

Dissertação de Mestrado

**Um Novo Algoritmo para Filtragem de *Speckle* em
Imagens SAR de Intensidade baseado em
Distâncias Estocásticas**

Leonardo José Tenório Mourão Torres
ljmtorres@gmail.com

Orientador:
Dr. Alejandro C. Frery

Maceió, Junho de 2012

Leonardo José Tenório Mourão Torres

**Um Novo Algoritmo para Filtragem de *Speckle* em
Imagens SAR de Intensidade baseado em
Distâncias Estocásticas**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Modelagem Computacional de Conhecimento do Instituto de Computação da Universidade Federal de Alagoas.

Orientador: Dr. Alejandro C. Frery

Catálogo na fonte
Universidade Federal de Alagoas
Biblioteca Central
Divisão de Tratamento Técnico
Bibliotecária: Fabiana Camargo dos Santos

T693n Torres, Leonardo José Tenório Mourão.

Um novo algoritmo para filtragem de speckle em imagens SAR de intensidade baseado em distâncias estocásticas / Leonardo José Tenório Mourão Torres. – 2012

73 f. : il.

Orientador: Alejandro C. Frery.

Dissertação (Mestrado em Modelagem Computacional de Conhecimento) – Universidade Federal de Alagoas. Instituto de Computação. Maceió, 2012.

Bibliografia: f. 68–73.

1. Imagens SAR. 2. Speckle – Redução. 3. Distâncias estocásticas. 4. Teoria da informação. 5. Filtragem. I. Título.

CDU: 004.932:004.852



Membros da Comissão Julgadora da Dissertação de Mestrado de Leonardo José Tenório Mourão Torrès intitulada "Um Novo Algoritmo para Filtragem de *Speckle* em Imagens SAR de Intensidade baseado em Distâncias Estocásticas", apresentada ao Programa de Pós-Graduação em Modelagem Computacional de Conhecimento da Universidade Federal de Alagoas em 1º de junho de 2012, às 10h00min, na sala de aula do Mestrado em Modelagem Computacional de Conhecimento.

Dr. Alejandro C. Frery – Orientador
Instituto de Computação
Universidade Federal de Alagoas

Dr. André Luiz Lins de Aquino – Examinador
Instituto de Computação
Universidade Federal de Alagoas

Dr. Osvaldo Anibal Rosso – Examinador
Pesquisador Visitante – Instituto de Computação
Universidade Federal de Alagoas

Dra. Corina da Costa Freitas – Examinadora
Divisão de Processamento de Imagens
Instituto Nacional de Pesquisas Espaciais

RESUMO

Este trabalho apresenta um novo algoritmo para filtragem de ruído *speckle* com base em distâncias estocásticas e testes entre distribuições. Uma janela é definida em torno de cada pixel e amostras sobrepostas são comparadas. Apenas aquelas que passarem por um teste de significância são utilizadas para calcular o valor filtrado. Modificações nas janelas Nagao-Matsuyama foram usadas para definir as amostras. A técnica é aplicada a imagens de Radar de Abertura Sintética (SAR) de intensidade homogênea, usando o modelo gama $\Gamma(L, L/\lambda)$ com número variável de *looks* L permitindo as mudanças na heterogeneidade. A proposta é comparada com o filtro de Lee, que é considerado um padrão, utilizando um protocolo baseado em Monte Carlo. Analisamos também, o comportamento do filtro em dados reais. Entre os critérios utilizados para quantificar a qualidade dos filtros estão: o número equivalente de *looks* (relacionada com a relação sinal-ruído), preservação da linha e preservação das bordas. Além disso, os filtros foram avaliados pelos Índice Universal de Qualidade de Imagem e a Correlação de Pearson em regiões de bordas. Estas medidas fizeram valer a proposta em dados simulados, que apresentaram ótimos resultados nos cenários adotados. Em particular, o filtro proposto reduziu o *speckle*, preservou bordas e características de textura mantendo uma boa relação sinal-ruído em dados SAR. Também foram abordadas aplicações em imagens SAR reais, que foram validadas com medidas numéricas. O método é bastante geral e pode ser estendido para outras situações, desde que haja um modelo estatístico subjacente. Assim, o novo filtro foi estendido para atuar em imagens PolSAR modeladas pela distribuição *Wishart* $\mathbf{Z} \sim \mathcal{W}(\mathbf{\Sigma}, L)$, em que L é o número equivalente de *looks* e $\mathbf{\Sigma}$ é uma matriz de covariância.

Palavras-chave: Imagens SAR. Speckle. Distâncias Estocásticas. Teoria da Informação. Filtragem.

ABSTRACT

This dissertation work presents a new approach for filter design based on stochastic distances and tests between distributions. A window is defined around each pixel, overlapping samples are compared and only those which pass a goodness-of-fit test are used to compute the filtered value. Modified Nagao-Matsuyama windows are used to define the samples. The technique is applied to intensity Synthetic Aperture Radar (SAR) data with homogeneous regions, using the Gamma model $\Gamma(L, L/\lambda)$ with varying number of looks L allowing, thus, changes in heterogeneity. The proposal is compared with the Lee's filter which is considered a standard, using a protocol based on Monte Carlo. We also analyzed the behavior of the filter on real data. Among the criteria used to quantify the quality of filters, we employ the equivalent number of looks (related to the signal-to-noise ratio), line contrast, and edge preservation. Moreover, we also assessed the filters by the Universal Image Quality Index and, the Pearson's correlation on edges regions. These measures made use of the proposal on simulated data, which showed excellent results in the scenarios adopted. In particular, the proposed filter reduces the speckled, has preserved edges and texture features that keeps a good signal-to-noise in SAR data. Also been discussed applications in real SAR images, which were validated with numerical measurements. Method is quite general and can be extended to other conditions, provided that there is an underlying statistical model. Thus, the new filter has been extended to operate in PolSAR images modeled by Wishart distribution $Z \sim \mathcal{W}(\Sigma, L)$, where L is equivalent number of looks and Σ is a covariance matrix.

Keywords: SAR images. Speckle. Stochastic Distances. Information Theory. Filtering.

AGRADECIMENTOS

Aos meus pais, Leopoldo e Isis, pela educação que me proporcionaram e por todas as oportunidades que, sobremaneira, foram fundamentais para meu desenvolvimento pessoal e acadêmico. A minha esposa, Genuclécia Torres, agradeço todo o seu amor, admiração e pela presença incansável com que me apoiou ao longo da elaboração desta dissertação.

Ao meu estimado amigo, Carlos Albuquerque e aos nobres do mestrado, Fabiano Brião, Felipe Prata, Fernando Pinto, Gilberto Pedro, Marcelo Queiroz e Rodrigo Pinheiro, agradeço por todas as horas de estudo juntos.

Aos meus amigos que estão no Rio de Janeiro: Paulo Rogério por toda a ajuda com o \LaTeX ; Ivan Martins e Rian Pinheiro pelos momentos de estudo em processamento e análise de imagens; Phillipe Cavalcante e Emanuella Toledo por serem os grandes amigos que são.

Aos caros colegas do LaCCAN, David Henrique e Raquel Cabral, por todo apoio e momentos descontraídos. Tonny e Juliana por todo suporte dado e, Deise com nossos almoços.

Agradecimentos especiais a Tamer Cavalcante e Michel Alves por terem sido grandes colaboradores e aos que fizeram meu semestre em Belo Horizonte ser muito produtivo: Dona Goreti, Evellyn, Celso Luiz, Fabrício e aos professores, Loureiro e Mario Campos.

Aos professores, André, Eliana e Leonardo Viana, que ambos colaboraram com comentários, questionamentos e conselhos que refinaram esta pesquisa.

Aos colegas de P&D na empresa RASTRU – Investigação e Perícia Digital, Alencar, Alisson e Valter pelo total apoio e incentivo à pesquisa.

Agradeço a ANP, a Petrobras e ao Laboratório de Computação Científica e Visualização da Universidade Federal de Alagoas por garantir acesso aos recursos computacionais do *cluster* GradeBR/UFAL da Rede Galileu.

A Fundação de Amparo à Pesquisa do Estado de Alagoas – FAPEAL (No. 2004049671-7), pelo apoio financeiro e incentivo à pesquisa.

Finalmente, não menos importante, ao meu orientador e amigo, Prof. Alejandro Frery, para quem não há agradecimentos que cheguem, por ter acreditado e confiado em mim. Como professor foi o expoente máximo, abriu-me horizontes e, principalmente, ensinou-me a pensar como um verdadeiro pesquisador. O meu grande abraço!

Leonardo Torres

LISTA DE FIGURAS

2.1	Geometria de operação do <i>Side-Looking Airborne Radar</i> – SLAR.	17
2.2	Dados e densidades da $\Gamma(L, L/\lambda)$ para $L = 2$ e $\lambda = \{50, 80, 120, 200\}$	23
2.3	Dados e densidades da $\Gamma(L, L/\lambda)$ para $\lambda = 150$ e $L = \{1, 3, 5, 7\}$	24
3.1	Vizinhança Nagao-Matsuyama modificada.	29
3.2	Imagem Phantom, dados <i>speckle</i> e versões filtradas.	33
3.3	Diagrama em blocos para avaliação da técnica proposta.	36
4.1	<i>Boxplot</i> (com uma variação <i>interquartil</i>) de uma f.d.p. $N(0, \sigma^2)$	39
4.2	Métricas dos quatros filtros e situações em janela 5×5 com 1-iteração.	41
4.3	Medidas de erros dos filtros e situações em janela 5×5 com 1-iteração.	42
4.4	Métricas dos quatros filtros e situações em janela 7×7 com 1-iteração.	43
4.5	Medidas de erros dos filtros e situações em janela 7×7 com 1-iteração.	44
4.6	Phantom, dados SAR simulados (3 e 5- <i>looks</i>) e imagens filtradas.	47
4.7	Métricas dos quatros filtros e situações em janela 5×5 com 5-iterações.	48
4.8	Medidas de erros dos filtros e situações em janela 5×5 com 5-iterações.	49
4.9	Métricas dos quatros filtros e situações em janela 7×7 com 5-iterações.	50
4.10	Medidas de erros dos filtros e situações em janela 7×7 com 5-iterações.	51
4.11	Dados SAR reais e imagens filtradas em 1-iteração.	56
4.12	Imagens filtradas em janela 5×5 com variação de α e #-iterações.	58
B.1	Dados PolSAR na decomposição de Pauli.	66
B.2	Dados PolSAR na decomposição de Sinclair.	67

LISTA DE TABELAS

2.1	Nomenclatura padrão do IEEE para Banda de RADAR.	16
2.2	Distribuições no modelo multiplicativo para dados SAR de intensidade.	25
3.1	(h, ϕ) -distância e funções relacionadas a h e ϕ	30
3.2	Distâncias e constantes κ	31
4.1	Situações simuladas com distribuição $\Gamma(L, L/\lambda)$	39
4.2	Estatísticas das métricas de imagens simuladas em janela 5×5 com 1-iteração. . .	52
4.3	Estatísticas das métricas de imagens simuladas em janela 7×7 com 1-iteração. . .	53
4.4	Estatísticas das métricas de imagens simuladas em janela 5×5 com 5-iterações. .	54
4.5	Estatísticas das métricas de imagens simuladas em janela 7×7 com 5-iterações. .	55
4.6	Estatísticas das métricas de qualidade em imagem SAR real.	57

LISTA DE EQUAÇÕES

2.1	Conceito de distância para definir vizinhanças.	14
2.2	Definição do fecho da vizinhança.	14
2.3	Função genérica para operador pontual.	14
2.4	Função genérica para operador local.	14
2.5	Função genérica para processo de convolução.	14
2.6	Máscara de Sobel.	15
2.7	Modelo do ruído multiplicativo.	20
2.8	Função de distribuição acumulada que caracteriza $X \sim \lambda$	21
2.9	Função indicadora de um conjunto A	21
2.10	Função densidade de probabilidade que caracteriza $X \sim \Gamma(\alpha, \gamma)$	21
2.11	Função gama da integral de Euler.	21
2.12	Função densidade de probabilidade que caracteriza $X \sim \Gamma^{-1}(\alpha, \gamma)$	22
2.13	Função densidade de probabilidade que caracteriza $X \sim \mathcal{N}^{-1}(\alpha, \gamma, \lambda)$	22
2.14	Função densidade de probabilidade que caracteriza $Y \sim \Gamma(L, L)$	22
2.15	Função densidade de probabilidade que caracteriza $Z \sim \Gamma(L, L/\lambda)$	23
2.16	Função densidade de probabilidade que caracteriza $Z \sim \mathcal{K}_I(\alpha, \gamma, L)$	23
2.17	Função densidade de probabilidade que caracteriza $Z \sim \mathcal{G}_I^0(\alpha, \gamma, L)$	24
2.18	Função densidade de probabilidade que caracteriza $Z \sim \mathcal{G}_I(\alpha, \gamma, \lambda, L)$	24
3.1	Função de verossimilhança da distribuição $\Gamma(L, L/\lambda)$	29
3.2	(h, ϕ) -divergência entre f_{Z_1} e f_{Z_i}	29
3.3	Distância d_ϕ^h entre f_{Z_1} e f_{Z_i}	30
3.4	Distância Kullback-Leibler entre f_{Z_1} e f_{Z_i} com $Z \sim \Gamma(L, L/\lambda)$	30
3.5	Distância Rényi de ordem β entre f_{Z_1} e f_{Z_i} com $Z \sim \Gamma(L, L/\lambda)$	31
3.6	Distância Bhattacharyya entre f_{Z_1} e f_{Z_i} com $Z \sim \Gamma(L, L/\lambda)$	31
3.7	Distância Hellinger entre f_{Z_1} e f_{Z_i} com $Z \sim \Gamma(L, L/\lambda)$	31
3.8	Estatística de teste S_ϕ^h dada por Nascimento et al. (2010).	31
3.9	Método de Bonferroni por <i>Šidák correction</i>	32
3.10	Teste Kullback-Leibler (S_{KL}) entre f_{Z_1} e f_{Z_i} com $Z \sim \Gamma(L, L/\lambda)$	32
3.11	Teste Rényi de ordem β (S_R^β) entre f_{Z_1} e f_{Z_i} com $Z \sim \Gamma(L, L/\lambda)$	32
3.12	Teste Bhattacharyya (S_B) entre f_{Z_1} e f_{Z_i} com $Z \sim \Gamma(L, L/\lambda)$	32
3.13	Teste Hellinger (S_H) entre f_{Z_1} e f_{Z_i} com $Z \sim \Gamma(L, L/\lambda)$	32
3.14	Índice universal de qualidade de imagem (Índice Q).	34
3.15	Coefficiente de Correlação de Pearson (Índice β_ρ).	34
3.16	Erro Absoluto Médio.	34
3.17	Erro Quadrático Médio.	34
3.18	Erro Quadrático Médio Normalizado.	35
3.19	Distorção de Contraste.	35
4.1	Definição do <i>Interquartile Range</i>	38
4.2	Função para obter limites superior e inferior de um <i>boxplot</i>	38

SUMÁRIO

1	INTRODUÇÃO	9
1.1	Definição do Problema	9
1.2	Contribuições	11
1.3	Objetivos	12
1.4	Organização da Dissertação	12
2	FUNDAMENTAÇÃO TEÓRICA	13
2.1	Processamento e Análise de Imagens	13
2.2	Radar de Abertura Sintética	15
2.3	Imageamento SAR	16
2.4	Processamento <i>Multilook</i>	18
2.5	Modelagem Estatística para Imagens SAR	19
2.5.1	Modelo Multiplicativo	20
2.6	Distribuições Aplicadas aos Dados SAR	20
2.6.1	Distribuições para o Retroespalhamento do Terreno	21
2.6.2	Distribuição para Dados <i>Speckle</i>	22
2.6.3	Distribuições para Intensidade do Retorno	22
2.7	Filtagem de <i>Speckle</i>	25
2.7.1	Filtros Padrões	25
2.7.2	Filtros <i>Maximum a Posteriori</i> (MAP)	27
3	REDUÇÃO DE <i>Speckle</i> USANDO DISTÂNCIAS ESTOCÁSTICAS	28
3.1	Metodologia Proposta	28
3.2	Avaliação da Qualidade de Imagens SAR	33
3.3	Algoritmo para Filtragem de <i>Speckle</i>	35
4	RESULTADOS E ANÁLISES	38
4.1	<i>Interquartile Range</i>	38
4.2	Dados Simulados	39
4.3	Dados SAR Reais	45
5	CONCLUSÕES	59
5.1	Considerações Finais	59
5.2	Trabalhos Futuros	60
A	AMBIENTE REPRODUTÍVEL E COMPUTACIONAL	61
B	APLICAÇÃO DO FILTRO PROPOSTO EM DADOS SAR POLARIMÉTRICOS	64
B.1	Resultados	64
	Referências Bibliográficas	68

1

INTRODUÇÃO

1.1 Definição do Problema

Imagens de Radar de Abertura Sintética (*Synthetic Aperture Radar* – SAR) são geradas por um sistema de iluminação ativo na faixa das microondas e são afetadas pela interferência coerente¹ do sinal (Oliver & Quegan, 2004). Atualmente, imagens SAR desempenham um importante papel nas áreas de sensoriamento remoto e observações das características de várias superfícies da Terra.

A modelagem estatística é essencial para interpretação de imagens SAR, que destina-se a descrevê-las e representar características por métodos estatísticos. Além disso, a modelagem estatística pode fornecer um suporte mais abrangente do processo de sensoriamento, no desenvolvimento de algoritmos para interpretação dos dados com maior eficiência e na simulação de imagens com mais credibilidade do que com outras abordagens (Gao, 2010).

De acordo com Lillesand et al. (2008), as vantagens relacionadas ao uso de imagens de radar são a operação noturna e atuação sob condições atmosféricas adversas. O imageamento SAR de regiões é realizado independente da iluminação solar, do céu se apresentar nublado ou durante precipitações. Cada região, em particular, possui características climáticas independentes e imagens de radar funcionam com eficiência em vários aspectos.

Essas vantagens fazem dos radares grande aliados dos sensores ópticos e suas aplicações destacam-se, por exemplo, na monitoração de parâmetros das geleiras na Península Antártica (Arigony-Neto et al., 2007), no mapeamento de regiões tropicais com alto índice de umidade e grandes concentrações de chuvas (Nezry et al., 1993), na classificação da cobertura da terra na Floresta Amazônica (Negri, 2009), dentre outras.

¹O termo coerente, relacionado a aplicação em radar, é utilizado para descrever sistemas que preservam a fase do sinal recebido.

Contudo, imagens SAR incorporam um ruído granular intrínseco à iluminação coerente que degrada sua qualidade, denominado *speckle* (Goodman, 1976; Oliver & Quegan, 2004; Lee & Pottier, 2009). Os sistemas de iluminação coerente apresentam-se no laser, ultrassom-B, microondas, sonar e a grande abertura sintética da antena no imageamento SAR (Oliver & Quegan, 2004). O ruído dificulta a segmentação, extração, análise e classificação dos objetos e informações contidas na imagem.

Um pré-processamento, que envolve muitas vezes a filtragem do ruído em dados SAR, pode comprometer suas características. Segundo Oliver & Quegan (2004), muitos filtros de *speckle* foram propostos e avaliados em aplicações de sensoriamento remoto. Estes filtros podem ser classificados em lineares e não lineares, sob o ponto de vista das operações que eles usam ou de acordo com o arcabouço, que utilizam no processo da filtragem, podendo ser ainda adaptativos ou não.

A redução do *speckle* é uma tarefa importante para interpretação correta das imagens SAR. Segundo Zhang (2004), as técnicas para suavizar este tipo de ruído podem ser classificadas em duas categorias: (i) durante o processo de imageamento SAR, que reduz a intensidade do *speckle* pela média de cada posição da imagem e pode ser realizada tanto no domínio espacial quanto no domínio da frequência, denominado processamento *multilook* (veja a seção 2.4); (ii) depois da imagem ter sido formada usando algoritmos de filtragem.

Tal importância é notada com o aumento da produção acadêmica no intuito de reduzir o efeito *speckle*, principalmente, na segunda categoria citada por Zhang (2004). Os modelos estatísticos mais conhecidos, que foram utilizados como base para desenvolver grande parte dos filtros de *speckle* existentes, são oriundos do modelo multiplicativo (Touzi, 2002).

O modelo multiplicativo expressa a intensidade observada como o resultado do produto da intensidade do sinal da cena e da intensidade do ruído *speckle*, podendo este último ser modelado seguindo uma distribuição Gama com média igual a um (Goodman, 1976).

A modelagem multiplicativa foi adotada, por exemplo, no desenvolvimento de filtros com base no mínimo erro quadrático médio (*Minimum Mean-Square Error* – MMSE), com os trabalhos de Lee (1981), Frost et al. (1982), Kuan et al. (1985) e Lee (1986). Ela foi usada também como suporte para o desenvolvimento do *maximum a posteriori* (MAP) (Sant’Anna, 1995; Moschetti et al., 2006), Gama MAP (Oliver, 1991; Lopes et al., 1993), e o modelo baseado no filtro de *despeckling* (Walessa & Datcu, 2000; Jin et al., 2004). Outras linhas de pesquisas vêm propondo novas abordagens, tais como, anisotrópicos (Eom, 2011), homomórfico (Gonzalez & Woods, 2008), robusto (Frery et al., 1997b), em lógica *fuzzy* (Cheng & Tian, 2009) e baseado em *wavelet* (Rakotomamonjy et al., 2000; Pižurica et al., 2003; Achim et al., 2003). Trabalhos como o de Lee et al. (2009), que visam propor melhorias nas abordagens clássicas também são indispensáveis e ressaltam a importância do tema.

Independentemente da aplicação, o processo de suavização de *speckle* em imagens SAR é de suma importância para a interpretação correta de seus dados. Os filtros, de uma forma geral, devem preservar o valor médio do retorno do radar, preservar as bordas presentes na

imagem e as informações de textura. Seguindo este raciocínio, o presente trabalho de dissertação apresenta uma proposta de filtragem que baseia-se no uso de distâncias estocásticas sobre pequenas áreas e, apenas, seleciona áreas provenientes da mesma distribuição que define o pixel central. Assim, como resultado final, teremos a redução do ruído e a preservação de bordas e informações de textura.

E como avaliar a desempenho de um filtro e das imagens filtradas? Wang et al. (2002) expõem que avaliar a qualidade de imagens em geral e, em particular, o desempenho de um filtro são tarefas difíceis. Portanto, trabalhos como de Wang & Bovik (2002); Moschetti et al. (2006) e Buemi et al. (2011), que apresentam técnicas e metodologias para avaliar a qualidade de filtros em imagens, são agregados nesta dissertação.

1.2 Contribuições

Propomos um novo algoritmo para reduzir o ruído *speckle*: amostras dentro da janela de filtragem são submetidas a testes de aderência à distribuição dos dados que circundam o pixel central, e as que não são rejeitadas são agregadas para calcular a média. Esses testes foram derivados das divergências (h, ϕ) , oriundas da Teoria da Informação. O modelo subjacente leva em conta possíveis alterações de homogeneidade na imagem, permitindo que um parâmetro possa variar, ao invés de fixá-lo para toda a imagem. Mensuramos a qualidade das imagens utilizando experimentos Monte Carlo juntamente com métricas e metodologias: (i) metodologia de Moschetti et al. (2006), onde este trabalho de dissertação avança utilizando medidas de erro; (ii) índice Q por Wang & Bovik (2002); (iii) correlação de Pearson entre as bordas da imagem sem ruído e a filtrada. A metodologia proposta é bastante geral e pode ser estendida para outras situações, desde que haja um modelo subjacente estatístico.

No decorrer deste trabalho alguns artigos, resumos e apresentações foram realizados, aos quais estão elencados a seguir:

- ✓ Torres, L.; Cavalcante, T. & Frery, A. C. (2012), Speckle Reduction using Stochastic Distances, *in* '17º Iberoamerican Congress on Pattern Recognition (CIARP)', Buenos Aires. (Apresentado)
- ✓ Torres, L.; Medeiros, A. C. & Frery, A. C. (2012), Polarimetric SAR Image Smoothing with Stochastic Distances, *in* '17º Iberoamerican Congress on Pattern Recognition (CIARP)', Buenos Aires. (Apresentado)
- ✓ Torres, L.; Cavalcante, T. & Frery, A. C. (2012), A New Algorithm of Speckle Filtering using Stochastic Distances, *in* 'IEEE International Geoscience and Remote Sensing Symposium (IGARSS)', Munich. (Apresentado)

- ✓ Pinheiro, R.; Torres, L., & Frery, A. C. (2011), Ambiente Computacional para suporte a Reproducible Research em Processamento Digital de Imagens, *in* 'Cuarto Simposio de Estadística Espacial y Modelamiento de Imágenes (SEEMI)', Valparaíso. (Apresentado)

1.3 Objetivos

Este trabalho de dissertação apresenta um novo algoritmo para filtragem de *speckle* com base em distâncias estocásticas e testes entre distribuições. A técnica é aplicada a imagens SAR de intensidade homogênea, utilizando o modelo gama para descrever a intensidade observada. Para tanto, serão necessários a execução das seguintes atividades:

- Apresentar os principais aspectos e características de dados SAR;
- Descrever as principais técnicas e procedimentos para filtragem de *speckle* em imagens SAR;
- Elaborar e propor processos metodológicos para suavizar o efeito *speckle* baseado em distâncias estocásticas;
- Estender técnicas de avaliação da qualidade em imagens coloridas às imagens SAR de intensidade;
- Avaliar o algoritmo proposta e os resultados alcançados.

1.4 Organização da Dissertação

Este trabalho apresenta a seguinte organização: No capítulo 2 resumimos os principais conceitos, técnicas e algoritmos relacionados. No capítulo 3 descrevemos o processo de redução do *speckle* em imagens SAR de intensidade homogênea usando distâncias estocásticas. Resultados e análises são apresentados no capítulo 4. E, finalizamos com as conclusão e próximos passos no capítulo 5. No apêndice A apresentamos os materiais e métodos utilizados neste trabalho, buscando a reprodutibilidade desta pesquisa. No apêndice B mostramos uma aplicação estendida do algoritmo proposto em dados SAR Polarimétricos.

O capítulo apresentou a abordagem do problema foco nesta dissertação. Em seguida, foram apresentadas as contribuições e objetivos desta pesquisa. Dando sequência, o segundo capítulo apresentará os conceitos e aspectos cruciais ao desenvolvimento desta dissertação.

2

FUNDAMENTAÇÃO TEÓRICA

INICIALMENTE, apresentamos alguns dos principais algoritmos e técnicas em processamento e análise de imagens. Nas seções subsequentes abordamos fundamentos em sensoriamento remoto e os principais modelos estatísticos que descrevem dados SAR. Por fim, os principais métodos para filtragem de *speckle* são discutidos.

2.1 Processamento e Análise de Imagens

Uma *imagem* pode ser definida como uma função bidimensional $f(x,y)$, em que o valor de f na coordenada espacial (x,y) da imagem, representa o nível de intensidade luminosa proveniente da cena observada ou o nível de cinza naquele ponto (Velho et al., 2009); o par $((x,y), f(x,y))$ é denominado pixel.

Processamento digital de imagens tem por finalidade a manipulação de imagens de modo a torná-las adequadas para a identificação ou segmentação dos objetos de interesses em regiões, de forma que as informações desejadas possam ser extraídas. Com a fase de pré-processamento dessas regiões é possível, por exemplo:

- atenuar ou eliminar ruído e estruturas indesejáveis;
- realçar contraste;
- selecionar estruturas e características de interesses e;
- classificar ou reconhecer objetos individuais, dentre outras técnicas.

Gonzalez & Woods (2008), Velho et al. (2009) e Chávez (2010) elencam alguns conceitos aos quais são relevantes a este trabalho:

Vizinhança: Definimos para cada coordenada $(x,y) \in S$ um conjunto de coordenadas que exclui (x,y) , denotada vizinhança: $\partial_{(x,y)} \subset S \setminus \{(x,y)\}$. A vizinhança pode ser vazia ($\partial_{(x,y)} = \emptyset$), como também pode ser formada por todas as outras coordenadas $\partial_{(x,y)} \subset S \setminus \{(x,y)\}$. O conceito de distância é o mais adequado para definir vizinhanças sobre o suporte S , por exemplo

$$\partial_{(x,y)} = \{(x_i, y_j) \in S \setminus \{(x,y)\} : d((x,y), (x_i, y_j)) \leq k\}, \quad (2.1)$$

onde $d((x,y), (x_i, y_j))$ é alguma representação de distância entre as coordenadas (x,y) , $(x_i, y_j) \in S$, e k é um valor inteiro não-negativo, que representa o *suporte da janela*. O fecho da vizinhança $\partial_{(x,y)}$ é definido por

$$\bar{\partial}_{(x,y)} = \partial_{(x,y)} \cup \{(x,y)\}. \quad (2.2)$$

O fecho da vizinhança $\bar{\partial}_{(x,y)}$ pode apresentar diferentes tamanhos e formatos (*suporte da janela*) — circular, quadrangular ou retangular — centrado sobre o ponto (x,y) .

Operador Pontual: É um processo no domínio espacial dado por

$$g(x,y) = Y(f(x,y)), \quad \forall (x,y) \in S, \quad (2.3)$$

onde f representa a imagem de entrada, g representa a imagem de saída e Y o operador pontual em f .

Operador Local: São operações realizadas no fecho da vizinhança de cada pixel. A intensidade de cada pixel na imagem de saída é dada por

$$g(x,y) = Y(\{f(u,v) : (u,v) \in \bar{\partial}_{(x,y)}\}), \quad (2.4)$$

onde f denota a imagem de entrada, Y o operador local e g a imagem de saída. Um processo de filtragem é um bom exemplo de operação local.

Convolução: Trata-se de uma técnica que pode ser incorporada em várias funções em processamento de imagens. A máscara de convolução de lado ℓ (ímpar) é um importante conceito neste processo, e pode ser definida por um conjunto de valores reais $w = w(u,v)$ com $-(\ell-1)/2 \leq u, v \leq (\ell-1)/2$, onde o ponto central da máscara é $(0,0)$. Assim, a equação genérica de convolução é dada por

$$g(x,y) = \sum_{u,v} f(x+u, x+v) w(u,v), \quad (2.5)$$

onde f denota a imagem de entrada, w denota os valores da máscara de convolução, $g = f \otimes w$ a imagem de saída e ' \otimes ' denota o produto de convolução.

Detecção de Bordas: A extração de bordas pode ser realizada por um algoritmo de detecção de bordas, a exemplo do operador de Sobel. O algoritmo considera os gradientes de nível de cinza da imagem original para gerar uma imagem gradiente ou imagem de intensidade de borda. Este algoritmo geralmente segue tais passos:

- calcula-se um limiar para a perseguição de bordas;
- quando o algoritmo encontra um ‘pixel’ com valor superior ao limiar estabelecido, tem-se início o processo de perseguição da borda;
- observa-se a vizinhança para identificar o próximo ‘pixel’ de maior valor de nível digital e segue-se nesta direção até que se encontre outra borda ou a fronteira da imagem.

Deste processo gera-se uma imagem binária com os valores de 1 referentes às bordas e 0 as regiões de não-bordas. A imagem binária será rotulada de modo que as porções da imagem com valores 0 constituirão regiões limitadas pelos valores 1.

$$G_x = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad G_y = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad (2.6)$$

O operador de Sobel é obtido utilizando máscara de convolução dada pela Equação 2.6 nas direções horizontal G_x e vertical G_y e a junção destes resultados produzem as bordas da imagem, também denotada ∇^2 . O deslocamento da máscara é realizado no eixo x ou no eixo y , ou seja, só detecta bordas nas duas direções. Este processo é utilizado ao longo deste trabalho como detector de bordas padrão.

2.2 Radar de Abertura Sintética

O termo RADAR (“*RA*dio *D*etection *A*nd *R*anging”) define um dispositivo capaz de detectar um objeto (alvo), indicando sua distância (*range*) e sua posição (direção) (Trevett, 1986) e tem sido utilizado de forma genérica para classificar os sistemas que operam na faixa de frequência das microondas (INPE, 2012).

De acordo com Ulaby et al. (1986); Ulaby & Elachi (1990) e Lee & Pottier (2009) algumas das principais vantagens do sensoriamento remoto por RADAR são: (i) pouca dependência das condições atmosféricas e; (ii) possuir sensor ativo, assim, não é afetado pela baixa visibilidade ótica do ambiente imageado.

A IEEE (2003) formaliza os padrões da faixa das microondas, sendo divididas em bandas e designadas por letras. A tabela 2.1 apresenta estes padrões, onde a primeira coluna contempla as designações banda-letra, em seguida o comprimento de onda do sinal e, por fim,

Tabela 2.1: Nomenclatura padrão do IEEE para Banda de RADAR.

Designação	Comprimento de Onda	Frequência
HF	100 ~ 10 m	3 ~ 30 MHz
VHF	10 ~ 1 m	30 ~ 300 MHz
UHF	100 ~ 30 cm	300 ~ 1000 MHz
Banda L	30 ~ 15 cm	1 ~ 2 GHz
Banda S	15 ~ 7,5 cm	2 ~ 4 GHz
Banda C	7,5 ~ 3,75 cm	4 ~ 8 GHz
Banda X	3,75 ~ 2,50 cm	8 ~ 12 GHz
Banda Ku	2,50 ~ 1,67 cm	12 ~ 18 GHz
Banda K	1,67 ~ 1,11 cm	18 ~ 27 GHz
Banda Ka	1,11 ~ 0,75 cm	27 ~ 40 GHz
Banda V	7,5 ~ 4,0 mm	40 ~ 75 GHz
Banda W	4,0 ~ 2,7 mm	75 ~ 110 GHz
Banda mm	2,7 ~ 1,0 mm	110 ~ 300 GHz

a frequência de atuação da banda.

A maioria dos radares imageadores aerotransportados utilizados em sensoriamento remoto são os de visão lateral (*Side-Looking Airborne Radar* – SLAR). A definição SLAR engloba dois tipos de radar imageador: (i) o de abertura real (*Real Aperture Radar* – RAR) e; (ii) o de abertura sintética (SAR), sendo este último utilizado neste trabalho.

O sistema SAR pode ser classificado em dois tipos: (i) convencionais e (ii) polarimétricos. No primeiro caso são sistemas capazes de sintetizar apenas a amplitude do sinal refletido em uma dada configuração de polarização da antena, ou seja, com polarização fixa e numa determinada frequência. Já os sistemas polarimétricos, fundamentados a partir de propriedades da Polarimetria, são capazes de sintetizar a amplitude e a fase dos sinais refletidos em diferentes configurações de polarização da antena (Negri, 2009). O sistema convencional para imageamento SAR será o conceito utilizado nesta pesquisa.

O tipo de detecção do sinal de retorno em um sistema SAR convencional pode ser linear ou quadrático. Deste modo, a imagem do terreno pode ser formada tanto em amplitude (detecção linear) quanto em intensidade (detecção quadrática) (Lucca, 1998). A seguir, será apresentado o processo de formação de imagens SAR e algumas de suas características.


2.3 Imageamento SAR

O imageamento por RADAR consiste na emissão de pulsos de microondas a intervalos regulares sobre uma região alvo e da recuperação dos sinais de retorno (*backscatter*) provenientes da interação entre os pulsos eletromagnético e a região alvo, à medida que o sensor

se desloca. A recepção do *backscatter* pode ser feita utilizando a mesma antena emissora (sistemas monoestáticos) ou uma segunda antena (sistemas biestáticos). Nos sistemas biestáticos, cada antena pode possuir características distintas de polarização, dimensão, ângulo de visada, dentre outras características (Ulaby et al., 1986; Lee & Pottier, 2009).

A Figura 2.1 apresenta uma geometria de operação do SLAR, que é um sensor ativo e emite radiação pulsante na faixa das microondas e recebe os sinais de retorno do alvo. Em geral um SLAR além de possuir um transmissor-receptor, um amplificador e um registrador, ele agrega uma antena em forma de barra presa ao lado inferior da aeronave.

Figura 2.1: Geometria de operação do *Side-Looking Airborne Radar* – SLAR.



Fonte: Imagem adaptada de Trevett (1986) e INPE (2012).

Podemos observar na Figura 2.1 a geometria de operação do SLAR, que atua em uma área conhecida e sua antena (representada na figura na cor “vermelha”) possui comprimento l e está instalada no lado inferior da aeronave em altitude de voo H . Uma seção do feixe luminoso emitido a um ângulo θ é considerado. A área em destaque na Figura 2.1 denota uma área irradiada a uma distância R da antena e ρ sua distância horizontal. Já o intervalo horizontal de retorno do sinal utilizado na construção da imagem, denota *swath width*. Os demais parâmetros a saber: θ_a decorre dos princípios da difração das ondas eletromagnéticas, dada por $\theta_a \propto (\lambda/l)$, em que λ é o comprimento de onda do RADAR; a resolução da trajetória, denota $r_a = R\theta_a$; a resolução do alcance (*range*) inclinado é dada por $r_R = (c\tau/2)$, onde τ é o comprimento do impulso do RADAR e c é a velocidade da luz; por fim, a resolução horizontal no terreno é $r_\rho = (c\tau/2 \sin\theta)$ (Trevett, 1986; INPE, 2012).

Os estudos de Frery et al. (1997a) e Gao (2010), caracterizam imagens SAR quanto ao “grau de homogeneidade”, elencadas em três tipos:

Homogênea: Em suma é representado pela homogeneidade do sinal de retorno, que neste caso não possui alta variabilidade. Áreas de campos e pastagens, lagos e oceanos representam, em geral, regiões homogêneas. Cumpre notar que a homogeneidade depende fortemente da frequência do sinal e do ângulo de incidência da iluminação

Heterogênea: Por possuir uma variabilidade no sinal de retorno, regiões de florestas definem áreas heterogêneas.

Extremamente Heterogênea: Este tipo de homogeneidade do sinal é utilizada para modelar áreas urbanas, onde o espalhamento do terreno é extremamente complexo, além disso, pode modelar os demais graus de homogeneidade.

Todos os processos para formação de imagens com iluminação coerente, tais como aqueles empregados por laser, ultrassom-B, sonar e radar de abertura sintética, sofrem uma degradação granular, denominado *speckle*. Este fenômeno em imagem SAR é causado pela interferência construtiva e destrutiva das ondas coerentes refletidas pelos dispersores (Goodman, 1976; Ulaby & Dobson, 1989; Oliver & Quegan, 2004).

Devido à presença do *speckle* é confuso determinar o que é borda em uma imagem SAR (Cheng & Tian, 2009). Ruído *speckle* contamina o conteúdo da imagem e, assim, retarda o processo de segmentação, extração, análise, classificação dos objetos e informações presentes na imagem. Portanto, um processo de filtragem que combata o ruído e preserve as características e propriedades da imagem é extremamente importante neste contexto.

A suavização do ruído pode ocorrer em dois momentos: (i) durante o processo de imageamento, onde reduz a intensidade do ruído *speckle* pela média de cada posição da imagem (Processamento *Multilook*); (ii) depois da imagem ter sido formada, através de algoritmos de processamento de filtragem (Zhang, 2004). Em ambos os processos há perda de resolução espacial. Segundo Moschetti et al. (2006), uma “boa” técnica deve combater o ruído *speckle* e, ao mesmo tempo, preservar os detalhes, bem como informações relevantes.

Nos tópicos seguintes, investigaremos e apresentaremos os processos para suavização do ruído *speckle*, dando ênfase à modelagem estatística e aos métodos de filtragem, considerados clássicos, do ruído em dados SAR.

2.4 Processamento *Multilook*

A principal finalidade deste processo é reduzir o nível do ruído *speckle* no momento da formação de imagens SAR.

Na literatura, há vários métodos para obtermos imagens *multilook*. Um método utilizado por Sant’Anna (1995) é a divisão em *looks* por tempo de integração, definida como sendo a diferença entre os instantes de entrada (t_i) e saída (t_j) de uma região alvo, em que i e j

podem ser um instante do processo apresentado na Figura 2.1 — sendo dependentes das características da antena, como resolução da trajetória, resolução do alcance, dentre outras — e o comprimento sintético da antena, que é dado pelo produto da velocidade do sensor (antena) pelo tempo de integração.

2.5 Modelagem Estatística para Imagens SAR

A estatística, de forma geral, visa prover modelos e métodos que descrevam um determinado conjunto de dados. Nos estudos de Gao (2010) são classificados e avaliados alguns dos principais modelos estatísticos, que têm sido desenvolvidos para descrever dados SAR. Gao (2010) afirma que a modelagem estatística é essencial para interpretação de imagens SAR, com o objetivo de descrevê-las e representar características intrínsecas a estes dados.

Pesquisadores já estabeleceram modelos estatísticos para descrever e caracterizar o efeito *speckle* como sendo uma variável aleatória e, geralmente modelado como ruído aleatório multiplicativo (Goodman, 1976; Ulaby & Dobson, 1989; Oliver, 1991). O ruído em imagens SAR são usualmente avaliados em dois formatos: (i) intensidade e (ii) amplitude (magnitude), dado os sistemas SAR convencionais (Xie et al., 2002).

As vantagens encontradas na utilização desses métodos e modelos são: (i) um suporte técnico para uma compreensão abrangente do mecanismo de espalhamento do terreno; (ii) o apoio no desenvolvimento de algoritmos para interpretação de imagens com maior eficiência; (iii) na obtenção de imagens simuladas com credibilidade e; (iv) no processo de interpretação e análise de dados SAR.

Outro aspecto importante é o processo empregado na modelagem estatística dos dados, podendo ser dividido em duas categorias (Zhang, 2004; Gao, 2010):

Paramétricos: Neste processo é conhecido um número finito de distribuições de probabilidade que descrevem a imagem e são dados *a priori*. Geralmente, os parâmetros destas distribuições são desconhecidos e devem ser estimados de acordo com os dados da imagem real. Finalmente, usando alguma métrica para aferir a estimação, a distribuição ideal é escolhida como modelo estatístico da imagem.

Não Paramétricos: Durante a manipulação do processo não paramétrico, não há distribuições ou parâmetros a serem assumidos e a distribuição ótima é obtida apenas pela análise dos dados da imagem real. Assim, há um conjunto infinito de distribuições para uma possibilidade infinita de parâmetros.

A modelagem paramétrica foi adotada devido o suporte estatístico que ela fornece, como exemplo, a geração de variáveis aleatórias para criar cenários controlados e, assim, com o conhecimento do cenário podemos avaliar o comportamento do método proposto.

O desempenho de um filtro de *speckle* depende fortemente dos modelos estatísticos que foram utilizados para descrever o *backscatter* e o ruído, dando origem à intensidade da imagem observada (Touzi, 2002). Na seção seguinte, apresentaremos uma das principais estruturas estatísticas para lidar com o ruído *speckle* em imagens SAR, conhecida como **modelo multiplicativo**. Este modelo utiliza-se do processo de modelagem paramétrica, assim, em seguida apresentaremos as distribuições que o descreve.

2.5.1 Modelo Multiplicativo

De acordo com Goodman (1976), o modelo multiplicativo pode ser usado para descrever dados SAR, a fim de lidar com o ruído *speckle* em imagens com iluminação coerente. A utilização deste modelo tem conduzido várias técnicas ao sucesso em processamento e análise de imagens.

Este modelo afirma que a intensidade observada em cada pixel é o resultado de uma variável aleatória $Z: \Omega \rightarrow \mathbb{R}_+$ que, por sua vez, é o produto de duas variáveis aleatórias independentes (Goodman, 1976; Ulaby & Dobson, 1989; Oliver, 1991): $X: \Omega \rightarrow \mathbb{R}_+$, que caracteriza a intensidade do retroespalhamento do terreno (*backscatter*); e $Y: \Omega \rightarrow \mathbb{R}_+$, define a intensidade do ruído *speckle* e, em certas condições, é modelado seguindo uma distribuição gama com média igual a um. A distribuição relacionada à intensidade observada

$$Z = XY \quad (2.7)$$

é completamente especificada pelas distribuições observadas em X e Y .

Algumas propriedades multiplicativas entre variáveis aleatórias são abordadas nos estudos de Lomnicki (1967), denotada *Transformada de Merllin* (veja Teorema 2.5.1).

Teorema 2.5.1 *Sejam X e Y variáveis aleatórias independentes e absolutamente contínuas, com funções densidade de probabilidade $f_X(x)$ e $f_Y(y)$, respectivamente, e se definirmos a variável $Z = XY$, então*

$$f_Z(z) = \int_{\mathbb{R}} \frac{1}{|x|} f_Y\left(\frac{z}{x}\right) f_X(x) dx.$$

As distribuições associadas a X e Y podem variar conforme a região alvo e, também, em função do tipo de detecção, seja linear ou quadrática, produzindo diferentes distribuições para cada dado observado Z (Ulaby & Dobson, 1989; Frery et al., 1997a; Gao, 2010).

2.6 Distribuições Aplicadas aos Dados SAR

A seguir, apresentaremos algumas das principais distribuições aplicáveis aos dados SAR. Contudo, direcionaremos as distribuições para aquelas que representam imagens de intensidade, fortemente utilizadas nesta dissertação.

Frery et al. (1995, 1997a) apresentam um modelo considerado geral para descrever o *backscatter*, e casos especiais de modelos mais simples podem ser encontrados em Gao (2010), ambos descrevem modelos para áreas com diferentes graus de homogeneidade.

2.6.1 Distribuições para o Retroespalhamento do Terreno

Distribuição constante

Para modelar regiões de intensidade homogênea, parte-se da hipótese que o retroespalhamento do terreno possui valor constante, porém desconhecido. Assim, supõe-se que pode ser modelado por uma distribuição constante, denotada por $X \sim \lambda$ e caracteriza pela função de distribuição acumulada, dada por

$$F_X(x) = \mathbb{1}_{[\lambda, \infty)}(x), \quad (2.8)$$

em que $\mathbb{1}_A(x)$ é a função indicadora do conjunto A :

$$\mathbb{1}_A(x) = \begin{cases} 1, & \text{se } x \in A \\ 0, & \text{se } x \notin A. \end{cases} \quad (2.9)$$

Distribuição gama

De acordo com Frery et al. (1997a) e Gao (2010), a distribuição gama descreve as características de terrenos heterogêneos em imagens SAR de intensidade de alta resolução. Uma variável aleatória que segue uma distribuição gama, denotada por $X \sim \Gamma(\alpha, \gamma)$, com parâmetros α e $\gamma \in \mathbb{R}_+$ é caracterizada pela densidade

$$f_X(x; \alpha, \gamma) = \frac{\gamma^\alpha}{\Gamma(\alpha)} x^{\alpha-1} \exp\{-\gamma x\}, \quad (2.10)$$

em que Γ é a função gama de *Euler*, que permite definir fatoriais para números não-inteiros ou não-integráveis é dada por

$$\Gamma(v+1) = \int_{\mathbb{R}_+} t^v \exp\{-t\} dt, \quad \forall v > -1. \quad (2.11)$$

As propriedades desta função podem ser encontradas em Graham et al. (1988). Uma variável aleatória com distribuição $\Gamma(\alpha, \gamma)$ possui esperança $E(X) = \alpha\gamma^{-1}$ e variância $\text{Var}(X) = \alpha\gamma^{-2}$.

Recíproca da distribuição gama

A recíproca da gama é utilizada para modelar áreas de intensidade extremamente heterogêneas (Frery et al., 1997a; Moschetti et al., 2006). Esta distribuição, denotada por $X \sim$

$\Gamma^{-1}(\alpha, \gamma)$, com parâmetros $-\alpha$ e $\gamma \in \mathbb{R}$ é caracterizada pela densidade

$$f_X(x; \alpha, \gamma) = \frac{x^{\alpha-1}}{\gamma^\alpha \Gamma(-\alpha)} \exp\left\{-\frac{\gamma}{x}\right\}. \quad (2.12)$$

Esta distribuição possui esperança $E(X) = \gamma/(\alpha - 1)$, para $\alpha < -1$, e infinito caso contrário, e variância $\text{Var}(X) = \gamma^2/((\alpha - 2)(\alpha - 1)^2)$, para $\alpha < -2$, e infinito caso contrário.

Distribuição Gaussiana Inversa Generalizada

O modelo geral, descrito por Frery et al. (1995) e Frery et al. (1997a), para descrever o *backscatter* faz-se uso da distribuição Gaussiana Inversa Generalizada, com parâmetros α, γ e $\lambda \in \mathbb{R}$, denotada por $X \sim \mathcal{N}^{-1}(\alpha, \gamma, \lambda)$ e caracterizada pela densidade

$$f_X(x; \alpha, \gamma, \lambda) = \frac{\sqrt{(\lambda/\gamma)^\alpha}}{2K_\alpha(2\sqrt{\lambda\gamma})} x^{\alpha-1} \exp\left\{-\frac{\gamma}{x} - \lambda x\right\}, \quad (2.13)$$

em que K_α indica a função de Bessel modificada de terceiro grau e ordem α , e o domínio dos parâmetros é dado por Frery et al. (1997a):

$$\begin{cases} \gamma > 0, \lambda \geq 0, & \text{se } \alpha < 0 \\ \gamma > 0, \lambda > 0, & \text{se } \alpha = 0 \\ \gamma \geq 0, \lambda > 0, & \text{se } \alpha > 0 \end{cases}.$$

As propriedades e outras informações sobre esta distribuição podem ser encontradas em Frery et al. (1995), Frery et al. (1997a) e Müller et al. (2000).

2.6.2 Distribuição para Dados *Speckle*

O ruído *speckle*, sob certas condições, pode ser modelado por uma distribuição gama univariada, denotada por $Y \sim \Gamma(L, L)$, com média $E(Y) = 1$ e variância $\text{Var}(Y) = 1/L$, onde $L \geq 1$ o número equivalente de *looks* da imagem SAR, que está relacionado à qualidade visual (Goodman, 1976; Ulaby et al., 1986). A função densidade de probabilidade que descreve o comportamento do ruído *speckle* é dada por

$$f_Y(y; L) = \frac{L^L}{\Gamma(L)} y^{L-1} \exp\{-Ly\}, \quad (2.14)$$

em que $y > 0$ e $L \geq 1$.

2.6.3 Distribuições para Intensidade do Retorno

As distribuições da intensidade do retorno Z para dados *multilook* são resultantes do produto de duas variáveis aleatórias independentes $Z = XY$. As distribuições associadas

a X e Y podem variar conforme a região alvo e produzirem diferentes distribuições para cada dado observado Z . A seguir apresentaremos algumas distribuições que caracterizam os dados observados para imagens SAR de intensidade.

Distribuição $\Gamma(L, L/\lambda)$


A distribuições gama, denotada por $Z \sim \Gamma(L, L/\lambda)$, representa dados *multilook* em regiões homogêneas e obtida pelo produto de duas variáveis aleatórias independentes, onde $X \sim \lambda$ dada pela Equação (2.8) e $Y \sim \Gamma(L, L)$ dada pela Equação (2.14) utilizando o Teorema 2.5.1 e caracterizada pela densidade

$$f_Z(z; L, \lambda) = \frac{L^L}{\lambda^L \Gamma(L)} z^{L-1} \exp\left\{-\frac{Lz}{\lambda}\right\}, \quad (2.15)$$

em que $z, \lambda > 0$ e $L \geq 1$.

As Figuras 2.2 e 2.3 apresentam a intensidade do retorno para diferentes parâmetros de configuração.

Figura 2.2: Dados e densidades da $\Gamma(L, L/\lambda)$ para $L = 2$ e $\lambda = \{50, 80, 120, 200\}$.



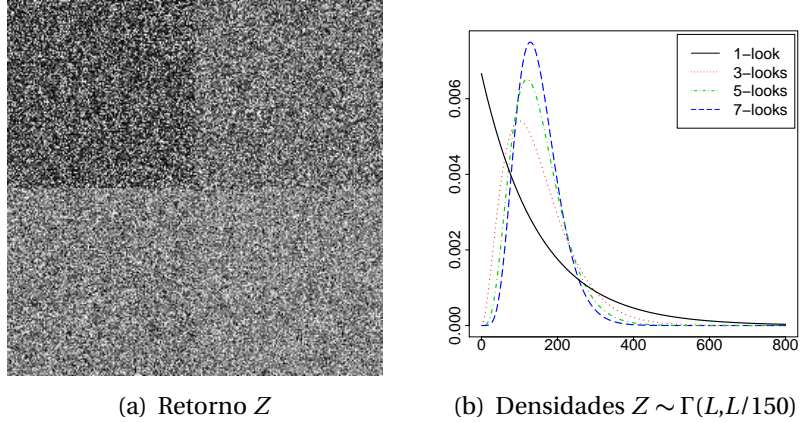
Distribuição $\mathcal{K}_I(\alpha, \gamma, L)$

A distribuição \mathcal{K} de intensidade, denotada por $Z \sim \mathcal{K}_I(\alpha, \gamma, L)$, representa o sinal de retorno de regiões heterogêneas e obtida pelo produto de duas variáveis aleatórias independentes, onde $X \sim \Gamma(\alpha, \gamma)$ dada pela Equação (2.10) e $Y \sim \Gamma(L, L)$ dada pela Equação (2.14) utilizando o Teorema 2.5.1 e caracterizada pela densidade

$$f_Z(z; \alpha, \gamma, L) = \frac{2\gamma L}{\Gamma(\alpha)\Gamma(L)} (\gamma L z)^{(\alpha+L)/2-1} K_{\alpha-L}(2\sqrt{\gamma L z}), \quad (2.16)$$

em que $\alpha, \gamma, z > 0$ e $L \geq 1$.

Figura 2.3: Dados e densidades da $\Gamma(L, L/\lambda)$ para $\lambda = 150$ e $L = \{1, 3, 5, 7\}$.



Distribuição $\mathcal{G}_I^0(\alpha, \gamma, L)$

A distribuição \mathcal{G} -Zero de intensidade, denotada por $Z \sim \mathcal{G}_I^0(\alpha, \gamma, L)$, representa o sinal de retorno de regiões heterogêneas e obtida pelo produto de duas variáveis aleatórias independentes, onde $X \sim \Gamma^{-1}(\alpha, \gamma)$ dada pela Equação (2.12) e $Y \sim \Gamma(L, L)$ dada pela Equação (2.14) utilizando o Teorema 2.5.1 e caracterizada pela densidade

$$f_Z(z; \alpha, \gamma, L) = \frac{L^L \Gamma(L - \alpha) z^{L-1}}{\gamma^\alpha \Gamma(-\alpha) (\gamma + Lz)^{L-\alpha}}, \quad (2.17)$$

em que $-\alpha, \gamma, z > 0$ e $L \geq 1$.

Distribuição $\mathcal{G}_I(\alpha, \gamma, \lambda, L)$

A distribuição \mathcal{G} de intensidade, denotada por $Z \sim \mathcal{G}_I(\alpha, \gamma, \lambda, L)$, representa o sinal de retorno de regiões heterogêneas e obtida pelo produto de duas variáveis aleatórias independentes, onde $X \sim \mathcal{N}^{-1}(\alpha, \gamma, \lambda)$ dada pela Equação (2.13) e $Y \sim \Gamma(L, L)$ dada pela Equação (2.14) utilizando o Teorema 2.5.1 e caracterizada pela densidade

$$f_Z(z; \alpha, \gamma, \lambda, L) = \frac{L^L (\lambda/\gamma)^{\alpha/2}}{\Gamma(L) K_\alpha(2\sqrt{\lambda\gamma})} z^{L-1} \left(\frac{\gamma + Lz}{\lambda} \right)^{(\alpha-L)/2} K_{\alpha-2}(2\sqrt{\lambda(\gamma + Lz)}), \quad (2.18)$$

em que o domínio dos parâmetros é dado por Frery et al. (1997a):

$$\begin{cases} \gamma > 0, \lambda \geq 0, & \text{se } \alpha < 0 \\ \gamma > 0, \lambda > 0, & \text{se } \alpha = 0. \\ \gamma \geq 0, \lambda > 0, & \text{se } \alpha > 0 \end{cases}$$

A tabela 2.2 mostra algumas distribuições usadas para descrever a intensidade observada em modelos *multilook* para diferentes graus de homogeneidade em sua forma simples.

Tabela 2.2: Distribuições no modelo multiplicativo para dados SAR de intensidade.

Grau de Homogeneidade	Backscatter X	Speckle Y	Retorno $Z = XY$
Homogêneas	λ		$\Gamma(L, L/\lambda)$
Heterogêneas	$\Gamma(\alpha, \gamma)$		$\mathcal{K}_I(\alpha, \gamma, L)$
Extremamente Heterogêneas	$\Gamma^{-1}(\alpha, \gamma)$	$\Gamma(L, L)$	$\mathcal{G}_I^0(\alpha, \gamma, L)$
Caso Geral	$\mathcal{N}^{-1}(\alpha, \gamma, \lambda)$		$\mathcal{G}_I(\alpha, \gamma, \lambda, L)$

2.7 Filtagem de *Speckle*

Nesta seção faremos uma breve revisão dos principais filtros, que reduzem o ruído *speckle*. Geralmente, estes filtros são baseados em modelos estatísticos, que obtêm a imagem filtrada por métodos de estimação tendo como amostras uma área vizinha ao pixel filtrado.

2.7.1 Filtros Padrões

Filtro de Lee

O filtro de Lee (Lee, 1986) foi proposto para reduzir o efeito *speckle* usando o modelo multiplicativo. O filtro é bastante geral, adaptativo e supõe que não existe correlação entre a relação sinal ruído.

Este filtro adaptativo utiliza a estatística local (média e variância) a fim de aliviar o efeito de ruído e, ao mesmo tempo, para reduzir o *speckle* mais eficazmente do que o filtro da mediana (Lee et al., 1994).

O método estatístico local, do qual o filtro de Lee foi baseado, não requer um modelo estatístico global do sinal. Na ausência de um modelo de sinal, a média $E(Z)$ e a variância $\text{Var}(Z)$ *a priori* são estimadas pela média e variância local numa dada janela. Ele usa a média e a variância observada em uma janela para estimar o retroespalhamento (não observado) dada pela equação

$$\hat{x} = \bar{x} + b(z - \bar{x}),$$

em que b é um estimador da relação da variância de x para a variância de z . Se não há nenhum modelo para x , seus momentos tem que ser estimados a partir dos dados. A média e a variância do *backscatter* pode ser estimado em cada janela de filtragem, $\bar{x} = \bar{z}/\bar{y} = \bar{z}$ e por

$$\hat{\sigma}_x^2 = \hat{\sigma}_z^2 - \frac{\bar{z}\sigma_y^2}{\sigma_y^2 + 1},$$

em que σ_y é o desvio padrão do ruído *speckle*, que pode ser calculado pelo número equivalente de *looks* $(\bar{z}/\hat{\sigma}_z)^2$.

Filtro de Frost

A proposta de [Frost et al. \(1982\)](#) é um filtro de Wiener adaptativo — detalhes podem ser encontrados em [Gonzalez & Woods \(2008\)](#) — para o modelo multiplicativo e incorporada a dependência estatística do sinal original, uma vez que se supõe uma função de correlação espacial exponencial entre pixels. A atualização do pixel ruidoso para áreas homogêneas é dada pela equação

$$\hat{x}(t) = z(t) \otimes m(t),$$

em que $m(t)$ é uma função de correlação exponencial, dada por

$$m(t) = \delta \exp\{-\gamma|t|\},$$

em que

$$\gamma^2 = \nu + \frac{2\nu\hat{\sigma}_x^2}{\sigma_y^2(\hat{\sigma}_x^2 + \bar{x}^2)}.$$

Os parâmetros t, γ, δ, ν e $\hat{\sigma}_x^2$ correspondem respectivamente, à distância do pixel observado ao central, à constante de decaimento, à constante de normalização, ao coeficiente de correlação e à variância estimada da imagem ideal.

Filtro de Kuan

O filtro de [Kuan et al. \(1985, 1987\)](#) também adota o modelo multiplicativo, semelhante a [\(Lee, 1981\)](#), que para estimar o retroespalhamento é utilizado o filtro de Wiener. A principal diferença entre as propostas consiste que Kuan não aplica aproximação por expansão de primeira ordem da série de Taylor. Contudo, as expressões de cálculo de estatísticas locais são as mesmas (\bar{z} e σ_z^2). A solução proposta por [Kuan et al. \(1987\)](#) para redução do *speckle* é expressada por

$$\hat{x} = \bar{z} + \frac{\hat{\sigma}_x^2(z - \bar{z})}{\hat{\sigma}_x^2 + \sigma_y^2(\bar{z}^2 + \hat{\sigma}_x^2)},$$

em que σ_y é o desvio padrão do ruído *speckle*.

Melhoramento de Lee

[Lee et al. \(2009\)](#) propõem um aprimoramento do filtro sigma de [Lee \(1983a,b\)](#), que apresenta deficiências, tais como: o viés dos dados filtrados, pontos pretos permanecendo nas imagens e borramento e omissão de objetos. A variação de sigma (I_1, I_2) foi redefinida baseando-se nas distribuições teóricas do *speckle*. Assim, o novo intervalo para a seleção dos pixels, para qualquer média \tilde{x} , pode ser calculado como $(I_1 \tilde{x}, I_2 \tilde{x})$. A média \tilde{x} é estimada através do erro quadrático médio mínimo (MMSE) dada por [Lee \(1980\)](#) e [Kuan et al. \(1985, 1987\)](#) em uma janela 3×3 .

Os dados numa janela 9×9 e com valores dentro do intervalo $(I_1 \tilde{x}, I_2 \tilde{x})$ são selecionados para a estimação do pixel central \hat{x} . Se o valor de \hat{x} for maior do o 98° percentil, o número vizinhos, também com valores superiores, serão contabilizados. Se a quantidade de vizinhos for maior do que um limiar T_k , nenhum dos pixels numa região 3×3 serão modificados, caso contrário o \hat{x} receberá o valor estimado através do filtro MMSE, assim como se o valor de \hat{x} for menor do que o 98° percentil.

2.7.2 Filtros *Maximum a Posteriori* (MAP)

Os filtros MAP utiliza-se de um modelo de distribuição para descrever os dados observados. Uma análise estatística é realizada previamente para selecionar a melhor distribuição que descrevem os dados. Obtêm-se os parâmetros da distribuição através de estimadores e um filtro de MAP é aplicado com base nesta distribuição.

Os estimadores de um filtro MAP, quando disponível, é a solução de $\text{argmax}_X \Pr(X | Z)$, em que X caracteriza o *backscatter* e Z é o modelo dos dados observados. Usando o Teorema de Bayes, que pode se escrito por $\Pr(X | Z) \propto \Pr(Z | X) \Pr(X)$, em que \propto denota proporcionalidade, $\Pr(X)$ é o retroespalhamento e $\Pr(Z | X)$ define os dados observados.

Diferentes hipóteses para a distribuição de X foram levantadas, a fim de calcular os estimadores MAP, com diferentes complexidades associadas. As distribuições apresentadas na tabela 2.2 foram supostas, uma vez que estas hipóteses levam a soluções viáveis, como apresentadas por Moschetti et al. (2006).

O presente capítulo elencou alguns conceitos sobre processamento de imagens e sensoriamento remoto. Apresentamos os principais modelos estatísticos para descrever dados SAR de intensidade em vários graus de homogeneidade. Por fim, tratamos os principais filtros de *speckle*. O capítulo seguinte apresenta uma nova abordagem para filtragem de *speckle*.

3

REDUÇÃO DE *Speckle* USANDO DISTÂNCIAS ESTOCÁSTICAS

ESSE capítulo tem como objetivo apresentar uma nova técnica para redução de *speckle* em dados SAR de intensidade e descrever um método para mensurar a qualidade das imagens filtradas. Podemos afirmar que a principal importância desse capítulo é fornecer subsídios suficientes para elaboração e conclusão dos objetivos propostos.

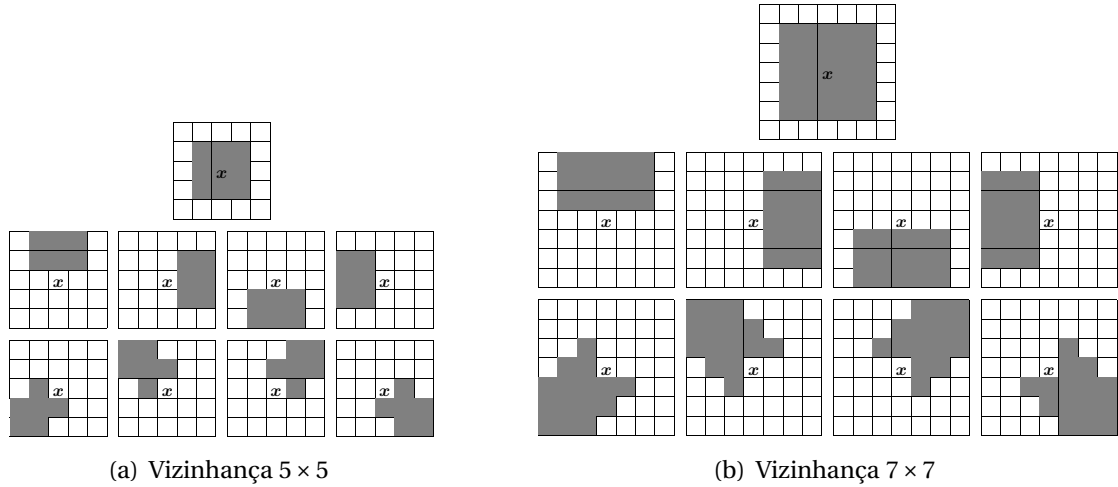
3.1 Metodologia Proposta

A proposta é baseado em distâncias e testes entre distribuições (Nascimento et al., 2010), obtidos da Teoria da Informação e nomeados (h, ϕ) -divergência sobre pequenas áreas dentro da janela de filtragem. Modificações nas janelas definidas por Nagao & Matsuyama (1979) foram usadas para compor as amostras, como apresenta a Figura 3.2(a) e numa versão estendida como mostra a Figura 3.2(b).

Para cada pixel filtrado observa-se uma vizinhança 5×5 (veja Figura 3.2(a)) ou uma vizinhança 7×7 (veja Figura 3.2(b)), na qual nove áreas parcialmente sobrepostas são definidas. Denota-se $\hat{\theta}_1$ o parâmetro estimado da região central de vizinhança 3×3 ou 5×5 , respectivamente, e $(\hat{\theta}_2, \dots, \hat{\theta}_9)$ os parâmetros estimados das oito áreas remanescentes.

Ao passo que estamos modelando regiões homogêneas de intensidade, os dados são descritos por uma distribuição $\Gamma(L, L/\lambda)$ e caracterizada pela Equação (2.15). Devido às suas propriedades assintóticas, o método de máxima verossimilhança é utilizado para estimar $\hat{\theta}_i = (L_i, \lambda_i)$. Fazendo L constante é um modelo para áreas homogêneas, contudo, deixando L variar ponto a ponto está em consonância com o modelo de Anfinson et al. (2009), que usa essa abordagem em dados SAR Polarimétricos (PolSAR) para descrever áreas com homogeneidade variável (quanto menor o número de *looks*, menor é a homogeneidade).

Figura 3.1: Vizinhança Nagao-Matsuyama modificada.



Baseado em uma amostra aleatória de tamanho n , $\mathbf{z} = (z_1, z_2, \dots, z_n)$, a função de verossimilhança relacionada à distribuição $\Gamma(L, L/\lambda)$ é dada por

$$\mathcal{L}(L, \lambda; \mathbf{z}) = \left(\frac{L^L}{\lambda^L \Gamma(L)} \right)^n \prod_{j=1}^n z_j^{L-1} \exp \left\{ -\frac{Lz_j}{\lambda} \right\}. \quad (3.1)$$

Assim, os estimadores de máxima verossimilhança para (L, λ) , denotados $(\hat{L}, \hat{\lambda})$, são soluções do seguinte sistema de equações não lineares:

$$\begin{cases} \ln \hat{L} - \psi^0(\hat{L}) - \ln(n^{-1} \sum_{j=1}^n z_j) + n^{-1} \sum_{j=1}^n \ln z_j = 0, \\ -n \hat{L} \hat{\lambda}^{-1} + \hat{L} \hat{\lambda}^{-2} \sum_{j=1}^n z_j = 0, \end{cases}$$

obtemos

$$\hat{\lambda} = \frac{1}{n} \sum_{j=1}^n z_j,$$

e

$$\ln \hat{L} - \psi^0(\hat{L}) - \ln \left(\frac{1}{n} \sum_{j=1}^n z_j \right) + \frac{1}{n} \sum_{j=1}^n \ln z_j = 0,$$

onde ψ^0 é a função digama.

Considere Z_1 e Z_i variáveis aleatórias definidas sobre o mesmo espaço de probabilidade, e suas distribuições são caracterizadas pelas densidades $f_{Z_1}(z_1; \boldsymbol{\theta}_1)$ e $f_{Z_i}(z_i; \boldsymbol{\theta}_i)$, respectivamente, onde $\boldsymbol{\theta}_1$ e $\boldsymbol{\theta}_i$ são os parâmetros. Supondo que as densidades tem mesmo suporte $I \subset \mathbb{R}$, a (h, ϕ) -divergência entre f_{Z_1} e f_{Z_i} é dada por

$$D_{\phi}^h(Z_1, Z_i) = h \left(\int_{x \in I} \phi \left(\frac{f_{Z_1}(x; \boldsymbol{\theta}_1)}{f_{Z_i}(x; \boldsymbol{\theta}_i)} \right) f_{Z_i}(x; \boldsymbol{\theta}_i) dx \right), \quad (3.2)$$

onde $\phi: (0, \infty) \rightarrow [0, \infty)$ é uma função convexa, $h: (0, \infty) \rightarrow [0, \infty)$ é uma função estritamente

crescente com $h(0) = 0$ e $h'(x) > 0$ para todo $x \in \mathbb{R}_+$, em que I é a união dos suportes das duas densidades (Salicrú et al., 1994).

De acordo com Nascimento et al. (2010), medidas de divergências podem muitas vezes não obedecerem às exigências rigorosas para serem consideradas métricas. Assim, define uma nova medida d_ϕ^h dada por

$$d_\phi^h(Z_1, Z_i) = \frac{D_\phi^h(Z_1, Z_i) + D_\phi^h(Z_i, Z_1)}{2}, \quad (3.3)$$

independentemente da divergência $D_\phi^h(\cdot, \cdot)$ ser simétrica ou não. As versões simétricas das medidas de divergências são chamadas de **distâncias**.

Algumas distâncias conhecidas surgem com escolhas adequadas de h e ϕ . A tabela 3.1 apresenta a seleção das funções h e ϕ que levam as respectivas distâncias listadas.

Tabela 3.1: (h, ϕ) -distância e funções relacionadas a h e ϕ .

(h, ϕ) -distância	$h(y)$	$\phi(x)$
Kullback-Leibler	$y/2$	$(x-1)\log(x)$
Rényni (ordem β)	$\frac{1}{\beta-1} \log[(\beta-1)y+1]$, $0 \leq y < \frac{1}{1-\beta}$	$\frac{x^{1-\beta} + x^\beta - \beta(x-1) - 2}{2(\beta-1)}$, $0 < \beta < 1$
Bhattacharyya	$-\log(-y+1)$, $0 \leq y < 1$	$-\sqrt{x} + \frac{x+1}{2}$
Hellinger	$y/2$, $0 \leq y < 2$	$(\sqrt{x}-1)^2$

Nascimento et al. (2010) deriva várias distâncias para a distribuição \mathcal{G}_I^0 . Com suporte nestes estudos, derivamos para a distribuição $\Gamma(L, L/\lambda)$ as seguintes distâncias: (i) Kullback-Leibler; (ii) Rényi de ordem β ; (iii) Bhattacharyya e; (iv) Hellinger.

Ao considerarmos as variáveis aleatórias Z_1 e Z_i com densidades f_{Z_1} e f_{Z_i} que são caracterizadas pela Equação (2.15), $\theta_1 = (L, \lambda_1)$ e $\theta_i = (L, \lambda_i)$ os respectivos parâmetros, com suporte I , obtemos

Distância Kullback-Leibler:

$$d_{\text{KL}}(Z_1, Z_i) = \frac{1}{2} \int (f_{Z_1} - f_{Z_i}) \log\left(\frac{f_{Z_1}}{f_{Z_i}}\right),$$

que resulta

$$d_{\text{KL}}(Z_1, Z_i) = L \left(\frac{\lambda_1^2 + \lambda_i^2}{2 \lambda_1 \lambda_i} - 1 \right). \quad (3.4)$$

Distância Rényi de ordem β :

$$d_{\text{R}}^\beta(Z_1, Z_i) = \frac{1}{\beta-1} \log \frac{\int f_{Z_1}^\beta f_{Z_i}^{1-\beta} + \int f_{Z_1}^{1-\beta} f_{Z_i}^\beta}{2},$$

que resulta

$$d_R^\beta(Z_1, Z_i) = \frac{L}{2(\beta-1)} \log \frac{\lambda_1 \lambda_i}{(\beta \lambda_i + (1-\beta) \lambda_1) (\beta \lambda_1 + (1-\beta) \lambda_i)}, \quad (3.5)$$

em que $0 < \beta < 1$.

Distância Bhattacharyya:

$$d_B(Z_1, Z_i) = -\log \left(\int \sqrt{f_{Z_1} f_{Z_i}} \right),$$

que resulta

$$d_B(Z_1, Z_i) = \log \left(\frac{(\lambda_1 + \lambda_i)^L}{2^L (\lambda_1 \lambda_i)^{L/2}} \right). \quad (3.6)$$

Distância Hellinger:

$$d_H(Z_1, Z_i) = 1 - \int \sqrt{f_{Z_1} f_{Z_i}},$$

que resulta

$$d_H(Z_1, Z_i) = 1 - \frac{2^L (\lambda_1 \lambda_i)^{L/2}}{(\lambda_1 + \lambda_i)^L}. \quad (3.7)$$

Distâncias podem ser convenientemente dimensionadas para apresentar boas propriedades estatísticas, que as tornam **estatísticas de testes** (Salicrú et al., 1994):

$$S_\phi^h(\hat{\theta}_1, \hat{\theta}_i) = \frac{2mn\kappa}{m+n} d_\phi^h(\hat{\theta}_1, \hat{\theta}_i), \quad (3.8)$$

em que $\hat{\theta}_1^{(m)}$ e $\hat{\theta}_i^{(n)}$ são estimadores por máxima verossimilhança dos parâmetros das distribuições \mathcal{D}_{Z_1} e \mathcal{D}_{Z_i} com base nas amostras de tamanho m e n , respectivamente, e $\kappa = (h'(0)\phi''(1))^{-1}$ uma constante que depende das funções h e ϕ . A tabela 3.2 apresenta a constante κ referente às funções h e ϕ das distâncias utilizadas neste trabalho.

Tabela 3.2: Distâncias e constantes κ .

Distâncias	κ
Kullback-Leibler	1
Rényi (ordem β)	$1/\beta$
Bhattacharyya	4
Hellinger	4

A estatística de teste distribui-se assintoticamente como uma lei qui-quadrado com grau de liberdade M , logo

$$S_\phi^h(\hat{\theta}_1, \hat{\theta}_i) \xrightarrow[m, n \rightarrow \infty]{\mathcal{D}} \chi_M^2,$$

onde $\xrightarrow{\mathcal{D}}$ denota a convergência em distribuição e χ_M^2 é a distribuição chi-quadrado, em que

M a dimensão de $\hat{\theta}_1$.

Proposição 1 Considerando que m e n assumem valores grandes e $S_{\phi}^h(\hat{\theta}_1, \hat{\theta}_i) = s$, então a hipótese nula $\theta_1 = \theta_i$ pode ser rejeitada a um nível de significância η se $\Pr(\chi_M^2 > s) \leq \eta$.

Detalhes podem ser encontrados em [Salicrú et al. \(1994\)](#).

Como estamos usando a mesma amostra para oito testes, nós ajustamos o valor de η pelo método de *Bonferroni*, chamado *Šidák correction*, que é dada por

$$\eta = 1 - (1 - \alpha)^{1/\tau}, \quad (3.9)$$

em que τ é o número de testes e, α o nível de significância para toda séries.

As estatísticas de testes obtidas a partir das Equações (3.4), (3.5), (3.6) e (3.7), respectivamente, são

Teste Kulback-Leibler:

$$S_{\text{KL}} = \frac{mn(\hat{L}_1 + \hat{L}_i)}{m+n} \left(\frac{\hat{\lambda}_1^2 + \hat{\lambda}_i^2}{2\hat{\lambda}_1\hat{\lambda}_i} - 1 \right). \quad (3.10)$$

Teste Rényi de ordem β :

$$S_{\text{R}}^{\beta} = \frac{2mn(\hat{L}_1 + \hat{L}_i)\beta(\beta-1)}{m+n} \log \frac{\hat{\lambda}_1\hat{\lambda}_i}{(\beta\hat{\lambda}_i + (1-\beta)\hat{\lambda}_1)(\beta\hat{\lambda}_1 + (1-\beta)\hat{\lambda}_i)}, \quad (3.11)$$

em que $0 < \beta < 1$. O valor para $\beta = 0.5$ foi utilizado neste trabalho.

Teste Bhattacharyya:

$$S_{\text{B}} = \frac{4mn}{m+n} (\hat{L}_1 + \hat{L}_i) \log \frac{\hat{\lambda}_1 + \hat{\lambda}_i}{2\sqrt{\hat{\lambda}_1\hat{\lambda}_i}}. \quad (3.12)$$

Teste Hellinger:

$$S_{\text{H}} = \frac{8mn}{m+n} \left(1 - \frac{2^{(\hat{L}_1 + \hat{L}_i)/2} (\hat{\lambda}_1\hat{\lambda}_i)^{(\hat{L}_1 + \hat{L}_i)/4}}{(\hat{\lambda}_1 + \hat{\lambda}_i)^{(\hat{L}_1 + \hat{L}_i)/2}} \right). \quad (3.13)$$

Embora todos os testes sejam diferentes, na prática, no cenário proposto, levaram exatamente as mesmas decisões em todas as situações aqui consideradas. Optamos, portanto, trabalhar com o teste baseado na distância Hellinger devida ter menor custo computacional em termos de números de operações. A flexibilidade dos dados é avaliada, assim, permitimos que o número de *looks* possa variar localmente; como em [Anfinson et al. \(2009\)](#).

O procedimento de filtragem consiste em verificar se as regiões podem ser consideradas como provenientes da mesma distribuição que produz os dados do bloco central (veja Figura 3.1). Fazemos uma junção das regiões que não são rejeitadas, sendo utilizada para calcular a média local. Caso todas as regiões sejam rejeitadas, o valor filtrado será atualizado com a média da vizinhança central em trono do pixel filtrado.

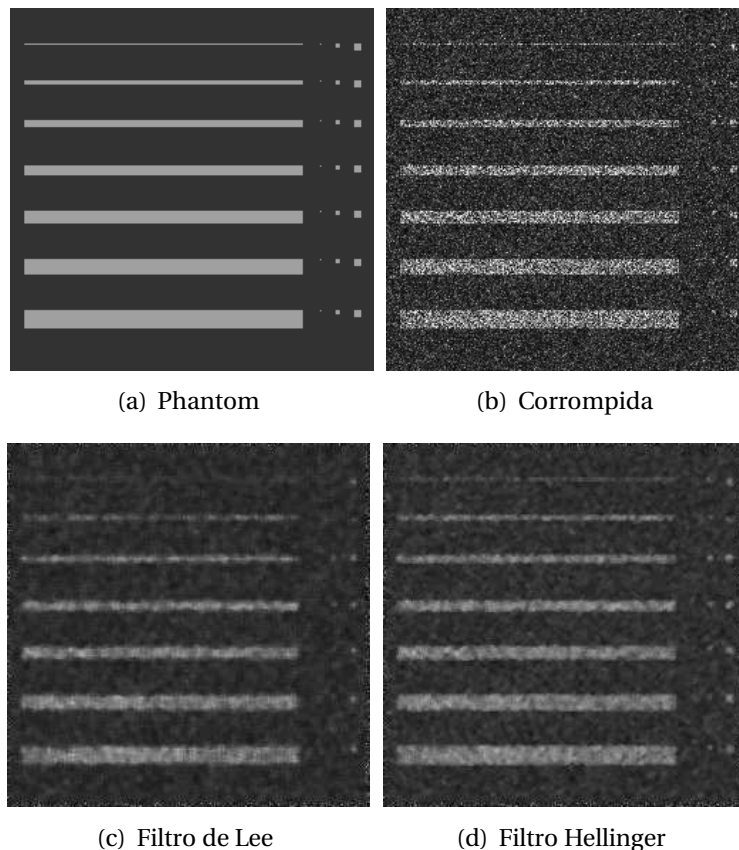
3.2 Avaliação da Qualidade de Imagens SAR

Avaliação da qualidade de imagens é uma tarefa importante para aplicações relacionadas a processamento de imagens. Seu objetivo é fornecer medidas ou métricas quantitativas que possam ser predizíveis sobre a qualidade das imagens avaliadas. Segundo Wang et al. (2002), avaliar a qualidade de imagens em geral e, em particular, o desempenho de um filtro são tarefas difíceis. Por isso, trabalhos como de Wang & Bovik (2002); Moschetti et al. (2006) e Buemi et al. (2011) são analisados e incrementados nesta dissertação.

Os experimentos Monte Carlo discutidos em Moschetti et al. (2006) consistem da simulação de imagens corrompidas com diferentes parâmetros. Cada imagem simulada foi submetida aos filtros, e medidas de qualidades são calculadas em cada processo de filtragem. A qualidade do filtro com relação a cada métrica pode ser avaliada com análise dos dados gerados das várias simulações, e não somente de uma simples imagem.

Nós usamos a imagem Phantom (veja Figura 3.3(a)) que consiste em tiras e pontos de luz em um fundo (*background*) homogêneo, e corrompê-la com ruído *speckle* (veja Figura 3.3(b)). Utilizamos as seguintes métricas nas versões filtradas (por exemplo, vejam as Figuras 3.3(c) e 3.3(d)):

Figura 3.2: Imagem Phantom, dados *speckle* e versões filtradas.



Número equivalente de *looks*: É aplicado em imagens de intensidade em áreas homogêneas. Pode ser estimado por $NEL = (\bar{z}/\hat{\sigma}_z)^2$, o que vale dizer, o quadrado da recíproca do coeficiente da variação. Neste caso, quanto maior o valor do NEL, melhor.

Contraste da linha: A preservação da largura da linha (observe a Figura 3.3(a)) será avaliada calculando três médias: nas coordenadas da linha original (x_ℓ) e duas linhas em torno dela (x_{ℓ_1} e x_{ℓ_2}). O contraste é definido como $2x_\ell - (x_{\ell_1} + x_{\ell_2})$, e comparado entre a Phantom e a imagem filtrada. Os melhores resultados são os menores.

Preservação das bordas: É mensurado em dois aspectos: pela média do gradiente da borda (a diferença absoluta das médias das linhas em torno das bordas); e pela variância (o mesmo que o anterior, mas utilizando os desvios padrões em vez das médias). Os melhores valores são os menores.

Índice Q: O índice universal de qualidade de imagem, ou simplesmente índice Q, foi proposto por Wang & Bovik (2002) e leva em consideração três fatores: (i) perda de correlação; (ii) distorção de brilho e; (iii) distorção de contraste. O índice Q é dado por

$$Q = \frac{s_{xy}}{s_x s_y} \frac{2\bar{x}\bar{y}}{\bar{x}^2 + \bar{y}^2} \frac{2s_x s_y}{s_x^2 + s_y^2}, \quad (3.14)$$

em que s_x^2 e \bar{x} denotam a variância e a média, respectivamente. O *range* de Q é $[-1,1]$, sendo 1 o melhor valor. Detalhes podem ser encontrados em Wang & Bovik (2002).

Índice β_ρ : É uma medida de correlação entre bordas das imagens X e Y, dada por

$$\beta_\rho = \frac{\sum_{j=1}^n (x_j - \bar{x})(y_j - \bar{y})}{\sqrt{\sum_{j=1}^n (x_j - \bar{x})^2 \sum_{j=1}^n (y_j - \bar{y})^2}}, \quad (3.15)$$

em que \bullet_j e $\bar{\bullet}$ denotam os valores do gradiente do j -ésimo pixel e as médias das imagens $\nabla^2 X$ e $\nabla^2 Y$, respectivamente. O *range* do índice β_ρ é $[-1,1]$, sendo 1 a correlação perfeita.

Nem todas as medidas de qualidade apresentadas anteriormente podem ser aplicadas a dados reais, a menos que possua o valor real do *backscatter*. Por esta razão, as seguintes métricas, além de serem aplicadas a dados simulados, devem ser utilizadas em dados reais (Baxter & Seibert, 1998), onde a menor medida é a melhor (todas são medidas de erro):

Erro Absoluto Médio:

$$MAE = \frac{1}{n} \sum_{j=1}^n |x_j - y_j|. \quad (3.16)$$

Erro Quadrático Médio:

$$MSE = \frac{1}{n} \sum_{j=1}^n (x_j - y_j)^2. \quad (3.17)$$

Erro Quadrático Médio Normalizado:

$$\text{NMSE} = \frac{\sum_{j=1}^n (x_j - y_j)^2}{\sum_{j=1}^n x_j^2}. \quad (3.18)$$

Distorção de Contraste:

$$\text{DCON} = \frac{1}{n} \sum_{j=1}^n \frac{|x_j - y_j|}{v + x_j + y_j}, \quad (3.19)$$

em que v depende da relação entre a luminância e nível de cinza do *display*. A utilização do valor $v = 23/255$ para esta métrica é sugerida por Baxter & Seibert (1998).

3.3 Algoritmo para Filtragem de *Speckle*

O Algoritmo 3.1 apresenta, de forma sucinta, os passos para filtragem de *speckle* utilizando distâncias estocásticas.

Algoritmo 3.1 Filtragem de *Speckle* baseado de Distâncias Estocásticas

Require: *Img* SAR de intensidade homogênea; filtragem de ordem w ; nível de significância α ;

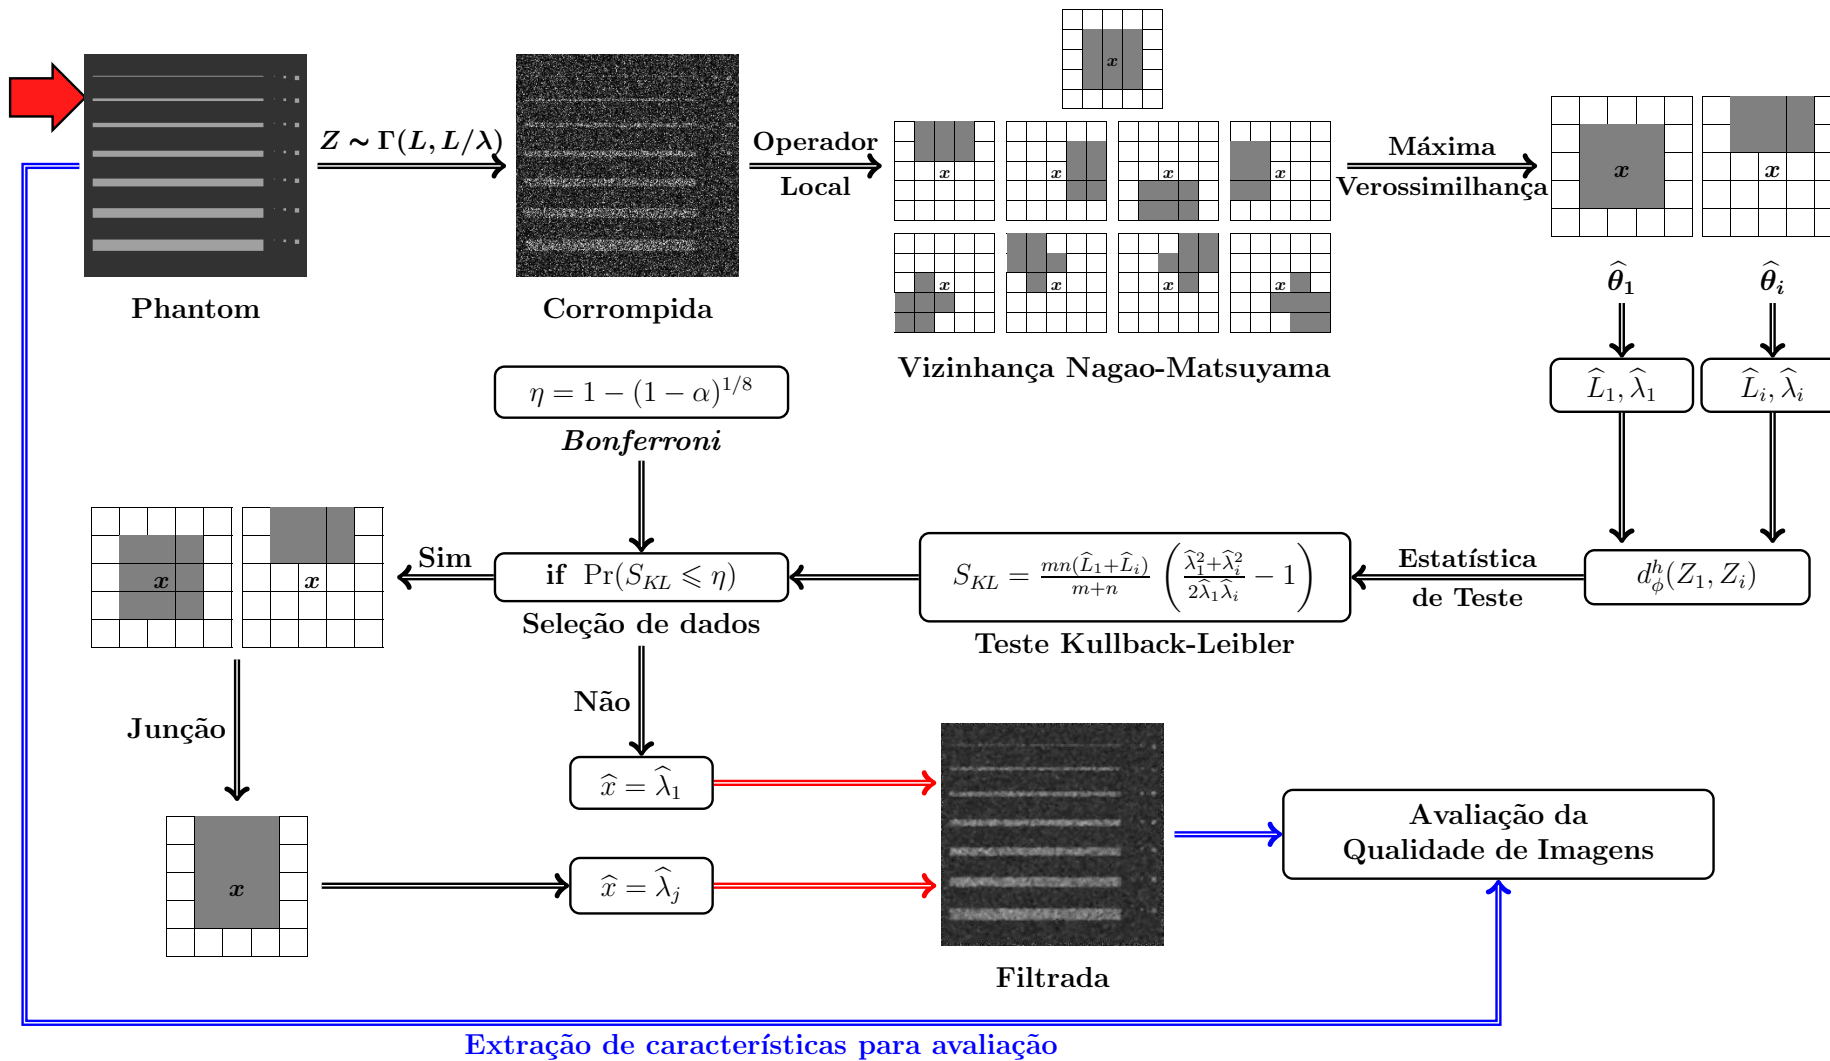
```

1: function FILTRAGEMSPECKLE(Img,  $w$ ,  $\alpha$ )
2:   regiao  $\leftarrow$  0
3:   for cada pixel  $((x,y), \text{Img}(x,y))$  do
4:     Obtêm-se vizinhança em janela  $w \times w$  por Nagao-Matsuyama
5:     Estima-se os parâmetros  $(\hat{\theta}_1, \dots, \hat{\theta}_9)$ 
6:     Calcula-se  $S_{\phi}^h(\hat{\theta}_1, \hat{\theta}_i)$ , para  $i = \{2, \dots, 9\}$ 
7:     Ajusta o nível de significância,  $\eta \leftarrow (1 - (1 - \alpha)^{1/8})$ 
8:     if  $(S_{\phi}^h(\hat{\theta}_1, \hat{\theta}_i) < \eta)$  then
9:       Seleciona região  $\hat{\theta}_i$  e mescla em dados_selecionados
10:    end if
11:    if  $(\text{dados\_selecionados} == \emptyset)$  then
12:      Seleciona somente a região  $\hat{\theta}_1$  em dados_selecionados
13:    end if
14:    ImgOut( $x,y$ )  $\leftarrow$  mean(dados_selecionados)
15:  end for
16:  return ImgOut
17: end function

```

A Figura 3.3 mostra a metodologia adotada para avaliação da técnica proposta em experimentos Monte Carlo. Os resultados do algoritmo de filtragem são avaliados por métricas de redução do ruído e de preservação de bordas descritas anteriormente.

Figura 3.3: Diagrama em blocos para avaliação da técnica proposta.



O presente capítulo tratou os materiais e métodos que foram utilizados para aferir a nova abordagem em filtragem de *speckle*. A seguir, no quarto capítulo, apresentaremos os resultados e análises dos experimentos.

4

RESULTADOS E ANÁLISES

UMA VEZ que estamos com a modelagem concluída e os dados para simulação, há necessidade da realização de experimentos para validação da proposta e metodologia adotada. Para obtenção dos resultados apresentados utilizamos a plataforma R no *cluster* do Laboratório de Computação Científica e Visualização da Universidade Federal de Alagoas (LCCV/UFAL) em processamento CPU: Core 2 Duo - Intel, 1GB de Ram, HD 80GB, sistema operacional Linux com distribuição Fedora.

4.1 *Interquartile Range*

Um conceito importante que devemos elencar para uma boa interação e análise dos dados simulados é o *interquartile range* (IQR). Os valores que dividem cada parte do IQR são chamados de primeiro, segundo, e terceiro *quartis*, e eles são denotados por Q1, Q2 e Q3, respectivamente. O IQR é uma medida de dispersão estatística, que é definida pela diferença do terceiro e primeiro *quartis*, dado por

$$\text{IQR} = Q3 - Q1, \quad (4.1)$$

e o Q2 é definido pelo valor da mediana no conjunto, que é correspondente a tendência central.


O IQR é usado para construir *boxplots*, que são simples representações gráficas de uma distribuição de probabilidade. Os limites superior e inferior de um *boxplot* são definidos por

$$\ell_3 = Q3 + 1.5 \text{ IQR} \quad \text{e} \quad \ell_1 = Q1 - 1.5 \text{ IQR}, \quad (4.2)$$

respectivamente. Os *outliers* serão os valores que estão fora destes limiares.

A Figura 4.1 apresenta um exemplo de *boxplot* com uma variação de *interquartil* de uma função densidade de probabilidade (f.d.p.) de uma Normal $N(0, \sigma^2)$.

Figura 4.1: *Boxplot* (com uma variação *interquartil*) de uma f.d.p. $N(0, \sigma^2)$.



4.2 Dados Simulados

A proposta foi comparada com o filtro de Lee (1986), que é considerado um padrão. Todos os filtros foram aplicados a uma e cinco iterações para cada série de testes. Os resultados obtidos foram sumarizados pela média dos *boxplots*. Cada *boxplot* apresenta os resultados de um filtro aplicado em 100 imagens geradas por amostras independentes da distribuição $\Gamma(L, L/\lambda)$ com diferentes parâmetros, mostrados na tabela 4.1. Esses parâmetros descrevem situações normalmente encontradas em análise de imagens SAR de intensidade homogênea. O nível de significância α também foi avaliado e testes foram realizados para 80%, 90% e 99% em janelas 5×5 e 7×7 .

Tabela 4.1: Situações simuladas com distribuição $\Gamma(L, L/\lambda)$.

Situação ID	L	λ	<i>Background</i>
#1	1	200	70
#2	3	195	55
#3	5	150	30
#4	7	170	35

A Figura 4.2 mostra seis medidas em um nível de iteração — número equivalente de *looks*, contraste da linha, média e variância da borda e os índices Q e β_p — correspondentes a quatro filtros em janela de ordem 5. Os filtros são identificados no eixo vertical ('L' para Lee e 'H' para Hellinger), cada situação ID é separada por uma linha tracejada (de #1 a #4, veja

tabela 4.1) e, também, pelo nível de significância α (80, 90 e 99 para 'H').

A Figura 4.3 mostra quatro medidas numéricas em um nível de iteração — Erro Absoluto Médio (MAE), Erro Quadrático Médio (MSE), Erro Quadrático Médio Normalizado (NMSE) e Distorção de Contraste (DCON) — correspondentes a quatro filtros em janela de ordem 5 e possui mesma configuração no eixo vertical da Figura 4.2.

O Filtro de Lee aplicado sobre janela de ordem 5 com 1-iteração só apresenta melhores resultados que a nossa proposta nas situações #1 e #2 da variância da borda e, no índice β_ρ em todas as situações (Figuras 4.3(d) e 4.3(f)) e o número equivalente de *looks* NEL (Figura 4.3(a)). O filtro com base em distâncias estocásticas, em mesma configuração, supera sistematicamente o filtro de Lee em relação a todos os outros critérios, a saber, contraste da linha (Figura 4.3(b)), média da borda (Figura 4.3(c)) e, o índice universal de qualidade de imagens (Figura 4.3(e)). Podemos observar também, que a proposta supera Lee em todas as medidas de erro avaliadas na Figura 4.3.


As Figuras 4.4 e 4.5 apresentam as métricas e medidas de erros aplicados aos quatro filtros sobre janela de ordem 7 com 1-iteração. Lee e o filtro proposto tiveram mesmo comportamento no processo de filtragem de ordem 5 como mesma configuração, como apresentado nas Figuras 4.2 e 4.3.

As Figuras 4.7(c) e 4.7(d) (Figuras 4.7(e) e 4.7(f), respectivamente) mostram dados simulados para 3-*looks* (5-*looks*, resp.) e sua imagem ampliada. Para cada coluna da Figura 4.6 apresentamos a imagem corrompida e as versões filtradas em janelas 5×5 com 1-iteração. Figuras 4.7(g) e 4.7(h) (Figuras 4.7(i) e 4.7(j), resp.) foram filtradas por Lee. Enquanto, que as Figuras 4.7(k) e 4.7(l) (Figuras 4.7(m) e 4.7(n), resp.) utilizamos o filtro baseado em distâncias estocásticas com nível de significância $\alpha = 99\%$.


As Figuras 4.7(h) e 4.7(l) (Figuras 4.7(j) e 4.7(n), resp.) apresentam os detalhes da redução do *speckle*, para Lee e Hellinger, em relação a Figura 4.7(d). Podemos notar, nas imagens ampliadas, que o filtro proposto reduz o *speckle* e preserva linhas e estruturas da imagem. Enquanto que a técnica de Lee combate o ruído, mas destrói algumas das características e melhor observadas na Figura 4.7(j) com relação a nossa proposta (Figura 4.7(n)) onde: a primeira linha com um pixel de largura foi perdida, enquanto nossa proposta a preserva; o mesmo acontece com os pontos de luz mais a direita em todas as versões filtradas.

As Figuras 4.7 e 4.8 apresentam todas medidas de qualidade aplicadas aos quatro filtros e situações em janelas de ordem 5 com 5-iterações. Comparando estas figuras as Figura 4.2 e 4.3, que apresentaram dados mensurados com mesma configuração, mas em 1-iterações, notamos um ganho da nossa proposta quanto a variância da borda, onde antes Lee era melhor. Lee apresenta ser bem consistente quando falamos do índice β_ρ , que mesmo aumen-


Figura 4.2: Métricas dos quatro filtros e situações em janela 5 × 5 com 1-iteração.




(a) Número Equivalente de Looks




(b) Contraste da Linha




(c) Média da Borda



(d) Variância da Borda



(e) Índice Q



(f) Índice β_ρ

Figura 4.3: Medidas de erros dos filtros e situações em janela 5 × 5 com 1-iteração.




Figura 4.4: Métricas dos quatro filtros e situações em janela 7 × 7 com 1-iteração.

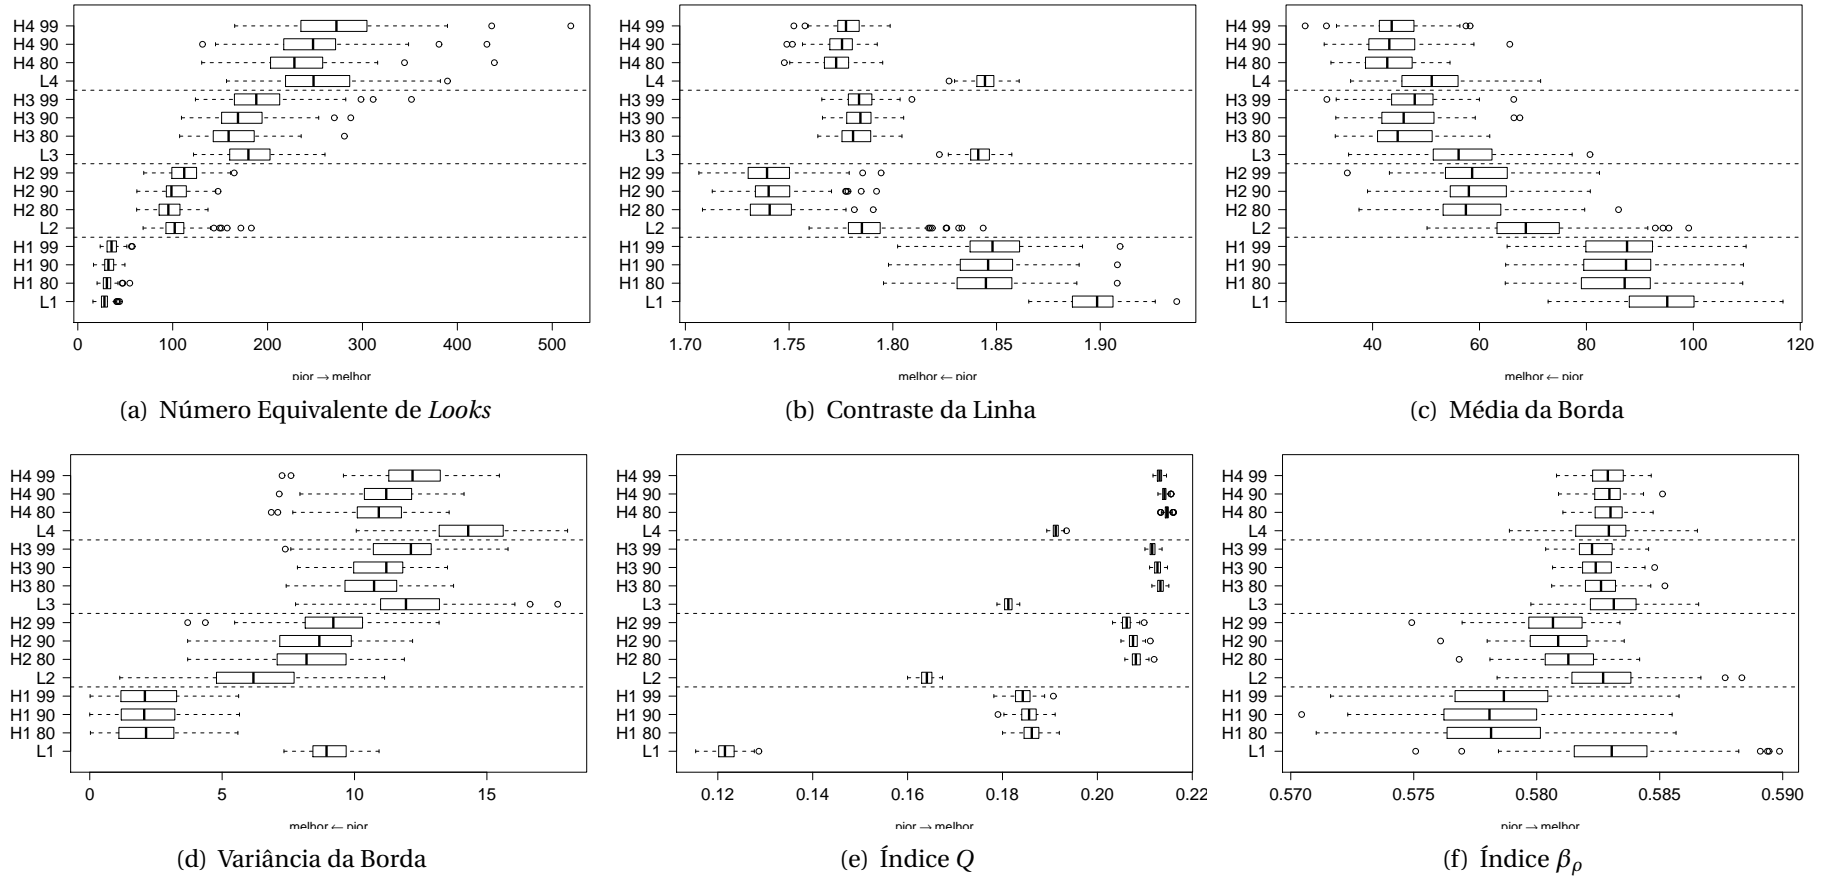
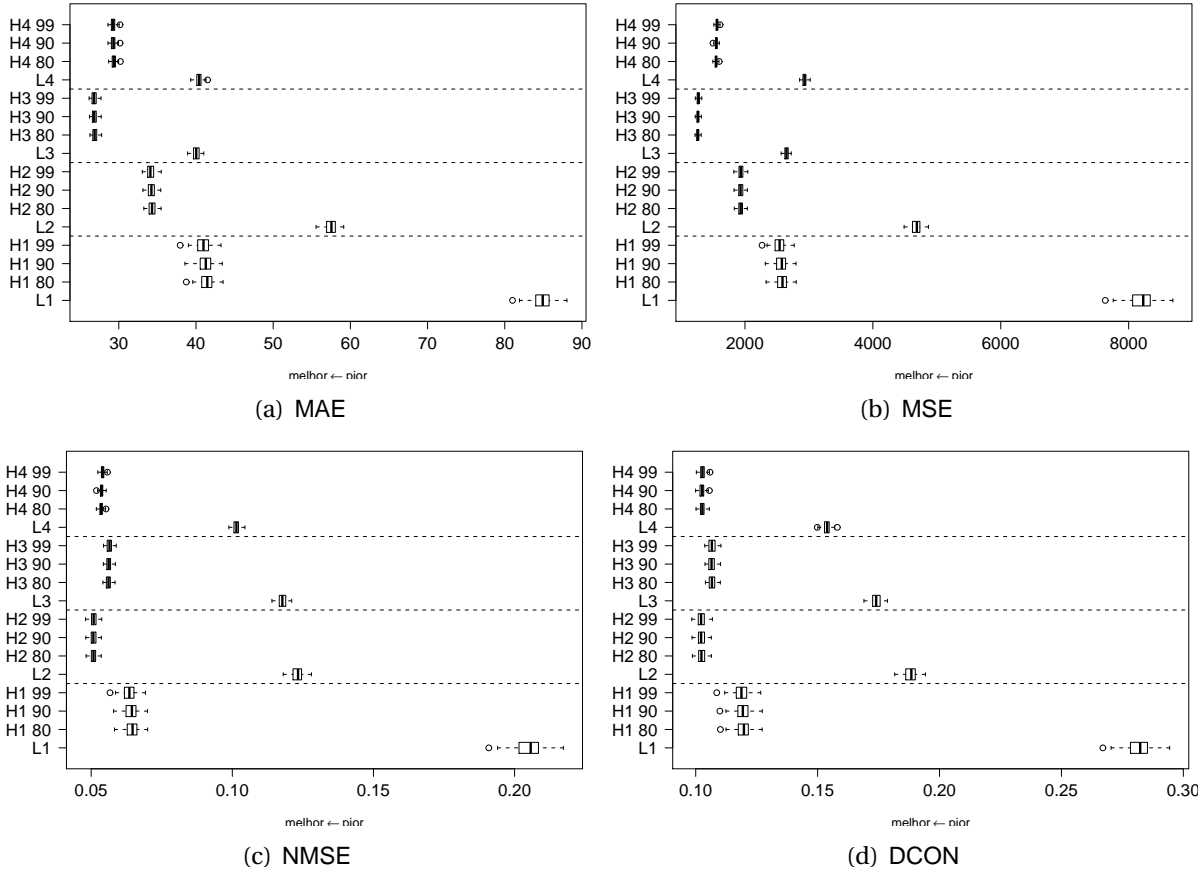


Figura 4.5: Medidas de erros dos filtros e situações em janela 7 × 7 com 1-iteração.



tando o número de iterações, no processo de filtragem, ele continua estável. Contudo, a diferença entre os valores do índice β_ρ com nossa proposta é relativamente pequena.

As Figuras 4.9 e 4.10 apresentam as métricas aplicadas aos quatro filtros e situações em janelas de ordem 7 com 5-iterações. Lee somente é melhor no índice β_ρ e nas demais métricas a proposta é bem consistente e com baixa variabilidade dos dados em relação a Lee.

As tabelas 4.2, 4.3, 4.4 e 4.5 mostram a sumarização da média dos *boxplots* (Figuras 4.2 a 4.5 e 4.7 a 4.10, resp.). Observe os índices (variância da borda e índice β_ρ) onde Lee é superior notamos que a diferença é relativamente pequena (máximo de 3 centésimos).

4.3 Dados SAR Reais

A Figura 4.12(a) apresenta uma imagem real e as versões filtradas em 1-iteração — Lee (Figuras 4.12(b) e 4.12(c)) e Hellinger (Figuras 4.12(d) e 4.12(e))—, com $\alpha = 99\%$ o nível de significância. A imagem original foi obtida pelo sensor E-SAR na Banda L (polarização HH) com 2.2×3.0 m de resolução do solo em 4-looks. Nascimento et al. (2010) analisada esta imagem, e o número equivalente de looks em áreas homogêneas é sempre inferior a três.

Chamo atenção para a área do canto superior direito da Figura 4.12(a) em relação as versões filtradas, notamos que: (i) apesar de combater o ruído, a textura é comprometida na abordagem realizada por Lee, principalmente, no uso da janela de ordem 7 (Figura 4.12(c)), onde a região fica ‘borrada’; (ii) já na abordagem proposta, além de suavizar o ruído, as características da região é mantida, com melhores resultados na filtragem de janela de ordem 5.

A tabela 4.6 apresenta uma avaliação numérica dos filtros aplicados e, notamos que o Filtro Hellinger de ordem 5 com $\alpha = 80\%$ obteve melhores resultados em todas as métricas. Assim, torna-se válida a avaliação subjetiva sobre as imagens filtradas.

A Figura 4.12 apresenta versões filtradas da Figura 4.13(a), nossa proposta foi aplicada variando α e #-iterações. Notamos que quanto maior o nível de significância e o #-iterações a imagem desfoca mais, contudo, a redução do *speckle* é visível. Em uma análise subjetiva, neste caso, o filtro proposto tem melhor atuação quando $\alpha = 90\%$ com 3-iterações. Na prática, combate o ruído, preserva bordas e textura, e realça o contraste da imagem.

Esse capítulo apresentou as principais abordagens para aferir a proposta apresentada. Dando ênfase em medidas quantitativas para avaliar a qualidade de imagens aplicadas aos dados SAR. Finalizamos com o próximo capítulo, onde serão relatados os principais impactos e contribuições deste trabalho e os passos futuros.

Figura 4.6: Phantom, dados SAR simulados (3 e 5-looks) e imagens filtradas.

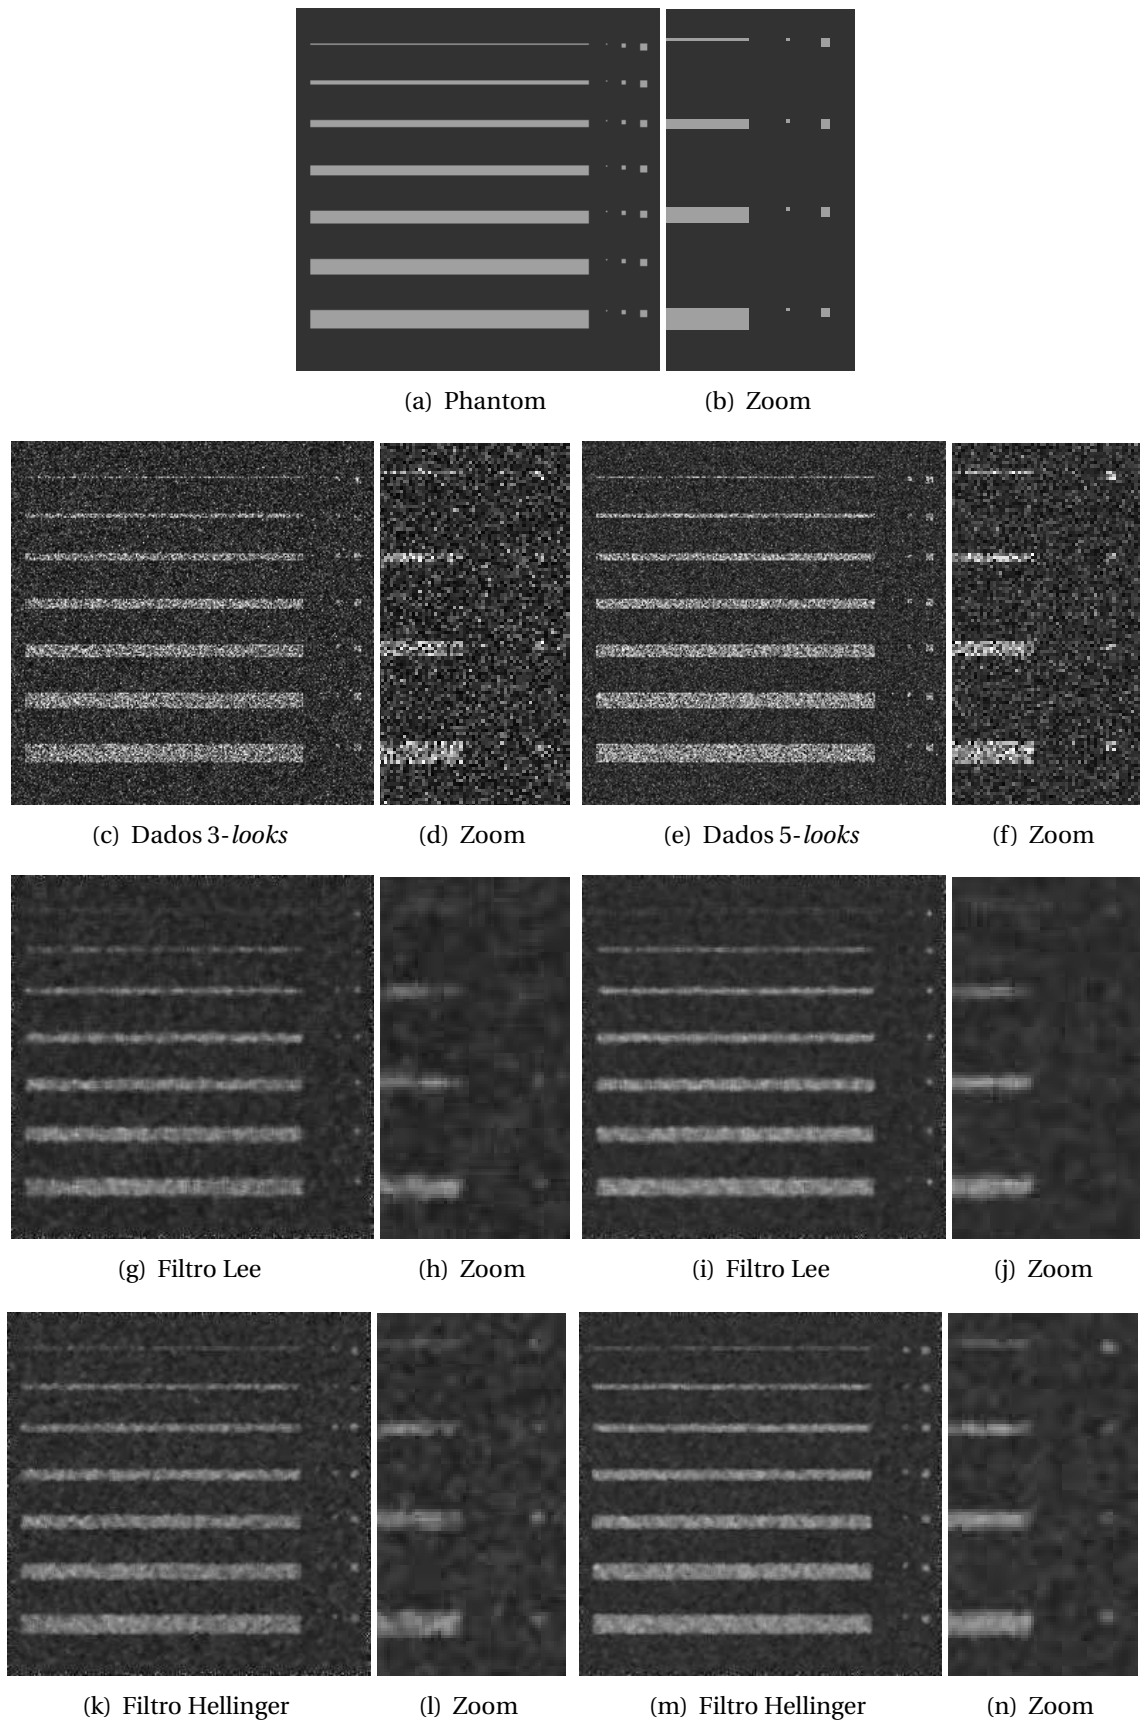


Figura 4.7: Métricas dos quatros filtros e situações em janela 5 × 5 com 5-iterações.

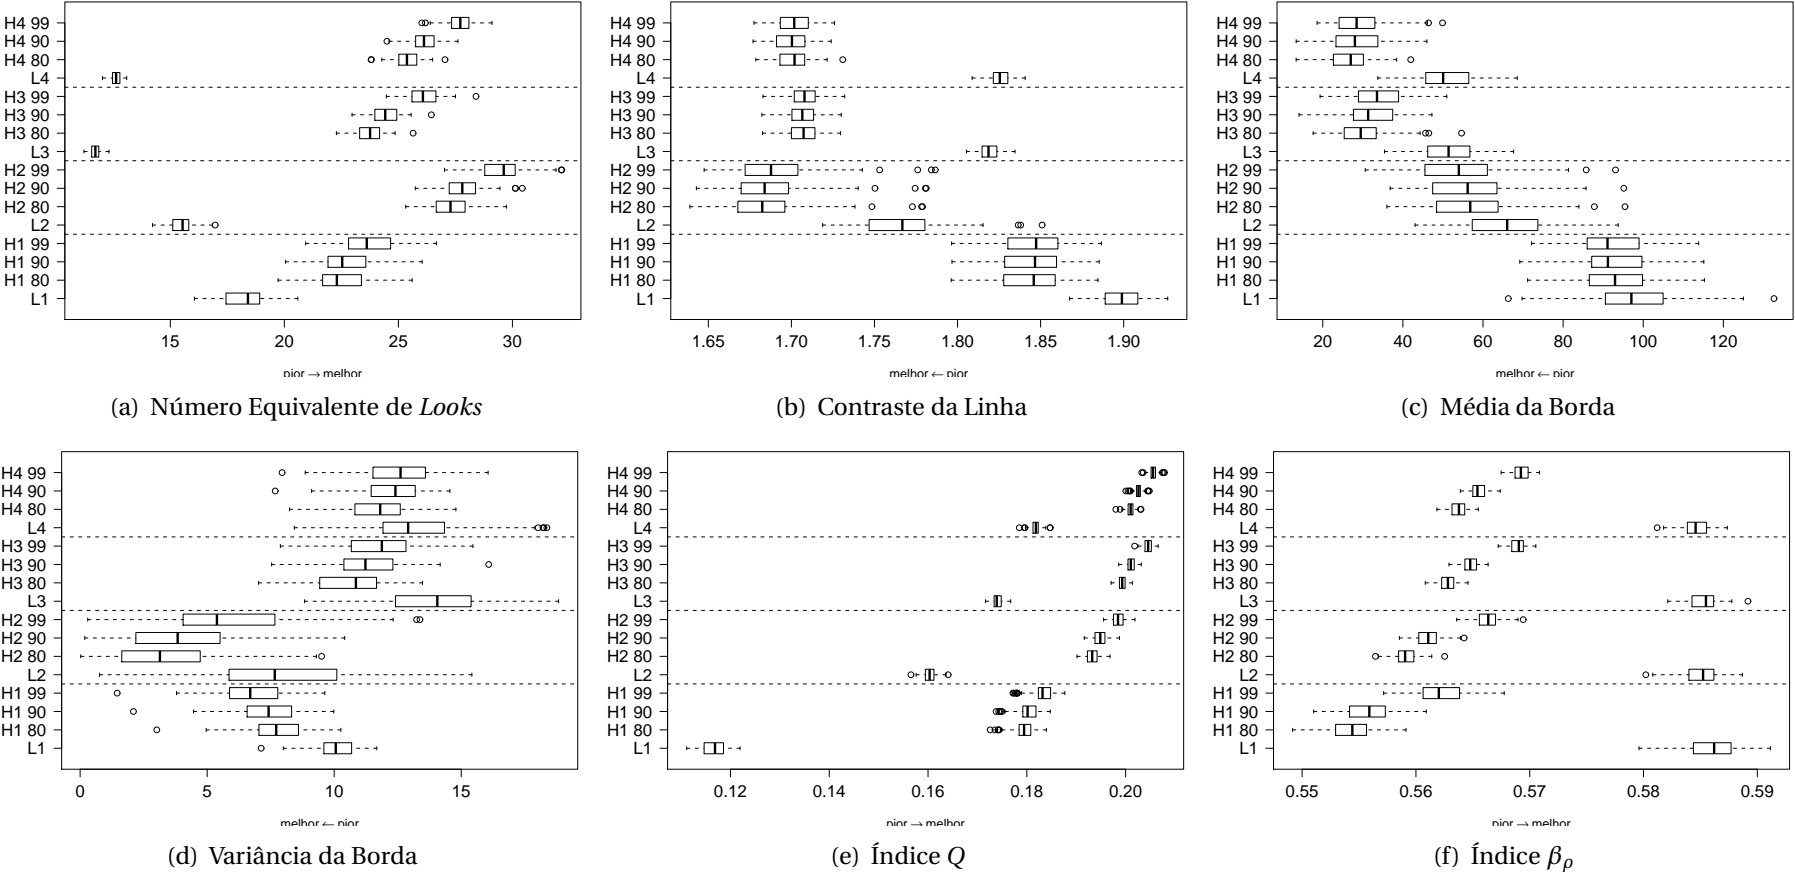


Figura 4.8: Medidas de erros dos filtros e situações em janela 5 × 5 com 5-iterações.







Figura 4.9: Métricas dos quatros filtros e situações em janela 7 × 7 com 5-iterações.




(a) Número Equivalente de Looks




(b) Contraste da Linha




(c) Média da Borda



(d) Variância da Borda



(e) Índice Q



(f) Índice β_ρ

Figura 4.10: Medidas de erros dos filtros e situações em janela 7×7 com 5-iterações.




Tabela 4.2: Estatísticas das métricas de imagens simuladas em janela 5×5 com 1-iteração.

Filtro <i>Speckle</i>	Métricas SAR				Índice Q		Índice β_ρ		Medidas Numéricas			
	NEL	Cont. Linha	Média Borda	Var. Borda	\bar{Q}	s_Q	$\bar{\beta}_\rho$	s_{β_ρ}	MAE	MSE	NMSE	DCON
Lee#1	14.908	1.888	88.876	3.355	0.147	0.003	0.584	0.003	77.219	7274.607	0.182	0.254
H#1 80	11.738	1.826	74.635	4.511	0.189	0.002	0.574	0.004	50.776	3900.473	0.098	0.143
H#1 90	12.416	1.828	74.271	4.314	0.190	0.002	0.576	0.004	49.950	3775.292	0.094	0.142
H#1 99	14.109	1.834	74.201	4.476	0.191	0.002	0.580	0.003	48.282	3531.431	0.088	0.138
Lee#2	50.727	1.798	63.393	5.314	0.198	0.002	0.583	0.002	49.324	3656.613	0.096	0.157
H#2 80	35.415	1.756	54.521	6.197	0.235	0.001	0.573	0.002	34.257	1888.969	0.050	0.098
H#2 90	38.104	1.757	54.224	6.558	0.235	0.001	0.574	0.002	33.647	1836.351	0.048	0.097
H#2 99	43.777	1.759	53.557	7.264	0.235	0.001	0.578	0.002	32.553	1739.498	0.046	0.094
Lee#3	90.768	1.851	53.673	8.479	0.218	0.001	0.583	0.001	33.048	1899.533	0.084	0.138
H#3 80	62.753	1.770	41.421	6.017	0.247	0.001	0.573	0.001	23.805	979.311	0.044	0.090
H#3 90	67.430	1.771	41.582	6.431	0.248	0.001	0.574	0.001	23.309	946.947	0.042	0.088
H#3 99	77.965	1.772	40.278	7.497	0.249	0.001	0.578	0.001	22.487	889.359	0.040	0.085
Lee#4	127.803	1.850	47.125	9.336	0.229	0.001	0.583	0.001	32.591	1987.863	0.069	0.118
H#4 80	87.5180	1.752	36.948	5.914	0.251	0.001	0.573	0.001	24.796	1108.108	0.038	0.083
H#4 90	92.8070	1.753	37.045	6.333	0.251	0.001	0.574	0.001	24.280	1071.062	0.037	0.081
H#4 99	107.816	1.755	37.838	7.440	0.253	0.001	0.578	0.001	23.444	1004.681	0.035	0.078

Tabela 4.3: Estatísticas das métricas de imagens simuladas em janela 7×7 com 1-iteração.

Filtro <i>Speckle</i>	Métricas SAR				Índice Q		Índice β_ρ		Medidas Numéricas			
	NEL	Cont. Linha	Média Borda	Var. Borda	\bar{Q}	s_Q	$\bar{\beta}_\rho$	s_{β_ρ}	MAE	MSE	NMSE	DCON
Lee#1	28.577	1.897	94.197	9.019	0.122	0.003	0.583	0.003	84.786	8203.312	0.205	0.282
H#1 80	31.417	1.844	85.685	2.269	0.186	0.002	0.578	0.003	41.412	2583.907	0.065	0.119
H#1 90	32.705	1.846	85.846	2.275	0.186	0.002	0.578	0.003	41.248	2570.779	0.064	0.119
H#1 99	36.102	1.848	86.200	2.311	0.184	0.002	0.579	0.003	40.917	2540.257	0.064	0.119
Lee#2	104.546	1.789	69.531	6.198	0.164	0.002	0.583	0.002	57.489	4685.225	0.123	0.188
H#2 80	96.8150	1.742	58.609	8.262	0.208	0.001	0.581	0.001	34.336	1932.055	0.051	0.102
H#2 90	102.638	1.742	59.385	8.544	0.208	0.001	0.581	0.001	34.246	1933.219	0.051	0.102
H#2 99	114.135	1.742	59.693	9.133	0.206	0.001	0.581	0.001	34.160	1936.862	0.051	0.102
Lee#3	182.451	1.842	56.885	12.002	0.181	0.001	0.583	0.001	40.040	2649.134	0.118	0.174
H#3 80	163.889	1.782	45.867	10.612	0.213	0.001	0.583	0.001	26.885	1262.457	0.056	0.107
H#3 90	174.487	1.784	46.691	10.954	0.213	0.001	0.582	0.001	26.826	1265.342	0.056	0.107
H#3 99	193.172	1.785	47.662	11.791	0.212	0.001	0.582	0.001	26.803	1271.508	0.057	0.107
Lee#4	257.415	1.845	51.047	14.441	0.191	0.001	0.583	0.001	40.388	2931.499	0.101	0.154
H#4 80	231.528	1.772	43.320	10.816	0.215	0.001	0.583	0.001	29.362	1547.671	0.054	0.103
H#4 90	247.535	1.775	43.658	11.176	0.214	0.001	0.583	0.001	29.292	1552.110	0.054	0.103
H#4 99	272.908	1.778	44.060	12.226	0.213	0.001	0.583	0.001	29.278	1561.900	0.054	0.103

Tabela 4.4: Estatísticas das métricas de imagens simuladas em janela 5×5 com 5-iterações.

Filtro <i>Speckle</i>	Métricas SAR				Índice Q		Índice β_ρ		Medidas Numéricas			
	NEL	Cont. Linha	Média Borda	Var. Borda	\bar{Q}	s_Q	$\bar{\beta}_\rho$	s_{β_ρ}	MAE	MSE	NMSE	DCON
Lee#1	72.992	1.899	97.234	10.084	0.117	0.003	0.586	0.002	89.355	8659.023	0.216	0.297
H#1 80	90.128	1.845	93.096	7.721	0.179	0.002	0.554	0.002	41.368	2554.209	0.064	0.122
H#1 90	91.076	1.845	92.807	7.439	0.180	0.002	0.556	0.002	41.262	2543.672	0.064	0.122
H#1 99	94.980	1.847	91.934	6.712	0.183	0.002	0.562	0.002	40.444	2457.441	0.061	0.119
Lee#2	61.952	1.766	66.018	7.911	0.160	0.001	0.585	0.002	60.685	4841.661	0.127	0.198
H#2 80	109.108	1.686	57.125	3.319	0.193	0.001	0.559	0.001	37.398	2230.008	0.059	0.114
H#2 90	111.232	1.687	56.296	4.037	0.195	0.001	0.561	0.001	36.977	2188.138	0.058	0.113
H#2 99	117.992	1.692	54.159	5.839	0.198	0.001	0.566	0.001	35.788	2067.885	0.054	0.109
Lee#3	46.94	1.819	51.262	13.916	0.174	0.001	0.585	0.001	43.270	2835.73	0.126	0.188
H#3 80	94.888	1.708	29.658	10.679	0.199	0.001	0.563	0.001	30.109	1483.123	0.066	0.121
H#3 90	97.644	1.708	32.124	11.306	0.201	0.001	0.565	0.001	29.582	1440.651	0.064	0.119
H#3 99	104.420	1.708	34.011	11.768	0.205	0.001	0.569	0.001	28.304	1341.679	0.060	0.113
Lee#4	50.520	1.826	50.830	13.194	0.182	0.001	0.585	0.001	44.356	3206.674	0.111	0.169
H#4 80	101.584	1.701	26.744	11.719	0.201	0.001	0.564	0.001	33.340	1823.295	0.063	0.118
H#4 90	104.584	1.700	28.390	12.236	0.203	0.001	0.566	0.001	32.729	1769.125	0.061	0.116
H#4 99	110.808	1.702	29.074	12.559	0.206	0.001	0.569	0.001	31.349	1654.907	0.057	0.110

Tabela 4.5: Estatísticas das métricas de imagens simuladas em janela 7×7 com 5-iterações.

Filtro <i>Speckle</i>	Métricas SAR				Índice Q		Índice β_ρ		Medidas Numéricas			
	NEL	Cont. Linha	Média Borda	Var. Borda	\bar{Q}	s_Q	$\bar{\beta}_\rho$	s_{β_ρ}	MAE	MSE	NMSE	DCON
Lee#1	107.650	1.909	97.168	12.333	0.086	0.002	0.584	0.002	98.734	10228.631	0.256	0.335
H#1 80	143.660	1.868	95.523	11.685	0.131	0.002	0.573	0.002	50.371	3293.797	0.082	0.152
H#1 90	144.965	1.868	95.546	11.688	0.130	0.002	0.573	0.002	50.619	3321.239	0.083	0.152
H#1 99	145.990	1.868	95.632	11.663	0.129	0.002	0.573	0.001	50.816	3346.056	0.084	0.153
Lee#2	71.870	1.782	75.892	4.586	0.130	0.001	0.584	0.002	71.601	6188.136	0.163	0.239
H#2 80	135.215	1.725	79.096	4.495	0.136	0.001	0.574	0.001	51.994	3459.593	0.091	0.162
H#2 90	137.872	1.726	79.204	4.464	0.136	0.001	0.574	0.001	52.125	3476.759	0.091	0.163
H#2 99	139.576	1.727	79.343	4.404	0.135	0.001	0.575	0.001	52.381	3509.352	0.092	0.164
Lee#3	52.215	1.811	54.193	22.543	0.151	0.001	0.584	0.001	51.377	3571.653	0.159	0.227
H#3 80	105.160	1.735	53.341	8.567	0.139	0.001	0.575	0.001	43.471	2429.700	0.108	0.180
H#3 90	108.881	1.736	53.518	8.736	0.139	0.001	0.575	0.001	43.545	2439.268	0.108	0.180
H#3 99	111.529	1.736	53.763	9.053	0.138	0.001	0.576	0.001	43.804	2468.557	0.110	0.182
Lee#4	55.610	1.818	46.855	22.743	0.160	0.001	0.584	0.001	53.018	4041.755	0.140	0.205
H#4 80	109.480	1.734	42.949	12.598	0.140	0.001	0.575	0.001	48.914	3062.634	0.106	0.178
H#4 90	112.714	1.735	43.122	12.870	0.139	0.001	0.575	0.001	48.973	3073.383	0.106	0.178
H#4 99	115.269	1.735	43.579	13.374	0.138	0.001	0.576	0.001	49.282	3114.306	0.108	0.180

Figura 4.11: Dados SAR reais e imagens filtradas em 1-iteração.



(a) Dados SAR



(b) Filtro de Lee 5×5



(c) Filtro de Lee 7×7




(d) Filtro Hellinger 5×5




(e) Filtro Hellinger 7×7

Tabela 4.6: Estatísticas das métricas de qualidade em imagem SAR real.


α	Speckle Filtro	Medidas de Qualidade				Índice Q	
		MAE	MSE	NMSE	DCON	\bar{Q}	s_Q
	Lee_w5	0.126	0.029	0.087	0.164	0.330	0.175
	Lee_w7	0.142	0.036	0.107	0.181	0.177	0.165
80%	H_w5	0.117	0.025	0.076	0.155	0.486	0.170
	H_w7	0.141	0.035	0.104	0.180	0.265	0.187
90%	H_w5	0.120	0.026	0.080	0.159	0.453	0.176
	H_w7	0.142	0.035	0.106	0.182	0.250	0.189
99%	H_w5	0.127	0.029	0.085	0.166	0.397	0.180
	H_w7	0.145	0.036	0.109	0.185	0.222	0.189

Figura 4.12: Imagens filtradas em janela 5×5 com variação de α e #-interações.


(a) Dados SAR




(b) H 99 #1




(c) H 99 #3




(d) H 99 #5




(e) H 90 #1




(f) H 90 #3




(g) H 90 #5



(h) H 80 #1



(i) H 80 #3



(j) H 80 #5

5

CONCLUSÕES

NESTE capítulo colocamos alguns comentários sobre o trabalho apresentado, enfatizando as contribuições oferecidas e trabalhos futuros que podem ser desenvolvidos.

5.1 Considerações Finais

Este trabalho propôs um novo filtro de *speckle* baseado em distâncias estocásticas e teste sobre distribuições. O objetivo, além de reduzir o ruído, é manter características de textura e bordas em imagens SAR de intensidade homogênea. O filtro define em torno de cada pixel amostras sobrepostas, que são comparadas e apenas aquelas que passarem por um teste de significância, cujo dados provieram da mesma distribuição, são utilizadas para calcular o valor filtrado. Nós utilizamos modificações nas janelas Nagao-Matsuyama para definir as amostras.

A proposta foi comparada com o filtro clássico de Lee e utilizamos um método baseado em experimentos Monte Carlo, que é uma solução numérica de problemas e baseia-se na simulação de variáveis aleatórias independentes. Dessa maneira, verificamos a variabilidade dos dados do modelo proposto, que foi relativamente baixa em relação ao filtro de Lee.

As medidas de qualidade de imagens usadas em experimentos Monte Carlo foram: (i) a metodologia de [Moschetti et al. \(2006\)](#), onde neste trabalho de dissertação avançamos utilizando medidas de erro; (ii) o índice Q por [Wang & Bovik \(2002\)](#); (iii) a correlação de Pearson entre as bordas da imagem sem ruído e a filtrada, como apresentado em [Buemi et al. \(2011\)](#). Essas medidas fizeram valer a proposta em dados simulados, que apresentou ótimos resultados nos casos mencionados. Em particular, o filtro proposto reduziu o ruído, preservou bordas e características de textura de imagens SAR de intensidade homogênea.

Também foram abordadas aplicações em dados SAR reais e métodos numéricos foram usados para fazer aferir a proposta. Os filtros baseados em distâncias estocásticas se comportam quase iguais, e eles superam o filtro de Lee em quase todas as medidas de erro avaliadas.

Nós também avaliamos o nível de significância com algumas variações, juntamente com filtros de ordem 5 e 7. A metodologia proposta é bastante geral e pode ser estendida para outras situações, desde que haja um modelo estatístico subjacente.

5.2 Trabalhos Futuros

Pretendemos estender a técnica proposta para outros modelos estatísticos e trabalhar com dados Polarimétricos. Para tanto pretendemos atingir os seguintes objetivos:

- Discutir os principais aspectos e características no contexto de dados PolSAR;
- Descrever as principais técnicas e procedimentos para filtragem de *speckle* em imagens PolSAR;
- Elaborar e propor processos metodológicos para suavizar o efeito *speckle* mantendo “boas” características de bordas;
- Estender técnicas de avaliação quantitativa e qualitativa em imagens coloridas à imagens Polarimétricas;
- Propor e desenvolver um algoritmo que utilize a metodologia proposta enfatizando a sua aplicação em redução de *speckle* em imagens PolSAR;
- Construir uma base de dados com imagens SAR e PolSAR, a fim de prover recursos para experimentos e validações de propostas com base nos conceitos de *Reproducible Research* (RR).

Apêndice A

AMBIENTE REPRODUTÍVEL E COMPUTACIONAL

O [ISI Web of Knowledge \(2012\)](#) consiste em sete base de dados fornecidos pelo *Thomson Scientific's Institute for Scientific Information*. Ele fornece informações e dados estatísticos sobre milhares de artigos e indexa periódicos, jornais acadêmicos, patentes, e muito mais.

Parte do registro bibliográfico desse trabalho fez-se uso do [ISI Web of Knowledge \(2012\)](#) e os bancos de dados de interesse foram: o *Science Citation Index Expanded* e o *Conference Proceedings Citation Index-Science*. Ambos são índices multidisciplinares científicos, que indexam mais de 6 mil jornais e incluem referências capturadas dos artigos indexados. O apoio em livros com enfoque em processamento de imagens e estatística e ferramentas complementares de busca, como o *Google* acadêmico, foram utilizados para complementar essa pesquisa.

[Volpato \(2008\)](#), ao discutir aspectos referentes à qualidade da publicação científica, nas diversas áreas do conhecimento, assegura que: um pesquisador deve buscar publicar seus resultados em periódicos aceitos e avaliados pela comunidade científica internacional, o que reforça a utilização do [ISI Web of Knowledge \(2012\)](#).

Para avaliar os periódicos e pesquisadores base dessa dissertação temos as seguintes métricas ([Volpato, 2008](#)):

Fator de Impacto: Consiste na medida da relevância do periódico diante da comunidade científica, por meio da relação entre a quantidade de citações e a quantidade de artigos publicados numa janela de dois anos.

Immediacy Index: É outra maneira de avaliar um periódico e informa a relação entre as citações ocorridas no ano e os artigos publicados no mesmo ano.

Índice h: Este índice avalia a qualidade científica de um pesquisador, assim, considera uma

ponderação entre o número de publicações e o número de citação de um autor recebeu. O valor h será sempre um número inteiro e indica que o autor possui h artigos com, no mínimo, h citações; para maiores informações recomendo a leitura dos estudos de Hirsch (2005).

Para organizar, catalogar e acompanhar mais facilmente todo material obtido do processo de bibliometria, fez-se uso da ferramenta *JabRef*¹. Com relação ao desenvolvimento dessa dissertação, a plataforma \LaTeX com editor de textos *Kile*² foi utilizado.

Nas etapas de processamento e análise das imagens utilizamos o ambiente e linguagem de programação R ($v2.11$) (Development Core Team, 2012), que está disponível na forma de FLOSS (*Free/Libre and Open Source Software*) (Ghosh & Glott, 2002), juntamente com o pacote *biOps* ($v0.2.1.1$) (Bordese & Alini, 2007). O R oferece uma grande diversidade de funções e técnicas estatísticas, preparação de gráficos de alta qualidade e manipulação de dados com grande precisão numérica, já sido aferida por Almiron et al. (2009).

A reprodutibilidade dos resultados é um fator primordial na ciência. O sucesso de uma pesquisa está ancorado na exposição de seus resultados a testes independentes e a replicações. Isto requer uma completa abertura de dados, procedimentos e materiais (Fomel & Claerbout, 2009). Nesse cenário, surge o conceito de *Reproducible Research* (RR), que é uma sistematização de boas práticas especialmente organizadas para a pesquisa computacional quantitativa.

Um trabalho que agrega estas práticas tem esse aspecto da sua metodologia aceito na comunidade científica, em particular nas áreas relacionadas a processamento de imagens. A IPOL (2012) (*Image Processing On Line*) destaca-se pela iniciativa de disponibilizar um repositório para pesquisas em processamento de imagens com reprodutibilidade dos resultados apresentados por suas publicações.

Assim, experimentos gerados podem ser facilmente replicados por pesquisadores autônomos de forma a validar os resultados apresentados. Agregando este princípio, o trabalho proposto faz uso das boas práticas de RR. Stodden et al. (2010) destaca o suporte a geração de um *artigo reprodutível*, onde deve estar associado a um sítio web público contendo:

- título;
- autores, com links às respectivas páginas Web;
- resumo;
- o artigo em PDF e informações de seu estado (em preparação, submetido ou aceito);

¹Um gerenciador de referências bibliográficas de código aberto e multiplataforma, baseado em bases de dados \LaTeX e, encontra-se disponível em <http://jabref.sourceforge.net/>.

²É um ambiente de desenvolvimento integrado \LaTeX para o KDE, permite que sejam usadas funcionalidades do \LaTeX em modo gráfico e, encontra-se disponível em <http://kile.sourceforge.net/>.

- os códigos que geram os dados, as figuras e as tabelas, todos documentados e com informações sobre como executá-los;
- a base de dados utilizada, e informações sobre como lê-las;
- informações da plataforma onde o software/ algoritmo foi testado/avaliado;
- contatos (e-mail e fórum de discussão) e;
- referências com os seus *abstracts*.

O leitor interessado em reproduzir os resultados alcançados neste trabalho, pode acessar de forma irrestrita o endereço: sites.google.com/site/projectspecklefilteringrr/.

Apêndice B

APLICAÇÃO DO FILTRO PROPOSTO EM DADOS SAR POLARIMÉTRICOS

ENTRE as tecnologias de sensoriamento remoto, dados SAR Polarimétricos (PolSAR) alcançaram uma posição de destaque. Imagem PolSAR também utiliza a iluminação coerente na faixa das microondas e técnica de sensoriamento remoto para fornecer imagens em grande escala bidimensional (2-D) de alta resolução espacial; detalhes podem ser encontrados em [Ulaby & Elachi \(1990\)](#) e [Lee & Pottier \(2009\)](#).

A modelagem estatística também fornece um bom suporte para o desenvolvimento de algoritmos, a fim de interpretar os dados de forma eficiente, e para a simulação de imagens plausíveis. A distribuição *scaled multilook complex Wishart* tem sido empregada com sucesso como um modelo estatístico para imagens PolSAR em regiões homogêneas; veja [Frery et al. \(2011b\)](#).

O filtro proposto nesta dissertação foi estendido para atuar em imagens PolSAR modeladas pela distribuição *Wishart* $\mathbf{Z} \sim \mathcal{W}(\mathbf{\Sigma}, L)$, em que L é o número equivalente de looks e $\mathbf{\Sigma}$ é uma matriz de covariância. Esta matriz de covariância complexa é Hermitiana e definida positiva, e tem toda informação que caracteriza o retroespalhamento em análise dos dados ([Anfinsen et al., 2009](#)). Não iremos detalhar a modelagem utilizada no filtro aplicado em dados PolSAR, contudo, informamos que foi fortemente embasado nos estudos de [Anfinsen et al. \(2009\)](#); [Nascimento et al. \(2010\)](#) e [Frery et al. \(2011a,b\)](#).

B.1 Resultados

Utilizamos a imagem AIRSAR da *NASA/Jet Propulsion Laboratory Airborne SAR* da Baía de San Francisco para fazer uma análise exploratória inicial desta proposta. A imagem foi gerada com 4-looks e resolução de 900×1024 pixels. A Figura [B.1](#) apresenta os resultados da Decomposição de Pauli, enquanto a Figura [B.2](#) mostra dados equivalentes usando a De-

composição de Sinclair (detalhes sobre as decomposições em [Lee & Pottier \(2009\)](#)). As Figuras B.2(a) e B.2(b) (Figuras B.3(a) e B.3(b), respectivamente) mostram o conjunto de dados originais e a imagem ampliada (zoom).

As Figuras B.2(c) e B.2(d) (Figuras B.3(c) e B.3(d), resp.) mostram o efeito do filtro da média aplicado numa janela de tamanho 5×5 para toda imagem. Embora a redução de ruído é evidente, é também claro que a desfocagem introduzida elimina informações úteis como, por exemplo, os detalhes curvilíneos na área de mata e a estrutura da área urbana.


As Figuras B.2(e) e B.2(f) (Figuras B.3(e) e B.3(f), resp.) apresentam o resultado da suavização da imagem original com o filtro baseado em distância estocásticas e testes entre distribuições. O efeito do ruído é aliviado com a redução da granulosidade, especialmente em área de floresta e sobre as áreas urbanas. Outro ponto positivo é que os pequenos detalhes são mais preservados do que quando o filtro da média é aplicado. A seletividade direcional do filtro proposto retém estruturas lineares como, por exemplo, as ruas e as docas. Estruturas brilhantes dentro da floresta são realçadas, e sua aparência linear é mantida.

Figura B.1: Dados PolSAR na decomposição de Pauli.




(a) Dados PolSAR

(b) Dados PolSAR zoom



(c) Filtro da Média


(d) Filtro da Média zoom



(e) Filtro Hellinger

(f) Filtro Hellinger zoom


Figura B.2: Dados PolSAR na decomposição de Sinclair.




(a) Dados PolSAR




(b) Dados PolSAR zoom



(c) Filtro da Média



(d) Filtro da Média zoom



(e) Filtro Hellinger



(f) Filtro Hellinger zoom

REFERÊNCIAS BIBLIOGRÁFICAS

- Achim, A., Tsakalides, P. & Bezerianos, A. (2003), 'SAR image denoising via Bayesian Wavelet shrinkage based on heavy-tailed modeling', *IEEE Transactions on Geoscience and Remote Sensing* **41**(8), 1773–1784.
- Almiron, M. G., Almeida, E. S. & Miranda, M. N. (2009), 'The reliability of statistical functions in four software packages freely used in numerical computation', *Brazilian Journal of Probability and Statistics* **23**(2), 107–119.
- Anfinsen, S. N., Doulgeris, A. P. & Eltoft, T. (2009), 'Estimation of the equivalent number of looks in polarimetric synthetic aperture radar imagery', *IEEE Transactions on Geoscience and Remote Sensing* **47**(11), 3795–3809.
- Arigony-Neto, J., Rau, F., Saurer, H., Jaña, R., Simões, J. C. & Vogt, S. (2007), 'A time series of SAR data for monitoring changes in boundaries of glacier zones on the Antarctic Peninsula', *Annals of Glaciology* **46**(1), 55–60(6).
- Baxter, R. & Seibert, M. (1998), 'Synthetic aperture radar image coding', *MIT Lincoln Laboratory Journal* **11**(2), 121–158.
- Bordese, M. & Alini, W. (2007), 'biOps: image processing and analysis', Online. URL <http://cran.r-project.org/web/packages/biOps/index.html>, acessado em maio de 2012.
- Buemi, M. E., Mejail, M., Jacobo-Berlles, J. C., Frery, A. C. & Ramos, H. S. (2011), Assessment of SAR image filtering using adaptive stack filters, in 'Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications', Vol. 7042 of *Lecture Notes in Computer Science*, Pucón, pp. 89–96.
- Chávez, J. L. (2010), *Tratamiento digital de imágenes multiespectrales*, 2nd. ed., Instituto de Geofísica, UNAM, México. ISBN: 9786070034039.
- Cheng, H. & Tian, J. (2009), Speckle reduction of synthetic aperture radar images based on fuzzy logic, in 'International Workshop on Education Technology and Computer Science', Wuhan, pp. 933–937.
- Development Core Team, R. (2012), *R: A Language and Environment for Statistical Computing*, R Foundation for Statistical Computing, Vienna. URL <http://www.R-project.org>, ISBN: 3-900051-07-0.
- Eom, K. B. (2011), 'Anisotropic adaptive filtering for speckle reduction in synthetic aperture radar images', *Optical Engineering* **50**(5), 057206–1 1–9.

- Fomel, S. & Claerbout, J. F. (2009), 'Reproducible research introduction', *Computing in Science & Engineering* **11**(1), 5–7.
- Frery, A. C., Cintra, R. J. & Nascimento, A. D. C. (2011*a*), Hypothesis test in complex Wishart distributions, in 'International Workshop on Science and Applications of SAR Polarimetry and Polarimetric Interferometry', Frascati.
- Frery, A. C., Müller, H.-J., Yanasse, C. C. F. & Sant'Anna, S. J. S. (1997*a*), 'A model for extremely heterogeneous clutter', *IEEE Transactions on Geoscience and Remote Sensing* **35**(3), 648–659.
- Frery, A. C., Nascimento, A. D. C. & Cintra, R. J. (2011*b*), 'Information theory and image understanding: An application to polarimetric SAR imagery', *Chilean Journal of Statistics* **2**(2), 81–100.
- Frery, A. C., Sant'Anna, S. J. S., Mascrenhas, N. D. A. & Bustos, O. H. (1997*b*), 'Robust inference techniques for speckle noise reduction in 1-look amplitude SAR images', *Applied Signal Processing* **4**, 61–76.
- Frery, A. C., Yanasse, C. C. F. & Sant'Anna, S. J. S. (1995), Alternative distributions for the multiplicative model in sar images, in 'Quantitative Remote Sensing for Science and Applications', Vol. 1, Florence, pp. 169–171.
- Frost, V. S., Stiles, J. A., Shanmugan, K. S. & Holtzman, J. C. (1982), '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**(2), 157–166.
- Gao, G. (2010), 'Statistical modeling of SAR images: A Survey', *Sensors* **10**(1), 775–795.
- Ghosh, R. A. & Glott, R. (2002), 'Free/libre and open source software: Survey and study', Online. URL <http://www.flossproject.org/outline.htm>, acessado em maio de 2011.
- Gonzalez, R. C. & Woods, R. E. (2008), *Digital Image Processing*, 3rd. ed., Prentice Hall, Nova York. ISBN: 9780131687288.
- Goodman, J. W. (1976), 'Some fundamental properties of speckle', *Journal of the Optical Society of America* **66**(11), 1145–1150.
- Graham, R., Knuth, D. & Patashnik, O. (1988), *Concrete mathematics: a foundation for computer science*, Addison-Wesley, Reading.
- Hirsch, J. E. (2005), An index to quantify an individual's scientific research output, in 'Proceedings of the National Academy of Sciences of the USA', Vol. 102, Stuttgart, pp. 16569–16572.

- IEEE (2003), *521-2002 IEEE Standard Letter Designations for Radar-Frequency Bands*, IEEE Aerospace & Electronic Systems Society, New York.
- INPE (2012), 'SPRING: Tutorial de Geoprocessamento', Online. URL <http://www.dpi.inpe.br/spring/>, acessado em maio de 2012.
- IPOL (2012), 'Image processing on line', Online. URL <http://www.ipol.im/>, acessado em maio de 2012.
- ISI Web of Knowledge (2012), 'Web of science', Online. URL <http://www.isiknowledge.com>, acessado em maio de 2012.
- Jin, J. Y., Silva, G. T. & Frery, A. C. (2004), 'SAR despeckling filters in ultrasound imaging', *Latin American Applied Research* **34**(1), 49–53.
- Kuan, D. T., Sawchuk, A. A., Strand, T. C. & Chavel, P. (1985), 'Adaptive noise smoothing filter for images with signal-dependent noise', *IEEE Transactions on Pattern Analysis and Machine Intelligence* **PAMI-7**(2), 165–177.
- Kuan, D. T., Sawchuk, A. A., Strand, T. C. & Chavel, P. (1987), 'Adaptive restoration of images with speckle', *IEEE Transactions on Acoustics, Speech and Signal Processing* **35**(3), 373–383.
- Lee, J.-S. (1980), 'Digital image enhancement and noise filtering by use of local statistics', *IEEE Transactions on Pattern Analysis and Machine Intelligence* **PAMI-2**(2), 165–168.
- Lee, J.-S. (1981), 'Speckle analysis and smoothing of synthetic aperture radar image', *Computer Graphics and Image Processing* **17**(1), 24–32.
- Lee, J. S. (1983a), 'Digital image smoothing and the sigma filter', *Computer Vision, Graphics, and Image Processing* **24**(2), 255–269.
- Lee, J. S. (1983b), 'A simple speckle smoothing algorithm for synthetic aperture radar images', *IEEE Transactions on Systems, Man and Cybernetics* **13**(1), 85–89.
- Lee, J.-S. (1986), 'Speckle suppression and analysis for synthetic aperture radar images', *Optical Engineering* **25**(5), 636–645.
- Lee, J.-S. & Pottier, E. (2009), *Polarimetric Radar Imaging: From Basics to Applications*, 1st ed., CRC Pres, Boca Raton. ISBN: 978-1420054972.
- Lee, J.-S., Jurkevich, L., Dewaele, P., Wambacq, P. & Oosterlinck, A. (1994), 'Speckle filtering of synthetic aperture radar images: A review', *Remote Sensing Reviews* **8**(4), 313–340.
- Lee, J.-S., Wen, J.-H., Ainsworth, T. L., Chen, K.-S. & Chen, A. J. (2009), 'Improved sigma filter for speckle filtering of SAR Imagery', *IEEE Transactions on Geoscience and Remote Sensing* **47**(1), 202–213.

- Lillesand, T. M., Kiefer, R. W. & Chipman, J. W. (2008), *Remote Sensing and Image Interpretation*, 6th. ed., John Wiley & Sons, Nova York. ISBN: 9780470052457.
- Lomnicki, Z. A. (1967), 'On the distribution of products of random variables', *Journal of the Royal Statistical Society, Series B (Methodological)* **29**(3), 513–524.
- Lopes, A., Nezry, E., Touzi, R. & Laur, H. (1993), 'Structure detection and statistical adaptive speckle filtering in SAR images', *International Journal of Remote Sensing* **14**(9), 1735–1758.
- Lucca, E. V. D. (1998), Avaliação e comparação de algoritmos de segmentação de imagens de radar de abertura sintética, Dissertação de mestrado, Instituto Nacional de Pesquisas Espaciais, São José dos Campos.
- Moschetti, E., Palacio, M. G., Picco, M., Bustos, O. H. & Frery, A. C. (2006), 'On the use of Lee's protocol for speckle-reducing techniques', *Latin American Applied Research* **36**(2), 115–121.
- Müller, H.-J., Frery, A. C., Jacobo-Berlles, J. C., Mejail, M. E. & Moreira, J. (2000), The harmonic branch of the multiplicative model: properties and applications, in 'Third European Conference on Synthetic Aperture Radar', Vol. 30, Munich, pp. 603–606.
- Nagao, M. & Matsuyama, T. (1979), 'Edge preserving smoothing', *Computer Graphics and Image Processing* **9**(4), 394–407.
- Nascimento, A. D. C., Cintra, R. J. & Frery, A. C. (2010), 'Hypothesis testing in speckled data with stochastic distances', *IEEE Transactions on Geoscience and Remote Sensing* **48**(1), 373–385.
- Negri, R. G. (2009), Avaliação de dados polarimétricos do sensor ALOS PALSAR para classificação da cobertura da terra da Amazônia, Dissertação de mestrado, Instituto Nacional de Pesquisas Espaciais, São José dos Campos.
- Nezry, E., Mougin, E., Lopes, A., Gastellu-Etchegorry, J. P. & Laumonier, Y. (1993), 'Tropical vegetation mapping with combined visible and SAR spaceborne data', *International Journal of Remote Sensing* **14**(11), 2165–2184.
- Oliver, C. & Quegan, S. (2004), *Understanding Synthetic Aperture Radar Images*, 1st. ed., SciTech Publishing. ISBN: 9781891121319.
- Oliver, C. J. (1991), 'Information from SAR images', *Journal of Physics D: Applied Physics* **24**(9), 1493–1514.
- Pižurica, A., Philips, W., Lemahieu, I. & Acheroy, M. (2003), 'A versatile wavelet domain noise filtration technique for medical imaging', *IEEE Transactions on Medical Imaging* **22**(3), 323–331.

- Rakotomamonjy, A., Deforge, P. & Marché, P. (2000), 'Wavelet-based speckle noise reduction in ultrasound B-scan images.', *Ultrason Imaging* **22**(2), 73–94.
- Salicrú, M., Morales, D., Menéndez, M. L. & Pardo, L. (1994), 'On the applications of divergence type measures in testing statistical hypotheses', *Journal of Multivariate Analysis* **21**(2), 372–391.
- Sant'Anna, S. J. S. (1995), Avaliação do desempenho de filtros redutores de "speckle" em imagens de radar de abertura sintética, Dissertação de mestrado, Instituto Nacional de Pesquisas Espaciais, São José dos Campos.
- Stodden, V., Donoho, D., Fomel, S., Friedlander, M. P., Gerstein, M., LeVeque, R., Mitchell, I., Ouellette, L. L. & Wiggins, C. (2010), 'Reproducible research: Addressing the need for data and code sharing in computational science', *Computing in Science & Engineering* **12**(5), 8–13.
- Touzi, R. (2002), 'A review of speckle filtering in the context of estimation theory', *IEEE Transactions on Geoscience and Remote Sensing* **40**(11), 2392–2404.
- Trevett, J. W. (1986), *Imaging radar for resources surveys*, 1st. ed., Chapman and Hall, New York. ISBN: 9780412255205.
- Ulaby, F. T. & Dobson, M. C. (1989), *Handbook of radar scattering statistics for terrain*, 1st. ed., Artech House, Norwood. ISBN: 9780890063361.
- Ulaby, F. T. & Elachi, C. (1990), *Radar Polarimetry for Geoscience Applications*, 1st. ed., Artech House, Norwood. ISBN: 978-0890064061.
- Ulaby, F. T., Moore, R. K. & Fung, A. K. (1986), *Microwave remote sensing: active and passive: radar remote sensing and surface scattering and emission theory*, Vol. 2, 2nd. ed., Artech House, Norwood. ISBN: 9780890061916.
- Velho, L., Frery, A. C. & Gomes, J. (2009), *Image Processing for Computer Graphics and Vision*, 2nd. ed., Springer, London. ISBN: 9781848001923.
- Volpato, G. L. (2008), *Publicação Científica*, 3rd. ed., Cultura Acadêmica, São Paulo. ISBN: 9788598605609.
- Walessa, M. & Datcu, M. (2000), 'Model-based despeckling and information extraction from SAR images', *IEEE Transactions on Geoscience and Remote Sensing* **38**(5), 2258–2269.
- Wang, Z. & Bovik, A. C. (2002), 'A universal image quality index', *IEEE Signal Processing Letters* **9**(3), 81–84.

- Wang, Z., Bovik, A. C. & Lu, L. (2002), Why is image quality assessment so difficult?, *in* 'IEEE International Conference on Acoustics, Speech, & Signal Processing', Vol. 4, Orlando, pp. IV 3313–3316.
- Xie, H., Pierce, L. E. & Ulaby, F. T. (2002), 'Statistical properties of logarithmically transformed speckle', *IEEE Transactions on Geoscience and Remote Sensing* **40**(3), 721–727.
- Zhang, Z. Z. (2004), *Introduction of Airborne and Spaceborn Synthetic Aperture Radar*, 1st. ed., House of Electronics Industry, Beijing.

Este trabalho foi redigido em \LaTeX utilizando uma modificação do estilo IC-UFAL. As referências bibliográficas foram preparadas no JabRef e administradas pelo \BIBTeX com o estilo LaCCAN. O texto utiliza fonte Fourier-GUTenberg e os elementos matemáticos a família tipográfica Euler Virtual Math, ambas em corpo de 12 pontos.