangle. \quad (3.10)$$

Segundo (CHAN; PENG, 2003), $CWT_{\psi}x(a,b)$ é o coeficiente “wavelet” no tempo b com escala a computado pelo produto interno da equação 3.10. Nesta equação, uma alta correlação entre o sinal e a “wavelet” produzirá um coeficiente com valor alto. O traço superior em $\overline{\psi}$ indica o complexo conjugado.

Um valor alto para a , ou seja, capturando baixas frequências, torna a largura da janela do tempo alta e a janela do espectro pequena. Isso torna possível colher informações globais do sinal. Variando o tamanho da escala, isto é, observando as altas frequências ao diminuir a largura, analisam-se os detalhes sutis do sinal que podem ser separados de um plano (fundo) grosseiro em locais “escondidos” no sinal. Isto garante à “wavelet” uma enorme vantagem à abordagem de Fourier ao trabalhar com reconhecimento e classificação de sinais.

O sinal original $x(t)$ pode ser recuperado pela expressão

$$x(t) = \frac{1}{C_{\psi}} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} CWT_{\psi}(x)(a,b)\psi_{a,b}(t) \frac{dbda}{a^2}, \quad (3.11)$$

onde C_{ψ} é uma constante definida como

$$C_{\psi} = \int_{-\infty}^{\infty} \frac{|\psi(\omega)|^2}{|\omega|} d\omega. \quad (3.12)$$

3.2.2 Análise por Multiresolução (MRA)

Pode-se falar, de uma maneira grosseira, que a MRA (“Multiresolution analysis”) atua como o “zoom” da lente de uma câmera, o qual permite observar os detalhes do sinal (“zoom in”) ou analisar todo o fundo do sinal (“zoom out”). A MRA separa o sinal em vários componentes em diferentes resoluções para que cada componente possa ser processado por diferentes algoritmos adaptados para diferentes objetivos e características do sinal.

3.2.2.1 Subespaço de Aproximação

A técnica de MRA consiste em utilizar uma função de escala ρ , também chamada de função de aproximação, que gera um conjunto de subespaços $V_{J \in \mathbb{Z}}$ de norma L^2 tal que

$$0 \leftarrow \dots \subset V_{-2} \subset V_{-1} \subset V_0 \subset V_1 \subset V_2 \subset \dots \rightarrow L^2. \tag{3.13}$$

A Figura 3.1 mostra como é a distribuição destes espaços.

3.2.2.2 Subespaço da Wavelet

Pode-se definir o subespaço das “wavelets” $W_{J \in \mathbb{Z}}$ como o complemento ortogonal de V_J em V_{J-1} . Assim, obtém-se a relação entre V e W : $V_{J-1} = V_J \oplus W_J$, sendo $W_J \perp V_J$. A figura 3.2 mostra a relação entre estes espaços.




Figura 3.1: Representação dos subespaços de aproximação gerados pela MRA com a função de escala ρ .




Figura 3.2: Representação dos subespaços V e W , que é o complemento ortogonal de V .

3.2.3 Transformada Wavelet Discreta (DWT)

O algoritmo DWT (“Discrete wavelet transform”) é baseado na relação entre os subespaços descritos da seção 3.2.2.

Segundo Ribeiro (2010), um sinal x no tempo t pode ser decomposto pela expressão

$$x(t) = \sum_{k=-\infty}^{\infty} c_{J,k} \rho_{J,t}(k) + \sum_{k=-\infty}^{\infty} \sum_{j=1}^J \psi_{j,t}(k) w_{j,k}, \quad (3.14)$$

onde

$$\rho_{j,t}(x) = 2^{-j} \rho(2^{-j}x - t) \quad (3.15)$$

e

$$\psi_{j,t}(x) = 2^{-j} \psi(2^{-j}x - t). \quad (3.16)$$

A função ρ denota uma função de escala e ψ representa a “wavelet”. O parâmetro J indica o número de resoluções para a decomposição. A decomposição consiste em duas convoluções discretas seguida por uma subamostragem por 2. Os coeficientes são expressos por:

$$c_{j+1,t} = \sum_k h(k - 2t) c_{j,k}, \quad (3.17)$$

$$w_{j+1,t} = \sum_k g(k - 2t) c_{j,k}. \quad (3.18)$$

O coeficiente $w_{j,t}$ é o coeficiente da “wavelet”, ou seja, representa os detalhes do sinal na escala j . O coeficiente $c_{j,t}$ representa uma versão suavizada do sinal original x oriunda da função de escala. Os termos h e g representam, respectivamente, os filtros passa-baixa e passa-alta que são descritos nas equações 3.19 e 3.20. Estes filtros são denominados por filtros de análise, pois são utilizados para decompor o sinal.

$$\frac{1}{2} \rho\left(\frac{x}{2}\right) = \sum_k h(k) \rho(x - k) \quad (3.19)$$

$$\frac{1}{2}\psi\left(\frac{x}{2}\right) = \sum_k g(k)\psi(x-k) \quad (3.20)$$

O processo para reconstruir o sinal é chamado de IDWT (“Inverse Discrete Wavelet Transform”) e pode ser definido pela equação 3.21. Os filtros \hat{h} e \hat{g} podem ser chamados de filtros de síntese, pois reconstruem o sinal. Cada tipo de “wavelet” possui seus filtros de análise e síntese.

$$c_{j,t} = 2 \sum_k [\hat{h}(k+2t)c_{j+1,k} + \hat{g}(k+2t)w_{j+1,k}] \quad (3.21)$$

3.2.4 A “wavelet” de Haar

O matemático húngaro Alfred Haar desenvolveu a “wavelet” de Haar por volta de 1910 (STANKOVIC; FALKOWSKI, 2003). Essa “wavelet” foi o primeiro exemplo, portanto, o mais simples, de uma transformada ortonormal. A função de Haar é um pulso retangular (STANKOVIC; FALKOWSKI, 2003).

Segundo Ribeiro (2010), a função da “wavelet” de Haar $\psi(t)$ pode ser descrita como

$$\psi(t) = \begin{cases} 1, & 0 \leq t < \frac{1}{2} \\ -1, & \frac{1}{2} \leq t < 1 \\ 0, & \text{caso contrário.} \end{cases} \quad (3.22)$$




Figura 3.3: “Wavelet” de Haar. Ela é considerada a “wavelet” mais simples. Seu gráfico é um pulso retangular.

A Figura 3.3 ilustra a “wavelet” (ψ) de Haar. A sua função de escala $\rho(t)$ é definida por

$$\rho(t) = \begin{cases} 1, & 0 \leq t < 1 \\ 0, & \text{caso contrário.} \end{cases} \quad (3.23)$$

3.2.5 Limiarização

Segundo (RIBEIRO, 2010), um sinal g livre de ruído é esparsos com muitos valores próximos de zero. Este sinal pode ser estimado utilizando a técnica de limiarização, também chamada de “thresholding”. As funções mais comuns são as “hard” e “soft thresholding” descritas pelas equações 3.24 e 3.25, nas quais o limiar é indicado por Υ e w denota o coeficiente “wavelet”. A Figura 3.4 ilustra estas funções.

$$\Upsilon_{hard}(w) = \begin{cases} w, & |w| > \Upsilon \\ 0, & \text{caso contrário} \end{cases} \quad (3.24)$$

$$\Upsilon_{soft}(w) = \begin{cases} w - \Upsilon, & w \geq \Upsilon \\ w + \Upsilon, & w \leq -\Upsilon \\ 0, & \text{caso contrário} \end{cases} \quad (3.25)$$




Figura 3.4: Representação das funções de limiarização. (a) sinal original. (b) “hard thresholding”. (c) “soft thresholding”.

A função do “hard thresholding” removerá os valores menores que Υ e manterá os valores maiores ou iguais ao limiar. A função de “soft thresholding” surgiu como uma alternativa para amenizar a descontinuidade dos coeficientes. Nesta função, os coeficientes com valores maiores que o limiar terão seus valores reduzidos. Geralmente, pode-se dizer que a “soft thresholding” fornece uma imagem visualmente mais agradável e reduz as mudanças bruscas ocasionadas pela “hard thresholding” (SAURABH; KUMAR; ANITHA, 2015).

Existem várias técnicas para calcular um limiar T ideal, por exemplo o método “Visu Sh-

rink”, o qual também é denominado por “Universal Threshold” (DONOHO; JOHNSTONE, 1995) e expresso por

$$\Upsilon_{VS} = \sigma \sqrt{2 \log(M)}, \quad (3.26)$$

onde σ_n representa o desvio padrão do ruído e M é o número de pixels da imagem (comprimento do sinal). É importante destacar que, para imagens SAR, o método é aplicado no domínio logarítmico da imagem (ARSENAULT; APRIL, 1976) com uma correção no “bias” (viés) (STARCK; MURTAGH; FADILI, 2010). Da mesma maneira, pode-se utilizar o “Bayes Shrink” (CHANG; YU; VETTERLI, 2000). Este “threshold” é dado por

$$\Upsilon_{BS} = \frac{\sigma_n^2}{\sigma_x}, \quad (3.27)$$

onde σ_n representa o desvio padrão do ruído. O desvio padrão estimado do sinal no domínio da “wavelet” é denotado por $\sigma_x = \sqrt{\max(\sigma_y^2 - \sigma_n^2, 0)}$ (HIREMATH; AKKASALIGAR; BADIGER, 2013). É possível determinar $\sigma_n = \text{median}(|w_{hh}|)/0,6745$ (DONOHO, 1995; DONOHO; JOHNSTONE, 1995; MÜLLER; VIDA KOVIC, 2012; WILCOX, 2012; SAURABH; KUMAR; ANITHA, 2015; FIROIU et al., 2011), onde w_{hh} é o coeficiente diagonal da “wavelet” no primeiro nível de decomposição. A determinação do σ_n foi elaborada através do modelo “median absolute deviation” (MAD). A estimação pelo MAD foi realizada sob propriedades estatísticas de uma distribuição Gaussiana e mais detalhes podem ser encontrados em Wilcox (2012). Finalmente, uma vez que \mathbf{y} (sinal ruidoso) possui média zero, σ_y^2 é a variância estimada para w_{hh} e é expressa por

$$\sigma_y^2 = \frac{1}{N^2} \sum_{i,j=1}^{N^2} w_{hh}^2(i, j), \quad (3.28)$$

onde $N \times N$ é o tamanho da sub-banda. Note que, se $\sigma_n^2 \geq \sigma_y^2$ ocorrer, σ_x é suposto 0, i. e., $\Upsilon = \infty$ e todos os coeficientes são configurados como 0 (CHANG; YU; VETTERLI, 2000). Para terminar todo o processo envolvendo a “soft-thresholding”, é aplicada uma exponencial para que os coeficientes “wavelet” retornem ao seu domínio original (ARSENAULT; APRIL, 1976).

3.3 Distribuição Exponencial-Polinomial (EP)

Como descrito no Capítulo 2, o ruído “speckle”, que é gerado pela interação das ondas refletidas por um determinado alvo da superfície, em imagens SAR é definido pelo modelo multiplicativo

$$Z = X.Y, \quad (3.29)$$

onde Z é a observação, X representa o retroespalhamento do terreno ou, segundo Chan e Peng (2003), pode representar a média deste retroespalhamento, e Y denota o “speckle” dependente do sinal, que possui média unitária $\mu = 1$ e variância $\sigma^2 = 1/L$, onde L é o número de “looks”. Chan e Peng (2003) afirmam que os coeficientes “wavelets” são modulados pelo “speckle” de uma maneira que sejam proporcionais à média do retroespalhamento. Logo, a equação 2.1 pode ser expressa pela equação 3.30 com $Y \sim \Gamma(L, L/a)$, onde a denota a média do retroespalhamento.


$$f_Y(y; L/a) = \frac{L^L}{a\Gamma(L)} \left(\frac{y}{a}\right)^{L-1} \exp\left(-\frac{L}{a}y\right), \quad y > 0, L \geq 1 \quad (3.30)$$

Seja $S_1 = aY_1$ e $S_2 = bY_2$ com $Y_1 \sim \Gamma(L, L/a)$ e $Y_2 \sim \Gamma(L, L/b)$, através da equação 3.30, Chan e Peng (2003) apresentam a FDP EP descrita na equação 3.31 para a “wavelet” de Haar ao aplicar a diferença entre S_1 e S_2 ($d = S_1 - S_2$). Foi dado esse nome porque $p_d(y)$ é o produto de uma função Exponencial por uma Polinomial. Se uma variável aleatória segue esta distribuição, ela é definida por $p_d(y) \sim EP(L, L/a, L/b)$. É importante destacar que a e b são médias de diferentes janelas centradas em “pixels” com localizações distintas.


$$p_{S_1-S_2}(y) = p_d(y) = \frac{\exp\left(-\frac{L}{b}|y|\right)}{(L-1)!} \left(\frac{L}{a}\right)^L \left(\frac{L}{b}\right)^L \left[\sum_{j=0}^{L-1} \frac{(L+j-1)!}{j!(L-j-1)!\left(\frac{L}{a} + \frac{L}{b}\right)^{L+j}} |y|^{L-j-1} \right] \quad (3.31)$$

Esta distribuição descreve a diferença entre duas variáveis aleatórias independentes modeladas pela distribuição Gama que para imagens SAR de intensidade “single look” é uma exponencial, ou seja, a FDP EP é a convolução de uma Gama com a mesma Gama, mas com o argumento invertido (diferença) (KLAR, 2015). Além disso, devido ao fato da Gama ser igual a uma Exponencial para $L = 1$, Krishna e Jose (2011) consideram a diferença de Gamas como uma distribuição generalizada de Laplace, a qual é uma diferença entre duas Exponenciais. A Figura 3.5 mostra os gráficos da distribuição EP dos componentes “wavelets” considerando um


nível de decomposição da “wavelet” de Haar.



(a) “Single look”



(b) Três “looks”



(c) Quatro “looks”

Figura 3.5: FDP EP para diferentes “looks” considerando um nível de decomposição da “wavelet” de Haar (CHAN; PENG, 2003). Notar que o primeiro gráfico segue uma distribuição de Laplace, que é a diferença entre duas distribuições Exponenciais.

Através da “wavelet” de Haar, Chan e Peng (2003), ao analisar os componentes de escala c^M e dos detalhes w^M , mostraram que com um determinado nível M de decomposição com a DWT, os componentes extraídos de uma imagem SAR de intensidade podem ser modelados pelas equações 3.32 e 3.33.

$$c^M \sim \Gamma(4^M L, 2^{-M}) \quad (3.32)$$

$$w^M \sim EP(2^{2M-1} L, 2^{-M} L) \quad (3.33)$$

Capítulo 4

DISTÂNCIAS ESTOCÁSTICAS

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). Segundo Nascimento, Cintra e Frery (2010), avaliar a distância entre duas amostras da imagem SAR é uma etapa importante na análise da imagem e, no seu trabalho, oito distâncias estocásticas são avaliadas em testes de hipóteses que empregam a estimação por máxima verossimilhança.

Trabalhando com a distribuição G^0 (FRERY et al., 1997), a qual é utilizada para modelar o retorno do sinal Z e possui a vantagem de caracterizar tanto regiões homogêneas quanto heterogêneas de uma determinada região da superfície, Nascimento, Cintra e Frery (2010) apresentaram a família de divergências (h, ϕ) (SALICRU et al., 1994) descritas na tabela 4.1 e as utilizaram na equação 4.1 para encontrar as respectivas divergências estocásticas.

De acordo com Nascimento, Cintra e Frery (2010), nem todas as divergências satisfazem a propriedade de simetria triangular. Para assegurar e/ou transformar estas divergências em distâncias estocásticas, Nascimento, Cintra e Frery (2010) utilizaram a equação 4.2 e encontraram as integrais abaixo onde f_X e f_Y denotam, respectivamente, as distribuições do “backscatter” e do “speckle”.

$$D_{\phi}^h(X, Y) = h \left(\int_I \phi \left(\frac{f_X(x; \theta_1)}{f_Y(x; \theta_2)} \right) f_Y(x; \theta_2) dx \right), \quad (4.1)$$

$$d_{\phi}^h(X, Y) = \frac{D_{\phi}^h(X, Y) + D_{\phi}^h(Y, X)}{2} \quad (4.2)$$

Tabela 4.1: Funções h e ϕ utilizadas para desenvolver as distâncias estocásticas. Tabela adaptada de (NASCIMENTO; CINTRA; FRERY, 2010).

| (h, ϕ) | $h(y)$ | $\phi(x)$ |
|------------------------|--|--|
| Kullback-Leibler | y | $x \log(x)$ |
| Rényi (ordem β) | $\frac{1}{\beta-1} \log((\beta-1)y+2), 0 \leq y < \frac{1}{1-\beta}$ | $\frac{x^\beta - \beta(x-1) - 2}{\beta-1}, 0 < \beta < 1$ |
| 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 | $-\log\left(-\frac{y}{2}+1\right), 0 \leq y < 2$ | $\frac{(x-1)^2}{x+1}$ |

Distância de Kullback-Leibler (d_{KL}):

$$d_{KL}(X, Y) = \frac{1}{2} \int (f_X - f_Y) \log\left(\frac{f_X}{f_Y}\right) \quad (4.3)$$

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

$$d_R^\beta(X, Y) = \frac{1}{\beta-1} \log\left(\frac{\int f_X^\beta f_Y^{1-\beta} + \int f_X^{1-\beta} f_Y^\beta}{2}\right) \quad (4.4)$$

Distância de Hellinger (d_H):

$$d_H(X, Y) = 1 - \int \sqrt{f_X f_Y} = 1 - \exp\left(-\frac{1}{2} d_R^{1/2}(X, Y)\right) \quad (4.5)$$

Distância de Bhattacharyya (d_B):

$$d_B(X, Y) = -\log\left(\int \sqrt{f_X f_Y}\right) = -\log(1 - d_H(X, Y)) \quad (4.6)$$

Distância de Jensen-Shannon (d_{JS}):

$$d_{JS}(X, Y) = \frac{1}{2} \left[\int f_X \log\left(\frac{2f_X}{f_Y + f_X}\right) + \int f_Y \log\left(\frac{2f_Y}{f_Y + f_X}\right) \right] \quad (4.7)$$

Distância aritmética-geométrica (d_{AG}):

$$d_{AG}(X, Y) = \frac{1}{2} \int (f_X + f_Y) \log\left(\frac{f_Y + f_X}{2\sqrt{f_Y f_X}}\right) \quad (4.8)$$

Distância triangular (d_T):

$$d_T(X, Y) = \int \frac{(f_X - f_Y)^2}{f_X + f_Y} \quad (4.9)$$

Distância de média harmônica (d_{HM}):

$$d_{HM}(X, Y) = -\log \left(\int \frac{2f_X f_Y}{f_X + f_Y} \right) = -\log \left(1 - \frac{d_T(X, Y)}{2} \right) \quad (4.10)$$

Neste capítulo, serão mostradas as distâncias a serem calculadas para remover o ruído “speckle” no seu caso mais severo, isto é, ruído “single look” ($L = 1$) do domínio das “wavelets” de Haar. Com base nas integrais das distâncias estocásticas de Nascimento, Cintra e Frery (2010) e na distribuição EP (CHAN; PENG, 2003), as distâncias foram calculadas com o “software” Matlab R2016a (MATLAB, 2016). Nas fórmulas das equações 4.11 a 4.18 a seguir, a_1 e a_2 representam, respectivamente, as médias de dois “patches” distintos. É importante destacar que as integrais definidas com o limite inferior 0 e o limite superior ∞ foram computadas pelo Matlab. As propriedades estatísticas do ruído foram consideradas constantes em toda a imagem.

Distância de Kullback-Leibler (d_{KLEP}):

$$d_{KLEP} = \frac{(\ln(a_1 + 1) - \ln(a_2 + 1))(a_1 - a_2)}{2(a_1 + 1)(a_2 + 1)} \quad (4.11)$$

Distância de Hellinger (d_{HEP}):

$$d_{HEP} = \frac{a_1 + a_2 - 2\sqrt{a_1 + 1}\sqrt{a_2 + 1} + 2}{(2a_1 + 2)(a_2 + 1)} \quad (4.12)$$

Distância de Rényi com $\beta = 0,5$ (d_{REP}):

$$d_{REP} = -2\ln(1 - d_{HEP}) \quad (4.13)$$

Distância de Bhattacharyya (d_{BEP}):

$$d_{BEP} = -\ln(1 - d_{HEP}) \quad (4.14)$$

Distância de Jensen-Shannon (d_{JSEP}):

$$d_{JSEP} = \frac{(\ln(2a_2 + 2) - \ln(a_1 + a_2 + 2))}{2(a_1 + 1)} + \frac{(\ln(2a_1 + 2) - \ln(a_1 + a_2 + 2))}{2(a_2 + 1)} \quad (4.15)$$

Distância Aritmética-Geométrica (d_{AGEP}):

$$d_{AGEP} = -\frac{(\ln(a_2 + 1) + \ln(4a_1 + 4) - 2\ln(a_1 + a_2 + 2))(a_1 + a_2 + 2)}{4(a_1 + 1)(a_2 + 1)} \quad (4.16)$$

Distância Triangular (d_{TEP}):

$$d_{TEP} = \frac{(a_1 - a_2)^2}{(a_1 + 1)(a_2 + 1)(a_1 + a_2 + 2)} \quad (4.17)$$

Distância da Média-Harmônica (d_{HMEP}):

$$d_{HMEP} = -\ln\left(1 - \frac{d_{TEP}}{2}\right) \quad (4.18)$$

Além disso, de acordo com a equação 3.32 da Seção 3.3, sabe-se que o coeficiente de aproximação de uma imagem SAR de intensidade segue a distribuição Gama ao sofrer uma decomposição “wavelet”. Portanto, as distâncias para esta distribuição também foram computadas. Entretanto, para as oito distâncias estocásticas apenas quatro tiveram suas fórmulas fechadas encontradas nas equações 4.19 a 4.22.

Distância de Kullback-Leibler (d_{KLG}):

$$d_{KLG} = \frac{(a_1 - a_2)^2}{2a_1a_2} \quad (4.19)$$

Distância de Hellinger (d_{HG}):

$$d_{HG} = \frac{(\sqrt{a_1} - \sqrt{a_2})^2}{a_1 + a_2} \quad (4.20)$$

Distância de Rényi com $\beta = 0,5$ (d_{RG}):

$$d_{RG} = -2\ln\left(\frac{2\sqrt{a_1}\sqrt{a_2}}{a_1 + a_2}\right) \quad (4.21)$$

Distância de Bhattacharyya (d_{BG}):


$$d_{BG} = -\ln\left(\frac{2\sqrt{a_1}\sqrt{a_2}}{a_1 + a_2}\right) \quad (4.22)$$

4.1 Propriedades das distâncias


Sabe-se que uma distância $d(x, y)$, com $x \in R$ e $y \in R$, deve ser:

- Homogênea ($d(x,x) = 0$)
- Simétrica ($d(x,y) = d(y,x)$)
- Não-negativa ($d(x,y) > 0, x \neq y$)


Para avaliar as propriedades acima, foram feitos gráficos 3-D com os eixos x e y dentro de um intervalo entre 0 e 255. Estes valores do intervalo serão usados como valores de média nas fórmulas. Através das Figuras 4.1 e 4.2, é possível visualizar o bom comportamento das oito distâncias estocásticas para a distribuição EP e das quatro para Gama no caso “single look”. As Figuras 4.1 e 4.2 mostram que os gráficos estão acima do eixo x , a cor azul escuro indica o valor zero quando x e y são iguais, e existe o comportamento simétrico da queda das curvas das distâncias ao inverter x e y . É importante destacar que o intervalo foi aleatoriamente escolhido e acredita-se que o comportamento dos gráficos sejam os mesmos para um intervalo maior.




(a) Aritmética-Geométrica




(b) Bhattacharyya




(c) Hellinger




(d) Jensen-Shannon




(e) Kullback-Leibler



(f) Média-Harmônica



(g) Rényi



(h) Triangular

Figura 4.1: Gráficos 3-D das distâncias estocásticas para a distribuição EP no caso “single look”. Os gráficos indicam que as distâncias obedecem as propriedades: homogênea, simétrica e não-negativa. O intervalo foi escolhido empiricamente.

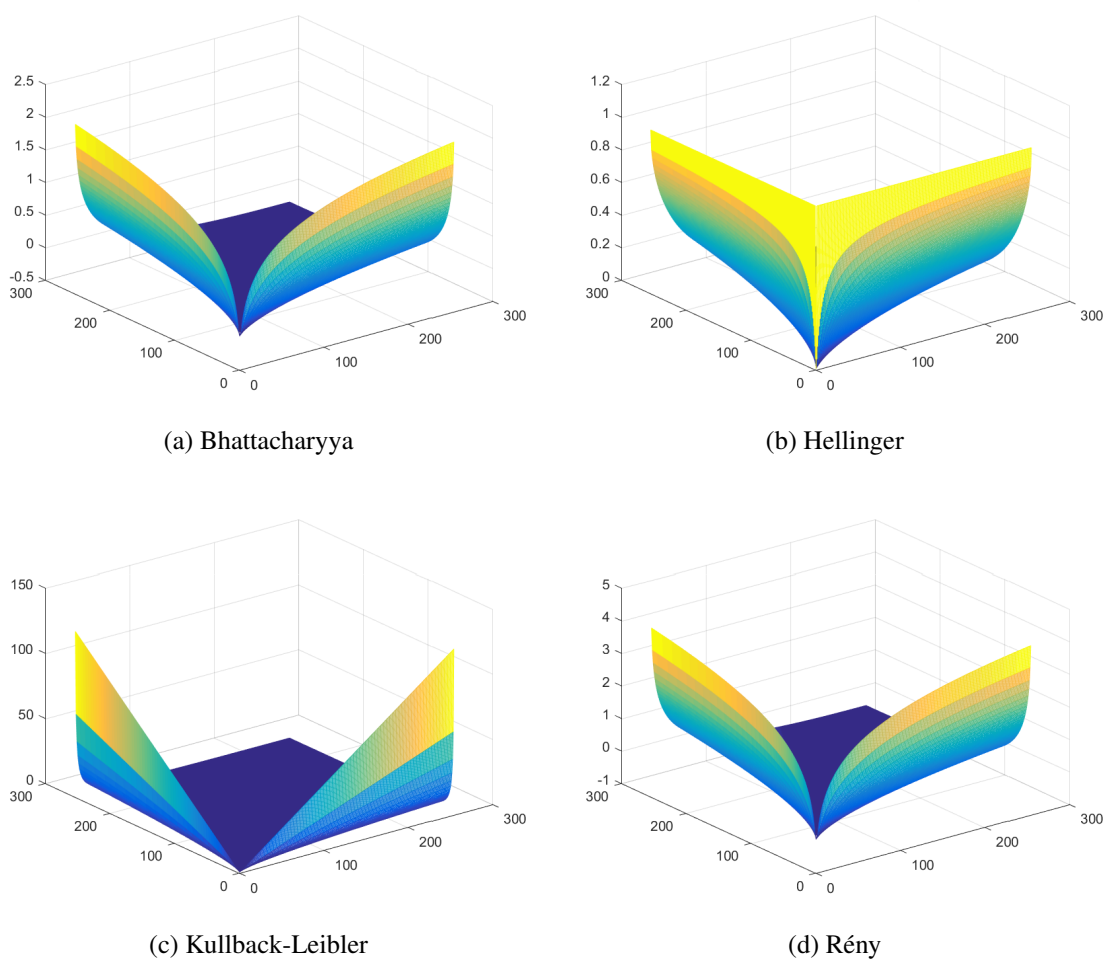


Figura 4.2: Gráficos 3-D das distâncias estocásticas para a distribuição Gama no caso “single look”. Os gráficos indicam que as distâncias obedecem as propriedades: homogênea, simétrica e não-negativa. O intervalo foi escolhido empiricamente.

Capítulo 5

FILTROS

Segundo Nath (2013), muitas pesquisas da literatura de Processamento de Imagens são dedicadas à restauração de imagens. Filtrar uma imagem é uma atividade na qual manipulam-se os dados da imagem obtida (sinal obtido) para produzir uma imagem visualmente melhor (sinal estimado). A restauração é a remoção ou atenuação das degradações, como os borramentos, que podem surgir pelo movimento relativo entre a câmera e a cena original, um sistema ótico fora de foco ou uma turbulência atmosférica 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 vista como um procedimento que permite ou nega a passagem de alguns elementos 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, que possuem máscaras (“kernels”, “templates” e janelas), podem suavizar a imagem e podem ser utilizados para a filtragem não linear (GONZALEZ; WOODS, 2007).

A Figura 5.1 mostra a área onde um filtro espacial poderia atuar. A região do pequeno quadrado possui uma vizinhança 3x3 pixels centrada nas coordenadas (x, y) da imagem, também chamada de “patch”, e um exemplo, seria ocorrer uma operação sobre os pixels dessa vizinhança (média, mediana, etc). Após o término da filtragem, o pixel centralizado da vizinhança seria trocado pelo valor estimado e o filtro marcaria uma nova vizinhança centralizada no próximo pixel. Segundo Gonzalez e Woods (2007), 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 pode possuir alguma capacidade para filtrar bordas. Um filtro linear passa-altas, como o Laplaciano, pode realçar bordas.

Pode-se dizer que os filtros de Lee (LEE, 1980), Frost (FROST et al., 1982) e Kuan (KUAN

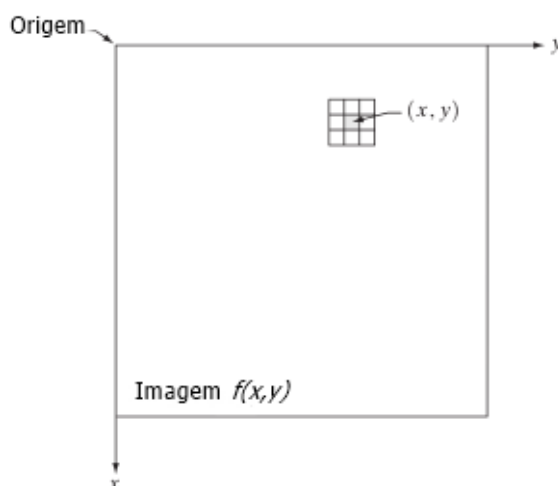


Figura 5.1: “Kernel” centralizado em um ponto (x,y) em uma imagem no domínio espacial.

et al., 1985) foram os primeiros filtros elaborados para imagens SAR décadas atrás (NI; GAO, 2016) e estimam o sinal de acordo com a região da vizinhança (WU et al., 2014). Segundo Yahya, Kamel e Malik (2014), Lee e Kuan possuem fundamentação similar mas se diferenciam no modelo do sinal produzido. Ambos Lee e Kuan removem o “speckle” computando uma combinação linear da intensidade do pixel central do “patch” com uma média do próprio “patch”. Logo, eles fazem um balanço entre o cálculo da média de regiões homogêneas e regiões de bordas.

Já o filtro de Frost utiliza um “kernel” com formato baseado numa distribuição Exponencial que, adaptativamente, varia entre um filtro de média e um filtro que permite manter bordas, ou seja, mantém o valor original do pixel (YAHYA; KAMEL; MALIK, 2014). De maneira geral, estes primeiros filtros são chamados de filtros espaciais locais, pois utilizam estatísticas locais para ajustar a quantidade de ruído que será removido em certas regiões. Eles atuam bem em regiões homogêneas e possuem o mérito da simplicidade dos seus algoritmos, mas em regiões heterogêneas perdem detalhes e, considerando todo o processo de filtragem da imagem, são limitados na filtragem do “speckle” (NI; GAO, 2016).

Para levar em consideração as características flutuantes das cenas, foi elaborada uma estimação “Maximum a Posteriori” (MAP) por Lopes et al. (1990). Em seguida, métodos mais sofisticados levaram em consideração as transformadas “wavelets” para filtrar os coeficientes de aproximação e de detalhe de uma imagem SAR (ARGENTI; ALPARONE, 2002; RANJANI; THIRUVENGADAM, 2010) e são apropriados para evitar artefatos como o anel de Gibbs (MARTINO et al., 2016b). Outras alternativas foram construídas baseadas no modelo esparsado do sinal e em dicionários adaptativos como fizeram Foucher (2008), Xu et al. (2015) e Huang et al. (2012).

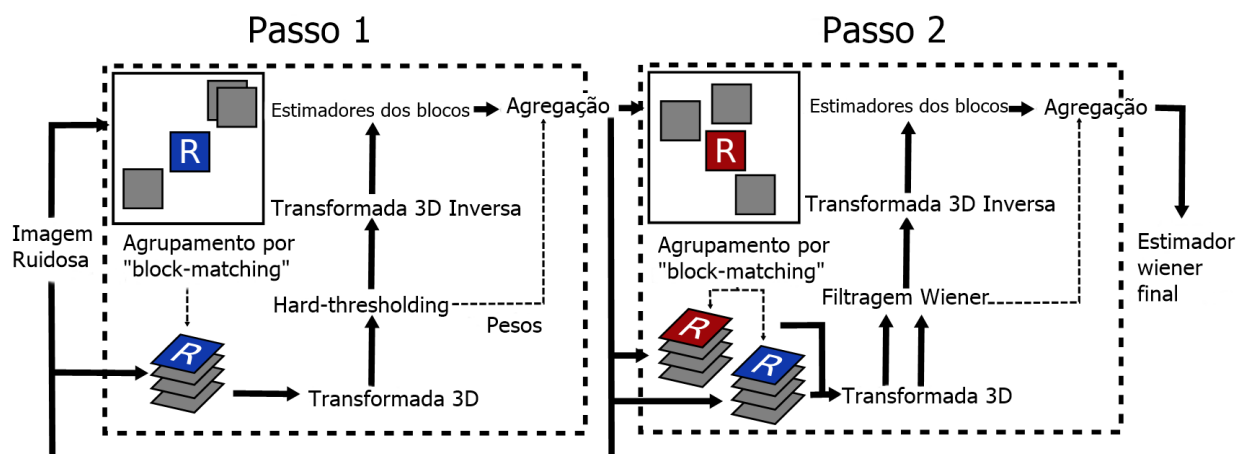


Figura 5.2: Esquema do algoritmo BM3D. Adaptada de (LEBRUN, 2012).

Como mencionado do Capítulo 1, o NLM (BUADES; COLL; MOREL, 2005) ganhou muita popularidade e forneceu a base para várias técnicas de filtragem SAR (MARTINO et al., 2016a, 2016b). A partir dele surgiu o filtro “Bayesian NLM” (BNLM) (COUPE et al., 2009; ZHONG; LI; JIAO, 2009) que minimiza o risco Bayesiano ao assumir que o próprio “patch” fornece uma boa aproximação das estatísticas do pixel central (NI; GAO, 2016) e utiliza a distância de Pearson (WU et al., 2014).

O filtro “Probabilistic Patch-Based” de Deledalle, Denis e Tupin (2009) utiliza a estimativa de máxima verossimilhança para, iterativamente, refinar os resultados, mas suprime detalhes finos e escuros (NI; GAO, 2016). Segundo Knaus e Zwicker (2014), o “Block Matching 3D Filtering” (BM3D) de Dabov et al. (2007) representa o estado-da-arte, pois chega próximo aos limites teóricos da área de “denoising”. Ele empilha “patches” similares e os filtra com uma “wavelet”. De acordo com Zhang et al. (2015a), o BM3D com “Shape-Adaptive” e “Principal Component Analysis” (BM3D-SAPCA), utiliza formas poligonais nos “kernels” e encontra uma representação esparsa dos “patches”.

Através dos princípios do BM3D esquematizado pela Figura 5.2, Parrilli et al. (2012) desenvolveram uma versão orientada para imagens SAR: SAR-BM3D, o qual utiliza muitos dos conceitos avançados e atuais da área de filtragem (“block matching”, não localidade, “wavelet shrinkage” e filtro de Wiener) (MARTINO et al., 2016a). Mais recentemente, o “Non Local Bayes” (NLB) (LEBRUN; BUADES; MOREL, 2013) efetua uma inversão das matrizes para encontrar patches similares e é melhor que o BM3D para imagens coloridas (ZHANG et al., 2015a). Além disso, pensando em acelerar o algoritmo do SAR-BM3D, Cozzolino et al. (2013) desenvolveram o “Fast Adaptive Nonlocal SAR” (FANS).

5.1 “Non Local Means” (NLM)

Muitos filtros descritos na literatura possuem seus “kernels” trabalhando localmente, ou seja, um pixel central em uma vizinhança de $m \times n$ pixels terá seu valor substituído baseado numa operação com os valores dos demais pixels dentro dessa vizinhança. O trabalho de Buades, Coll e Morel (2005) expande esse conceito de localidade.

O filtro NLM realiza uma média ponderada, cujos pesos são determinados através de um critério de similaridade radiométrica estabelecido entre os pixels de uma imagem. A caracterização de similaridade utilizada por Buades, Coll e Morel (2005) é expressa 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 da não localidade (“non local”).

Os “patches” que forem considerados similares ao “patch” do pixel referenciado receberão pesos com valores altos, enquanto que “patches” considerados distantes, ou seja, não similares do pixel referenciado receberão pesos de ponderação baixa. Na Figura 5.3 é exemplificado o funcionamento das janelas de busca e dos “patches” do filtro NLM. O “patch” referenciado Δ_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 , Δ_s . O NLM percorrerá toda a janela de busca.

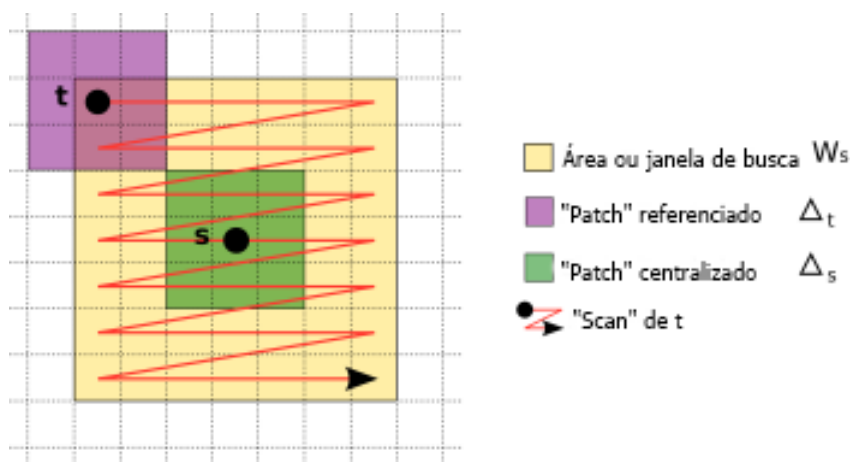


Figura 5.3: Representação das janelas do NLM. A maior janela em laranja é a janela de busca. A janela em verde é o “patch” referenciado. O “patch” em roxo representa o patch sendo avaliado. O caminho em vermelho indica o caminho a ser percorrido pelo “patch” roxo.

Seja $\tilde{I} = \{\tilde{I}(i) | i \in \Omega\}$ uma imagem ruidosa discreta e Ω o domínio da imagem, o valor estimado do NLM representado por $NL[\tilde{I}](i)$, para um pixel i nas coordenadas (x, y) , é computado como uma média ponderada de todos os pixels da imagem conforme a equação 5.1,

$$NL[\tilde{I}](i) = \sum_{j \in \Omega} p(i, j) \tilde{I}(j) \quad (5.1)$$

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

A similaridade entre os pixels depende da intensidade do nível de cinza medida pela distância Euclidiana $\|\Delta(N_i) - \Delta(N_j)\|_{2,\alpha}^2$, onde $\alpha > 0$ é o desvio padrão de um “kernel” Gaussiano, e $\Delta(N_i)$ e $\Delta(N_j)$ representam os vetores dos “patches”. A aplicação da distância Euclidiana nos “patches” ruidosos aparece na equação 5.2,

$$E\|\Delta(N_i) - \Delta(N_j)\|_{2,\alpha}^2 = \|u(N_i) - u(N_j)\|_{2,\alpha}^2 + 2\sigma^2 \quad (5.2)$$

onde u e Δ são, respectivamente, a imagem original e a imagem ruidosa, E é o valor esperado e σ^2 é a variância do ruído. A equação 5.2 mostra que os pixels mais similares a i em z 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 5.3,

$$p(i, j) = \frac{1}{Z(i)} e^{-\frac{\|\Delta(N_i) - \Delta(N_j)\|_{2,\alpha}^2}{h^2}} \quad (5.3)$$

onde $Z(i)$ é uma constante normalizadora expressa pela equação 5.4.

$$Z(i) = \sum_j e^{-\frac{\|\Delta(N_i) - \Delta(N_j)\|_{2,\alpha}^2}{h^2}}, \quad (5.4)$$

e o parâmetro h atua na suavização da filtragem controlando a queda dos pesos. A Figura 5.4 exemplifica a atribuição de pesos que fornece pesos grandes para $s1$ e $s2$ por causa da similaridade com t . Já o valor de $p(t, s3)$ é bem menor, pois as intensidades dos valores dos níveis de cinza são bem diferentes.

5.2 “Probabilistic Patch-Based” (PPB)

O PPB (DELEDALLE; DENIS; TUPIN, 2009) foi desenvolvido através de uma abordagem probabilística utilizando a estimação pela máxima verossimilhança ponderada (WMLE - “Weighted Maximum Likelihood Estimation”). Este filtro encontra a melhor estimativa do parâmetro da distribuição paramétrica do ruído $p(A_s | \sigma_s)$, onde A_s representa a amostra da imagem SAR em amplitude localizada em s e σ_s denota o parâmetro desconhecido variando no espaço, o qual será a refletividade da imagem. Deledalle, Denis e Tupin (2009) mostraram que se os pixels da amostra são modelados sendo independentes e identicamente distribuídos de




Figura 5.4: Exemplo de atribuição de pesos no NLM: $q1$ 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).

acordo com a distribuição Rayleigh, a WMLE de σ_s é expressa por (MARTINO et al., 2016a)

$$\hat{\sigma}_s^{WMLE} = \frac{\sum_{t \in \Omega} p_{s,t} A_t^2}{\sum_{t \in \Omega} p_{s,t}}, \quad (5.5)$$

onde Ω é uma janela grande centrada em s (área de busca) e o peso $p_{s,t} \in [0, 1]$ depende do pixel alvo s e do pixel teste t . O peso é avaliado como a probabilidade de dois “patches” Δ_s e Δ_t , centrados em s e t , respectivamente, compartilharem os mesmos parâmetros:

$$p_{s,t}^{non-it.PPB} = P(\sigma_{\Delta_s} = \sigma_{\Delta_t} | A)^{\frac{1}{h}}, \quad (5.6)$$

onde $h > 0$ é o parâmetro que direciona a queda dos pesos e o sobrescrito “non-itPPB” significa “noniterative PPB” (PPB não iterativo). Para refinar os pesos, Deledalle, Denis e Tupin (2009) propuseram uma versão iterativa do PPB, na qual uma estimação da refletividade da imagem no passo $i-1$ $\hat{\sigma}^{i-1}$ é utilizada como um conhecimento *a priori* no passo i . Os pesos são refinados pela equação

$$p_{s,t}^{it.PPB,i} = P(\sigma_{\Delta_s} = \sigma_{\Delta_t} | A, \hat{\sigma}^{i-1})^{\frac{1}{h}}, \quad (5.7)$$

sendo que o sobrescrito “it.PPB” significa “iterative PPB” (PPB iterativo). Utilizando a divergência de Kullback-Leibler para modelar o conhecimento *a priori*, Deledalle, Denis e Tupin (2009) encontraram a seguinte expressão para refinar os pesos:

$$p_{s,t}^{it.PPB,i} = \exp \left[- \sum_k \left(\frac{1}{\tilde{h}} \ln \left(\frac{A_{s,k}}{A_{t,k}} + \frac{A_{t,k}}{A_{s,k}} \right) + \frac{L}{T_{fil}} \frac{|\hat{\sigma}_{s,k}^{i-1} - \hat{\sigma}_{t,k}^{i-1}|^2}{\hat{\sigma}_{s,k}^{i-1} \hat{\sigma}_{t,k}^{i-1}} \right) \right] \quad (5.8)$$

onde L é o número equivalente de “looks” (EQL - “Equivalent Number of Looks”), $\hat{h} = h/(2L - 1)$, T_{fil} é um parâmetro que conduz a queda da divergência de Kullback-Leibler e K é um índice que identifica os pixels dentro dos “patches” Δ_s e Δ_t .

5.3 SAR-BM3D

O SAR-BM3D (PARRILLI et al., 2012) é uma versão orientada para SAR do filtro BM3D (DABOV et al., 2007) e, portanto, ele possui dois passos. Porém, apenas no segundo passo é onde ocorrerá de fato a atenuação do “speckle” através de um filtro de Wiener adaptativo no domínio das “wavelets” (MARTINO et al., 2016b). Assim como o BM3D, nos dois passos existem três etapas:

- Agrupamento: ocorre como os princípios do NLM, ou seja, os blocos similares serão empilhados formando um único bloco 3D.
- Filtragem colaborativa: etapa onde acontece a filtragem pelas “wavelets”.
- Agregação: os blocos filtrados retornam às suas localizações originais.

A Figura 5.2 representa o esquema do BM3D que servirá de base para explicar o SAR-BM3D. No primeiro passo, é produzida uma imagem parcialmente filtrada usada como piloto (guia), da qual os parâmetros serão estimados para o próximo passo, que envolve um filtro de Wiener. Quanto melhor a imagem piloto, ou seja, quanto melhor a atenuação do ruído, os parâmetros serão considerados mais reais, logo, a imagem final será próxima da ideal (real livre de ruído). A diferença é que, além de adaptar o critério utilizado para identificar os blocos similares moldado nas estatísticas do “speckle” (PENNA, 2014), o SAR-BM3D utiliza uma transformada “wavelet” discreta não decimada (UDWT - “Undecimated Discrete Wavelet Transform”) ao invés do “hard thresholding” no primeiro passo para obter uma estimativa mais confiável.

5.4 Filtros de pós-processamento

Como mencionado anteriormente, devido ao fato de que o BM3D possa ter alcançado o limite teórico da área de “denoising” e que os métodos subsequentes além de serem mais complexos eles melhoram modestamente a qualidade visual da imagem (KNAUS; ZWICKER, 2014), alguns pesquisadores buscam desenvolver algoritmos mais simples capazes de gerar uma imagem com qualidade superior ou pelo menos igual aos métodos complexos.

O “Dual-Domain Image Denoising” (DDID) (KNAUS; ZWICKER, 2013) consegue obter resultados comparáveis ao BM3D. Este filtro é iterativo e guiado, i.e., utiliza uma imagem filtrada previamente, que utiliza uma combinação do filtro bilateral (TOMASI; MANDUCHI, 1998) no domínio espacial e uma “wavelet” baseada na STFT no domínio da frequência. Enquanto o filtro bilateral atua para melhorar o contraste das bordas causando um efeito de “ringing” (fenômeno de Gibbs), a STFT preservará estruturas repetitivas que o filtro bilateral tende a borrar (KNAUS; ZWICKER, 2015)

A partir do DDID surgiu o “Progressive Image Denoising” (PID) (KNAUS; ZWICKER, 2014), que é baseado numa estimação robusta do ruído do sinal. Também foram elaborados os métodos “Non-local Dual Image Denoising” (NLDD) (PIERAZZO et al., 2014) e “Cycle Spinning DDID” (CSID) (ZHANG et al., 2015a) para imagens SAR, os quais contornam o fenômeno de Gibbs gerado pelo DDID. Seguindo o mesmo fundamento do PID, Knaus e Zwicker (2015) elaboraram o “Dual-Domain Filtering” (DDF), o qual possui como a principal diferença em relação ao PID o fato de necessitar poucas iterações para encontrar resultados superiores. Além disso, o DDF pode atuar como um filtro guia, ou seja, utiliza uma segunda imagem para realizar um pós-processamento na imagem resultante de outro filtro.

Pensando no alto custo computacional do DDID, que filtra uma janela de dimensão grande para recuperar um único pixel e que ainda causa borramentos (PIERAZZO; FACCILOLO, 2017), Pierazzo et al. (2015) criaram o “Data Adaptive Dual Domain Denoising” (DA3D), que é um método utilizado como “passo final” e faz uma filtragem do domínio da frequência em patches com formatos adaptativos. O DA3D melhora os resultados de métodos considerados o estado-da-arte, como o BM3D, com um tempo de execução muito baixo.

Além disso, o DA3D consegue melhorar a qualidade da imagem adaptando seu processamento para os dados adjacentes. Para remover os artefatos produzidos pelos métodos não locais, como o efeito “staircasing”, este filtro utiliza uma regressão não linear local de primeira ordem no “kernel” para estimar, em cada “patch”, uma aproximação refinada da imagem com os dados dentro do “patch”.

Capítulo 6

MEDIDAS DE AVALIAÇÃO

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

De acordo com Penna (2014), 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 de diferentes tipos de ruídos. Estes índices podem ser divididos em duas classes: índices com referência e sem referência.

6.1 Índices com referência

Estes métodos utilizam a informação da imagem original e da filtrada e são aplicados com muita frequência no campo de filtragem (MITTAL; MOORTHY; BOVIK, 2012). Uma abordagem típica consiste em escolher uma imagem de referência (óptica ou sintética), que representará a refletividade original (“ground truth”) 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 a 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 (PENNA, 2014). A seguir, serão apresentadas as medidas PSNR e SSIM utilizadas para avaliar os filtros neste trabalho, É importante destacar que existem outras medidas na literatura de Processamento de Imagens e Sinais.

6.1.1 PSNR

O PSNR (“Peak Signal-to-Noise Ratio” - razão sinal-ruído de pico) computa a razão entre a potência máxima possível de um sinal e o erro da sua estimação conforme a equação 6.1, onde \hat{I} é a imagem estimada e I a ideal (livre de ruído). MAX_I indica o valor máximo observado na imagem ideal e o $MSE(\hat{I}, I)$ fornece o valor do erro médio quadrático (“mean squared error”) através da equação 6.2 onde n é o número de “pixels” da imagem. Quanto maior o valor do PSNR, maior a qualidade da imagem estimada (PENNA, 2014).

$$PSNR = 10 \log_{10} \left[\frac{MAX_I^2}{MSE(\hat{I}, I)} \right] \quad (6.1)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{I}_i - I_i)^2 \quad (6.2)$$

6.1.2 SSIM

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

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

Juntos eles formam o SSIM representado pela equação 6.3, onde $\mu_{\hat{I}}$ e $\sigma_{\hat{I}}$ são, respectivamente, a média e o desvio padrão de \hat{I} . μ_I e σ_I são, respectivamente, a média e o desvio padrão de I . $\sigma_{\hat{I}}\sigma_I$ indica a correlação entre \hat{I} e I . 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 (PENNA, 2014).

$$SSIM = l(\hat{I}, I)c(\hat{I}, I)s(\hat{I}, I) = \left(\frac{2\mu_{\hat{I}}\mu_I + C_1}{\mu_{\hat{I}}^2 + \mu_I^2 + C_1} \right) \left(\frac{2\sigma_{\hat{I}}\sigma_I + C_2}{\sigma_{\hat{I}}^2 + \sigma_I^2 + C_2} \right) \left(\frac{2\sigma_{\hat{I}I} + C_3}{\sigma_{\hat{I}}\sigma_I + C_3} \right) \quad (6.3)$$

6.2 Índices sem referência

Métodos sem referência efetuam a avaliação da qualidade da imagem 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 (PENNA, 2014).

6.2.1 ENL

Segundo (ARGENTI et al., 2013), esta medida é adequada para imagens SAR, pois avalia o nível de suavização em áreas homogêneas. Quanto maior o ENL, maior a capacidade de suavização do filtro. Ele é encontrado através da equação 6.4, na qual μ e σ^2 representam, respectivamente, a média e a variância da imagem. No entanto, esta medida favorece filtros que podem produzir imagens super borradas (PENNA; MASCARENHAS, 2018).

$$ENL = \frac{\mu^2}{\sigma^2} \quad (6.4)$$

6.2.2 Razão r da imagem

O índice r é definida como a razão ponto a ponto entre a imagem ruidosa \tilde{I} e filtrada \hat{I} mostrada na equação 6.5 (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 (PENNA; MASCARENHAS, 2018).

$$r = \frac{\tilde{I}}{\hat{I}} \quad (6.5)$$

Recentemente, Gomez et al. (2015) desenvolveram o “ $\alpha\beta$ -ratio estimator”, que mede a quantidade de estruturas remanescentes na razão r . Primeiramente, Gomez et al. (2015) apresentam o estimador de bordas β_{ratio} que indica a presença de estruturas geométricas na razão

quando seu valor for alto. Em seguida, Gomez et al. (2015) definem o estimador $\alpha\beta$ através da equação

$$\alpha\beta = (\alpha|\delta_{ENL}| + (1 - \alpha)|\delta_{\mu}|) + \beta_{ratio}, \quad (6.6)$$

onde $\alpha \in [0, 1]$, $\delta_{ENL} = ENL_{ruidoso} - ENL_r$ e $\delta_{\mu} = 1 - \mu_r$. Ambos ENL_r e μ_r são calculados em uma área homogênea da razão r .

Capítulo 7

PROPOSTA E RESULTADOS

Como foi apresentado nos Capítulos 1 e 2, a proposta é tornar o filtro NLM capaz de atenuar o “speckle single look” em imagens SAR de intensidade diretamente no domínio das “wavelets” de Haar substituindo a distância Euclidiana do algoritmo original. Isso se torna possível através dos cálculos de novas distâncias estocásticas (NASCIMENTO; CINTRA; FRERY, 2010) baseadas na distribuição EP (CHAN; PENG, 2003) e Gama conforme mostradas no Capítulo 4.

Segundo Liu et al. (2014), a imagem é decomposta pela coluna por uma transformada “wavelet” unidimensional. Em seguida, a decomposição pela “wavelet” é feita em linhas por uma transformada bidimensional. A Figura 7.1 exemplifica este processo. Nessa figura, no processo final, existem quatro componentes: LL, HL, LH e HH. L de “low-pass” (passa-baixa) e H de “high-pass” (passa-alta). LL representa os componentes obtidos com o filtro passa-baixa, ou seja, são os componentes de aproximação da imagem. LH, HL e HH representam, respectivamente, os coeficientes dos detalhes, isto é, componentes obtidos com o filtro passa-alta, horizontais, verticais e diagonais.




Figura 7.1: Decomposição de uma imagem pela Transformada “wavelet”.

A transformação homomórfica (ARSENAULT; APRIL, 1976), ao transportar a imagem para o domínio logarítmico, converte o ruído multiplicativo para aditivo e o torna independente do sinal. Quanto maior for o número de “looks”, a conversão da Gama ficará próxima de uma Gaussiana. A Figura 7.2 ilustra o gráfico da densidade que modela o “speckle” ao ser aplicada a

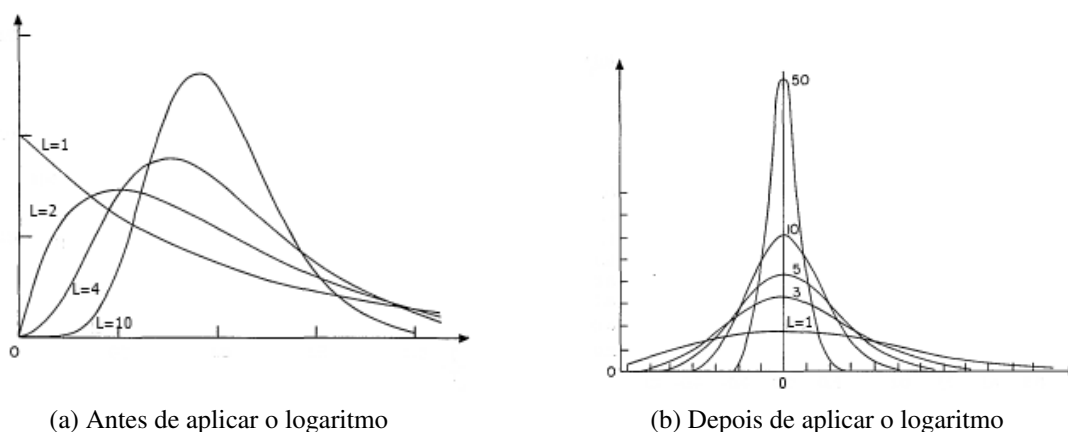


Figura 7.2: Gráfico da fdp do “speckle”. L representa o número de “looks”. Quanto maior o L , a função se aproxima mais de uma Gaussiana no gráfico (b).

transformação. 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 (PENNA, 2014). De acordo com Starck, Murtagh e Fadili (2010), o viés pode ser removido subtraindo o logaritmo da imagem por $\Psi_0(L) - \log(L)$, onde Ψ denota uma função digama. Para a imagem voltar ao seu domínio original, aplica-se a função exponencial.

As Figuras 7.3 e 7.4 mostram os diagramas do método proposto. Primeiramente, na Figura 7.3, a imagem ruidosa, isto é, o retorno Z é decomposto em 1 nível através da “wavelet” de Haar. Assim, obtém-se o coeficiente de aproximação (cA) e os coeficientes de detalhes: horizontal (cH), vertical (cV) e diagonal (cD). É importante destacar que, experimentalmente, não foram encontrados resultados superiores utilizando mais de um nível de decomposição. Com os coeficientes encontrados, é possível utilizar o NLM com as distâncias estocásticas apresentadas no Capítulo 4 e obter os coeficientes filtrados: cAF, cHF, cVF, cDF. Após a transformação homomórfica dos coeficientes de detalhe filtrados, é aplicado o “soft threshold” com o limiar computado pelo “Visu Shrink”. Em seguida, depois do “thresholding”, os coeficientes retornam ao seu domínio original com a função exponencial e é aplicada a IDWT. Optou-se pelo uso da transformação homomórfica após a filtragem das imagens sintéticas, pois, heurísticamente, foram encontrados resultados de PSNR e SSIM superiores nos experimentos sintéticos.

Já a Figura 7.4 mostra a etapa de pós-processamento para remover qualquer artefato gerado no método proposto. Como o DA3D foi elaborado para o ruído aditivo, utilizou-se novamente da transformação homomórfica. Além disso, a imagem filtrada pelo SAR-BM3D (X_SARBM3D), foi usada como guia já que a filosofia do DA3D é baseada em uma imagem estimada por um algoritmo do estado-da-arte.

Para a comparação dos resultados do método proposto, os recentes filtros serão utilizados:

FANS (COZZOLINO et al., 2013), “Optimized Bayesian NLM” (OBNLM) (COUPE et al., 2009), Iterative PPB (DELEDALLE; DENIS; TUPIN, 2009) e SAR-BM3D (PARRILLI et al., 2012). É importante notar que, os filtros PPB, FANS e SAR-BM3D foram desenvolvidos para imagens SAR em amplitude, isto é, considerando a distribuição de Rayleigh. Portanto, é necessário aplicar a raiz quadrada na imagem SAR de intensidade nestes filtros para transformá-la em imagem SAR em amplitude. Após a filtragem, a imagem deve ser elevada ao quadrado para voltar a ser uma imagem SAR em intensidade.

Nas sessões dos experimentos sintéticos e reais a seguir, optou-se por mostrar os resultados das distâncias que apresentaram o melhor valor de PSNR e SSIM para os casos sintéticos, e melhor média e desvio padrão para as imagens reais. As distâncias são: Rényi (Concord e Cameraman), Kullback-Leibler (Lena), Aritmética-Geométrica (Barbara e Região 2), Jensen-Shannon (Região 1) e Média-Harmônica (Região 3). No apêndice A, mostram-se as tabelas com os valores para as demais distâncias para cada imagem. Analisando o apêndice, pode-se dizer que os valores de cada distância são muito próximos entre eles. Isto significa que o resultado das distâncias acaba sendo o mesmo e que há diferenças muito tênues ao comparar as imagens filtradas.

Para os coeficientes de aproximação que não tiveram as fórmulas fechadas de algumas distâncias para distribuição Gama, utilizou-se a distância de Kullback-Leibler, pois ela forneceu bons resultados em (PENNA; MASCARENHAS, 2018) e eles são muito próximos das demais distâncias. Além disto, acredita-se que escolher diferentes distâncias para os coeficientes de aproximação e detalhes não ocasionará algum efeito prejudicial no resultado final da filtragem porque, conforme o diagrama da Figura 7.3 mostra, são processos independentes.

7.1 Resultados sintéticos

O código utilizado para gerar o ruído “speckle” para a análise em resultado sintético foi obtido através do filtro PPB (“Probabilistic Patch-Based”) de Deledalle, Denis e Tupin (2009). Este código gera uma distribuição exponencial pela soma do quadrado de duas Gaussianas. A Figura 7.5 mostra o código.

Para os resultados sintéticos, quatro imagens foram utilizadas: Barbara, Cameraman, Concord e Lena. Para cada imagem, dez realizações do “speckle” foram feitas e as médias dos valores do PSNR, SSIM e do tempo foram calculadas. A Figura 7.6 mostra as imagens originais e ruidosas com o ruído “single look”.

Qualquer filtro forjado pelos paradigmas do NLM precisa ser configurado com três parâmetros

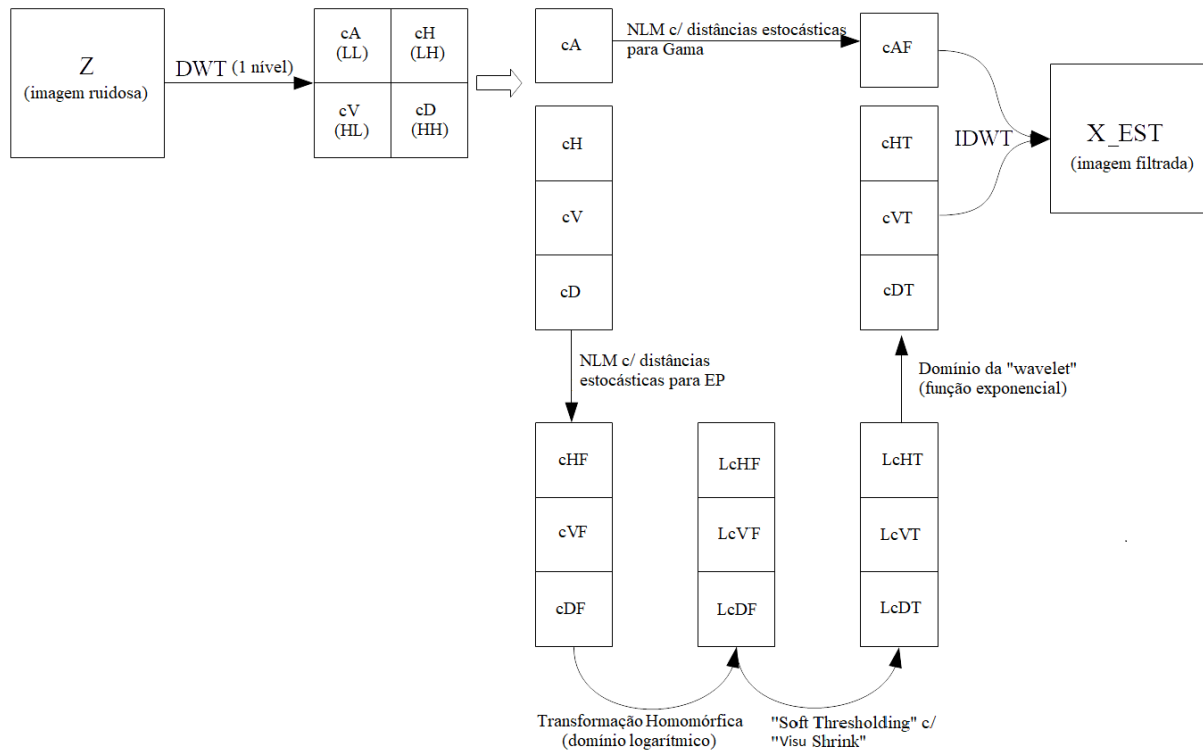


Figura 7.3: Diagrama do método proposto com 1 nível de decomposição utilizando a "wavelet" de Haar.

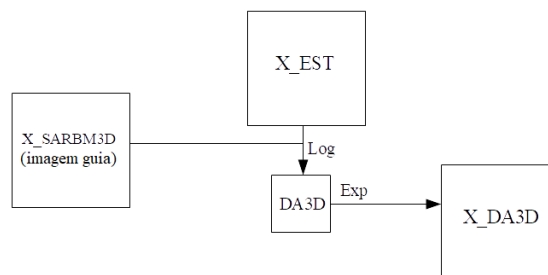


Figura 7.4: Diagrama do pós-processamento.

```

1 disp('Criando o ruído. ');
2 L = 1; %numero de looks
3 s = zeros(size(img)); %Uma matriz de zeros da dimensão da imagem.
4 for k = 1:L
5     %Gama: valor absoluto(parte real de uma Gaussiana + parte imaginaria da Gaussiana)^2/2.
6     %Isto equivale a soma do quadrado de duas Gaussianas.
7     s = s + abs(randn(size(img)) + i * randn(size(img))).^2 / 2;
8 end

```

Figura 7.5: Código para gerar o "speckle".



(a) Barbara



(b) Barbara ruidosa




(c) Cameraman



(d) Cameraman ruidosa



(e) Concord



(f) Concord ruidosa



(g) Lena



(h) Lena ruidosa

Figura 7.6: Ruído “speckle single look” para os experimentos sintéticos.

básicos: área de busca, tamanho dos “patches” e parâmetro de suavização h . A Tabela 7.1 mostra a definição destes parâmetros para cada imagem. Nesta tabela, σ_c indica o desvio padrão do coeficiente de aproximação. Todos os valores foram encontrados experimentalmente. O coeficiente de escala é representado por c e o coeficiente de detalhe é indicado por w . De acordo com Penna e Mascarenhas (2018), ainda não é conhecida uma expressão na literatura para computar um valor ideal para h . Os valores dos parâmetros para os demais filtros foram mantidos de acordo com os respectivos artigos.

Tabela 7.1: Configuração dos parâmetros para os experimentos sintéticos.

| Imagens (dimensão) | h para c | h para w | “Patch” c | “Patch” w | Área de busca c | Área de busca w |
|--------------------------|--------------|------------------------|-------------|-------------|-------------------|-------------------|
| Barbara (512 × 512) | 0,22 | $1,35 \times \sigma_c$ | 5 × 5 | 3 × 3 | 11 × 11 | 11 × 11 |
| Cameraman (256 × 256) | 0,25 | $1,5 \times \sigma_c$ | 3 × 3 | 3 × 3 | 11 × 11 | 11 × 11 |
| Concord (412 × 412) | 0,13 | $1,25 \times \sigma_c$ | 5 × 5 | 5 × 5 | 11 × 11 | 11 × 11 |
| Lena (512 × 512) | 0,22 | $0,4 \times \sigma_c$ | 5 × 5 | 5 × 5 | 11 × 11 | 11 × 11 |

As Figuras 7.7 a 7.10 mostram as imagens filtradas. Além do método proposto (MP) os resultados com o DA3D utilizando, como guia, o próprio MP (MP + DA3D) e o SAR-BM3D (DA3D (SAR-BM3D)) foram incluídos. Para dar a mesma vantagem do processamento final, a filtragem do SAR-BM3D com o DA3D foi adicionado (SARBM3D + DA3D). Analisando as figuras, nota-se a competitividade do MP com os filtros recentes. O MP produz uma imagem estimada visualmente melhor que o PPB e o OBNLM. Porém, pode-se dizer que o SAR-BM3D e o FANS possuem uma preservação de detalhes finos e bordas superior ao MP devido à filosofia do NLM, que tende a produzir uma imagem mais suavizada. Através do DA3D, é perceptível um ganho dos detalhes e a redução de artefatos. Fazendo com que o MP fique com resultados próximos aos do estado-da-arte.

Os valores do PSNR, SSIM e do tempo (em segundos) das Tabelas 7.2 a 7.5 indicam a competitividade do MP e a vantagem de utilizar o DA3D. O MP com o DA3D (SAR-BM3D) supera o SAR-BM3D e os demais filtros. O sinal + na coluna de Tempo representa o tempo adicional do DA3D na etapa de pós-processamento. Analisando as tabelas, conclui-se que o MP superou o PPB e OBNLM embora ele produza alguns artefatos na imagem filtrada. Além disso, a abordagem proposta foi próxima ao FANS e SAR-BM3D e os superou em alguns casos utilizando o DA3D. No entanto, é importante destacar o excelente resultado do SAR-BM3D com o DA3D. Apenas para a imagem de Concord o MP superou o SAR-BM3D + DA3D.

Com relação ao tempo de execução, é perceptível que o MP é inferior aos demais filtros.

Isto acontece devido ao fato de que foi utilizado o algoritmo original do NLM, ou seja, não foi utilizada nenhuma otimização na performance ou vetorização do código.



(a) FANS



(b) MP + DA3D (SAR-BM3D)



(c) MP + DA3D



(d) SAR-BM3D + DA3D



(e) OBNLM



(f) PPB



(g) MP



(h) SAR-BM3D

Figura 7.7: Resultados para Barbara com a distância Aritmética-Geométrica.



Figura 7.8: Resultados para Cameraman com a distância de Rényi.




Figura 7.9: Resultados para Concord com a distância de Rényi.



Figura 7.10: Resultados para Lena com a distância de Kullback-Leibler.

Tabela 7.2: Valores do PSNR, SSIM e tempo de processamento para a imagem da Barbara. Os valores são médias sobre dez realizações do “speckle” (distância da Aritmética-Geométrica).

| Filtros | PSNR | SSIM | Tempo (s) |
|----------------------|-------|------|-----------|
| FANS | 21,46 | 0,56 | 7,70 |
| MP | 21,40 | 0,51 | 200,37 |
| MP + DA3D (SAR-BM3D) | 21,81 | 0,55 | +12,82 |
| MP + DA3D | 21,49 | 0,53 | +10,19 |
| OBNLM | 19,59 | 0,37 | 1,12 |
| PPB | 21,40 | 0,46 | 62,47 |
| SAR-BM3D | 22,16 | 0,56 | 100,13 |
| SAR-BM3D + DA3D | 22,30 | 0,59 | +12,74 |

Tabela 7.3: Valores do PSNR, SSIM e tempo de processamento para a imagem do Cameraman. Os valores são médias sobre dez realizações do “speckle” (distância de Rényi).

| Filtros | PSNR | SSIM | Tempo (s) |
|----------------------|-------|------|-----------|
| FANS | 22,39 | 0,69 | 2,12 |
| MP | 20,75 | 0,63 | 59,74 |
| MP + DA3D (SAR-BM3D) | 22,20 | 0,68 | +4,00 |
| MP + DA3D | 20,82 | 0,62 | +3,10 |
| OBNLM | 19,26 | 0,38 | 0,27 |
| PPB | 21,00 | 0,49 | 17,75 |
| SAR-BM3D | 22,71 | 0,63 | 24,32 |
| SAR-BM3D + DA3D | 22,98 | 0,71 | +3,93 |

Tabela 7.4: Valores do PSNR, SSIM e tempo de processamento para a imagem de Concord. Os valores são médias sobre dez realizações do “speckle” (distância de Rényi).

| Filtros | PSNR | SSIM | Tempo (s) |
|----------------------|-------|------|-----------|
| FANS | 23,20 | 0,56 | 4,82 |
| MP | 23,40 | 0,52 | 158,32 |
| MP + DA3D (SAR-BM3D) | 23,44 | 0,52 | +5,45 |
| MP + DA3D | 23,30 | 0,51 | +4,55 |
| OBNLM | 21,61 | 0,39 | 0,84 |
| PPB | 22,49 | 0,43 | 41,68 |
| SAR-BM3D | 23,49 | 0,55 | 64,13 |
| SAR-BM3D + DA3D | 23,43 | 0,53 | +5,56 |

Tabela 7.5: Valores do PSNR, SSIM e tempo de processamento para a imagem da Lena. Os valores são médias sobre dez realizações do “speckle” (distância de Kullback-Leibler).

| Filtros | PSNR | SSIM | Tempo (s) |
|----------------------|-------|------|-----------|
| FANS | 23,74 | 0,68 | 7,69 |
| MP | 23,90 | 0,63 | 194,34 |
| MP + DA3D (SAR-BM3D) | 24,62 | 0,68 | +12,12 |
| MP + DA3D | 24,15 | 0,66 | +9,35 |
| OBNLM | 20,78 | 0,35 | 1,22 |
| PPB | 23,33 | 0,47 | 63,19 |
| SAR-BM3D | 24,51 | 0,62 | 101,59 |
| SAR-BM3D + DA3D | 25,08 | 0,71 | +12,68 |

7.1.1 Análise dos histogramas

O intuito desta subseção é mostrar a eficácia do modelo proposto analisando os histogramas de uma imagem do experimento sintético. Além disso, com os histogramas torna-se possível mostrar a atuação heurística da limiarização dos coeficientes de detalhes (cH, cV e cD).

Foi selecionado uma realização aleatória da imagem Lena com a distância de Kullback-Leibler. A Figura 7.11 ilustra os histogramas da imagem original, ruidosa, filtrada e limiarizada. É possível ver que, através da limiarização, o histograma final possui mais vales que o histograma da imagem filtrada pelo método proposto.

Já as Figuras 7.12, 7.13 e 7.14 exibem, respectivamente, os histogramas dos coeficientes de aproximação (cA) e de detalhes ruidosos, filtrados e limiarizados. Observando a Figura 7.12 é possível ver que os histogramas seguem as distribuições das equações 3.32 e 3.33 da seção 3.3.

Analisando as figuras dos histogramas, é possível notar o bom desempenho do filtro proposto, pois preserva a média dos coeficientes de detalhes e o histograma do coeficiente de aproximação aproxima-se do histograma da imagem real. Na Tabela 7.6, indica-se os valores da média, desvio padrão, PSNR, SSIM do método proposto “puro”, isto é, sem a limiarização, e o método com a limiarização. Os valores foram obtidos com a média de dez realizações do “speckle”. A média e desvio padrão da imagem original são, respectivamente, 124,05 e 47,85. Nota-se que os dois métodos possuem a média e o desvio padrão próximos aos valores originais. Porém a limiarização garantiu um PSNR e SSIM superior. Este padrão se repetiu para todos os experimentos sintéticos, ou seja, a limiarização obteve valores melhores. Por isso, optou-se em mostrar os valores do PSNR e SSIM do método proposto com a limiarização nos resultados sintéticos. O apêndice A contém as tabelas com todos os valores.

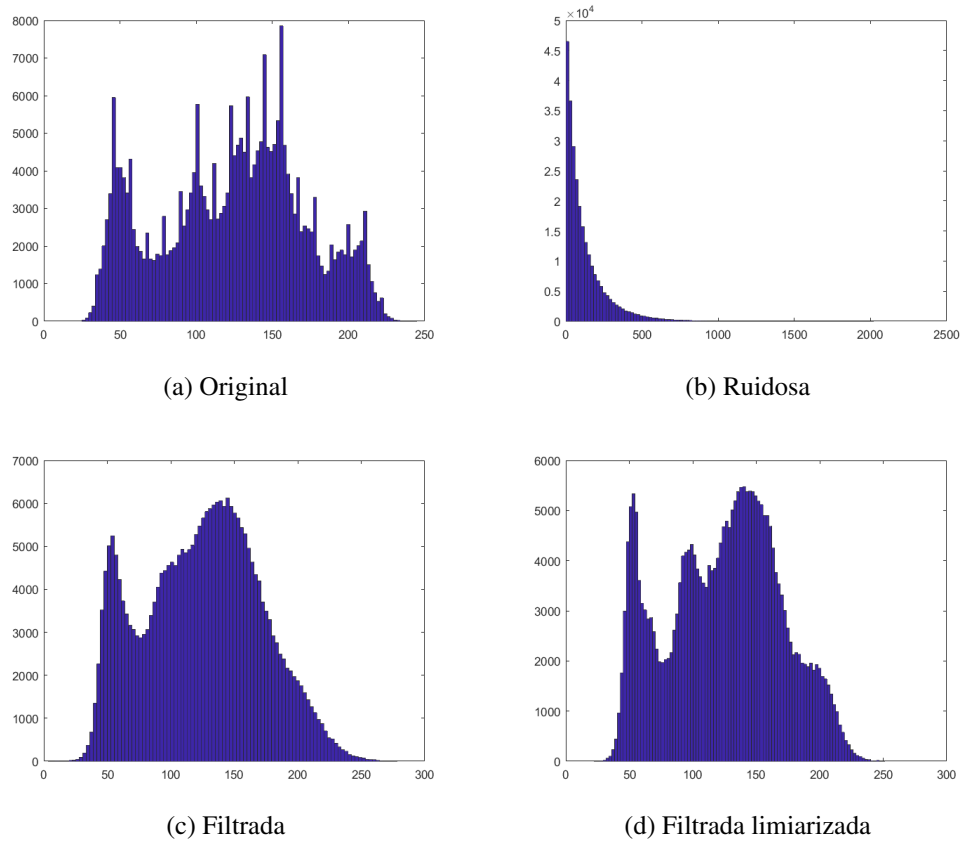


Figura 7.11: Histogramas das imagens da Lena.




Figura 7.12: Histogramas dos coeficientes ruidosos.




Figura 7.13: Histogramas dos coeficientes filtrados.

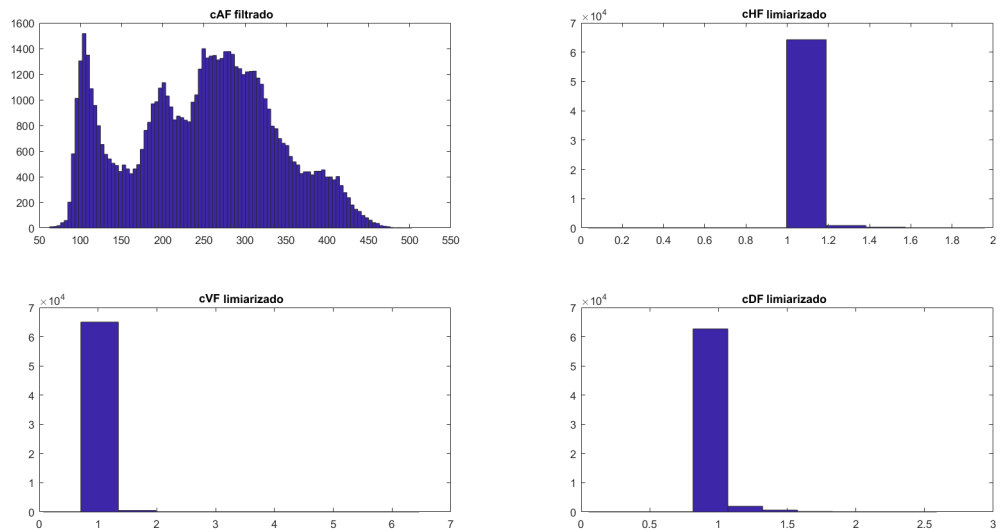


Figura 7.14: Histogramas dos coeficientes filtrados limiarizados.

Tabela 7.6: Valores da média, desvio padrão, PSNR, SSIM do filtro proposto com e sem limiarização para a imagem da Lena. Os valores são médias sobre dez realizações do “speckle” com a distância de Kullback-Leibler. PSNR da imagem ruidosa: 5,65

| Filtros | MP puro | MP + limiarização |
|---------------|---------|-------------------|
| Média | 124,21 | 124,21 |
| Desvio padrão | 46,03 | 44,78 |
| PSNR | 22,39 | 23,90 |
| SSIM | 0,38 | 0,63 |

7.2 Resultados reais

Três regiões SAR reais de intensidade de uma mesma imagem foram utilizadas para comparar e analisar os filtros. A imagem da região de Oberpfaffenhofen próxima a Munique (Alemanha) é apresentada na Figura 7.15. Ela é uma imagem “single look” e foi obtida através da plataforma E-SAR (“Experimental airborne SAR System”) do Centro Espacial Alemão (DLR - “Deutsches Zentrum für Luft- und Raumfahrt”) com polarização HH (horizontal-horizontal). Sua dimensão é de 7134×1475 pixels. Três áreas foram escolhidas aleatoriamente com dimensão de 512×512 que continham os tipos de rugosidade mais comuns: homogênea (rios, lagos, pastos), heterogêneas (florestas) e extremamente heterogêneas (centros urbanos). Os quadrados marcados da Figura 7.15 indicam as três regiões, que são apresentadas com uma melhor visualização na Figura 7.16.



Figura 7.15: Imagem SAR “single look” HH de Oberpfaffenhofen.




Figura 7.16: Regiões de dimensão 512×512 escolhidas.

Para todas as regiões, o NLM foi configurado com “patches” 5×5 e área de busca com dimensão de 11×11 . O coeficiente de aproximação da DWT foi filtrado com o parâmetro de suavização $h = 5 \times 10^{-3}$, enquanto que os coeficientes de detalhes foram processados com $h = 5 \times 10^{-3} \sigma_{cA}^2$, onde σ_{cA}^2 é a variância do coeficiente de aproximação. Todos os valores foram encontrados experimentalmente. No entanto, os experimentos nas imagens reais utilizando a limiarização conforme o diagrama da Figura 7.3 e a subseção 7.1.1 mostraram que, tanto visualmente quanto nos valores da média e do desvio padrão da razão que serão apresentados

nas tabelas a seguir, não houve algum ganho de desempenho. Portanto, para os experimentos reais, após a filtragem dos coeficientes de detalhes decidiu-se não efetuar a limiarização.

Examinando as Figuras 7.17, 7.18 e 7.19, as quais mostram as regiões 1, 2 e 3 filtradas, é possível considerar que o método proposto (MP) é competitivo com o FANS, PPB e OBNLM. Visualmente, o PPB produz uma imagem mais borrada. Além disso, a abordagem proposta é bastante efetiva em subtrair o “speckle” em regiões homogêneas e heterogêneas. No entanto, ela perde detalhes em superfícies extremamente heterogêneas. O filtro FANS também tende a perder estruturas finas nas áreas rugosas.

Os resultados do MP com o DA3D utilizando o SAR-BM3D como guia mostram que o DA3D é uma boa ferramenta para recuperar estruturas removidas na filtragem. O DA3D fornece uma vantagem sobre os demais métodos, pois consegue recuperar algumas estruturas retidas no processo de filtragem. Além disso, o DA3D garante a eficácia do SAR-BM3D, que supera todos os filtros utilizando a técnica de pós-processamento. Contudo, aplicando o DA3D no MP sem uma imagem guia não levou a uma melhora significativa.

Sabe-se que não é possível aplicar as medidas de PSNR e SSIM uma vez que não existe uma refletividade livre de ruído (“ground truth”). Ademais, o conhecido número equivalente de “looks” : $ENL = \mu^2 / \sigma^2$, onde μ e σ^2 são, respectivamente, a média e variância locais, favorece imagens super suavizadas ocasionando, erroneamente, em um resultado de valor elevado (PENNA; MASCARENHAS, 2018).

Aplicar a razão r entre a imagem ruidosa y e a filtrada \hat{f} : $r = y / \hat{f}$ pode ser uma medida sem referência eficaz (ARGENTI et al., 2013). Esta razão mostra o padrão do ruído removido que, supostamente, deve ser distribuído de acordo com uma distribuição Gama. Através de um filtro ideal, r deve conter apenas o padrão do ruído. Caso contrário, r fornecerá uma imagem com estruturas e bordas (PENNA; MASCARENHAS, 2018).

Observando as Figuras 7.20, 7.21 e 7.22, nota-se que o método proposto perdeu algumas estruturas como o PPB, OBNLM e FANS. É bastante difícil encontrar detalhes na razão do SAR-BM3D confirmando o seu lugar no estado-da-arte. Finalmente, através do DA3D, é perceptível que no nosso método alguns detalhes e estruturas foram reobtidas e que, visualmente, melhorou o resultado do SAR-BM3D.

No entanto, pode-se dizer que a inspeção visual é uma medida subjetiva. Não é possível detectar um viés introduzido na imagem filtrada ou fornecer uma análise quantitativa. De acordo com Penna e Mascarenhas (2018), utilizar a média (μ_r) e o desvio padrão (σ_r) da razão r é possível fazer uma abordagem quantitativa. Os valores de μ_r e σ_r devem ser próximos aos seus




Figura 7.17: Resultados para a região 1 (R1).




Figura 7.18: Resultados para a região 2 (R2).




Figura 7.19: Resultados para a região 3 (R3).

valores teóricos, ou seja, $\mu \approx 1$ e $\sigma \approx 1$ para $L = 1$.

As Tabelas 7.7, 7.8 e 7.9 mostram os valores de μ_r e σ_r para as regiões 1, 2 e 3. É possível analisar que a média do método proposto é a única que mais se aproximou do valor ideal e que, para todos os filtros, houve um viés na variância. Também é possível identificar uma desvantagem ao utilizar o DA3D nas regiões. Ele visualmente melhora a imagem ao recuperar estruturas. No entanto, os valores da média e do desvio padrão das razões quando aplicado ao método proposto e ao SAR-BM3D decaem. Embora o PPB apresente imagens borradas, a sua variância é superior em relação aos demais filtros.

Tabela 7.7: Média (μ_r) e desvio padrão (σ_r) da razão da região 1 com a distância de Jensen-Shannon. Os melhores valores estão marcados em negrito.

| Filtros | μ_r | σ_r |
|----------------------|-------------|-------------|
| FANS | 0,83 | 0,46 |
| MP | 1,00 | 0,61 |
| MP + DA3D (SAR-BM3D) | 0,55 | 0,28 |
| MP + DA3D | 0,56 | 0,33 |
| OBNLM | 0,94 | 0,50 |
| PPB | 0,96 | 0,57 |
| SAR-BM3D | 0,96 | 0,42 |
| SAR-BM3D + DA3D | 0,55 | 0,26 |

Tabela 7.8: Média (μ_r) e desvio padrão (σ_r) da razão da região 2 com a distância Aritmética-Geométrica. Os melhores valores estão marcados em negrito.

| Filtros | μ_r | σ_r |
|----------------------|-------------|-------------|
| FANS | 0,83 | 0,46 |
| MP | 1,00 | 1,00 |
| MP + DA3D (SAR-BM3D) | 0,56 | 0,28 |
| MP + DA3D | 0,56 | 0,56 |
| OBNLM | 0,94 | 0,50 |
| PPB | 0,96 | 0,57 |
| SAR-BM3D | 0,96 | 0,44 |
| SAR-BM3D + DA3D | 0,55 | 0,26 |




Figura 7.20: Razão da região 1 (R1).




Figura 7.21: Razão da região 2 (R2).




Figura 7.22: Razão da região 3 (R3).

Tabela 7.9: Média (μ_r) e desvio padrão (σ_r) da razão da região 3 com a distância da Média-Harmônica. Os melhores valores estão marcados em negrito.

| Filtros | μ_r | σ_r |
|----------------------|-------------|-------------|
| FANS | 0,84 | 0,45 |
| MP | 1,00 | 0,53 |
| MP + DA3D (SAR-BM3D) | 0,56 | 0,28 |
| MP + DA3D | 0,56 | 0,29 |
| OBNLM | 0,96 | 0,49 |
| PPB | 0,98 | 0,54 |
| SAR-BM3D | 0,97 | 0,44 |
| SAR-BM3D + DA3D | 0,55 | 0,27 |

Capítulo 8

CONCLUSÃO

Sistemas SAR são ferramentas necessárias e fundamentais para estudar a superfície terrestre. O ruído “speckle”, que aparece em imagens adquiridas por sistemas que utilizam imageamento coerente, precisa ser atenuado. Assim, pode-se fazer uma boa análise e interpretação das cenas.

O filtro apresentado neste trabalho utilizou uma nova abordagem para filtrar o ruído “speckle single look” em imagens SAR de intensidade. É uma técnica fundamentada no conceito do filtro NLM originalmente desenvolvido para remover o ruído AWGN.

O cerne desta nova proposta é utilizar as distâncias estocásticas calculadas para a distribuição Gama para o coeficiente de aproximação e EP para os coeficientes de detalhe com o algoritmo NLM substituindo a distância Euclidiana do código original para encontrar “patches” similares. Além disso, todo o processo de filtragem com o NLM é realizado no domínio das “wavelets” de Haar.

Das oito distâncias estocásticas apresentadas, foi possível obter oito distâncias para a distribuição EP e quatro distâncias para a distribuição Gama, considerando o caso “single look” do “speckle”. No Capítulo 4, foi mostrado que as distâncias computadas satisfazem três propriedades básicas para uma distância: positividade, similaridade e homogeneidade.

Os resultados em imagens sintéticas e reais mostraram que o método proposto é competitivo com os filtros já desenvolvidos na literatura. Também foi observado que utilizar o algoritmo DA3D após a filtragem sobre imagens SAR fornece uma recuperação de estruturas na imagem estimada. Contudo, ainda é necessário melhorar o tempo de execução do código.

Com relação aos experimentos sintéticos, pode-se dizer que, heurísticamente, foi necessário utilizar a limiarização com o limiar computado pelo “Visu Shrink” para que o método proposto

alcançasse valores de PSNR e SSIM melhores. Isto significa que devem ser feitos experimentos em outras imagens sintéticas usando medidas diferentes para avaliar a performance do filtro.

Ao analisar os experimentos reais, a abordagem proposta mostrou superioridade em relação aos testes sintéticos porque não houve a necessidade de aplicar a limiarização. Além disso, o filtro superou alguns algoritmos já existentes na literatura tanto subjetivamente quanto quantitativamente. A questão de solucionar a perda de detalhes das regiões heterogêneas para o filtro proposto ainda está aberta. Todavia, analisando os resultados dos demais filtros, isto não é um problema pertencente apenas ao método proposto com as distâncias estocásticas visto que outros métodos também apresentaram esta perda de estruturas finas.

Por fim, além de inovar através do uso das distribuições EP e Gama no domínio Haar, e as distâncias estocásticas correspondentes na filtragem NLM, este filtro mostrou ser competitivo com os algoritmos do estado-da-arte de filtragem do “speckle”.

8.1 Trabalhos futuros

Como a abordagem foi feita nos conceitos do NLM, que é uma filosofia inferior ao BM3D, pode-se transportar todo o conceito das distâncias estocásticas para o algoritmo do BM3D. Com relação ao tempo de execução, uma alternativa para diminuir o tempo através de uma otimização da performance ou vetorização do código do NLM deve ser estudada. Também é de grande interesse utilizar a idéia proposta para outros tipos de “wavelets”.

Os resultados mostraram que o método proposto tende a perder detalhes de regiões extremamente heterogêneas. Logo, é necessário estudar solucionar esta perda. Além disso, pode-se dizer que seria de grande importância expandir o algoritmo proposto para o caso “multi-look”, isto é, $L > 1$.

Com relação à limiarização, como mencionado nos experimentos reais e sintéticos, observou-se que utilizá-la após a filtragem das imagens sintéticas, heurísticamente, provou melhorar os resultados, mas não houve uma melhora nos valores das imagens SAR reais. Seria ideal utilizar, como trabalho futuro, a abordagem proposta com as imagens elaboradas do “benchmark” de Martino et al. (2014) e o próprio “benchmark”, que permite capturar outros valores para conferir o desempenho dos filtros para imagens SAR junto com o estimador $\alpha\beta$ apresentado na seção 6.2.2. Também é de grande importância realizar testes sintéticos com mais iterações do ruído “speckle” a fazer mais análises estatísticas através de testes “goodness of fit” e simulações Monte Carlo.

Por fim, julga-se interessante encarar, futuramente, os filtros de pós-processamento com um conhecimento Bayesiano a priori. Assim, acredita-se que é possível o DA3D, por exemplo, tratar outros tipos de ruído já que originalmente foi desenvolvido para o AWGN, além do fato do algoritmo ter mostrado uma boa eficácia para recuperar bordas em imagens reais.

REFERÊNCIAS

- AHARON, M.; ELAD, M.; BRUCKSTEIN, A. K-svd: An algorithm for designing overcomplete dictionaries for sparse representation. *IEEE Transactions on Signal Processing*, v. 54, n. 11, p. 4311–4322, 2006.
- ARGENTI, F.; ALPARONE, L. Speckle removal from sar images in the undecimated wavelet domain. *IEEE Transactions on Geoscience and Remote Sensing*, v. 40, n. 11, p. 2363–2374, 2002.
- 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.
- ARSENAULT, H. H.; APRIL, G. Properties of speckle integrated with a finite aperture and logarithmically transformed. *Journal of the Optical Society of America*, v. 66, n. 11, p. 1160–1163, Nov. 1976.
- 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.
- BINDILATTI, A. A.; VIEIRA, M. A.; MASCARENHAS, N. D. Poisson wiener filtering with non-local weighted parameter estimation using stochastic distances. *Signal Processing*, v. 144, n. Supplement C, p. 68 – 76, 2018. ISSN 0165-1684. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0165168417303523>.
- 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.
- CHAN, A. K.; PENG, C. *Wavelet for sensing technologies*. [S.l.]: Boston : Artech House, 2003. 246 p. ISBN 1580533175 (alk. paper).
- 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.
- 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.

- 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.
- 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. A. et al. Mulog, or how to apply gaussian denoisers to multi-channel sar speckle reduction? *IEEE Transactions on Image Processing*, v. 26, n. 9, p. 4389–4403, Sept 2017. ISSN 1057-7149.
- DONOHO, D. L. De-noising by soft-thresholding. *IEEE Transactions on Information Theory*, v. 41, n. 3, p. 613–627, May 1995. ISSN 0018-9448.
- DONOHO, D. L.; JOHNSTONE, I. M. Adapting to unknown smoothness via wavelet shrinkage. *Journal of the American Statistical Association*, v. 90, n. 432, p. 1200–1224, 1995. Disponível em: <http://www.tandfonline.com/doi/abs/10.1080/01621459.1995.10476626>.
- 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.
- FIROIU, I. et al. Bayesian hyperanalytic denoising of sonar images. *IEEE Geoscience and Remote Sensing Letters*, v. 8, n. 6, p. 1065–1069, Nov 2011. ISSN 1545-598X.
- 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.
- 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.
- GOMEZ, L. et al. A new image quality index for objectively evaluating despeckling filtering in sar images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, PP, n. 99, p. 1–11, 2015. ISSN 1939-1404.
- GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing*. 3. ed. [S.l.]: Prentice Hall, 2007. 954 p.
- GOODMAN, J. W. Some fundamental properties of speckle*. *J. Opt. Soc. Am., OSA*, v. 66, n. 11, p. 1145–1150, Nov 1976. Disponível em: <http://www.osapublishing.org/abstract.cfm?URI=josa-66-11-1145>.
- HIREMATH, P.; AKKASALIGAR, P. T.; BADIGER, S. Speckle noise reduction in medical ultrasound images. In: GUNARATHNE, G. (Ed.). *Advancements and Breakthroughs in Ultrasound Imaging*. Rijeka: InTech, 2013. cap. 08, p. 295. Disponível em: <http://dx.doi.org/10.5772/56519>.

- HORTA, M. M. *Modelos de mistura de distribuições na segmentação de imagens SAR polarimétricas multi-look*. 116 p. Dissertação (Mestrado) — Universidade de São Paulo - Instituto de Física de São Carlos - Departamento de Física e Informática, 2009.
- HUANG, Y. M. et al. Multiplicative noise removal via a learned dictionary. *IEEE Transactions on Image Processing*, v. 21, n. 11, p. 4534–4543, Nov 2012. ISSN 1057-7149.
- KLAR, B. A note on gamma difference distributions. *Journal of Statistical Computation and Simulation*, v. 85, n. 18, p. 3708–3715, 2015. Disponível em: <http://dx.doi.org/10.1080/00949655.2014.996566>.
- KNAUS, C.; ZWICKER, M. Dual-domain image denoising. In: *Image Processing (ICIP), 2013 20th IEEE International Conference on*. [S.l.: s.n.], 2013. p. 440–444.
- KNAUS, C.; ZWICKER, M. Progressive image denoising. *Image Processing, IEEE Transactions on*, v. 23, n. 7, p. 3114–3125, July 2014. ISSN 1057-7149.
- KNAUS, C.; ZWICKER, M. Dual-domain filtering. *SIAM Journal on Imaging Sciences*, v. 8, n. 3, p. 1396–1420, 2015. Disponível em: <http://dx.doi.org/10.1137/140978879>.
- KRISHNA, E.; JOSE, K. Marshall-olkin generalized asymmetric laplace distributions and processes. *Statistica*, v. 71, n. 4, p. 453–467, 2011. ISSN 1973-2201. Disponível em: <https://trivista-statistica.unibo.it/article/view/3627>.
- 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. 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.
- LIU, J. et al. An adaptive sar image speckle reduction algorithm based on wavelet transform and partial differential equations. In: *EUSAR 2014; 10th European Conference on Synthetic Aperture Radar; Proceedings of*. [S.l.: s.n.], 2014. p. 1–4.
- 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.
- MAITY, A. et al. A comparative study on approaches to speckle noise reduction in images. In: *Computational Intelligence and Networks (CINE), 2015 International Conference on*. [S.l.: s.n.], 2015. p. 148–155. ISSN 2375-5822.
- MALLADI, R.; KASILINGAM, D.; COSTA, A. Speckle filtering of sar images using holder 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.

- MALLAT, S. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 11, n. 7, p. 674–693, Jul 1989. ISSN 0162-8828.
- MARTINO, G. D. et al. Benchmarking framework for sar despeckling. *IEEE Transactions on Geoscience and Remote Sensing*, v. 52, n. 3, p. 1596–1615, March 2014. ISSN 0196-2892.
- MARTINO, G. D. et al. Scattering-based nonlocal means sar despeckling. *IEEE Transactions on Geoscience and Remote Sensing*, v. 54, n. 6, p. 3574–3588, June 2016. ISSN 0196-2892.
- MARTINO, G. D. et al. Scattering-based SARBM3D. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 9, n. 6, p. 2131–2144, June 2016. ISSN 1939-1404.
- MATLAB. *version 9.0.0.341360 (R2016a)*. Natick, Massachusetts: The MathWorks Inc., 2016.
- 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.
- MISRA, A.; KARTIKEYAN, B.; GARG, S. Wavelet based sar data denoising and analysis. In: *2014 IEEE International Advance Computing Conference (IACC)*. [S.l.: s.n.], 2014. p. 1087–1092.
- 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.
- MÜLLER, P.; VIDAKOVIC, B. *Bayesian Inference in Wavelet-Based Models*. Springer New York, 2012. 396 p. (Lecture Notes in Statistics). ISBN 9781461205678. Disponível em: <https://books.google.com.br/books?id=plflBwAAQBAJ>.
- 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.
- NI, W.; GAO, X. Despeckling of sar image using generalized guided filter with bayesian nonlocal means. *IEEE Transactions on Geoscience and Remote Sensing*, v. 54, n. 1, p. 567–579, Jan 2016. ISSN 0196-2892.
- 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.
- PENG, Q.; ZHAO, L. Sar image filtering based on the cauchy-rayleigh mixture model. *IEEE Geoscience and Remote Sensing Letters*, v. 11, n. 5, p. 960–964, May 2014. ISSN 1545-598X.
- PENNA, P. A. *Filtragem de ruído speckle em imagens de radar de abertura sintética por filtros de média não local com transformação homomórfica e distâncias estocásticas*. Dissertação (Mestrado) — Universidade Federal de São Carlos - Departamento de Computação, 2014.

- PENNA, P. A.; MASCARENHAS, N. D. (Non-) Homomorphic approaches to denoise intensity sar images with non-local means and stochastic distances. *Computers & Geosciences*, v. 111, n. Supplement C, p. 127 – 138, 2018. ISSN 0098-3004. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0098300417300432>.
- PIERAZZO, N.; FACCILOLO, G. Data Adaptive Dual Domain Denoising: a Method to Boost State of the Art Denoising Algorithms. *Image Processing On Line*, v. 7, p. 93–114, 2017.
- PIERAZZO, N. et al. Non-local dual image denoising. In: *2014 IEEE International Conference on Image Processing (ICIP)*. [S.l.: s.n.], 2014. p. 813–817.
- PIERAZZO, N. et al. DA3D: Fast and data adaptive dual domain denoising. In: *2015 IEEE International Conference on Image Processing (ICIP)*. [S.l.: s.n.], 2015. p. 432–436.
- RANJANI, J. J.; THIRUVENGADAM, S. J. Dual-tree complex wavelet transform based sar despeckling using interscale dependence. *IEEE Transactions on Geoscience and Remote Sensing*, v. 48, n. 6, p. 2723–2731, June 2010. ISSN 0196-2892.
- RIBEIRO, E. da S. *Novas Propostas em Filtragem de Projeções Tomográficas sob Ruído Poisson*. 152 p. Dissertação (Mestrado) — Universidade Federal de São Carlos - Departamento de Computação, 2010.
- SALICRU, M. et al. On the applications of divergence type measures in testing statistical hypotheses. *Journal of Multivariate Analysis*, v. 51, n. 2, p. 372 – 391, 1994. ISSN 0047-259X. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0047259X84710682>.
- SANTOS, C. A. N.; MARTINS, D. L. N.; MASCARENHAS, N. D. A. Ultrasound image despeckling using stochastic distance-based bm3d. *IEEE Transactions on Image Processing*, v. 26, n. 6, p. 2632–2643, June 2017. ISSN 1057-7149.
- SAURABH, A.; KUMAR, A.; ANITHA, U. Performance analysis of various wavelet thresholding techniques for despeckling of sonar images. In: *2015 3rd International Conference on Signal Processing, Communication and Networking (ICSCN)*. [S.l.: s.n.], 2015. p. 1–7.
- STANKOVIC, R. S.; FALKOWSKI, B. J. The haar wavelet transform: its status and achievements. *Computers & Electrical Engineering*, v. 29, n. 1, p. 25 – 44, 2003. ISSN 0045-7906. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0045790601000118>.
- 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. 316 p.
- 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. C. 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.; FRERY, A. C. SAR image despeckling algorithms using stochastic distances and nonlocal means. In: *Workshop of Theses and Dissertations (WTD) in SIBGRAPI 2013 (XXVI Conference on Graphics, Patterns and Images)*. Arequipa, Peru: [s.n.], 2013.
- 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, 2014. ISSN 0031-3203. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0031320313001532>.
- 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.
- WILCOX, R. *Introduction to Robust Estimation and Hypothesis Testing*. Academic Press, 2012. 608 p. (Statistical Modeling and Decision Science). ISBN 9780123869838. Disponível em: <https://books.google.com.br/books?id=zZ0snCw9aYMC>.
- WU, J. et al. A nonlocal means for speckle reduction of sar image with multiscale-fusion-based steerable kernel function. *IEEE Geoscience and Remote Sensing Letters*, v. 13, n. 11, p. 1646–1650, Nov 2016. ISSN 1545-598X.
- WU, J. et al. Local maximal homogeneous region search for sar speckle reduction with sketch-based geometrical kernel function. *IEEE Transactions on Geoscience and Remote Sensing*, v. 52, n. 9, p. 5751–5764, Sept 2014. ISSN 0196-2892.
- XU, B. et al. An iterative sar image filtering method using nonlocal sparse model. *IEEE Geoscience and Remote Sensing Letters*, v. 12, n. 8, p. 1635–1639, Aug 2015. ISSN 1545-598X.
- YAHYA, N.; KAMEL, N. S.; MALIK, A. S. Subspace-based technique for speckle noise reduction in sar images. *IEEE Transactions on Geoscience and Remote Sensing*, v. 52, n. 10, p. 6257–6271, Oct 2014. ISSN 0196-2892.
- ZHANG, F. et al. Cycle spinning dual-domain SAR image denoising. In: *2015 IEEE International Conference on Signal Processing Communications and Computing (ICSPCC)*. [S.l.: s.n.], 2015. p. 1–4.
- ZHANG, J. et al. Wavelet and fast bilateral filter based de-speckling method for medical ultrasound images. *Biomedical Signal Processing and Control*, v. 18, p. 1 – 10, 2015. ISSN 1746-8094. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1746809414001955>.
- ZHONG, H.; LI, Y.; JIAO, L. Bayesian nonlocal means filter for sar image despeckling. In: *APSAR 2009. 2nd Asian-Pacific Conference on Synthetic Aperture Radar, 2009*. [S.l.: s.n.], 2009. p. 1096–1099.

GLOSSÁRIO

AWGN – *Additive White Gaussian Noise*

BM3D-SAPCA – *BM3D Shape-Adaptive Principal Component Analysis*

BM3D – *Block Matching 3D Filtering*

BNLM – *Bayesian NLM*

CSID – *Cycle Spinning DDID*

CWT – *Continuous Wavelet Transform*

DA3D – *Data Adaptive Dual Domain Denoising*

DDF – *Dual-Domain Filtering*

DDID – *Dual-Domain Image Denoising*

DLR – *Deutsches Zentrum für Luft- und Raumfahrt*

DWT – *Discrete Wavelet Transform*

E-SAR – *Experimental airborne SAR System*

ENL – *Equivalent Number of Looks*

EP – *Exponential-Polynomial distribution*

EQL – *Equivalent Number of Looks*

FANS – *Fast Adaptive Nonlocal SAR*

FDP – *Funcao Densidade de Probabilidade*

IDWT – *Inverse Discrete Wavelet Transform*

K-SVD – *K-means Singular Value Decomposition*

MAD – *Median Absolute Deviation*

-
- MAP** – *Maximum a Posteriori*
- MRA** – *Multiresolution Analysis*
- MSE** – *Mean Square Error*
- NLB** – *Non Local Bayes*
- NLDD** – *Non-local Dual Image Denoising*
- NLM** – *Non-Local Means*
- OBNLM** – *Optimized Bayesian NLM*
- PID** – *Progressive Image Denoising*
- PPB** – *Probabilistic Patch-Based*
- PSNR** – *Peak Signal-to-Noise Ratio*
- SAR** – *Synthetic Aperture Radar*
- SSIM** – *Structural Similarity Index*
- STFT** – *Short Time Fourier Transform*
- TF** – *Transformada de Fourier*
- UWT** – *Undecimated Discrete Wavelet Transform*
- WMLE** – *Weighted Maximum Likelihood Estimation*

Apendice A

TABELAS DOS DEMAIS RESULTADOS

Neste apêndice serão mostradas as tabelas com os valores dos demais resultados de filtragem utilizando as distâncias estocásticas para os testes sintéticos e reais.

Denominações:

- MP: Método proposto.
- MP+TH: MP com limiarização.
- MP+DA3D: MP com DA3D sem guia, i.e., o MP serve como próprio guia.
- MP+DA3D(SAR-BM3D): MP com DA3D utilizando o SAR-BM3D como guia.
- SAR-BM3D+DA3D: SAR-BM3D com DA3D sem guia, i.e., o SAR-BM3D serve como próprio guia.
- MP+TH+DA3D: DA3D sem guia aplicado no MP+TH.
- MP+TH+DA3D(SAR-BM3D): DA3D com guia aplicado no MP+TH.
- +: tempo adicional para o DA3D.

A.1 Experimentos sintéticos

A.1.1 Barbara

Tabela A.1: Barbara: Aritmética-Geométrica.

| Filtros | PSNR | SSIM | Tempo(s) |
|----------------------|-------|------|----------|
| MP | 20,53 | 0,36 | 200,38 |
| MP+TH | 21,41 | 0,51 | 200,38 |
| OBNLM | 19,6 | 0,37 | 1,12 |
| PPB | 21,4 | 0,47 | 62,47 |
| FANS | 21,47 | 0,56 | 7,7 |
| SAR-BM3D | 22,16 | 0,56 | 100,13 |
| MP+TH+DA3D | 21,49 | 0,53 | +10,19 |
| MP+TH+DA3D(SAR-BM3D) | 21,81 | 0,56 | +12,82 |
| SAR-BM3D+DA3D | 22,3 | 0,6 | +12,75 |

Tabela A.2: Barbara: Bhattacharyya.

| Filtros | PSNR | SSIM | Tempo(s) |
|----------------------|-------|------|----------|
| MP | 20,15 | 0,34 | 224,31 |
| MP+TH | 20,93 | 0,49 | 224,31 |
| OBNLM | 19,62 | 0,37 | 1,13 |
| PPB | 21,38 | 0,47 | 62,31 |
| FANS | 21,49 | 0,56 | 7,7 |
| SAR-BM3D | 22,13 | 0,56 | 98,75 |
| MP+TH+DA3D | 20,87 | 0,5 | +9,03 |
| MP+TH+DA3D(SAR-BM3D) | 21,22 | 0,53 | +13,39 |
| SAR-BM3D+DA3D | 22,25 | 0,59 | +13,28 |

Tabela A.3: Barbara: Hellinger.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 20,15 | 0,34 | 196,79 |
| MP+TH | 20,93 | 0,49 | 196,79 |
| OBNLM | 19,61 | 0,37 | 1,13 |
| PPB | 21,41 | 0,47 | 62,42 |
| FANS | 21,54 | 0,56 | 7,85 |
| SAR-BM3D | 22,15 | 0,56 | 99,93 |
| MP+TH+DA3D | 20,87 | 0,5 | +9,18 |
| MP+TH+DA3D(SAR-BM3D) | 21,21 | 0,53 | +12,72 |
| SAR-BM3D+DA3D | 22,27 | 0,59 | +12,81 |

Tabela A.4: Barbara: Jensen-Shannon.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 20,52 | 0,36 | 202,22 |
| MP+TH | 21,38 | 0,51 | 202,22 |
| OBNLM | 19,61 | 0,37 | 1,14 |
| PPB | 21,37 | 0,46 | 62,32 |
| FANS | 21,54 | 0,56 | 7,68 |
| SAR-BM3D | 22,16 | 0,56 | 98,64 |
| MP+TH+DA3D | 21,47 | 0,53 | +10,56 |
| MP+TH+DA3D(SAR-BM3D) | 21,79 | 0,56 | +13,21 |
| SAR-BM3D+DA3D | 22,28 | 0,59 | +13,65 |

Tabela A.5: Barbara: Kullback-Leibler.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 20,53 | 0,36 | 189,99 |
| MP+TH | 21,39 | 0,51 | 189,99 |
| OBNLM | 19,61 | 0,37 | 1,15 |
| PPB | 21,39 | 0,47 | 62,44 |
| FANS | 21,43 | 0,56 | 7,93 |
| SAR-BM3D | 22,15 | 0,56 | 99,05 |
| MP+TH+DA3D | 21,48 | 0,53 | +10,66 |
| MP+TH+DA3D(SAR-BM3D) | 21,79 | 0,56 | +13,37 |
| SAR-BM3D+DA3D | 22,27 | 0,59 | +12,52 |

Tabela A.6: Barbara: Média-Harmônica.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 20,53 | 0,36 | 168,49 |
| MP+TH | 21,4 | 0,51 | 168,49 |
| OBNLM | 19,63 | 0,37 | 1,11 |
| PPB | 21,42 | 0,47 | 62,5 |
| FANS | 21,61 | 0,56 | 7,84 |
| SAR-BM3D | 22,17 | 0,56 | 100,1 |
| MP+TH+DA3D | 21,48 | 0,53 | +9,6 |
| MP+TH+DA3D(SAR-BM3D) | 21,8 | 0,56 | +12,08 |
| SAR-BM3D+DA3D | 22,29 | 0,6 | +12,18 |

Tabela A.7: Barbara: Rényi.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 20,4 | 0,35 | 243,24 |
| MP+TH | 21,24 | 0,51 | 243,24 |
| OBNLM | 19,63 | 0,37 | 1,15 |
| PPB | 21,44 | 0,47 | 64,23 |
| FANS | 21,56 | 0,56 | 8,78 |
| SAR-BM3D | 22,19 | 0,57 | 104,21 |
| MP+TH+DA3D | 21,22 | 0,52 | +9,24 |
| MP+TH+DA3D(SAR-BM3D) | 21,57 | 0,54 | +12,49 |
| SAR-BM3D+DA3D | 22,31 | 0,6 | +12,82 |

Tabela A.8: Barbara: Triangular.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 20,53 | 0,36 | 171,38 |
| MP+TH | 21,4 | 0,51 | 171,38 |
| OBNLM | 19,63 | 0,37 | 1,2 |
| PPB | 21,4 | 0,47 | 66,26 |
| FANS | 21,48 | 0,56 | 8,75 |
| SAR-BM3D | 22,16 | 0,57 | 108,34 |
| MP+TH+DA3D | 21,48 | 0,53 | +11,74 |
| MP+TH+DA3D(SAR-BM3D) | 21,79 | 0,56 | +13,83 |
| SAR-BM3D+DA3D | 22,27 | 0,6 | +14,81 |

A.1.2 Cameraman

Tabela A.9: Cameraman: Aritmética-Geométrica.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 19,86 | 0,37 | 62,07 |
| MP+TH | 20,67 | 0,53 | 62,07 |
| OBNLM | 19,25 | 0,38 | 0,31 |
| PPB | 20,86 | 0,5 | 19,1 |
| FANS | 22,41 | 0,7 | 2,4 |
| SAR-BM3D | 22,74 | 0,64 | 29,03 |
| MP+TH+DA3D | 21,11 | 0,64 | +3,5 |
| MP+TH+DA3D(SAR-BM3D) | 22,49 | 0,7 | +3,84 |
| SAR-BM3D+DA3D | 23,02 | 0,72 | +4,12 |

Tabela A.10: Cameraman: Bhattacharyya.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 19,69 | 0,36 | 57,63 |
| MP+TH | 20,47 | 0,58 | 57,63 |
| OBNLM | 19,26 | 0,38 | 0,27 |
| PPB | 20,89 | 0,5 | 17,58 |
| FANS | 22,33 | 0,69 | 2,05 |
| SAR-BM3D | 22,66 | 0,64 | 23,86 |
| MP+TH+DA3D | 20,37 | 0,62 | +3,21 |
| MP+TH+DA3D(SAR-BM3D) | 21,86 | 0,68 | +4,59 |
| SAR-BM3D+DA3D | 22,97 | 0,72 | +4,54 |

Tabela A.11: Cameraman: Hellinger.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 19,65 | 0,36 | 49,57 |
| MP+TH | 20,44 | 0,58 | 49,57 |
| OBNLM | 19,23 | 0,38 | 0,26 |
| PPB | 21,06 | 0,5 | 17,57 |
| FANS | 22,47 | 0,7 | 2,04 |
| SAR-BM3D | 22,72 | 0,64 | 23,73 |
| MP+TH+DA3D | 20,33 | 0,62 | +3,25 |
| MP+TH+DA3D(SAR-BM3D) | 21,78 | 0,68 | +4,92 |
| SAR-BM3D+DA3D | 22,98 | 0,72 | +4,92 |

Tabela A.12: Cameraman: Jensen-Shannon.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 19,88 | 0,37 | 55,75 |
| MP+TH | 20,69 | 0,53 | 55,75 |
| OBNLM | 19,27 | 0,38 | 0,27 |
| PPB | 20,94 | 0,5 | 18,21 |
| FANS | 22,33 | 0,69 | 2,28 |
| SAR-BM3D | 22,74 | 0,64 | 25,82 |
| MP+TH+DA3D | 21,12 | 0,64 | +3,73 |
| MP+TH+DA3D(SAR-BM3D) | 22,46 | 0,7 | +4,49 |
| SAR-BM3D+DA3D | 23,02 | 0,72 | +4,06 |

Tabela A.13: Cameraman: Kullback-Leibler.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 19,87 | 0,37 | 60,38 |
| MP+TH | 20,69 | 0,53 | 60,38 |
| OBNLM | 19,26 | 0,38 | 0,3 |
| PPB | 21,05 | 0,5 | 19,37 |
| FANS | 22,32 | 0,69 | 2,42 |
| SAR-BM3D | 22,74 | 0,64 | 27,4 |
| MP+TH+DA3D | 21,13 | 0,64 | +3,45 |
| MP+TH+DA3D(SAR-BM3D) | 22,46 | 0,7 | +4,12 |
| SAR-BM3D+DA3D | 23,02 | 0,72 | +4,25 |

Tabela A.14: Cameraman: Média-Harmônica.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 19,83 | 0,37 | 43,67 |
| MP+TH | 20,63 | 0,53 | 43,67 |
| OBNLM | 19,21 | 0,38 | 0,27 |
| PPB | 20,9 | 0,5 | 18,04 |
| FANS | 22,29 | 0,69 | 2,1 |
| SAR-BM3D | 22,57 | 0,64 | 24,64 |
| MP+TH+DA3D | 21,07 | 0,64 | +3,99 |
| MP+TH+DA3D(SAR-BM3D) | 22,37 | 0,69 | +4,35 |
| SAR-BM3D+DA3D | 22,86 | 0,72 | +4,67 |

Tabela A.15: Cameraman: Rényi.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 19,92 | 0,37 | 59,79 |
| MP+TH | 20,75 | 0,57 | 59,79 |
| OBNLM | 19,27 | 0,38 | 0,27 |
| PPB | 21,01 | 0,5 | 17,76 |
| FANS | 22,4 | 0,69 | 2,12 |
| SAR-BM3D | 22,72 | 0,64 | 24,32 |
| MP+TH+DA3D | 20,82 | 0,63 | +3,15 |
| MP+TH+DA3D(SAR-BM3D) | 22,21 | 0,69 | +4,01 |
| SAR-BM3D+DA3D | 22,98 | 0,72 | +3,94 |

Tabela A.16: Cameraman: Triangular.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 19,82 | 0,37 | 41,5 |
| MP+TH | 20,63 | 0,53 | 41,5 |
| OBNLM | 19,21 | 0,38 | 0,28 |
| PPB | 20,93 | 0,5 | 18 |
| FANS | 22,49 | 0,7 | 2,11 |
| SAR-BM3D | 22,68 | 0,64 | 24,37 |
| MP+TH+DA3D | 21,08 | 0,64 | +3,32 |
| MP+TH+DA3D(SAR-BM3D) | 22,43 | 0,7 | +3,75 |
| SAR-BM3D+DA3D | 22,94 | 0,72 | +3,81 |

A.1.3 Concord

Tabela A.17: Concord: Aritmética-Geométrica.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 22,31 | 0,38 | 135,41 |
| MP+TH | 23,39 | 0,53 | 135,41 |
| OBNLM | 21,62 | 0,4 | 0,73 |
| PPB | 22,49 | 0,44 | 41,42 |
| FANS | 23,2 | 0,57 | 4,8 |
| SAR-BM3D | 23,48 | 0,56 | 64,35 |
| MP+TH+DA3D | 23,57 | 0,53 | +5,16 |
| MP+TH+DA3D(SAR-BM3D) | 23,64 | 0,54 | +5,97 |
| SAR-BM3D+DA3D | 23,38 | 0,54 | +5,66 |

Tabela A.18: Concord: Bhattacharyya.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 22,11 | 0,36 | 154,24 |
| MP+TH | 23,15 | 0,52 | 154,24 |
| OBNLM | 21,56 | 0,4 | 0,74 |
| PPB | 22,48 | 0,44 | 42,34 |
| FANS | 23,15 | 0,57 | 5,07 |
| SAR-BM3D | 23,48 | 0,56 | 65,52 |
| MP+TH+DA3D | 22,91 | 0,49 | +4,43 |
| MP+TH+DA3D(SAR-BM3D) | 23,1 | 0,5 | +82 |
| SAR-BM3D+DA3D | 23,4 | 0,54 | +5,76 |

Tabela A.19: Concord: Hellinger.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 22,17 | 0,36 | 150,44 |
| MP+TH | 23,21 | 0,52 | 150,44 |
| OBNLM | 21,58 | 0,4 | 0,81 |
| PPB | 22,53 | 0,44 | 45,11 |
| FANS | 23,01 | 0,57 | 5,45 |
| SAR-BM3D | 23,52 | 0,56 | 72,55 |
| MP+TH+DA3D | 22,96 | 0,49 | +4,72 |
| MP+TH+DA3D(SAR-BM3D) | 23,15 | 0,51 | +6,27 |
| SAR-BM3D+DA3D | 23,47 | 0,54 | +6,34 |

Tabela A.20: Concord: Jensen-Shannon.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 22,32 | 0,38 | 137,97 |
| MP+TH | 23,4 | 0,53 | 137,97 |
| OBNLM | 21,59 | 0,39 | 0,76 |
| PPB | 22,5 | 0,44 | 41,54 |
| FANS | 23,2 | 0,57 | 4,72 |
| SAR-BM3D | 23,48 | 0,55 | 62,69 |
| MP+TH+DA3D | 23,58 | 0,53 | +5,89 |
| MP+TH+DA3D(SAR-BM3D) | 23,65 | 0,54 | +6,35 |
| SAR-BM3D+DA3D | 23,4 | 0,54 | +6,38 |

Tabela A.21: Concord: Kullback-Leibler.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 22,33 | 0,38 | 128,43 |
| MP+TH | 23,41 | 0,53 | 128,43 |
| OBNLM | 21,61 | 0,4 | 0,75 |
| PPB | 22,54 | 0,44 | 41,24 |
| FANS | 23,29 | 0,57 | 4,72 |
| SAR-BM3D | 23,51 | 0,56 | 62,82 |
| MP+TH+DA3D | 23,6 | 0,53 | +5,68 |
| MP+TH+DA3D(SAR-BM3D) | 23,68 | 0,54 | +6,3 |
| SAR-BM3D+DA3D | 23,44 | 0,54 | +6,15 |

Tabela A.22: Concord: Média-Harmônica.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 22,29 | 0,38 | 120,26 |
| MP+TH | 23,37 | 0,53 | 120,26 |
| OBNLM | 21,57 | 0,4 | 0,76 |
| PPB | 22,5 | 0,44 | 41,82 |
| FANS | 23,23 | 0,57 | 4,95 |
| SAR-BM3D | 23,46 | 0,55 | 65,97 |
| MP+TH+DA3D | 23,55 | 0,53 | +5,97 |
| MP+TH+DA3D(SAR-BM3D) | 23,63 | 0,53 | +6,43 |
| SAR-BM3D+DA3D | 23,39 | 0,54 | +6,49 |

Tabela A.23: Concord: Rényi.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 22,34 | 0,37 | 158,32 |
| MP+TH | 23,41 | 0,53 | 158,32 |
| OBNLM | 21,62 | 0,4 | 0,85 |
| PPB | 22,49 | 0,44 | 41,69 |
| FANS | 23,2 | 0,57 | 4,83 |
| SAR-BM3D | 23,5 | 0,56 | 64,13 |
| MP+TH+DA3D | 23,31 | 0,51 | +4,56 |
| MP+TH+DA3D(SAR-BM3D) | 23,44 | 0,52 | +5,45 |
| SAR-BM3D+DA3D | 23,43 | 0,54 | +5,57 |

Tabela A.24: Concord: Triangular.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 22,32 | 0,38 | 118,92 |
| MP+TH | 23,4 | 0,53 | 118,92 |
| OBNLM | 21,61 | 0,4 | 0,79 |
| PPB | 22,49 | 0,44 | 43,19 |
| FANS | 23,26 | 0,57 | 5,19 |
| SAR-BM3D | 23,48 | 0,56 | 68,23 |
| MP+TH+DA3D | 23,57 | 0,53 | +4,82 |
| MP+TH+DA3D(SAR-BM3D) | 23,64 | 0,54 | +5,28 |
| SAR-BM3D+DA3D | 23,38 | 0,54 | +5,27 |

A.1.4 Lena

Tabela A.25: Lena: Aritmética-Geométrica.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 22,36 | 0,38 | 215,67 |
| MP+TH | 23,87 | 0,63 | 215,67 |
| OBNLM | 20,79 | 0,36 | 1,26 |
| PPB | 23,35 | 0,48 | 65,45 |
| FANS | 24,06 | 0,68 | 8,1 |
| SAR-BM3D | 24,49 | 0,63 | 104,4 |
| MP+TH+DA3D | 24,14 | 0,67 | +10,69 |
| MP+TH+DA3D(SAR-BM3D) | 24,62 | 0,69 | +14,28 |
| SAR-BM3D+DA3D | 25,11 | 0,71 | +13,42 |

Tabela A.26: Lena: Bhattacharyya.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 21,88 | 0,36 | 232,4 |
| MP+TH | 23,19 | 0,62 | 232,4 |
| OBNLM | 20,79 | 0,36 | 1,17 |
| PPB | 23,35 | 0,48 | 62,79 |
| FANS | 23,96 | 0,68 | 7,68 |
| SAR-BM3D | 24,53 | 0,63 | 100,25 |
| MP+TH+DA3D | 23,15 | 0,64 | +7,86 |
| MP+TH+DA3D(SAR-BM3D) | 23,64 | 0,66 | +11,72 |
| SAR-BM3D+DA3D | 25,12 | 0,71 | +11,17 |

Tabela A.27: Lena: Hellinger.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 21,85 | 0,36 | 193,87 |
| MP+TH | 23,18 | 0,62 | 193,87 |
| OBNLM | 20,81 | 0,36 | 1,14 |
| PPB | 23,37 | 0,48 | 62,36 |
| FANS | 24,03 | 0,68 | 7,6 |
| SAR-BM3D | 24,51 | 0,63 | 99,08 |
| MP+TH+DA3D | 23,14 | 0,64 | +7,35 |
| MP+TH+DA3D(SAR-BM3D) | 23,63 | 0,66 | +10,56 |
| SAR-BM3D+DA3D | 25,11 | 0,71 | +10,59 |

Tabela A.28: Lena: Jensen-Shannon.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 22,38 | 0,38 | 221,98 |
| MP+TH | 23,88 | 0,63 | 221,98 |
| OBNLM | 20,77 | 0,36 | 1,19 |
| PPB | 23,35 | 0,48 | 67,09 |
| FANS | 23,98 | 0,68 | 8,17 |
| SAR-BM3D | 24,53 | 0,63 | 109,19 |
| MP+TH+DA3D | 24,13 | 0,67 | +9,33 |
| MP+TH+DA3D(SAR-BM3D) | 24,59 | 0,69 | +11,47 |
| SAR-BM3D+DA3D | 25,1 | 0,71 | +12,79 |

Tabela A.29: Lena: Kullback-Leibler.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 22,4 | 0,38 | 194,35 |
| MP+TH | 23,9 | 0,63 | 194,35 |
| OBNLM | 20,79 | 0,36 | 1,22 |
| PPB | 23,33 | 0,48 | 63,19 |
| FANS | 23,75 | 0,68 | 7,69 |
| SAR-BM3D | 24,51 | 0,63 | 101,6 |
| MP+TH+DA3D | 24,15 | 0,67 | +9,35 |
| MP+TH+DA3D(SAR-BM3D) | 24,62 | 0,69 | +12,13 |
| SAR-BM3D+DA3D | 25,09 | 0,71 | +12,68 |

Tabela A.30: Lena: Média-Harmônica.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 22,36 | 0,38 | 173,51 |
| MP+TH | 23,87 | 0,63 | 173,51 |
| OBNLM | 20,78 | 0,36 | 1,15 |
| PPB | 23,32 | 0,48 | 63,2 |
| FANS | 23,97 | 0,68 | 7,79 |
| SAR-BM3D | 24,47 | 0,62 | 101,46 |
| MP+TH+DA3D | 24,12 | 0,67 | +11,43 |
| MP+TH+DA3D(SAR-BM3D) | 24,58 | 0,69 | +14,1 |
| SAR-BM3D+DA3D | 25,06 | 0,71 | +13,67 |

Tabela A.31: Lena: Rényi.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 22,24 | 0,38 | 226,88 |
| MP+TH | 23,66 | 0,63 | 226,88 |
| OBNLM | 20,81 | 0,36 | 1,14 |
| PPB | 23,36 | 0,48 | 62,37 |
| FANS | 23,94 | 0,68 | 7,55 |
| SAR-BM3D | 24,52 | 0,63 | 99,61 |
| MP+TH+DA3D | 23,72 | 0,65 | +8,52 |
| MP+TH+DA3D(SAR-BM3D) | 24,2 | 0,67 | +10,77 |
| SAR-BM3D+DA3D | 25,12 | 0,71 | +11,15 |

Tabela A.32: Lena: Triangular.

| Filtros | PSNR | SSIM | Tempo(s) |
|-----------------------------|-------------|-------------|-----------------|
| MP | 22,38 | 0,38 | 158,89 |
| MP+TH | 23,87 | 0,63 | 158,89 |
| OBNLM | 20,78 | 0,36 | 1,18 |
| PPB | 23,3 | 0,48 | 64,38 |
| FANS | 23,92 | 0,68 | 8,15 |
| SAR-BM3D | 24,47 | 0,63 | 103,95 |
| MP+TH+DA3D | 24,11 | 0,67 | +9,29 |
| MP+TH+DA3D(SAR-BM3D) | 24,58 | 0,69 | +11,66 |
| SAR-BM3D+DA3D | 25,07 | 0,71 | +11,38 |

A.2 Experimentos reais

A.2.1 Região 1

Tabela A.33: R1: Aritmética-Geométrica.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 0,61 | 212,25 |
| MP+TH | 1 | 0,54 | 212,25 |
| OBNLM | 0,94 | 0,51 | 0,97 |
| PPB | 0,96 | 0,58 | 62,22 |
| FANS | 0,84 | 0,46 | 6,31 |
| SAR-BM3D | 0,97 | 0,43 | 97,73 |
| MP+DA3D | 0,57 | 0,34 | +43,7 |
| MP+DA3D(SAR-BM3D) | 0,56 | 0,29 | +35,81 |
| SAR-BM3D+DA3D | 0,55 | 0,26 | +42,41 |
| MP+TH+DA3D | 0,56 | 0,31 | +31,45 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +30,36 |

Tabela A.34: R1: Bhattacharyya.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 0,62 | 228,98 |
| MP+TH | 1 | 0,54 | 228,98 |
| OBNLM | 0,94 | 0,51 | 1,04 |
| PPB | 0,96 | 0,58 | 62,21 |
| FANS | 0,84 | 0,46 | 6,3 |
| SAR-BM3D | 0,97 | 0,43 | 98,04 |
| MP+DA3D | 0,57 | 0,34 | +29,41 |
| MP+DA3D(SAR-BM3D) | 0,56 | 0,29 | +27,66 |
| SAR-BM3D+DA3D | 0,55 | 0,26 | +31,6 |
| MP+TH+DA3D | 0,56 | 0,31 | +28,24 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +28,92 |

Tabela A.35: R1: Hellinger.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 0,62 | 197,11 |
| MP+TH | 1 | 0,54 | 197,11 |
| OBNLM | 0,94 | 0,51 | 1,04 |
| PPB | 0,96 | 0,58 | 62,46 |
| FANS | 0,84 | 0,46 | 6,53 |
| SAR-BM3D | 0,97 | 0,43 | 98,65 |
| MP+DA3D | 0,57 | 0,34 | +29,61 |
| MP+DA3D(SAR-BM3D) | 0,56 | 0,29 | +27,44 |
| SAR-BM3D+DA3D | 0,55 | 0,26 | +26,77 |
| MP+TH+DA3D | 0,56 | 0,31 | +28,67 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +28,51 |

Tabela A.36: R1: Jensen-Shannon.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 0,61 | 201,03 |
| MP+TH | 1 | 0,54 | 201,03 |
| OBNLM | 0,94 | 0,51 | 1,02 |
| PPB | 0,96 | 0,58 | 62,17 |
| FANS | 0,84 | 0,46 | 6,31 |
| SAR-BM3D | 0,97 | 0,43 | 98,08 |
| MP+DA3D | 0,57 | 0,34 | +30,55 |
| MP+DA3D(SAR-BM3D) | 0,56 | 0,29 | +30,04 |
| SAR-BM3D+DA3D | 0,55 | 0,26 | +32,06 |
| MP+TH+DA3D | 0,56 | 0,31 | +29,91 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +27,65 |

Tabela A.37: R1: Kullback-Leibler.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 0,61 | 197,06 |
| MP+TH | 1 | 0,54 | 197,06 |
| OBNLM | 0,94 | 0,51 | 1,17 |
| PPB | 0,96 | 0,58 | 63,55 |
| FANS | 0,84 | 0,46 | 6,5 |
| SAR-BM3D | 0,97 | 0,43 | 100,5 |
| MP+DA3D | 0,57 | 0,34 | +32,19 |
| MP+DA3D(SAR-BM3D) | 0,56 | 0,29 | +28,93 |
| SAR-BM3D+DA3D | 0,55 | 0,26 | +27,9 |
| MP+TH+DA3D | 0,56 | 0,31 | +29,08 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +37,05 |

Tabela A.38: R1: Média-Harmônica.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 0,61 | 174,55 |
| MP+TH | 1 | 0,54 | 174,55 |
| OBNLM | 0,94 | 0,51 | 0,99 |
| PPB | 0,96 | 0,58 | 62,69 |
| FANS | 0,84 | 0,46 | 6,43 |
| SAR-BM3D | 0,97 | 0,43 | 98,37 |
| MP+DA3D | 0,57 | 0,34 | +31,01 |
| MP+DA3D(SAR-BM3D) | 0,56 | 0,29 | +28,65 |
| SAR-BM3D+DA3D | 0,55 | 0,26 | +30,06 |
| MP+TH+DA3D | 0,56 | 0,31 | +27,23 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +27,11 |

Tabela A.39: R1: Rényi.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 0,62 | 225,79 |
| MP+TH | 1 | 0,54 | 225,79 |
| OBNLM | 0,94 | 0,51 | 1 |
| PPB | 0,96 | 0,58 | 62,27 |
| FANS | 0,84 | 0,47 | 6,33 |
| SAR-BM3D | 0,97 | 0,43 | 98,49 |
| MP+DA3D | 0,57 | 0,34 | +29,54 |
| MP+DA3D(SAR-BM3D) | 0,56 | 0,29 | +31,23 |
| SAR-BM3D+DA3D | 0,55 | 0,26 | +34,94 |
| MP+TH+DA3D | 0,56 | 0,31 | +35,35 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +35,03 |

Tabela A.40: R1: Triangular.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 0,61 | 157,42 |
| MP+TH | 1 | 0,54 | 157,42 |
| OBNLM | 0,94 | 0,51 | 0,98 |
| PPB | 0,96 | 0,58 | 62,46 |
| FANS | 0,84 | 0,47 | 6,42 |
| SAR-BM3D | 0,97 | 0,43 | 99,73 |
| MP+DA3D | 0,57 | 0,34 | +49,86 |
| MP+DA3D(SAR-BM3D) | 0,56 | 0,29 | +32,82 |
| SAR-BM3D+DA3D | 0,55 | 0,26 | +37,81 |
| MP+TH+DA3D | 0,56 | 0,31 | +32,5 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +34,66 |

A.2.2 Região 2

Tabela A.41: R2: Aritmética-Geométrica.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 1 | 196,09 |
| MP+TH | 1 | 0,53 | 196,09 |
| OBNLM | 0,95 | 0,5 | 1,06 |
| PPB | 0,97 | 0,58 | 62,28 |
| FANS | 0,84 | 0,46 | 6,41 |
| SAR-BM3D | 0,97 | 0,44 | 98,29 |
| MP+DA3D | 0,57 | 0,56 | +28 |
| MP+DA3D(SAR-BM3D) | 0,56 | 0,29 | +24,49 |
| SAR-BM3D+DA3D | 0,55 | 0,27 | +25,15 |
| MP+TH+DA3D | 0,56 | 0,3 | +26,83 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +24,71 |

Tabela A.42: R2: Bhattacharyya.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 1,13 | 227,99 |
| MP+TH | 1 | 0,53 | 227,99 |
| OBNLM | 0,95 | 0,5 | 1,04 |
| PPB | 0,97 | 0,58 | 62,07 |
| FANS | 0,84 | 0,47 | 6,61 |
| SAR-BM3D | 0,97 | 0,44 | 98,51 |
| MP+DA3D | 0,57 | 0,63 | +27,39 |
| MP+DA3D(SAR-BM3D) | 0,56 | 0,29 | +24,55 |
| SAR-BM3D+DA3D | 0,55 | 0,27 | +24,69 |
| MP+TH+DA3D | 0,56 | 0,3 | +25,95 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +25,86 |

Tabela A.43: R2: Hellinger.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 1,13 | 196,41 |
| MP+TH | 1 | 0,53 | 196,41 |
| OBNLM | 0,95 | 0,5 | 1,07 |
| PPB | 0,97 | 0,58 | 62,21 |
| FANS | 0,84 | 0,47 | 6,33 |
| SAR-BM3D | 0,97 | 0,44 | 99,53 |
| MP+DA3D | 0,57 | 0,63 | +28,53 |
| MP+DA3D(SAR-BM3D) | 0,56 | 0,29 | +24,77 |
| SAR-BM3D+DA3D | 0,55 | 0,27 | +24,41 |
| MP+TH+DA3D | 0,56 | 0,3 | +25,22 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +24,63 |

Tabela A.44: R2: Jensen-Shannon.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 1 | 199,57 |
| MP+TH | 1 | 0,53 | 199,57 |
| OBNLM | 0,95 | 0,5 | 1,07 |
| PPB | 0,97 | 0,58 | 62,01 |
| FANS | 0,84 | 0,47 | 6,4 |
| SAR-BM3D | 0,97 | 0,44 | 97,74 |
| MP+DA3D | 0,57 | 0,56 | +29,11 |
| MP+DA3D(SAR-BM3D) | 0,56 | 0,29 | +24,81 |
| SAR-BM3D+DA3D | 0,55 | 0,27 | +24,84 |
| MP+TH+DA3D | 0,56 | 0,3 | +25,91 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +24,6 |

Tabela A.45: R2: Kullback-Leibler.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 1 | 192,2 |
| MP+TH | 1 | 0,53 | 192,2 |
| OBNLM | 0,95 | 0,5 | 1,04 |
| PPB | 0,97 | 0,58 | 62,01 |
| FANS | 0,84 | 0,47 | 6,4 |
| SAR-BM3D | 0,97 | 0,44 | 98,32 |
| MP+DA3D | 0,57 | 0,56 | +27,9 |
| MP+DA3D(SAR-BM3D) | 0,56 | 0,29 | +24,62 |
| SAR-BM3D+DA3D | 0,55 | 0,27 | +24,71 |
| MP+TH+DA3D | 0,56 | 0,3 | +25,45 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +24,32 |

Tabela A.46: R2: Média-Harmônica.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 1 | 168,26 |
| MP+TH | 1 | 0,53 | 168,26 |
| OBNLM | 0,95 | 0,5 | 1,04 |
| PPB | 0,97 | 0,58 | 62,21 |
| FANS | 0,84 | 0,47 | 6,47 |
| SAR-BM3D | 0,97 | 0,44 | 99,34 |
| MP+DA3D | 0,57 | 0,56 | +27,95 |
| MP+DA3D(SAR-BM3D) | 0,56 | 0,29 | +25,43 |
| SAR-BM3D+DA3D | 0,55 | 0,27 | +25,29 |
| MP+TH+DA3D | 0,56 | 0,3 | +25,8 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +25,07 |

Tabela A.47: R2: Rényi.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 1,02 | 227,07 |
| MP+TH | 1 | 0,53 | 227,07 |
| OBNLM | 0,95 | 0,5 | 1,06 |
| PPB | 0,97 | 0,58 | 62,29 |
| FANS | 0,84 | 0,47 | 6,41 |
| SAR-BM3D | 0,97 | 0,44 | 99,62 |
| MP+DA3D | 0,57 | 0,57 | +27,64 |
| MP+DA3D(SAR-BM3D) | 0,56 | 0,29 | +25,82 |
| SAR-BM3D+DA3D | 0,55 | 0,27 | +24,86 |
| MP+TH+DA3D | 0,56 | 0,3 | +25,47 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +24,74 |

Tabela A.48: R2: Triangular.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 1 | 157,6 |
| MP+TH | 1 | 0,53 | 157,6 |
| OBNLM | 0,95 | 0,5 | 1,11 |
| PPB | 0,97 | 0,58 | 63,19 |
| FANS | 0,84 | 0,47 | 6,84 |
| SAR-BM3D | 0,97 | 0,44 | 103,11 |
| MP+DA3D | 0,57 | 0,56 | +28,15 |
| MP+DA3D(SAR-BM3D) | 0,56 | 0,29 | +24,63 |
| SAR-BM3D+DA3D | 0,55 | 0,27 | +24,17 |
| MP+TH+DA3D | 0,56 | 0,3 | +26,56 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +24,99 |

A.2.3 Região 3

Tabela A.49: R3: Aritmética-Geométrica.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 0,53 | 197,83 |
| MP+TH | 1 | 0,5 | 197,83 |
| OBNLM | 0,96 | 0,49 | 1,23 |
| PPB | 0,98 | 0,55 | 62,08 |
| FANS | 0,84 | 0,45 | 6,31 |
| SAR-BM3D | 0,98 | 0,45 | 100,19 |
| MP+DA3D | 0,57 | 0,3 | +33,19 |
| MP+DA3D(SAR-BM3D) | 0,57 | 0,29 | +20,67 |
| SAR-BM3D+DA3D | 0,56 | 0,27 | +26,39 |
| MP+TH+DA3D | 0,56 | 0,29 | +33,36 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +31,14 |

Tabela A.50: R3: Bhattacharyya.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 0,54 | 229,06 |
| MP+TH | 1 | 0,51 | 229,06 |
| OBNLM | 0,96 | 0,49 | 1,22 |
| PPB | 0,98 | 0,54 | 62,44 |
| FANS | 0,84 | 0,45 | 6,31 |
| SAR-BM3D | 0,98 | 0,45 | 99,2 |
| MP+DA3D | 0,56 | 0,3 | +38,41 |
| MP+DA3D(SAR-BM3D) | 0,56 | 0,29 | +33,57 |
| SAR-BM3D+DA3D | 0,56 | 0,27 | +29,86 |
| MP+TH+DA3D | 0,56 | 0,29 | +32,08 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +28,5 |

Tabela A.51: R3: Hellinger.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 0,54 | 200,73 |
| MP+TH | 1 | 0,51 | 200,73 |
| OBNLM | 0,96 | 0,49 | 1,23 |
| PPB | 0,98 | 0,55 | 62,59 |
| FANS | 0,84 | 0,45 | 6,32 |
| SAR-BM3D | 0,98 | 0,45 | 99,17 |
| MP+DA3D | 0,56 | 0,3 | +28,48 |
| MP+DA3D(SAR-BM3D) | 0,56 | 0,29 | +21,81 |
| SAR-BM3D+DA3D | 0,56 | 0,27 | +19,2 |
| MP+TH+DA3D | 0,56 | 0,29 | +21,11 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +19,16 |

Tabela A.52: R3: Jensen-Shannon.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 0,53 | 200,46 |
| MP+TH | 1 | 0,5 | 200,46 |
| OBNLM | 0,96 | 0,49 | 1,26 |
| PPB | 0,98 | 0,54 | 62,66 |
| FANS | 0,84 | 0,45 | 6,28 |
| SAR-BM3D | 0,98 | 0,45 | 98,88 |
| MP+DA3D | 0,57 | 0,3 | +23,66 |
| MP+DA3D(SAR-BM3D) | 0,57 | 0,29 | +19,72 |
| SAR-BM3D+DA3D | 0,56 | 0,27 | +19,44 |
| MP+TH+DA3D | 0,56 | 0,29 | +22,09 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +19,48 |

Tabela A.53: R3: Kullback-Leibler.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 0,53 | 191,66 |
| MP+TH | 1 | 0,5 | 191,66 |
| OBNLM | 0,96 | 0,49 | 1,25 |
| PPB | 0,98 | 0,55 | 62,65 |
| FANS | 0,84 | 0,45 | 6,3 |
| SAR-BM3D | 0,98 | 0,45 | 98,9 |
| MP+DA3D | 0,57 | 0,3 | +23,48 |
| MP+DA3D(SAR-BM3D) | 0,57 | 0,29 | +19,24 |
| SAR-BM3D+DA3D | 0,56 | 0,27 | +20,44 |
| MP+TH+DA3D | 0,56 | 0,29 | +23,93 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +20,04 |

Tabela A.54: R3: Média-Harmônica.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 0,53 | 173,54 |
| MP+TH | 1 | 0,5 | 173,54 |
| OBNLM | 0,96 | 0,49 | 1,24 |
| PPB | 0,98 | 0,54 | 62,68 |
| FANS | 0,84 | 0,45 | 6,38 |
| SAR-BM3D | 0,98 | 0,45 | 99,37 |
| MP+DA3D | 0,57 | 0,3 | +23,54 |
| MP+DA3D(SAR-BM3D) | 0,57 | 0,29 | +18,94 |
| SAR-BM3D+DA3D | 0,56 | 0,27 | +19,24 |
| MP+TH+DA3D | 0,56 | 0,29 | +30,91 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +27,94 |

Tabela A.55: R3: Rényi.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 0,53 | 238,04 |
| MP+TH | 1 | 0,51 | 238,04 |
| OBNLM | 0,96 | 0,49 | 1,27 |
| PPB | 0,98 | 0,54 | 76,18 |
| FANS | 0,84 | 0,45 | 6,36 |
| SAR-BM3D | 0,98 | 0,45 | 139,05 |
| MP+DA3D | 0,56 | 0,3 | +35,26 |
| MP+DA3D(SAR-BM3D) | 0,56 | 0,29 | +26,53 |
| SAR-BM3D+DA3D | 0,56 | 0,27 | +30,18 |
| MP+TH+DA3D | 0,56 | 0,29 | +33,36 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +23,02 |

Tabela A.56: R3: Triangular.

| Filtros | Média razão | Desvio padrão razão | Tempo(s) |
|----------------------|-------------|---------------------|----------|
| MP | 1 | 0,53 | 208,53 |
| MP+TH | 1 | 0,5 | 208,53 |
| OBNLM | 0,96 | 0,49 | 1,52 |
| PPB | 0,98 | 0,55 | 73,15 |
| FANS | 0,84 | 0,45 | 6,78 |
| SAR-BM3D | 0,98 | 0,45 | 130,33 |
| MP+DA3D | 0,57 | 0,3 | +29,44 |
| MP+DA3D(SAR-BM3D) | 0,57 | 0,29 | +29,93 |
| SAR-BM3D+DA3D | 0,56 | 0,27 | +26,5 |
| MP+TH+DA3D | 0,56 | 0,29 | +29,71 |
| MP+TH+DA3D(SAR-BM3D) | 0,56 | 0,29 | +22,36 |