UNIVERSIDADE DE SÃO PAULO INSTITUTO DE FÍSICA DE SÃO CARLOS DEPARTAMENTO DE FÍSICA E INFORMÁTICA

FILTRAGEM ADAPTATIVA DE IMAGENS DE RADAR DE ABERTURA SINTÉTICA UTILIZANDO A ABORDAGEM MAXIMUM A POSTERIORI

FÁTIMA NELSIZEUMA SOMBRA DE MEDEIROS

Tese apresentada ao Instituto de Física de São Carlos, Universidade de São Paulo, para obtenção do título de Doutor em Ciências "Física Aplicada-Opção: Física Computacional"

Orientador: Prof. Dr. Luciano da Fontoura Costa Co-Orientador: Prof. Dr. Nelson Delfino D'Ávila Mascarenhas

ou

USP/IFSC/SBI

° 8-2-001311

São Carlos – São Paulo 1999 Medeiros, Fátima Nelsizeuma Sombra de

Filtragem adaptativa de imagens de radar de abertura sintética utilizando abordagem maximum a posteriori/ Fátima Nelsizeuma Sombra de Medeiros. — São Carlos, 1999.

156 p.

Tese (Doutorado) - Instituto de Física de São Carlos, 1999.

Orientador: Prof. Dr. Luciano da Fontoura Costa.

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

1. Filtragem. 2. Ruído speckle. 3. Imagens SAR. I Título



Av. Dr. Carlos Botelho, 1465 CEP 13560-250 - São Carlos - SP Brasil

Fone (016) 273-9333 Fax (016) 272-2218

MEMBROS DA COMISSÃO JULGADORA DA TESE DE DOUTORADO DE FÁTIMA NELSIZEUMA SOMBRA DE MEDEIROS APRESENTADA AO INSTITUTO DE FÍSICA DE SÃO CARLOS DA UNIVERSIDADE DE SÃO PAULO, EM 17 DE DEZEMBRO DE 1999.

COMISSÃO JULGADORA:
lot
Prof. Dr. Ludiano da Fontoura Costa/IFSC-USP
·
Dr. Paulo Estevão Cruvinel/EMBRAPA-CNPDIA
Prof. Dr. Alberto Tannus/IFSC-USP
ale
Prof. Dr. Luciano Vieira Dutra/INPE
Olyand Clay
Prof. Dr. Alejandro César Frery Orgambide/UFPE

Dedico este trabalho ao Grande Mestre

AGRADECIMENTOS

Desde o nascimento estou aos teus cuidados, desde o ventre de minha mãe tu és o meu Deus. Sl 21,11.

Em primeiro lugar agradeço a Deus. Nos momentos difíceis pude recostar minha cabeça em seu regaço acolhedor e receber forças...

Aos professores Luciano da Fontoura Costa e Nelson Mascarenhas que são exemplos de competência, dedicação e simplicidade. Durante estes anos aprendi muito com eles.

Aos meus filhos Antônio Luís, Clarice e Laura cuja infância encontrarei sempre nestas páginas...

Ao meu querido Luiz que incondicionalmente me apoiou em todas as etapas.

Parte da força que hoje tenho é herança de meu avô Raimundo Lopes Sombra. Meus avós sempre confiaram em Deus e este foi seu legado. Deixaram-nos de herança a religiosidade e a fé.

Aos meus pais José Nelson e Lourdinha que sempre me guiaram vigilantes, mas nunca me tiraram a liberdade.

Aos meus queridos irmãos que acompanharam minha caminhada até aqui.

Aos queridos amigos Júlia, Regina Coelho, Ricardo Villela, Alan e Rocha um agradecimento especial, pois viveram o começo de tudo comigo, ajudaram-me, compartilharam tudo.

Aos amigos Jander, Consularo, Andrea, Leandro, Pinda, Felipe, Dani, Murillo, Edson, Luiz Rios e demais componentes do Grupo de Visão Ciberbética cujo companheirismo e sensibilidade impressionaram-me.

Ao Marquinhos, Cláudia Toffanelli, Bruno Rosa, Alexandre, Regina Fumie, Mara, Neuza, Betânia e Wladerez pela gentileza e amizade.

Às irmãs Sacramentinas do Colégio São Carlos que acolheram minhas crianças com carinho.

Ao PICDT-CAPES e Projeto FINEP-RECOPE #77.97.0575.00 pelo suporte financeiro.

ÍNDICE

1 IN	TRODUÇÃO	<u>.1</u>
1.1	OBJETIVOS E CONTRIBUIÇÕES DO TRABALHO	
1.2	ORGANIZAÇÃO DA TESE	.4
	REVISÃO BIBLIOGRÁFICA SOBRE RUÍDO "SPECKLE" EM IMAGENS	_
<u>SAR</u>		<u>7</u>
		_
2.1	INTRODUÇÃO	
2.2	IMAGENS DE RADAR DE ABERTURA SINTÉTICA	
2.3	ORIGEM E MODELAGEM DO "SPECKLE"	
2.3.1	CAMINHADA ALEATÓRIA NO PLANO COMPLEXO	
2.4	MODELO MULTIPLICATIVO	
2.5	REVISÃO DAS TÉCNICAS DE FILTRAGEM DE "SPECKLE"	.21
2.6	CONCLUSÃO	.46
	<u>RINCIPAIS FERRAMENTAS UTILIZADAS NESTA TESE PARA MELHORI</u>	
E AV	ALIAÇÃO DA FILTRAGEM	<u>.47</u>
3.1	Introdução	.47
3.2	ALGORITMO DE K-MÉDIAS	.48
3.2.1	RESULTADO DE APLICAÇÃO DO ALGORITMO DE K-MÉDIAS COMBINADO AOS	
ALG	ORITMOS DE FILTRAGEM MAP	50
	CRESCIMENTO DE REGIÕES	
3.3.1	The Control of the Co	
Сом	IBINADO AOS ALGORITMOS DE FILTRAGEM MAP	54
3.4	MEDIDAS DE AVALIAÇÃO UTILIZADAS NESTA TESE	
3.4.1		
3.4.2	- Wassess Options in the	
	DIDA S	64
	CONCLUSÃO	
3.3	LANGAU	'

4 AB	ORDAGEM MAP PARA REDUÇÃO DO RUÍDO "SPECKLE"	6 <u>7</u>
4.1	Introdução	67
4.2	MODELO DE FILTRO MAP PROPOSTO PARA IMAGENS DETECTADAS	
	MPLITUDE E UMA VISADA	69
4.2.1	DENSIDADE "A PRIORI" GAUSSIANA	
4.2.2	DENSIDADE "A PRIORI" GAMA	
4.2.3	DENSIDADE "A PRIORI" CHI-QUADRADO	
4.2.4	DENSIDADE "A PRIORI" EXPONENCIAL	
4.2.5	DENSIDADE "A PRIORI" RAYLEIGH	
4.2.6	DENSIDADE "A PRIORI" BETA	
4.2.7	DENSIDADE "A PRIORI" LOG-NORMAL	75
4.3	MODELO PROPOSTO DE FILTRO MAP PARA IMAGENS AMPLITUDE DE	
N VIS	SADAS	76
4.3.1	Densidade "a priori" Gaussiana	76
4.3.2	Densidade "a priori" gama	77
4.3.3	Densidade "a priori" chi-quadrado	78
4.3.4	DENSIDADE "A PRIORI" EXPONENCIAL	78
4.3.5	Densidade "a priori" Rayleigh	79
4.3.6	Densidade "a priori" beta	80
4.3.7	DENSIDADE "A PRIORI" LOG-NORMAL	80
4.4	SÍNTESE DAS EQUAÇÕES MAP	
4.5	IMPLEMENTAÇÃO DO ALGORITMO MAP	
4.6	CONCLUSÃO	84
•		0.5
<u>5 F</u>	RESULTADOS EXPERIMENTAIS	85
		85
5.1	INTRODUÇÃO	
5.2	IMAGEM ARTIFICIALMENTE CONTAMINADA POR RUÍDO "SPECKLE"	86
	M ESTATÍSTICA RAYLEIGH (DETECÇÃO LINEAR E 1 VISADA) IMAGEM REAL SAR OBTIDA POR DETECÇÃO LINEAR E COM 1 VISAD	
5.3	IMAGEM REAL SAR OBTIDA POR DETECÇÃO LINEAR E COM T VISAD IMAGEM ARTIFICIALMENTE CONTAMINADA POR RUÍDO "SPECKLE"	
5.4		
	M ESTATÍSTICA RAIZ DE GAMA (DETECÇÃO LINEAR E MÚLTIPLAS	93
	ADAS)IMAGEM REAL SAR OBTIDA POR DETECÇÃO LINEAR E COM	
5.5	JLTIPLAS VISADAS	96
IVIU	LIHEAS VISADAS	

5.6	ANÁLISE COMPARATIVA DOS RESULTADOS	98
5.7	CONCLUSÃO	100
<u>6 C</u>	ONCLUSÃO	102
6.1	CONCLUSÕES GERAIS	102
6.2	CONTRIBUIÇÕES DESTE TRABALHO	
6.3	TRABALHOS FUTUROS	104
7 R	EFERÊNCIAS BIBLIOGRÁFICAS	<u>106</u>
<u>APÊ</u>	NDICE A	112
Cond	CEITOS BÁSICOS EM PROBABILIDADE	112
<u>APÊ</u>	NDICE B	115
MÉT	odos de Estimação de Parâmetros	115
B.1	MÉTODO DOS MOMENTOS	
B.2	MÉTODO DE MÁXIMA VEROSSIMILHANÇA	116
<u>APÊ</u>	NDICE C	118
TEO	rema Central do Limite	118
<u>APÊ</u>	ENDICE D	120
MÉT	ODO DE NEWTON-RAPHSON	120
D.1	ANÁLISE DE VELOCIDADE DE CONVERGÊNCIA	120
<u>APÎ</u>	ÈNDICE E	122
ALG	goritmos de Classificação do Software SPRING Utilizados na Tese	
E.1	MAXVER	
E.2	ICM	123

APÊNDICE F126		
Resu	JLTADOS DE APLICAÇÃO DOS ALGORITMOS	126
F.1	IMAGENS ARTIFICIALMENTE CONTAMINADAS PELO RUÍDO	
"SPE	ECKLE" COM ESTATÍSTICA DE IMAGENS EM AMPLITUDE E UMA VISADA	126
F.2	IMAGENS REAIS SAR EM AMPLITUDE E 1 VISADA	136
F.3	IMAGEM ARTIFICIALMENTE CONTAMINADA POR "SPECKLE" EM	
AMP	PLITUDE E MÚLTIPLAS VISADAS	142
F.4	IMAGENS SAR REAIS EM AMPLITUDE E MÚLTIPLAS VISADAS	148

LISTA DE FIGURAS

Figura 2.1 – Geometria de imageamento do sistema SAR9
Figura 2.2 – Caminhada aleatória no plano complexo
Figura 2.3 – Sinal em amplitude.
Figura $2.4 - (a)$ Padrão de "speckle" em amplitude e respectivo (b) histograma 15
Figura 2.5 – Sinal em intensidade
Figura 2.6 – (a) Padrão de "speckle" em intensidade e respectivo (b) histograma16
Figura 2.7 – (a) Imagem <i>APTO</i> (b) imagem <i>SAR580</i>
Figura 2.8 – Histogramas (a) imagem APTO (b) imagem SAR58023
Figura 2.9 – Filtragem homomórfica
Figura 2.10 - Imagem (SAR580) filtrada pelo filtro (a) Lee e(b) respectivo
histograma
Figura 2.11 - Imagem (APTO) filtrada pelo filtro (a) Kuan e (b) respectivo
histograma
Figura 2.12 - Imagem (SAR580) filtrada pelo filtro (a) Kuan e (b) respectivo
histograma
Figura 2.13 - Imagem (SAR580) (a) filtrada pelo filtro Kuan-Curlander com
janelamento adaptativo e (b) respectivo histograma29
Figura 2.14 - Imagem (SAR580) filtrada pelo filtro (a) Frost e (b) respectivo
histograma30
Figura 2.15 - Vizinhanças de Tomita & Tsuji31
Figura 2.16 - Vizinhanças de Nagao & Matsuyama31
Figura 2.17 – Conjunto de conexões (cliques) ao redor do pixel central (preto)37
Figura 2.18 – (a) Imagem $SAR580$ filtrada com $R=1$ e (b) seu respectivo histograma.
40
Figura 2.19 – (a) Imagem $SAR580$ filtrada com $R=2$ e (b) seu respectivo histograma.
40
Figura 2.20 – (a) Imagem <i>JERS256</i> filtrada com <i>R</i> =1 e (b) seu respectivo histograma
41
Figura 2.21 – Janelas para detecção de hordas pas imagens (a)HL (b)LH (c)HH 43

Figura 2.22 (a) Imagem original (b) imagem contaminada com ruído "speckle" com
distribuição raiz de gama (4 "looks")
Figura 2.23 Filtragem baseada em "wavelets"
Figura 2.24 (a) Imagem ruidosa VILA (b) filtrada por "wavelets"
Figura 2.25 – (a) Imagem <i>CAÇAPAVA</i> (b) filtragem baseada em "wavelets"45
Figura 2.26 – (a) Imagem JERS256 (b) filtragem baseada em "wavelets"45
Figura 3.1 – (a) Imagem <i>CAÇAPAVA</i> e (b) seu respectivo histograma de <i>R</i> 49
Figura 3.2 -Incorporação do algoritmo k-médias à filtragem
Figura 3.3 - Imagem (SAR580) filtrada pelos (a) MAP gama (b) MAP gama
combinado ao k-médias51
Figura 3.4 – Histogramas da imagem (SAR580) filtrada pelos (a) MAP gama (b)
MAP gama combinado ao k-médias51
Figura 3.5 – Imagem BLA (a) artificialmente contaminada pelo "speckle" Rayleigh
(b) filtrada pelo MAP Gaussiano com crescimento de região53
Figura 3.6 – Limiar de rejeição da Homogeneidade para a imagem <i>BLA</i> 54
Figura 3.7 – Imagem (SAR580) filtrada pelos filtros (a) MAP Gaussiano (b)MAP
Gaussiano combinado ao crescimento de regiões55
Figura 3.8 – Histograma da Imagem (SAR580) filtrada pelos filtros (a) MAP
Gaussiano (b) MAP Gaussiano combinado ao crescimento de regiões55
Figura 3.9 – (a) Imagem SAR580 (b) histograma da região homogênea59
Figura 3.10- (a) Pontos no espaço de coordenadas (b) e (c) possíveis ajustes de retas
aos pontos61
Figura 3.11 – Descrição paramétrica de uma reta
Figura 3.12-Transformada de Hough original para detecção de retas63
Figura 3.13 - Transformada de Hough aplicada a imagem (SAR580) filtrada pelos
filtros (a) MAP gama com k-médias (b) Kuan64
Figura 3.14 – "Backmapping" da transformada de Hough aplicada a imagem
(SAR580) filtrada pelos filtros (a) MAP gama com k-médias (b) Kuan65
Figura 3.15 – Seqüência de passos para o cálculo da medida de dispersão66
Figura 4.1 -Algoritmo MAP83
Figura 5.1 – Imagem APTO (a) Índices β (b) Medidas de perda de resolução espacial
86

Figura 5.2 – Imagem APTO (a) média geral sobre a imagem APTO (b) média sobre
região homogênea87
Figura 5.3 – Imagem APTO (a) média das oscilações do "speckle" (b) variância das
oscilações do "speckle"87
Figura 5.4 – Imagem APTO (a) RMSNE (b) MSE
Figura 5.5 – Histograma de uma região homogênea filtrada pelo (a) MAP Gaussiano
(b) MAP Gaussiano com k-médias90
Figura 5.6 – Imagem SAR580 (a) Índices β (b) medidas de perda de resolução
espacial90
Figura 5.7 – Imagem SAR580 (a) média geral sobre a imagem SAR580 (b) média
sobre região homogênea91
Figura 5.8 – Imagem SAR580 (a) média das oscilações do "speckle" (b) variância das
oscilações do "speckle"91
Figura 5.9 – Imagem $LENA$ (a) Índices β (b) medidas de perda de resolução espacial.
93
Figura 5.10 – Imagem LENA (a) média geral sobre a imagem APTO (b) média sobre
região homogênea
Figura 5.11 – Imagem LENA (a) média das oscilações do "speckle" (b) variância das
oscilações do "speckle"94
Figura 5.12 – Imagem LENA (a) RMSNE (b) MSE95
Figura $5.13 - (a)$ Índices β (b) medidas de perda de resolução espacial96
Figura 5.14 -Média (a) geral sobre a imagem JERS (b) sobre região homogênea97
Figura 5.15 – Medidas das oscilações do "speckle" (a) média (b) variância97
Figura E.1 – (a) Vizinhança de um pixel (b) correspondente conjunto de cliques124
Figura E.2 -Algoritmos de Classificação (a) MaxVer (b) ICM125
Figura F.3 – (a) Imagem original e (b) seu respectivo histograma (c) imagem
contaminada pelo ruído "speckle" e (d) seu respectivo histograma127
Figura F.4 – Imagem APTO filtrada pelo (a) MAP Gaus e (b) seus respectivos
histogramas (c) MAP Gama e (d) seus respectivos histogramas128
Figura F.5 – Imagem APTO filtrada pelo (a) MAP Chi e (b) seus respectivos
histogramas (c) MAP Exp e (d) seus respectivos histogramas

Figura F.6 – Imagem APTO filtrada pelo (a) MAP Beta e (b) seus respectivos
histogramas (c) MAP Log e (d) seus respectivos histogramas
Figura F.7 – Imagem <i>LENA</i> filtrada pelo (a) MAP Gaus e (b) seus respectivos
histogramas (c) MAP Gama e (d) seus respectivos histogramas
Figura F.8 – Imagem LENA filtrada pelo (a) MAP Chi e (b) seus respectivos
histogramas (c) MAP Exp e (d) seus respectivos histogramas
Figura F.9 – Imagem <i>LENA</i> filtrada pelo (a) MAP Beta e (b) seus respectivos
histogramas (c) MAP Log e (d) seus respectivos histogramas
Figura F.10 – Imagens artificialmente contaminadas e filtradas pelo (a) Kuan e (b)
seus respectivos histogramas (c) "wavelets" e (d) seus respectivos histogramas135
Figura F.11 – Imagens reais SAR em amplitude e 1 visada
Figura F.12 – Imagem SAR580 filtrada pelo (a) MAP Gaus e (b) seus respectivos
histogramas (c) MAP Gama e (d) seus respectivos histogramas
Figura F.13 – Imagens reais SAR580 filtradas pelo (a) MAP Chi e (b) seus
respectivos histogramas (c) MAP Exp e (d) seus respectivos histogramas139
Figura F.14 – Imagens reais SAR580 filtradas pelo (a) MAP Ray e (b) seus
respectivos histogramas (c) MAP Beta e (d) seus respectivos histogramas (e)
histogramas das imagens filtradas pelo MAP Log140
Figura F.15 – Imagem real SAR filtrada pelo (a) Kuan e seu respectivo histograma
(b)"wavelets" e seu respectivo histograma.
Figura $F.16 - (a)$ Imagens original e ruidosa e (b) seus respectivos histogramas142
Figura F.17 – Imagem $LENA$ filtrada pelo (a) Kuan e seu respectivo histograma 143
Figura F.18 – Imagem LENA filtrada pelo (a) MAP Gaus e (b) seus respectivos
histogramas (c) MAP Gama e (d) seus respectivos histogramas144
Figura F.19 – Imagem LENA filtrada pelo (a) MAP Chi e (b) seus respectivos
histogramas (c) MAP Exp e (d) seus respectivos histogramas (e) MAP Ray e146
Figura F.20 – Imagem LENA filtrada pelo (a) MAP Beta e (b) seus respectivos
histogramas (c) MAP Log e (d) seus respectivos histogramas147
Figura F.21 –Imagens reais SAR em amplitude e com múltiplas visadas149
Figura F.22 – Imagens reais SAR filtradas pelo (a) Kuan e (b) seus respectivos
histogramas (c) "wavelets" e (d) seus respectivos histogramas
Figura F.23 – Imagem JERS481 filtrada pelo (a) MAP Gaus e (b) seus respectivos
histogramas (c) MAP Gama e (d) seus respectivos histogramas151

Figura F.24 – Imagem <i>JERS481</i> filtrada pelo (a) MAP Chi e (b) seus respectivos
histogramas (c) MAP Exp e (d) seus respectivos histogramas
Figura F.25 – Imagem reais <i>JERS481</i> filtrada pelos (a) MAP Ray e (b) seus
respectivos histogramas (c) MAP Beta e (d) seus respectivos histogramas (e)
histogramas das imagens filtradas pelo MAP Log
Figura F.26 – Imagem ZONE filtrada pelo (a) MAP Gaus e (b) seus respectivos
histogramas (c) MAP Gama e (d) seus respectivos histogramas
Figura F.27 – Imagem ZONE filtrada pelo (a) MAP Chi e (b) seus respectivos
histogramas (c) MAP Exp e (d) seus respectivos histogramas
Figura F.28 – Imagem reais $ZONE$ filtrada pelos (a) MAP Ray e (b) seus respectivos
histogramas (c) MAP Beta e (d) seus respectivos histogramas (e) histogramas das
imagens filtradas pelo MAP Log

LISTA DE TABELAS

Tabela 2.1 – Bandas de frequências	8
Tabela 2.2 – Valor teórico de σ_n para detecção linear.	.18
Tabela 2.3 – Valor teórico de σ_n para detecção quadrática	.19
Tabela 2.4 – R x janela.	.28
Tabela 4.1 - Equações MAP para modelo de speckle presente em imagens obtidas	
por deteção linear e múltiplas (N) visadas.	.81
Tabela 5.1 – Medidas de desempenho calculadas sobre a imagem APTO	.89
Tabela 5.2 – Medidas de desempenho calculadas sobre a imagem SAR580	.92
Tabela 5.3 – Medidas de desempenho calculadas sobre a imagem LENA	.95
Tabela 5.4 – Medidas de desempenho calculadas sobre a imagem <i>JERS481</i>	.98

RESUMO

Imagens de radar de abertura sintética (SAR) são tipicamente corrompidas pelo ruído "speckle" que também degrada imagens geradas por ultra-som, laser, etc. Esta tese propõe algoritmos de filtragem baseados na abordagem "maximum a posteriori" (MAP) para redução de "speckle" em imagens SAR. Na derivação dos filtros MAP, para imagens obtidas por detecção linear, são utilizadas as distribuições (condicionais) Rayleigh e raiz quadrada de gama na regra de Bayes como modelos para o ruído "speckle" em imagens SAR obtidas em amplitudes com 1 e múltiplas visadas, respectivamente, e usadas várias distribuições para o modelo "a priori". Toda a formulação dos algoritmos tem por base o modelo multiplicativo que constitui o modelo mais adequado ao "speckle". Propõe-se ainda neste trabalho a combinação dos filtros MAP formulados com o algoritmo k-médias e com a técnica de crescimento de regiões, como forma de melhoria da abordagem de filtragem proposta. Os resultados de filtragem foram avaliados segundo critérios (medidas) de melhoria da relação sinal-ruído e perda de resolução. O primeiro critério avalia a redução da intensidade do ruído "speckle" sobre regiões homogêneas e para avaliar a perda de resolução decorrente da filtragem é proposta uma nova técnica baseada na transformada de Hough. Os algoritmos foram testados em imagens artificialmente contaminadas por ruído "speckle" e em imagens SAR reais apresentando estatísticas Rayleigh e raiz de gama. Os resultados obtidos mostram a melhoria que proporcionam os algoritmos de filtragem MAP, especialmente quando combinados com o classificador k-médias e com a técnica de crescimento de região. O uso da técnica de crescimento de região reforça a conclusão de que o uso de vizinhança estatisticamente mais semelhante ao pixel ruidoso melhora a estimação dos parâmetros de filtragem. As medidas de desempenho e validação dos algoritmos MAP permitiram concluir que os filtros com distribuições "a priori" Gaussiana, gama, chi-quadrado e beta apresentaram melhores resultados de filtragem em relação aos demais modelos "a priori" quando comparados ao filtro de Kuan e com a técnica de "wavelets" para a classe de imagens utilizadas.

ABSTRACT

Synthetic aperture radar (SAR) images are typically corrupted by speckle noise, which also degrade images produced by laser beams, ultrasound, etc. This thesis proposes filtering algorithms based on the "maximum a posteriori" (MAP) approach, to reduce speckle in SAR images. To derive the MAP filters for linearly detected images we assumed the multiplicative model for the speckle and used the conditional density functions in the Bayes rule following a Rayleigh and square root of gamma for one-look and N-looks images, respectively, and several different "a priori" densities. The MAP filters are combined with the k-means classifier and region growing tools to improve the proposed filtering approach. Measures evaluating both the signal-to-noise improvement and resolution loss due to filtering are computed. To assess the improvement brought by the proposed algorithms we evaluate them with respect to signal to noise ratio and edge preservation. The former is a classical way to evaluate the speckle strenght reduction over homogeneous areas and the latter is a new proposed technique based on the Hough transform that measures distortions at the edges produced by the speckle MAP filtering algorithms. The qualitative analysis of the MAP proposed algorithms includes the methods based on the curvature and wavelets. The algorithms were applied to simulated noisy speckled images and real SAR images with statistics of linearly detected images with one-look and N-looks. The obtained results demonstrated the improvement brought by the speckle MAP filtering algorithms, specially when combined with the k-means clustering algorithm and with the region growing approach. This region growing approach reinforces the conclusion that the use of a neighborhood whose pixels have statistics similar to the noisy pixel provides a better estimation for filtering. The evaluating measures point out that the MAP filters whose "a priori" models are the Gaussian, gamma, chi-square and beta presented better results than the other "a priori" models proposed in this thesis, the Kuan filter and the wavelets filter, for the class of images that were tested.

Lista de Abreviaturas, Símbolos e Operações

Funções e Operadores

 $\log(x)$ logaritmo natural de x $\Gamma(x)$ função gama $\frac{\partial f(x)}{\partial x}$ derivada de f(x)* convolução

Probabilidade e Estatística

Variável aleatória X Probabilidade de um evento APr(A)MLEEstimador de máxima verossimilhança função densidade de probabilidade pdf operador esperança matemática E[.] esperança matemática μ σ^2 variância desvio padrão σ espaço de amostras Ω conjunto dos números reais no intervalo $(-\infty, +\infty)$. \Re

1 Introdução

Nos últimos anos sistemas de imageamento por radar de abertura sintética (Synthetic Aperture Radar - SAR) têm desempenhado um importante papel na área de sensoriamento remoto devido à possibilidade de mapeamento e monitoração do uso do solo e desmatamento em regiões como a floresta Amazônica, acompanhamento e discriminação de culturas, cartografia, evolução geográfica, crescimento urbano, etc. Dentre outras aplicações, consta ainda a detecção de costas marítimas, cuja precisão das informações é imperativa em navegação automática e nos estudos de evolução da geografia e cartografia e na avaliação da poluição causada por derramamento de petróleo.

O imageamento por radar de abertura sintética possui sua própria fonte de iluminação (ativa) podendo operar à noite e sob condições meteorológicas adversas, além de apresentar imagens da superfície da terra com alta resolução. Entretanto, a quantidade de ruído "speckle" presente nas imagens constitui um dos maiores problemas em processamento automático de imagens SAR, pois torna difícil a extração de informação ou mesmo a detecção de alvos. O ruído "speckle" surge quando uma superficie é iluminada com uma fonte de luz coerente e se apresenta como um padrão granular na imagem obtida por um sistema ótico. Portanto, este fenômeno é inerente ao processo de formação de imagens em sistemas de imageamento coerente como ultra-som, laser, sonar, radar etc., e estas imagens em suas diversas aplicações têm sido objeto de estudo e contribuído para o avanço científico e tecnológico. Em quaisquer que sejam as aplicações, ou seja, em imagens médicas, meteorologia, geologia, engenharia, etc., a interpretação e análise das mesmas é comprometida pela presença do ruído. É necessário que se aplique algum tipo de suavização (pré-processamento) antes de qualquer interpretação dos dados [Horgan (1994)].

O processamento digital de imagem refere-se à transformação de uma imagem para o formato digital e o seu processamento por computadores digitais [Pitas

Introdução

2

(1995)]. A finalidade deste processamento é extrair informação de imagens e transformar a imagem de tal modo que a informação seja mais facilmente discernível por um observador humano [Mascarenhas & Velasco (1989)]. Na maioria dos casos o objetivo da filtragem, que é o enfoque principal deste trabalho, é melhorar a visibilidade de detalhes na imagem ou facilitar a detecção automática de bordas e padrões de textura.

Na literatura existem vários trabalhos que investigam as propriedades estatísticas do "speckle" com vistas à filtragem do mesmo. Técnicas de filtragem passa-baixa apresentam a desvantagem de suavizar detalhes da imagem e reduzir a definição da mesma. A filtragem adaptativa, ao contrário dos filtros lineares, suaviza o ruído enquanto preserva detalhes e isto acontece pelo fato de utilizar estatísticas locais do sinal em uma vizinhança. Devido à natureza randômica deste tipo de ruído, a abordagem estatística tem sido bastante apropriada em sua análise e modelagem, produzindo melhores resultados do que os métodos tradicionais.

A metodologia proposta neste trabalho utiliza o critério "maximum a posteriori" (MAP) na estimação das imagens não ruidosas. Para a modelagem do ruído "speckle", que é inerente ao processo de formação das imagens SAR, utilizou-se o modelo multiplicativo. Os modelos de filtros estatísticos propostos neste trabalho utilizam diversas funções de distribuições "a priori" para a imagem a ser filtrada, bem como utilizam as distribuições Rayleigh e raiz de gama para modelagem do ruído "speckle" em imagens SAR obtidas por detecção linear (amplitude) com 1 e múltiplas visadas ("N looks"), respectivamente. Além destes modelos é proposto o uso de técnicas de aglomeração ("clustering") de pixels segundo suas semelhanças estatísticas, medidas pela razão de variâncias proposta por Changle Li em [Li (1988)], para a escolha formal de tamanhos de janela de filtragem. Sugere-se ainda nesta tese uma abordagem de crescimento de regiões combinada aos filtros MAP, de tal forma que as propriedades estatísticas do pixel a ser filtrado sejam calculadas nas vizinhanças crescidas em torno dele, apresentando forma e tamanho variáveis.

Os algoritmos propostos de filtragem de "speckle" são avaliados quanto à contribuição na melhoria da qualidade das imagens filtradas facilitando assim uma melhor interpretação dos dados imageados. Esta avaliação é feita sob vários aspectos e quantifica numericamente índices de redução do "speckle" em regiões homogêneas, preservação radiométrica e preservação de bordas, comparando-os com

algoritmos descritos na literatura. A investigação dos efeitos de degradação de bordas pela filtragem é verificada através uma nova técnica que se baseia na transformada de Hough [Schalkoff (1989)] e que é proposta nesta tese.

1.1 Objetivos e Contribuições do Trabalho

Os principais aspectos motivadores desta tese são a modelagem estatística do "speckle" em dados de radar de abertura sintética e a filtragem do mesmo com vistas a uma posterior segmentação e interpretação correta dos dados. Dentre os objetivos a serem atingidos neste trabalho estão:

- Propor algoritmos de filtragem do ruído "speckle" capazes de reduzir o ruído em áreas homogêneas enquanto preserva bordas.
- Avaliar os efeitos da filtragem MAP segundo a suposição de diferentes modelos de distribuição a "priori" para a imagem não ruidosa.
- Investigar os efeitos da filtragem de ruído guiada por um algoritmo de agrupamento de pixels por semelhanças estatísticas.
- Utilizar uma metodologia de avaliação de desempenho que não considere apenas o critério de melhoria da relação sinal e ruído, mas que utilize também uma ferramenta capaz de avaliar perdas de resolução devido à filtragem.
- Proposta de filtros de ruído "speckle" baseados na abordagem MAP com diferentes modelos de densidade a "priori" para a imagem a ser estimada, como a distribuição Gaussiana e algumas outras distribuições definidas na semi-reta positiva como as densidades gama, chi-quadrado, exponencial, Rayleigh, beta e log-normal. Os filtros desenvolvidos consideram o modelo Rayleigh para o "speckle" em regiões homogêneas de imagens SAR em amplitude e 1 visada e o modelo raiz de gama para imagens em amplitude e múltiplas visadas.

As contribuições originais podem ser resumidas nos seguintes tópicos:

- Formulação e implementação de algoritmos de filtragem do ruído "speckle" baseados na abordagem MAP considerando os modelos Rayleigh e raiz de gama para o "speckle" presente em imagens SAR em amplitude com 1 e múltiplas visadas, respectivamente.
- É sugerido o uso do algoritmo de agrupamento ("clustering") k-médias unidimensional sobre a razão de variâncias (R) proposta por Changle Li [Li (1988)]

obtendo-se assim uma maneira formal e não heurística como propõe o autor (vide **Tabela 2.4**), para definir tamanhos fixos de janela de filtragem. Este algoritmo é combinado à filtragem MAP e sua contribuição é agrupar em classes, pixels que apresentem semelhança estatística a partir da informação de R. Este parâmetro R deve ser calculado para todos os pixels da imagem utilizando uma janela de tamanho fixo para definir a amostra de dados sobre a qual se aplica o algoritmo de k-médias.

- Ao contrário dos algoritmos de supressão de ruído em processamento de imagens que costumam utilizar janelas quadradas ou retangulares, neste trabalho investigamos o uso de regiões de vizinhança do pixel (ruidoso) de tamanhos e formas variáveis para estimar os parâmetros de filtragem. Utiliza-se o crescimento de região nessa nova estratégia para buscar o sub-conjunto de pixels vizinhos ao que se deseja filtrar, com maior homogeneidade estatística. As propriedades estatísticas calculadas nesta região de tamanho e forma irregulares são utilizadas no filtro MAP para atualização do pixel ruidoso.
- Na avaliação do desempenho dos filtros fez-se uso de várias medidas disponíveis na literatura, como a clássica medida da relação sinal ruído e ainda é introduzida uma nova medida que avalia os efeitos da filtragem sobre a resolução da imagem utilizando a transformada de Hough.

1.2 Organização da Tese

Esta tese está organizada em 7 capítulos, incluindo as referências bibliográficas. O capítulo 2 apresenta os trabalhos revistos disponíveis na literatura que estão mais diretamente relacionados a este trabalho. Os capítulos 3, 4 e 5 apresentam respectivamente as principais ferramentas utilizadas para melhoria e avaliação do desempenho dos filtros propostos, os algoritmos propriamente ditos e os resultados de simulação. No capítulo 6 estão as conclusões gerais e sugestões para trabalhos futuros e há ainda os apêndices A, B, C, D e E que contêm tópicos da literatura relevantes a esta tese. No apêndice F são apresentados os conjuntos de imagens ruidosas utilizados para testar os algoritmos e seus respectivos resultados da aplicação dos filtros propostos.

Segue uma breve apresentação dos capítulos:

Capítulo 1: Apresenta alguns aspectos introdutórios relevantes ao texto, os principais aspectos motivadores, as metas a serem atingidas é a estrutura do trabalho.

Capítulo 2: Apresenta uma revisão bibliográfica dos principais trabalhos sobre o ruído "speckle" em imagens de radar de abertura sintética (SAR) relacionados à abordagem feita nesta tese. É feita uma breve revisão das técnicas de supressão do ruído "speckle" que adotam o modelo multiplicativo no seu desenvolvimento e alguns aspectos de modelagem estatística dos dados SAR.

Capítulo 3: Discute as principais ferramentas utilizadas neste trabalho para avaliação de desempenho dos filtros propostos e sugere uma nova técnica que investiga o efeito de degradação de bordas pela filtragem. Propõe o uso combinado dos algoritmos de k-médias e crescimento de região com os filtros MAP.

Capítulo 4: Apresenta a formulação proposta neste trabalho para os filtros de "speckle" baseados na abordagem "maximum a posteriori" com as diferentes distribuições "a priori" utilizadas e os modelos Rayleigh e raiz de gama para o "speckle" em amplitude com uma e múltiplas visadas respectivamente.

Capítulo 5: Apresenta uma síntese das aplicações dos algoritmos propostos e a discussão dos resultados experimentais obtidos.

Capítulo 6: São apresentadas as discussões gerais a respeito dos resultados e contribuições originais desta tese bem como as perspectivas futuras de trabalhos relacionados.

Apêndice A: São apresentados alguns conceitos básicos em probabilidade fundamentais à introdução do leitor de outras áreas ao assunto de que trata esta tese.

Apêndice B: Neste apêndice é feita uma introdução aos métodos de estimação de parâmetros apresentando a formulação para o método dos momentos e de máxima verossimilhança.

Apêndice C: Faz uma breve apresentação do teorema central do limite, ao qual são feitas referências especialmente na modelagem do "speckle" pela caminhada aleatória no plano complexo.

Apêndice D: Introduz o método de Newton-Raphson que é utilizado na solução iterativa de algumas equações polinomiais dos estimadores MAP.

Apêndice E: Apresenta as técnicas MaxVer e ICM (implementadas no software SPRING) que são utilizadas na etapa de classificação das imagens filtradas.

Apêndice F: Apresenta os conjuntos de imagens utilizadas para testes dos algoritmos e os respectivos resultados de aplicação dos diversas filtros.

2 Revisão Bibliográfica sobre Ruído "Speckle" em Imagens SAR

2.1 Introdução

As primeiras abordagens ao problema de filtragem do ruído "speckle" em imagens digitais foram baseadas na análise de Fourier. Nesta abordagem a transformada de Fourier 2D é aplicada à imagem, em seguida é aplicado um filtro passa-baixa, e por fim é aplicada a transformada inversa de Fourier [Lee et al. (1994)]. Poderíamos então afirmar que os filtros de supressão do ruído "speckle" deveriam apresentar uma ação combinada de suavização de regiões homogêneas (pequena variância) e preservação de detalhes e bordas (grande variância). Na literatura são apresentadas várias técnicas de filtragem considerando a natureza multiplicativa do ruído "speckle". Neste capítulo é feita inicialmente uma descrição introdutória da formação de imagens de radar de abertura sintética (SAR), que representam parte do conjunto de dados utilizados para teste dos algoritmos implementados. Nas seções seguintes apresentamos a origem e modelagem estatística do ruído "speckle" inerente às imagens geradas por fontes coerentes. Na última seção são apresentadas as técnicas de filtragem de "speckle" disponíveis na literatura.

2.2 Imagens de Radar de Abertura Sintética

A penetração das ondas eletromagnéticas na faixa das microondas em um meio é diretamente proporcional ao comprimento de onda. Desta forma quanto menor a frequência do sinal maior será sua penetração. O radar imageador ilumina a cena pela transmissão de sua própria fonte de radiação de microondas e por serem pouco atenuadas pela atmosfera ou por nuvens, permitem o uso de sensores de microondas

sob quaisquer condições atmosféricas. O espectro de radiação usado pelos radares foi dividido em faixas e foram atribuídos rótulos às mesmas como mostra a **Tabela 2.1**.

Banda	Faixa de Freqüência	Faixa de Comprimento de Onda
	(GHz)	(cm)
P	0.4 - 1	30 –75
L	1 - 2	15 – 30
S	2 - 4	7.5 –15
С	4 - 8	3.7 – 15
X	8 - 12	2.5 – 3.7

Tabela 2.1 – Bandas de freqüências¹.

Os algoritmos propostos nesta tese se aplicam a imagens SAR captadas em quaisquer das bandas de frequências apresentadas na **Tabela 2.1**, desde que as mesmas sejam obtidas por deteção linear com uma e múltiplas visadas.

A geometria de um sistema de imageamento por radar é mostrada na **Figura 2.1.** O sensor SAR (antena) é fixado na plataforma (avião ou satélite) que é deslocada a uma velocidade constante V e altura H em relação ao solo. A direção de vôo da plataforma é conhecida por azimute (perpendicular à direção de varredura ou "range") e a distância da trilha do radar, ou alcance de imageamento do radar, é medida na direção de varredura ("range"), ou seja, esta é a coordenada ao longo da linha de imageamento do radar. A antena aponta lateralmente (paralelamente) com um ângulo θ em relação ao nadir². À medida que a plataforma se desloca, o transmissor envia pulsos a intervalos regulares e registra os ecos correspondentes para um posterior processamento e formação da imagem SAR. Os sinais captados são processados para recuperar a amplitude de reflexão dos sinais no terreno que são

¹ URL: http://www.nasoftware.co.uk/sar-intro/. Consultado em 9 jun. 1998.

² ponto na superfície da terra verticalmente abaixo do centro da plataforma de sensoriamento remoto (URL: http://telsat.belspo.be//glossary/radar.html. Consultado em 23 fev. 1998).

influenciados pela condutividade do solo e pela rugosidade da superfície. É possível determinar a distância aos objetos imageados através do registro desta amplitude e do tempo de trajeto das ondas refletidas que são captadas. Cada pixel da imagem SAR resultante representa a magnitude da reflexão do sinal associado com uma coordenada em azimute e uma coordenada em varredura ("range") .

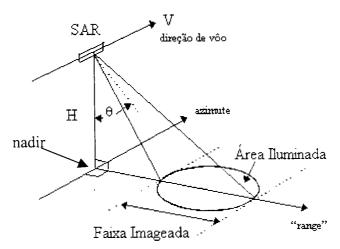


Figura 2.1 – Geometria de imageamento do sistema SAR³.

Tipicamente a antena é retangular e tem dimensões $d_a \times d_e$, onde a e e denotam azimute e elevação, respectivamente. Estas dimensões são significativas, porque determinam a área iluminada pela antena. Num instrumento ótico, a resolução é determinada pela distância ("range"), frequência e tamanho da abertura: uma grande abertura implica em uma resolução melhor. Entretanto, para obter imagens utilizando comprimentos de ondas superiores aos sistemas de radar, antenas muito grandes são requeridas. Se o radar é acoplado a uma plataforma móvel, é possível combinar os sinais refletidos ao longo de uma trilha de vôo para sintetizar uma grande antena. A abertura sintética, ou área usada para captar os sinais de retorno, é criada artificialmente durante o processamento do sinal.

A equação que relaciona o tamanho de um elemento de resolução em azimute r_a , o comprimento (abertura) da antena transmissora na direção de azimute l, o

³ http://www.dpi.inpe.br/spring/teoria/radar/radar.htm. Consultado em 28 out. 1998.

comprimento de onda λ e a distância (varredura ou "range") R_o entre o alvo e a plataforma móvel é dada por [Richards (1986)]:

$$r_a = \frac{R_0 \lambda}{l} \tag{2.1}$$

Esta expressão mostra que uma antena de 10m produz uma resolução em azimute de 20m a uma distância de 1km da fonte de radiação com comprimento de onda de 20cm. Entretanto, se esta distância for de 100km, então uma resolução de 20m em azimute implicaria numa antena de 1km de comprimento, o que se torna impraticável. A abertura sintética é resultante da simulação de uma longa antena pela utilização do movimento da plataforma de vôo durante a transmissão dos pulsos.

2.3 Origem e Modelagem do "Speckle"

As superficies de muitos materiais são extremamente rugosas na escala do comprimento de onda ótico (λ≈5x10⁻⁷m). Quando a luz refletida por uma superfície como esta é aproximadamente monocromática, a onda eletromagnética refletida de um ponto de observação distante, consiste de muitas componentes ou pequenas ondas, onde cada uma delas é proveniente de um diferente elemento microscópico da superfície iluminada. A interferência ou adição destas pequenas ondas defasadas resultam no padrão granular conhecido por "speckle". A observação destes padrões granulares desordenados em objetos visualizados sob intensa fonte de luz coerente deu-se em 1960 [Goodman (1975)]. Desde então este fenômeno tem sido investigado e os métodos da teoria de probabilidade e estatística têm sido os que melhor o descrevem. Para entender a origem física do "speckle" é essencial conhecer suas propriedades estatísticas. As estatísticas de primeira ordem da amplitude, intensidade e fase do "speckle" são derivadas da caminhada aleatória no plano complexo [Goodman (1975)] e serão mostradas na seção a seguir.

2.3.1 Caminhada Aleatória no Plano Complexo

Seja u(x,y,z,t) a representação analítica da componente de um campo elétrico em um ponto de observação (x,y,z) e no instante t. Para uma onda monocromática, o sinal analítico é descrito pela expressão:

$$u(x, y, z;t) = A(x, y, z) \exp(i2\pi vt)$$
 (2.2)

onde v é a frequência, e A representa o fasor de amplitude do campo que é dado por:

$$A(x, y, z) = |A(x, y, z)| \exp[i\theta(x, y, z)]$$
(2.3)

A intensidade do campo ou irradiância é dada pela seguinte equação:

$$I(x, y, z) = |A(x, y, z)|^{2}$$
 (2.4)

Considerando que a amplitude do campo em um determinado ponto de observação consiste das múltiplas contribuições dos diferentes elementos espalhadores da superfície rugosa, a representação deste fasor de amplitude é dada pelo somatório destas (N) contribuições $(\frac{1}{\sqrt{N}})a_k(x,y,z)$, k=1,2,...N como mostra a expressão:

$$A(x, y, z) = \sum_{k=1}^{N} \frac{1}{\sqrt{N}} a_k(x, y, z) = \frac{1}{\sqrt{N}} \sum_{k=1}^{N} |a_k| e^{i\Phi_k}$$
 (2.5)

Denomina-se à representação fasorial deste campo e suas contibuições no plano complexo de caminhada aleatória. A **Figura 2.2** ilustra a representação fasorial da caminhada aleatória, onde A é a resultante da soma das N contribuições.

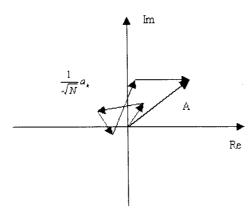


Figura 2.2 - Caminhada aleatória no plano complexo.

Considerando a hipótese de que a fase (Φ_k) e a amplitude (a_k) do k-ésimo elemento fasorial são estatisticamente independentes entre si e das amplitudes e fases dos outros elementos, e a hipótese de que as fases dos elementos são uniformemente distribuídas no intervalo $(-\pi,\pi)$, as propriedades estatísticas do campo complexo resultante são derivadas em [Goodman (1975)]. Sejam as partes real e imaginária do campo descritas por:

$$A^{(r)} = \frac{1}{\sqrt{N}} \sum_{k=1}^{N} |a_{k}| \cos \Phi_{k}$$

$$A^{(i)} = \frac{1}{\sqrt{N}} \sum_{k=1}^{N} |a_{k}| \sin \Phi_{k}$$
(2.6)

Então as esperanças matemáticas das partes real e imaginária do fasor complexo podem ser calculadas pela expressão:

$$E[A^{(r)}] = \frac{1}{\sqrt{N}} \sum_{k=1}^{N} E[|a_k|] E[\cos \Phi_k]$$

$$E[A^{(i)}] = \frac{1}{\sqrt{N}} \sum_{k=1}^{N} E[|a_k|] E[\sin \Phi_k]$$
(2.7)

Utilizando-se as hipóteses acima mencionadas sobre a distribuição uniforme das fases temos:

$$E[\cos \Phi_k] = E[\sin \Phi_k] = 0$$

$$E[A^{(r)}] = E[A^{(i)}] = 0$$
(2.8)

Similarmente é provado que os momentos de segunda ordem das partes real e imaginária do campo complexo são iguais e que estas componentes são ortogonais, ou seja,

$$E\left[\left(A^{(r)}\right)^{2}\right] = E\left[\left(A^{(i)}\right)^{2}\right] = \sigma^{2}$$

$$E\left[A^{(r)}A^{(i)}\right] = 0$$
(2.9)

No caso do número de fasores elementares, N, ser muito grande, as partes real $(A^{(r)})$ e imaginária $(A^{(i)})$ do campo serão a soma de um número grande de variáveis aleatórias independentes. Pelo teorema central do limite [Apêndice C] $A^{(r)}$ e $A^{(i)}$ são assintoticamente Gaussianas e portanto, a densidade conjunta das partes real e imaginária do campo é assintoticamente Gaussiana [Gibra (1973)], ou seja,

$$p_{A^{(i)}A^{(r)}}\left(A^{(i)}A^{(r)}\right) = \frac{1}{2\pi\sigma^2}e^{-\frac{\left(A^{i}\right)^2 + \left(A^{r}\right)^2}{2\sigma^2}}$$
(2.10)

Em muitos experimentos físicos o sinal medido pode ser em amplitude (x_A) ou em intensidade (I) e nestes casos tem-se os sinais definidos pelas expressões:

$$I = (A^{(i)})^2 + (A^{(r)})^2$$

$$x_A = \sqrt{I}$$

$$\theta = \tan^{-1} \frac{A^{(i)}}{A^{(r)}}$$
(2.11)

A Figura 2.3 mostra o campo detetado (fasor resultante) como sendo um campo complexo e o quadrado do módulo do campo chamado de sinal intensidade (I), enquanto que a raiz quadrada da intensidade é chamada de amplitude (x_A). Similarmente na Figura 2.5 é exibido graficamente o sinal em intensidade.

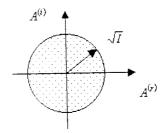


Figura 2.3 – Sinal em amplitude.

Aplicando-se técnicas de transformações de variáveis aleatórias nas **Equações 2.11** e **2.16** verifica-se que a amplitude (x_A) obedece a uma distribuição Rayleigh e a intensidade (I) do campo obedece a uma exponencial negativa com a fase obedecendo a uma distribuição uniforme, como mostram os histogramas dos padrões de amplitude na **Figura 2.4** e intensidade na **Figura 2.6**.

A função de densidade de x_A obedece a uma distribuição Rayleigh, sua média e variância são dadas pelas expressões:

$$p_{x_A}(x_A) = \frac{x_A}{\sigma^2} e^{-\frac{x_A^2}{2\sigma^2}}, x_A \ge 0$$
 (2.12)

$$E[x_A] = \sigma \sqrt{\frac{\pi}{2}} \tag{2.13}$$

$$Var\left[x_{A}\right] = \left(2 - \frac{\pi}{2}\right)\sigma^{2} \tag{2.14}$$

Uma propriedade interessante dessa distribuição é que a relação sinal-ruído definida pela razão entre o desvio padrão e a média é uma constante e é dada por:

$$SNR = \beta = \frac{\sqrt{Var(x_A)}}{E[x_A]}$$

$$\beta = \sqrt{\frac{4}{\pi} - 1} = 0.5227$$
(2.15)

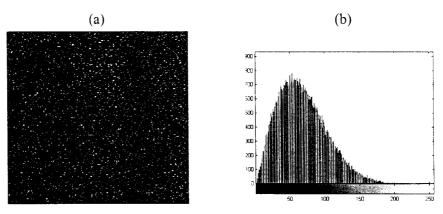


Figura 2.4 – (a) Padrão de "speckle" em amplitude e respectivo (b) histograma.

Conhecendo a estatística da amplitude complexa pode-se da mesma forma obter as estatísticas da intensidade do padrão de "speckle" como segue:

$$I = (A^{(i)})^{2} + (A^{(r)})^{2}$$

$$\theta = \tan^{-1} \frac{A^{(i)}}{A^{(r)}}$$
(2.16)

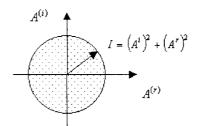


Figura 2.5 – Sinal em intensidade.

A função de densidade de I obedece a estatística de uma distribuição exponencial negativa, enquanto a fase (θ) obedece a uma distribuição uniforme como mostram as expressões:

$$p_{I}(I) = \frac{1}{2\sigma^{2}} e^{-\frac{1}{2\sigma^{2}}} , I \ge 0$$

$$p_{\theta}(\theta) = \frac{1}{2\pi} , -\pi \le \theta \le \pi$$

$$(2.17)$$

E como a função de densidade de probabilidade conjunta de I e θ é dada por:

$$p_{I,\theta}(I,\theta) = \frac{1}{4\pi\sigma^2} e^{\frac{1}{2\sigma^2}} , I \ge 0, -\pi \le \theta \le \pi$$
 (2.18)

observa-se que a intensidade e a fase são estatisticamente independentes pois

$$p_{I,\theta}(I,\theta) = p_{\theta}(\theta)p_{I}(I) \tag{2.19}$$

Neste caso a razão entre o desvio padrão e a média da intensidade observada é unitária.

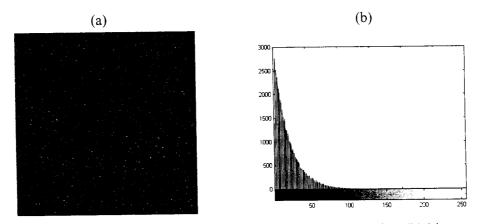


Figura 2.6 – (a) Padrão de "speckle" em intensidade e respectivo (b) histograma.

Uma prática comum para reduzir o "speckle" é fazer a média de N imagens (N visadas) independentes de uma mesma cena [Lee et al. (1994)]. O número de visadas ("looks") numa imagem mede a quantidade de informação usada para formar cada valor de pixel. Na prática, para imagens SAR, isso é feito dividindo-se o comprimento da abertura sintética (ou o espectro de frequência Doppler) em N segmentos. Cada segmento é processado independentemente para formar uma imagem amplitude ou intensidade e as N imagens são somadas para juntas formarem uma imagem SAR de N visadas (N-"looks") [Lee et al. (1994)]. Este processamento de múltiplas visadas (N "looks") compromete a resolução em azimute da imagem, embora reduza o desvio padrão do "speckle" de \sqrt{N} . Dessa forma, a obtenção de imagens amplitude com múltiplas (N) visadas pode resultar de duas alternativas:

(1) fazendo a média de N imagens amplitudes independentes (x_{Ai}) , ou seja,

$$(x_A)_{N_{-} \text{Visadas}} = \frac{1}{N} \sum_{i=1}^{N} x_{Ai}$$
 (2.20)

(2) fazendo a média de N imagens intensidade (x_{li}) e aplicando a raiz quadrada ao resultado, ou seja,

$$(x_A)_{N_{\perp} Visadas} = \sqrt{\frac{1}{N} \sum_{i=1}^{N} x_{Ii}}$$
 (2.21)

No caso (2) tem-se uma expressão exata para a função densidade de probabilidade e no caso (1) a função densidade de probabilidade é uma aproximação e é obtida da convolução de N distribuições Rayleigh, cuja forma fechada para N=2 existe, mas para N≥3 costuma-se fazer uma aproximação por não existir uma forma fechada [Yanasse et al. (1995)] e a função densidade de probabilidade é descrita pela raiz quadrada da gama como mostra a equação:

$$p(x_A) = \frac{2N^N}{\sigma^{2N} \Gamma(N)} x_A^{2N-1} e^{-Nx^2/\sigma^2}$$
 (2.22)

com média e variância dadas pelas expressões [Lee et al. (1994)]:

$$E[x_A] = \frac{\Gamma(N+1/2)}{\Gamma(N)} \sqrt{\sigma^2/N}$$
 (2.23)

$$Var[x_A] = \left(N - \frac{\Gamma^2(N+1/2)}{\Gamma^2(N)}\right) \sigma^2 / N$$
 (2.24)

A razão entre o desvio padrão e a média (ou desvio padrão do "speckle") para imagem SAR em amplitude e múltiplas visadas é dada pela expressão:

$$\sigma_n = \frac{\sigma_z}{\mu_z} = \sqrt{\frac{N\Gamma^2(N)}{\Gamma^2(N+1/2)} - 1}$$
 (2.25)

onde $\Gamma(.)$ representa a função gama.

Para o caso (1) a expressão da relação sinal-ruído, ou desvio padrão do "speckle" utilizando a **Equação 2.15** é obtida da expressão:

$$\left(\sigma_n^2\right)_{N_Visadas} = \frac{\left(\sigma_n^2\right)_{1_Visada}}{N}$$

$$\sigma_n = \frac{\sqrt{\frac{4}{\pi} - 1}}{\sqrt{N}} = \frac{0.5227}{\sqrt{N}}$$
(2.26)

O número equivalente de visadas ("looks") ou ENL ("equivalent number of looks") é dado pela equação:

$$ENL_A = N$$

$$N = 0.2732 \frac{1}{\sigma_n^2}$$
(2.27)

Observa-se da **Tabela 2.2** que é mínima a diferença do cálculo do desvio padrão do ruído "speckle" considerando as duas alternativas citadas anteriormente para a obtenção da imagem amplitude com múltiplas (*N*) visadas.

Número de Visadas
(Looks)
N $\sigma_n = \frac{\sigma_Z}{Z}$ Média de AmplitudesRaiz da Intensidade Média10.522720.36960.363030.30170.2941

Tabela 2.2 – Valor teórico de σ_n para detecção linear.

Para a obtenção de imagens SAR em intensidade com múltiplas visadas o processo é análogo, ou seja, faz-se a média de N imagens intensidades independentes cuja distribuição resultante da média de N imagens com distribuição exponencial negativa é a distribuição gama. No contexto desta tese são utilizadas as notações x_I e I para fazer referência à imagem intensidade. A função de densidade gama, sua esperança matemática e variância são dadas pelas expressões [Lee et al. (1994)]:

$$f(x_I) = \frac{N^N x_I^{N-1}}{\Gamma(N)\sigma^{2N}} e^{-\frac{Nx_I}{\sigma^2}} , x_I \ge 0$$
 (2.28)

$$E[x_t] = \sigma^2 \tag{2.29}$$

$$Var[x_{I}] = \frac{\sigma^{4}}{N}$$
 (2.30)

onde $\Gamma(N)$ é o valor da função gama e x é uma variável aleatória com parâmetros σ e N. Para N=1 a distribuição gama é idêntica à distribuição exponencial e para $N=\lambda/2$ ($\lambda>0$) e $\sigma=1/2$ a distribuição gama é idêntica à distribuição chi-quadrado com λ graus de liberdade.

A razão entre o desvio padrão e a média (ou desvio padrão do "speckle") para imagem SAR em intensidade e múltiplas visadas é dada pela expressão:

$$\sigma_n = \frac{1}{\sqrt{N}} \tag{2.31}$$

O número equivalente de visadas ou número de "looks" é o inverso da variância do ruído e para imagens obtidas por detecção quadrática (intensidade) é dado por:

$$ENL_I = N = \frac{1}{\sigma_n^2} \tag{2.32}$$

A **Tabela 2.3** apresenta os resultados da relação entro o desvio padrão e a média sobre regiões homogêneas para imagens obtidas por detecção quadrática.

Tabela 2.3 – Valor teórico de σ_n para detecção quadrática.

Número de σ_z Visadas (Looks)

Número de Visadas (Looks)	σ_z/z
N	
1	1
2	0.7071
4	0.5

2.4 Modelo Multiplicativo

Tem sido experimentalmente verificado que, sobre regiões homogêneas, o desvio padrão do sinal é proporcional à sua média [Lee (1981)]. Este fato sugere o uso do modelo multiplicativo para o "speckle" e tem sido muito utilizado na

modelagem de dados SAR e de outras imagens geradas por fonte de luz coerente. Para a formulação dos algoritmos de filtragem será utilizado o modelo multiplicativo descrito pela seguinte equação:

$$z = xn \tag{2.33}$$

A variável z corresponde à versão ruidosa da imagem x, e n é o ruído de média unitária estatisticamente independente da imagem real x, que modela o "backscatter" do terrreno que é sempre considerado positivo. Neste trabalho supõem-se várias distribuições para o "backscatter" do terreno. O modelo multiplicativo se aplica às imagens com detecção linear e quadrática, ou seja, para imagens em amplitude e intensidade. Os modelos de distribuições geralmente atribuídos ao ruído "speckle" em imagem obtidas por detecção linear com uma e múltiplas visadas são Rayleigh e raiz de gama respectivamente. No caso de imagens obtidas por deteção linear, a modelagem para regiões homogêneas parte da hipótese básica que o "backscatter" desconhecido embora constante, possui um valor [Vieira (1996)] e que leva a um retorno (observação ruidosa) que segue uma distribuição Rayleigh para imagens obtidas por detecção linear e 1 visada e um retorno que segue uma distribuição raiz quadrada da gama para imagens obtidas por detecção linear e múltiplas visadas.

Na ausência de um modelo preciso para o sinal x, utiliza-se a própria imagem ruidosa para estimar a média e variância "a priori" utilizando a média e variância locais calculadas numa janela fixa [Lee et al. (1994)] segundo as Equações 2.34 e 2.37. Considerando o fato de que o ruído apresenta média unitária ($\bar{n} = 1$), serão apresentadas as expressões de variância do ruído (σ_n^2) e da cena original (σ_x^2) que são obtidas a partir do modelo multiplicativo. A barra sobre a variável também indica esperança matemática além da notação $E[\]$, já usada em seções anteriores.

$$\overline{z} = \overline{x}\overline{n} = \overline{x} \tag{2.34}$$

ou ainda,

$$E[z] = E[x] \tag{2.35}$$

$$\sigma_{z}^{2} = E[(z - \overline{z})^{2}] = E[(xn - \overline{xn})^{2}]$$

$$\sigma_{z}^{2} = E[x^{2}]E[n^{2}] - \overline{x}^{2}\overline{n}^{2}$$
(2.36)

Considerando-se que as medições são efetuadas em regiões homogêneas, $E[x^2] = \overline{x}^2$, e fazendo-se algumas manipulações matemáticas obtêm-se as expressões da variância do ruído e da cena original como mostram as expressões a seguir:

$$\sigma_z^2 = \overline{x}^2 \sigma_n^2$$

$$\sigma_n = \frac{0.5227}{\sqrt{N}}$$

$$\sigma_x^2 = \frac{\sigma_z^2 - \sigma_n^2 \overline{z}^2}{1 + \sigma_n^2}$$
(2.37)

O valor teórico de σ_n é conhecido e depende do tipo de detecção (linear ou quadrática) e do número de visadas (N) segundo a **Tabela 2.2.** Em imagens SAR obtidas por detecção linear (amplitude) e 1 visada, o valor de σ_n é 0.5227.

Um dos critérios para avaliação de desempenho dos filtros redutores de "speckle" é o índice β , calculado sobre regiões homogêneas da imagem a partir da razão entre o desvio padrão e a média. Quanto menor for este valor calculado sobre áreas homogêneas da imagem, maior será a redução do ruído. A expressão deste índice é a seguinte:

$$\beta = \frac{\sigma_z}{\bar{z}} \tag{2.38}$$

2.5 Revisão das Técnicas de Filtragem de "Speckle"

Uma classe de filtros adaptativos que usa média e variância amostrais de pixels foi desenvolvida por [Lee (1980)] para superar a suavização indiscriminada do filtro da média. Estes filtros são chamados adaptativos por utilizarem informações de uma vizinhança próxima ao pixel a ser processado e podem ser usados em imagens corrompidas por ruído aditivo, multiplicativo ou uma combinação de ambos. Alguns destes filtros diferem no critério de minimização como o filtro de Lee [Lee (1981)]

que utiliza o critério de minimização do erro médio quadrático enquanto Lopes e seus colaboradores [Lopes et al. (1993)] propõem um filtro que se baseia no critério "maximum a porteriori" (MAP) para imagem intensidade (detecção quadrática) com uso das distribuições gama e beta como conhecimento "a priori". Estes filtros, independentes dos critérios utilizados, têm por objetivo melhorar visualmente as imagens SAR e portanto, possibilitar a percepção de estruturas e detalhes das mesmas. O grande desafio destes algoritmos propostos na literatura é filtrar o ruído "speckle" nas imagens preservando detalhes e bordas.

Um exemplo de aplicação é a imagem (APTO) da Figura 2.7a contaminada artificialmente por ruído multiplicativo em amplitude e 1 visada, ou seja, com desvio padrão 0.5227 e média unitária. A imagem real SAR (Figura 2.7b) utilizada foi obtida por um sistema aerotransportado (SAR580) sobre a região de Freiburg na Alemanha, e corresponde a um pedaço de imagem de 512x512 pixels, banda L, 1 visada e detecção linear com resolução de 1,5m/pixel. Nesta imagem estão presentes florestas de caducifólias que cobrem boa parte da imagem, alguns campos de culturas, construções (canto superior) e tanques de tratamento de esgotos (canto inferior direito).

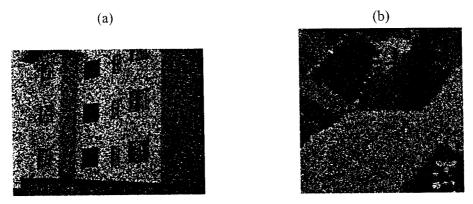


Figura 2.7 - (a) Imagem APTO (b) imagem SAR580.

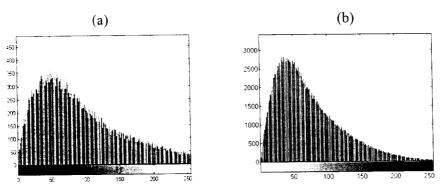


Figura 2.8 - Histogramas (a) imagem APTO (b) imagem SAR580.

Alguns exemplos de aplicação de alguns filtros de redução de ruído serão apresentados nesta seção a seguir.

Filtros da Mediana e da Média

Dentre as técnicas de filtragem de sinal e imagem, os filtros da média e da mediana [Pratt (1991)] são os mais conhecidos. Neste último toma-se para cada pixel p uma vizinhança contendo um número ímpar de pixels (n), que pode ser unidimensional (com filtragem sucessiva em linhas e colunas) ou 2-D. A mediana m_p desse conjunto de pixels é obtida ordenando-se os mesmos numa lista segundo seu valor em intensidade. O pixel a ser filtrado então é atualizado com o valor intermediário dessa lista ordenada. Observa-se que esse filtro elimina valores de intensidade discrepantes na imagem, pois se esses valores diferem muito dos demais eles não são a mediana dos pixels naquela vizinhança. Também no domínio espacial os filtros de média móvel (passa-baixa) podem ser utilizados para redução de ruído fazendo-se uso de uma simples janela que desliza por toda imagem atualizando os pixels por uma média dos seus vizinhos dentro da mesma. Este tipo de filtro é bem geral e não adota nenhum modelo para o ruído. Uma desvantagem da técnica passabaixa em quaisquer dos dois domínios, a saber, frequência e espaço, é a suavização indiscriminada de toda a imagem, inclusive bordas e detalhes. Em consequência da perda de resolução resultante deste tipo de filtragem, tarefas posteriores de segmentação e interpretação destas imagens tornam-se mais difíceis de serem executadas.

FSC-USD SERVIÇO DE BIBLIOTECA INFORMAÇÃO

Filtragem Homomórfica

As técnicas de filtragem podem ser aplicadas no domínio do logaritmo da intensidade (o chamado domínio da densidade da imagem). A justificativa para isto pode ser apresentada em termos de transformar o ruído multiplicativo em aditivo, aplicar técnicas de filtragem de ruído aditivo e independente de sinal e voltar ao domínio original pela transformação exponencial. Os objetivos de aplicar a filtragem homomórfica consistem em estabelecer uma representação da imagem de saída que use a faixa dinâmica da intensidade da imagem e realçar as regiões de alta frequência [Schalkoff (1989)]. Arsenault & April [Arsenault & April (1976)] aplicaram esta transformação em imagens contaminadas pelo ruído "speckle". Os autores mostraram que sob certas condições, o padrão de "speckle" presente em imagens intensidade com múltiplas (N) visadas submetido a uma transformação logarítmica é aproximadamente um ruído aditivo Gaussiano com variância igual a 1/N se N é muito grande.

A Equação 2.39 mostra a transformação logarítmica sobre a imagem ruidosa (z=xn), convertendo o modelo multiplicativo em aditivo (ruído independente do sinal) como segue:

$$\log z = \log x + \log n \tag{2.39}$$

Uma vez convertido o modelo, qualquer filtro de remoção de ruído aditivo pode ser aplicado à imagem degradada. Tais filtros podem ser implementados no domínio da frequência, utilizando a Transformada Rápida de Fourier (FFT). No estágio final uma função exponencial é aplicada para retornar ao modelo original da imagem estimada.

Um exemplo de implementação de um filtro pontual no domínio espacial é mostrado utilizando o filtro de Wiener [Pratt (1991)] que é a estimativa ótima de x minimizando o erro quadrático médio.

$$\hat{x} = \overline{z} + H(z - \overline{z}) \tag{2.40}$$

$$H = \frac{\sigma_x^2}{\sigma_x^2 + \sigma_n^2} \tag{2.41}$$

onde σ_n^2 é a variância do ruído. Um esquema em diagrama de blocos que poderia resumir a abordagem homomórfica é apresentado a seguir:



Figura 2.9 – Filtragem homomórfica.

Sadjadi [Sadjadi (1990)] observou em seus experimentos que a técnica de filtragem homomórfica não é capaz de separar completamente o sinal do ruído e que não observou ganhos com esta técnica. O autor ressalta ainda que não há evidências conclusivas da superioridade da filtragem homomórfica sobre a filtragem convencional e que este fato é devido parcialmente à função característica linear do sensor imageador, que é ignorada na formulação z=xn. Uma possível solução seria deconvoluir o dado observado para remover os efeitos do sistema linear e então aplicar a filtragem homomórfica. Infelizmente, o desempenho das técnicas de deconvolução degrada rapidamente à medida que a relação sinal-ruído diminui e como as imagens de radar apresentam baixa relação sinal-ruído, a filtragem inversa não produz imagens com qualidade aceitáveis [Frost et al. (1982)].

• Filtro de Lee

Em [Lee (1980)] é feita uma expansão de primeira ordem em série de Taylor (uma aproximação) para o valor do pixel observado. A linearização do pixel ruidoso utilizando o modelo multiplicativo (Equação 2.33) é feita sobre \bar{x}, \bar{n}) como mostra a expressão[Lee (1980)]:

$$z' = \overline{nx} + \overline{x}(n - \overline{n}) + \overline{n}(x - \overline{x})$$
 (2.42)

como $\overline{n} = 1$, o valor linearizado (z') é dado pela expressão:

$$z' = x + \overline{x}(n-1) \tag{2.43}$$

O filtro linear resultante utiliza estatística local e minimiza o erro quadrático médio e é dado pela expressão:

$$\hat{x} = \overline{z} + K(z - \overline{z}) \tag{2.44}$$

(2.45)

onde \hat{x} é o valor estimado, o parâmetro de ponderação $K \in [0,1]$ e σ_x^2 , repetida aqui por conveniência, denota a variância estimada para a cena não ruidosa. Em casos de vizinhanças livres de bordas (áreas homogêneas), a estimativa do pixel não ruidoso é a própria média calculada em uma janela pois o valor de $\sigma_x^2 \approx 0$. Em regiões próximas a bordas temos $\sigma_x^2 >> 0$ e portanto a estimativa é o próprio pixel. Convém salientar que valores de $\sigma_x^2 < 0$ não são consistentes com o modelo e nestes casos o pixel estimado é atualizado pela média local, pois se trata de uma região com baixo número de refletores, não satisfazendo portanto as condições de aplicação do teorema central do limite [Apêndice C].

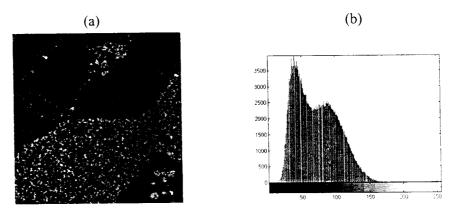
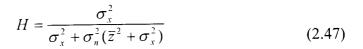


Figura 2.10 - Imagem (SAR580) filtrada pelo filtro (a) Lee e(b) respectivo histograma.

• Filtro de Kuan-Curlander

Kuan e seus colaboradores [Kuan et al. (1987)] consideraram o modelo multiplicativo para o "speckle" e propõem, neste artigo, um filtro pontual que minimiza o erro quadrático médio nos moldes do filtro de Lee com a diferença de que o filtro proposto não envolve aproximação por expansão de primeira ordem da série de Taylor, embora as expressões de cálculo das estatísticas locais sejam as mesmas ($\bar{z} \in \sigma_z^2$) [Mascarenhas (1996b)]. O filtro de Kuan apresenta a seguinte expressão para o estimador de x e para o fator de ponderação da filtragem H:

$$\hat{x} = \overline{z} + H(z - \overline{z}) \tag{2.46}$$



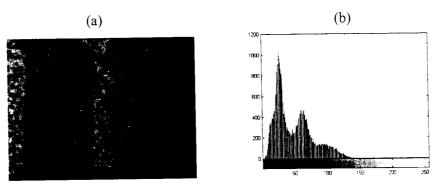


Figura 2.11 - Imagem (*APTO*) filtrada pelo filtro (a) Kuan e (b) respectivo histograma.

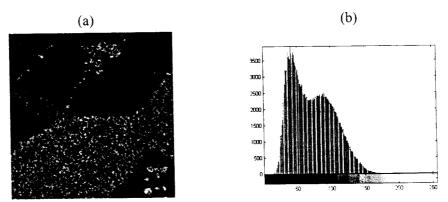


Figura 2.12 - Imagem (*SAR580*) filtrada pelo filtro (a) Kuan e (b) respectivo histograma.

• Janelamento Adaptativo

Li [Li (1988)] introduziu a razão das variâncias, (R), das imagens original (estimada pela Equação 2.37) e ruidosa como uma forma de estabelecer limiares para a escolha do tamanho da janela de filtragem, para estimação das estatísticas locais. Esta razão R varia normalmente de 0 a 1, podendo ainda assumir valores negativos como nos casos de regiões muito homogêneas onde falha o modelo de caminhada aleatória, resultando assim em um numerador negativo.

$$R = \frac{\sigma_x^2}{\sigma_z^2} = \frac{\sigma_z^2 - \sigma_n^2 \overline{z}^2}{\sigma_z^2 (1 + \sigma_n^2)}$$
 (2.48)

Como se pode avaliar da **Equação 2.48**, valores muito próximos de 0 são indicativos de regiões homogêneas e implicam em maiores janelas de filtragem como indica a **Tabela 2.4**. À medida que este valor se aproxima de 1 estas janelas diminuem significando que estas regiões são de alto contraste ou elevada variância (por exemplo, detalhes, bordas etc.). O problema com esta técnica é a escolha empírica dos limiares de *R* para determinar o tamanho da janela.

Uma das contribuições desta tese é a proposição de um critério formal para a escolha destes limiares utilizando o algoritmo de k-médias comentado em capítulos posteriores. Os autores utilizaram valores de R calculados em uma janela 5x5, e de acordo com o valor obtido, um tamanho de janela segundo os limiares estabelecidos por Li [Li (1988)] é escolhido para computar a estatística local como mostra a Tabela 2.4. A Figura 2.13 mostra o resultado de aplicação do filtro de Kuan-Curlander [Nathan & Curlander (1987)] com janelamento adaptativo à imagem SAR580.

Tabela $2.4 - R \times j$ anela.

R	Janela
0≤ <i>R</i> <0.2	9X9
0.2≤R<0.4	7X7
0.4≤R<0.6	5X5
0.6≤R<0.8	3X3
0.8≤R<1.0	próprio pixel

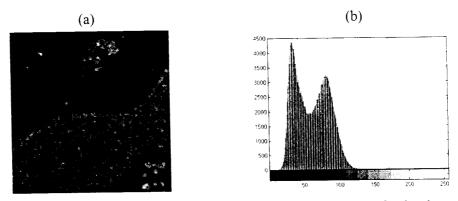


Figura 2.13 - Imagem (*SAR580*) (a) filtrada pelo filtro Kuan-Curlander com janelamento adaptativo e (b) respectivo histograma.

• Filtro de Frost

Trata-se de um filtro adaptativo convolucional de mínimo erro médio quadrático com base no modelo multiplicativo proposto por Frost [Frost et al. (1982)]. Sua característica principal é a dependência entre pixels vizinhos incorporada por uma função de correlação espacial do tipo exponencial. É um filtro adaptativo que preserva a estrutura de bordas [Sant'Anna (1995)] da imagem.

A expressão que modela o ruído "speckle" adotado por Frost [Frost et al. (1982)] é dada por:

$$y = (xn) * h \tag{2.49}$$

 \cdot onde h corresponde à resposta impulsiva do sistema.

Embora o algoritmo tenha sido desenvolvido para qualquer tipo de resposta do sistema, a função h em aplicações práticas é suposta como sendo uma função delta (isto é, assume-se que a função densidade do espectro de potência de h é constante na faixa de interesse) [Lee et al. (1994)] implicando assim na independência das variáveis x e n e valendo o modelo multiplicativo. O filtro de Frost apresenta a seguinte estrutura:

$$\hat{x}(t) = y(t) * m(t)$$
 (2.50)

onde \hat{x} e y são respectivamente o sinal estimado e o sinal ruidoso, t corresponde à distância entre os pixels no domínio espacial. A função de resposta impulsiva, m(t) é escolhida para minimizar:

$$J = E[(\hat{x}(t) - x(t))^{2}]$$
 (2.51)

A solução pode ser encontrada seguindo a derivação do filtro de Wiener no domínio da frequência [Lee et al. (1994)]:

$$m(t) = \alpha e^{-\alpha|t|} \tag{2.52}$$

onde

$$\alpha^2 = \frac{2}{\sigma_n^2} \left[\frac{\sigma_x^2}{\sigma_x^2 + \overline{x}} \right] + a \tag{2.53}$$

A constante de decaimento α depende de \overline{x} , σ_x^2 , σ_n^2 e a, sendo que a normalmente é considerada uma constante. No cálculo de \overline{x} e σ_x^2 são utilizadas a média e a variância amostrais calculadas numa janela 5x5. O valor da variância do ruído (σ_n^2) vai depender do tipo de detecção (linear ou quadrática) e do número de visadas (vide **Tabela 2.2** ou **Tabela 2.3**, conforme o caso).

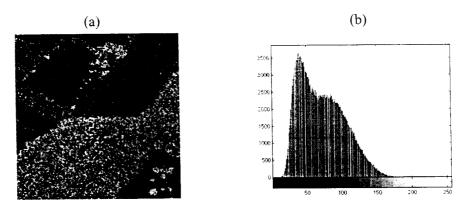


Figura 2.14 - Imagem (*SAR580*) filtrada pelo filtro (a) Frost e (b) respectivo histograma.

• Filtro de Tomita & Tsuji

Tomita & Tsuji [Tomita & Tsuji (1977)] propuseram um filtro de suavização que resolve o conflito entre a eliminação de ruído e a degradação de bordas,

definindo o tamanho e a geometria da vizinhança local envolvida no cálculo da média. A remoção do ruído é feita buscando a vizinhança mais homogênea ao redor de cada pixel na imagem e atribuindo ao mesmo o nível de cinza médio da vizinhança selecionada. No filtro de variância mínima proposto por Tomita & Tsuji [Tomita & Tsuji (1977)] a média μ e a variância σ^2 são avaliadas em 5 subjanelas (2r+1)x(2r+1) compostas dentro de uma janela (4r+1)x(4r+1) e a saída do filtro (\hat{x}) é definida como a média da subjanela que tem menor variância entre as 5, ou seja, $(\hat{x}_{ij} = \mu_{kl})$.

$$(k,l) = \arg\min\{\sigma_{ij}^2, \sigma_{i-m,j-m}^2, \sigma_{i+m,j-m}^2, \sigma_{i-m,j+m}^2, \sigma_{i+m,j+m}^2\}$$
(2.54)

e arg min significa que (k,l)=(i+m,j-m) se $\sigma_{i+m,j-m}^2$ for a menor entre as 5 variâncias calculadas. Na **Figura 2.15** são apresentadas as vizinhanças de Tomita & Tsuji.

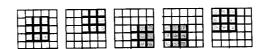


Figura 2.15 - Vizinhanças de Tomita & Tsuji.

Filtro de Nagao & Matsuyama

O filtro de Nagao & Matsuyama [Nagao & Matsuyama (1979)] foi projetado para remover ruído aditivo sem borrar bordas e detalhes em imagens digitalizadas, aprimorando assim o filtro de Tomita & Tsuji [Tomita & Tsuji (1977)]. Foram redefinidos o tamanho e a geometria das áreas das vizinhanças, originalmente quadradas, (vide Figura 2.16), permitindo a preservação de bordas em regiões de formas mais complexas. O algoritmo busca a vizinhança mais homogênea em torno do pixel ruidoso e atualiza este pixel com a média dos níveis de cinza dos pixels desta vizinhança. A remoção do ruído é feita pelo uso repetido do método, que é iterativo e durante as iterações as bordas vão se definindo melhor.

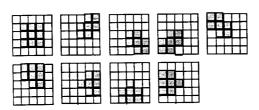


Figura 2.16 - Vizinhanças de Nagao & Matsuyama.

• Abordagem "Maximum a Posteriori" (MAP)

Kuan e seus colaboradores [Kuan et al. (1987)] utilizaram a abordagem Bayesiana para propor um filtro MAP para redução do "speckle" em imagens com detecção quadrática (intensidade) com 1 e múltiplas visadas (N "looks"). O modelo maximiza o critério de Bayes com respeito a x que é o sinal a ser estimado como mostra a equação:

$$f(x | z) = \frac{f(z | x)f(x)}{f(z)}$$
 (2.55)

onde f(x) corresponde ao modelo da cena original sem ruído e f(z|x) é o termo de máxima verossimilhança que descreve a variável observada, dado o modelo do ruído. Este termo corresponde à densidade condicional que modela o ruído "speckle" e segue uma distribuição gama, (vide **Equação 2.28**) exceto pelo fato da variável x_t ser substituída por z e σ^2 por x [Lee et al. (1994)] como mostra a expressão a seguir:

$$f(z \mid x) = \frac{N^{N} z^{N-1}}{\Gamma(N) x^{N}} \exp\left(-\frac{Nz}{x}\right)$$
 (2.56)

Como mostra a **Equação** 2.55, a abordagem MAP incorpora o conhecimento "a priori" da cena que se quer estimar e o modelo de ruído que contamina esta cena. Na proposta de Kuan [**Kuan et al. (1987)**] é suposto que as flutuações da cena em intensidade obedecem a uma distribuição Gaussiana, ou seja, para a derivação da 'equação polinomial do estimador MAP foi incorporado o modelo "a priori" Gaussiano dado por:

$$f(x) = \frac{1}{\sqrt{2\pi\sigma_x^2}} \exp\left[\frac{-(x-\bar{x})}{2\sigma_x^2}\right]$$
 (2.57)

com média \bar{x} e variância σ_x^2 , ambas estimadas localmente segundo as **Equações** 2.34 e 2.37 respectivamente. O estimador de x é obtido da maximização da equação:

$$\log f(z \mid x) + \log f(x) \tag{2.58}$$

com respeito a x e desse modo a contribuição de f(z) é desconsiderada, pois não depende de x. O estimador de x é a solução da **Equação 2.59**, que estiver entre o

pixel observado e a média, ou seja, a solução é a raiz real e positiva da expressão abaixo:

$$x^{3} - \overline{x}x^{2} + N^{2}\sigma_{x}^{2}x - N\sigma_{x}^{2}z = 0$$
 (2.59)

Assumindo N=1, a equação MAP para 1 visada é obtida de maneira similar.

Mais tarde, Lopes e seus colaboradores [Lopes et al. (1990)] fizeram uma nova proposta de filtros MAP, nos quais o modelo "a priori" Gaussiano foi substituído pelas distribuições beta e gama, ainda com detecção quadrática. Os autores concluiram que, para áreas de vegetação, o conhecimento "a priori" gama, ou seja, o filtro MAP gama-gama se ajustava melhor e que para regiões heterogêneas o modelo MAP originalmente proposto por [Kuan et al. (1987)] era mais adequado. Em [Lopes et al. (1990)] os autores denominam os filtros MAP segundo a combinação do nome da técnica empregada (MAP) com o nome da distribuição que modela o ruído "speckle" seguido do nome da distribuição "a priori" (Ex: MAP gama-gama). Nesta tese denominamos os filtros propostos pela combinação do nome da técnica e parte do nome que identifique a distribuição "a priori" (Ex: MAP exp).

Em [Sant'Anna (1995)] são propostos filtros redutores de "speckle" utilizando a abordagem MAP para os casos de deteção linear e deteção quadrática considerando os modelos Rayleigh e gama respectivamente (portanto, uma visada), e supondo diferentes distribuições "a priori". Sant'Anna [Sant'Anna (1995)] propõe novos critérios de avaliação de desempenho dos filtros MAP tais como: avaliação de desempenho de classificação ponto a ponto, avaliação de perda de resolução através de deteção de bordas e da análise da resposta impulsiva de um alvo pontual.

Técnicas Baseadas em Campos Randômicos Markovianos (MRF) a) O Filtro ICM

O algoritmo ICM ("Iterated Conditional Modes") ou Modas Condicionais Iterativas proposto por Besag [Besag (1986)] é uma proposta iterativa para a melhoria da segmentação pelo *MLE* (Maximum Likelihood Estimator) ou método de Máxima Verossimilhança [Apêndice B]. Esta técnica iterativa consiste na maximização das distribuições locais para cada coordenada (pixel) até que haja evidência de convergência [Mascarenhas & Frery (1994)].

Em [Mascarenhas & Frery (1994)] é proposto um novo procedimento de filtragem do ruído "speckle" baseado no algoritmo ICM, considerando que o número de classes na distribuição "a priori" varia de 16 a 256 níveis. Este procedimento adota na modelagem da distribuição "a priori" para as classes o modelo multiclasses de Potts-Strauss ("multi-level logistic") [Li (1995)], que é um caso especial da classe de modelos de campos randômicos markovianos (MRF). O algoritmo ICM usa ambas as densidades de probabilidade condicionais, a saber, densidade de probabilidade da observação ruidosa dado o "backscatter" (sinal original sem ruído) que obedece a uma distribuição Rayleigh em caso de detecção linear e uma visada, e a densidade de probabilidade condicional do "backscatter" x para um certo pixel dado os valores de "backscatter" numa vizinhança (δ_x) deste pixel. Esta distribuição na vizinhança (δ_x) tem a seguinte forma:

$$\Pr(x \mid \delta_x) = \exp(\beta \# \{t \in \delta_x : x = x_t\})$$
 (2.60)

onde o conjunto $\delta_x = \{t \in S : \|s - t\| = 1\}$ é o conjunto de vizinhos da coordenada $x \in S$. O parâmetro $\beta \in \Re$ é estimado a cada ciclo da iteração por um procedimento de estimação de máxima pseudo-verossimilhança e é denominado de parâmetro de atração, quando assume um valor positivo, e de repulsão se este valor é negativo.

A expressão a ser maximizada para a atualização da coordenada x a cada iteração é dada por:

$$\Pr(x \mid z, \delta_x) \propto \exp(\beta \# \{t \in \delta_x : x = x_t\}) \cdot (\frac{z}{x^2}) \exp\left(-\frac{z^2}{2x^2}\right)$$
 (2.61)

onde z é a coordenada observada da imagem ruidosa.

O processo de iteração inicia com a classificação pontual dos pixels pelo método de máxima verossimilhança com um número de classes que vai de 16 a 256 níveis usando a função de densidade de probabilidade Rayleigh.

b) Filtragem com "Simulated Annealing"

Em [McConnell et al. (1995)] é apresentado um algoritmo capaz de filtrar o "speckle" preservando detalhes e resolução. Este algoritmo é baseado na solução

MAP que realiza a estimação do "backscatter" ou RCS ("radar cross-section") em imagens de radar de abertura sintética (SAR) usando "simulated annealing" [Li (1995); Therrien (1989)] e estatística gama para o conhecimento "a priori" do "backscatter" e para o modelo de ruído em imagens SAR de múltiplas visadas e detecção quadrática. Em imagens SAR existe uma continuidade espacial na qual o valor em nível de cinza de um determinado pixel ("backscatter") tende a ser similar aos pixels vizinhos. Esta informação é incorporada ao método proposto pelos autores pela modelagem do conhecimento "a posteriori" como um campo randômico markoviano (MRF). Este campo tem uma distribuição de Gibbs dada por :

$$p(x \mid z) = \frac{1}{Z} e^{-\frac{U}{T}}$$
 (2.62)

onde Z é uma constante de normalização e T é uma constante chamada temperatura. O símbolo U representa uma função potencial que expressa ambas as estatísticas dos dados e a conectividade local [McConnell et al. (1995)].

O "simulated annealing" [Therrien (1989), Li (1995)] é uma técnica para localizar o mínimo global de uma dada função, chamada função objetivo ou função custo (\mathcal{C}). A função custo é tal que quanto menor o valor de \mathcal{C} melhor a configuração $(s \in S)$ de imagem correspondente, onde s corresponde a uma configuração no espaço (S) das possíveis configurações de imagens que se pode obter. O algoritmo de "simulated annealing" procede fazendo a mudança aleatória de uma configuração s_i para outra s_i no espaço de configuração da imagem e avaliando a variação na função custo, ou seja, $\Delta C_{ij} = C(s_j - s_i)$. Esta busca no espaço de configurações é necessária para evitar que o sistema se acomode em mínimos locais. A aceitação da nova configuração ou a manutenção da anterior é feita mediante critério probabilístico (Equação 2.62), isto é, se houver um aumento na função custo a nova configuração é mais provável de ser aceita com o parâmetro temperatura (T) mais alto que mais baixo. Sempre que houver decréscimo na energia a configuração será aceita. A estratégia do algoritmo consiste em desviar-se dos mínimos locais através da redução lenta do parâmetro T. O algoritmo então caminha na direção dos estados de baixa energia à medida que o parâmetro temperatura é conduzido lentamente para zero $(T \to 0)$, fazendo com que a distribuição $p(x \mid z)$ tenda para os estados de baixa energia de U, garantindo assim a convergência para o máximo global da distribuição "a posteriori".

Em resumo, o sistema no qual se busca o mínimo global deve ser provido das seguintes condições:

a) A temperatura T empregada na atualização do estado do sistema tenda a zero lentamente conforme a expressão:

$$T_k \ge \frac{c_0}{\log(1+k)} \tag{2.63}$$

onde k é o número de iterações e c_{θ} é uma constante que controla a suavização.

- b) Cada pixel na imagem deve ser visitado um grande número de vezes.
- O algoritmo procede como segue [Oliver & Quegan (1998)]:
- Passo 1. Um pixel particular é randomicamente perturbado para um valor qualquer.
- Passo 2. A probabilidade conjunta de todos os pixels na imagem é avaliada com base na função objetivo que é definida para toda a imagem.
- Passo 3. O critério de aceitação da configuração é tal que: se a probabilidade de uma nova configuração é maior que a anterior, ou seja, se $\Delta C_{ij} < 0$, o novo valor do pixel é adotado. Se a probabilidade é menor que a anterior, o novo valor pode ser aceito, ou seja, se $\Delta C_{ij} > 0$ a probabilidade de aceitação é dada por $\exp(-\Delta C_{ij}/T_k)$.
- Passo 4. Um novo pixel é selecionado randomicamente e todo o processo é repetido a partir do passo 1.

No trabalho de McConnell e seus colaboradores [McConnell et al. (1995)] o uso de 100 iterações e a visita cíclica aos pixels foram ajustes suficientes para que o resultado desejado fosse atingido. Para utilização do "simulated annealing", os autores formularam a função potencial, U, que incorpora o conhecimento "a priori" a partir da regra de Bayes, como segue:

$$p(x \mid z) = \frac{p(z \mid x)p(x)}{\int p(z \mid x)p(x)dx}$$
(2.64)

onde z representa os dados observados, x é o estimador do "backscatter", $p(z \mid x)$ é o modelo de estatística do ruído e p(x) é o modelo "a priori" e ambas as distribuições são assumidas como sendo gama. Deste modelo deseja-se encontrar x que maximize $p(x \mid z)$ para obter o estimador MAP. Assim, tomando o log da expressão de $p(x \mid z)$ e ignorando termos constantes obtém-se:

$$x_{MAP} = \max_{x} [\log p(z \mid x) + p(x)]$$
 (2.65)

O máximo de x é procurado usando o método de "simulated annealing", e a função potencial, portanto, é da forma:

$$-U = \log p(z \mid x) + \log p(x) \tag{2.66}$$

O termo de máxima verossimilhança descreve o modelo do ruído e obedece a uma distribuição gama de ordem v_z dada por:

$$p(z \mid x) = \left(\frac{v_z}{x}\right)^{v_z} \frac{z^{v_z - 1}}{\Gamma(v_z)} \exp\left(\frac{-zv_z}{x}\right)$$
 (2.67)

O conjunto de conexões (cliques) [Therrien (1989)] ao redor do pixel central (preto) com apenas 2 pixels na vizinhança é apresentado na Figura 2.17 e é usado no termo de conhecimento "a priori" e nesta distribuição a seguinte notação foi utilizada: os subscritos zero, 1 e 2 são usados para marcar respectivamente os pixels central e os 2 vizinhos.

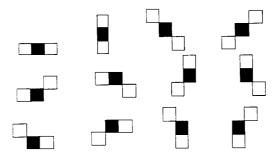


Figura 2.17 - Conjunto de conexões (cliques) ao redor do pixel central (preto).

A distribuição "a priori" é descrita por uma distribuição gama de ordem ν , e mostra como o valor de x_0 estimado pela média de seus 2 vizinhos se comporta.

$$p(x \mid x_1, x_2) = \left(\frac{v}{x}\right)^{v} \frac{x_1^{v-1}}{\Gamma(v)} \exp\left(\frac{-x_1 v}{x}\right) \left(\frac{v}{x}\right)^{v} \frac{x_2^{v-1}}{\Gamma(v)} \exp\left(\frac{-x_2 v}{x}\right)$$
(2.68)

Os autores apresentam um modelo simplificado, no qual assumem que a média dos pixels vizinhos é um bom estimador para o pixel central.

Usando as **Equações 2.66**, **2.67** e **2.68** é derivada a expressão de U e assim a solução de máxima verossimilhança é dada por [McConnell et al. (1995)]:

$$x_0 = \frac{z_0 + \frac{v}{v_z} (x_1 + x_2)}{1 + 2\frac{v}{v_z}}$$
 (2.69)

O valor estimado de x, (no caso do pixel central x_0), depende de v e é escolhido de acordo com a probabilidade gerada a partir de cada uma das 12 conexões. Um pequeno valor de v favorece a atualização da imagem pelo valor z, enquanto que um grande valor implica em suavização da mesma, ou seja, a atualização (pela média dos vizinhos pois a **Equação 2.62** se reduz à expressão $\left(\frac{x_1 + x_2}{2}\right)$. Desta maneira o algoritmo de "simulated annealing" é capaz de se adaptar à imagem, preservando detalhes quando necessário, mas podendo ainda suavizá-la.

Em [Oliver & Quegan (1998)] é apresentado um algoritmo iterativo (CMAP) que combina o modelo de vizinhança correlacionada com o modelo "a priori" do RCS na reconstrução MAP e é observado que sobre regiões uniformes há uma maior redução do ruído "speckle".

Técnica de Redução de Ruído Baseada em Curvatura

A técnica proposta por Sethian [Sethian (1999)] considera que uma imagem pode ser interpretada como uma superfície cujas curvas de nível de iso-intensidades podem se propagar gradualmente. A idéia consiste em remover ruído pela variação no fluxo de propagação das curvas. A função de intensidade $\phi(x,y)$ da escala de cinza descrita em termos da função de velocidade de propagação é dada por:

$$\frac{\hat{c}\phi}{\hat{c}t} = \phi_t = F|\nabla\phi| \tag{2.70}$$

onde F corresponde à curvatura como propõe o autor e é descrita por:

$$F = \nabla \cdot \frac{\nabla \phi}{|\nabla \phi|} = k \tag{2.71}$$

Considerando o caso da propagação da curva (contorno) no plano, Sethian [Sethian (1999)] estabelece a Equação 2.72 para o cálculo de k das curvas de nível zero, como mostra a expressão:

$$k = \frac{\phi_{xx}\phi_{y}^{2} - 2\phi_{y}\phi_{x}\phi_{xy} + \phi_{yy}\phi_{x}^{2}}{(\phi_{x}^{2} + \phi_{y}^{2})^{2}}$$
(2.72)

onde ϕ_{xx} corresponde à derivada parcial de segunda ordem de ϕ com relação à variável x.

O esquema de filtragem baseado na curvatura utiliza a função Min/Max [Sethian (1999)] para guiar o sentido correto de propagação do fluxo do contorno de tal forma que sejam eliminadas pequenas oscilações e sejam preservadas propriedades importantes da imagem. O ponto de partida do algoritmo de fluxo Min/Max é a função de velocidade F(k) = -k. A velocidade de propagação da curvatura imprimida pelo algoritmo é tal que F(k) = -k corresponde ao colapso da curvatura (eliminação de pontos de alta curvatura) desde que o contorno se mova na direção de sua normal com velocidade negativa. Considere a função de velocidade $\overline{F} = -F$:

$$\overline{F}_{\min \max}^{R} = \begin{cases} \max(k,0) & se \quad Ave_{\phi(x,y)}^{R} < T_{LIMIAR} \\ \min(k,0) & caso \quad contrário \end{cases}$$
 (2.73)

onde $Ave_{\phi(x,y)}^R$ é definida como sendo a média local de ϕ (intensidades) numa região de raio R centrada em (x,y). Para entender melhor como funciona o algoritmo de redução do ruído é preciso descrever a **Equação 2.73**. Inicialmente é estabelecido um limiar T que no caso das imagens de teste foi T=127. Este valor corresponde ao nível de cinza intermediário na escala de 0 a 255. Em seguida avalia-se a média local

na região de raio R centrada no pixel de coordenadas (x,y). Se esta média for inferior ao limiar então a evolução da curvatura corresponderá ao valor máximo no intervalo (k,0), ou seja, se k (curvatura) for negativo então não haverá evolução da curva pois o valor máximo é nulo. Caso a média seja superior ao limiar o sentido de propagação ocorrerá de acordo com o valor mínimo do intervalo.

Alguns exemplos do uso desta técnica na filtragem de ruído multiplicativo são mostrados a seguir e foram resultados da implementação feita pelo colega Leandro Farias Estrozi, aluno de doutorado no Grupo de Pesquisa em Visão Cibernética - IFSC/USP. A **Figura 2.18** apresenta a imagem SAR580 filtrada segundo a técnica proposta por Sethian utilizando R=1 e na **Figura 2.19** o algoritmo é aplicado com R=2. Observa-se que o método preserva bordas, embora descaracterize, na imagem filtrada, as diferentes texturas presentes na região imageada.

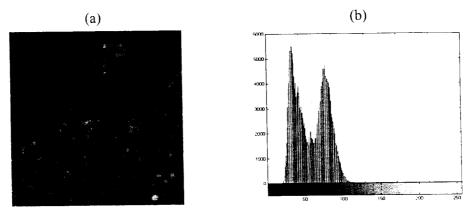


Figura 2.18 - (a) Imagem SAR580 filtrada com R=1 e (b) seu respectivo histograma.

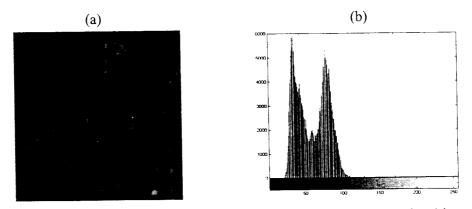


Figura 2.19 - (a) Imagem SAR580 filtrada com R=2 e (b) seu respectivo histograma.

O algoritmo implementado também foi aplicado a imagens reais SAR cujo "speckle" é modelado pela distribuição raiz de gama, ou seja, imagens amplitude e

com múltiplas visadas. Foi usada a imagem *JERS256* (**Figura 2.20**) que apresenta 3 visadas teóricas e está descrita no [**Apêndice F**].

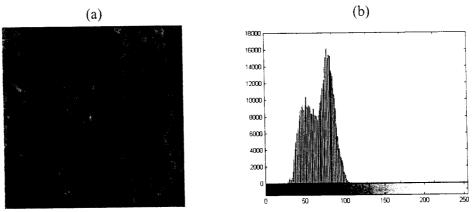


Figura 2.20 – (a) Imagem JERS256 filtrada com R=1 e (b) seu respectivo histograma.

Técnicas Baseadas em "Wavelets"

Para a definição de "wavelets" utiliza-se o conjunto de funções:

$$\psi^{a,b} = \frac{1}{\sqrt{|a|}} \psi(\frac{t-b}{a}), \quad (a, b \in \Re, a \neq 0)$$
 (2.74)

as quais são versões transladadas e escaladas (dilatadas) de uma função $\psi(t)$, chamada de wavelet mãe. Uma integral de transformação usando as funções da **Equação 2.74** como base é chamada de transformada contínua em "wavelets" e é dada por:

$$U(b,a) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} u(t)\psi(\frac{t-b}{a})dt$$
 (2.75)

Os parâmetros a e b variam continuamente sobre o conjunto \Re com a restrição de que $a\neq 0$. A função u pode ser reconstruída a partir de sua transformada de wavelet por meio da fórmula [Daubechies (1992)]:

$$u = C_{\Psi}^{-1} \int_{-\infty - \infty}^{\infty} \frac{da \, db}{a^2} \langle u, \Psi^{a,b} \rangle \Psi^{a,b}$$
 (2.76)

onde <> denota o produto interno no espaço L^2 [Daubechies (1992)] da função u com uma família de "wavelets" Ψ . A constante C_{Ψ} depende somente de Ψ , é finita,

ou seja, $C_{\Psi} < \infty$ e de média nula ($\int \Psi(t)dt = 0$) e cuja expressão é dada por [Daubechies (1992)]:

$$C_{\Psi} = 2\pi \int_{-\infty}^{\infty} d\xi |\Psi(\xi)|^2 |\xi|^{-1}$$
 (2.77)

Assim sendo se Ψ satisfaz à condição de admissibilidade (**Equação 2.77**) então é possível reconstruir u a partir de sua transformada de "wavelets", ou seja, a transformação inversa reconstrói o sinal original. Para sinais digitais é usada uma wavelet discreta $\psi_{j,k}$, a qual é formada de ψ , pela amostragem dos parâmetros a e b seguindo o teorema de Nyquist. Uma wavelet é ortogonal, quando todos os pares formados pelas funções bases $\psi_{j,k}$, são ortogonais entre si. Uma wavelet ortogonal cuja norma é 1 é chamada de wavelet ortonormal. A base de Haar é a base ortonormal mais simples. Uma transformada em wavelet de uma imagem consiste de quatro subimagens, as quais correspondem individualmente à quarta parte da imagem. A subimagem composta das baixas frequências na direção das linhas e das colunas é iterativamente decomposta nível por nível em quatro subimagens.

No trabalho [Fukuda & Hirosawa (1998)] é proposto um filtro para supressão do "speckle" em imagens SAR utilizando "wavelets". O filtro suprime o ruído reduzindo a amplitude dos coeficientes de detalhes da imagem nos subespaços "wavelets", e preserva bordas evitando a redução da amplitude ao redor das mesmas utilizando a informação contida nos coeficientes de detalhes para a detecção de bordas. A notação utilizada define como imagem aproximada a subimagem composta pelas baixas frequências, e as três subimagens remanescentes com os coeficientes de detalhes. A idéia básica do filtro de supressão do "speckle" em imagens SAR proposta por Fukuda & Hirosawa [Fukuda & Hirosawa (1998)] com a redução seletiva da amplitude do "speckle" se dá da seguinte forma:

Passo 1. Decomponha a imagem SAR em subespaços wavelet com uma estrutura piramidal até o nível M.

Passo 2. Processe as imagens de detalhes de cada subespaço seguindo os passos:

Passo 2a. Classifique cada pixel das imagens de detalhes como "ALTO"ou como "BAIXO segundo um limiar T:

se [o valor absoluto da amplitude] \geq T, então classifique como "ALTO".

se [o valor absoluto da amplitude] < T, então classifique como "BAIXO".

Passo 2b. Multiplique a amplitude dos pixels que são classificados como "BAIXO" por α , que é um número dado em porcentagem.

Passo 2c. Centralize uma janela 3x3 sobre cada pixel classificado como "ALTO". Para cada uma das 3 imagens de detalhes (HL, LH e HH), defina como "ALTAS" as áreas da janela como mostra a **Figura 2.21**.

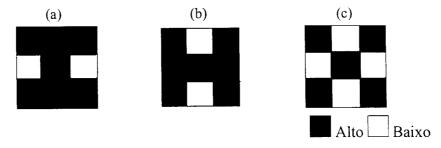


Figura 2.21 – Janelas para detecção de bordas nas imagens (a)HL (b)LH (c)HH.

Passo 2c-1. Faça com que a amplitude do pixel central da janela (o pixel observado) mantenha seu valor original se a área "ALTA" na janela contém pelo menos um pixel "ALTO".

Passo 2c-2. Multiplique a amplitude do pixel central da janela por β se a área "ALTA" da janela não contém nenhum pixel classificado como "ALTO".

Passo 3. Reconstrua a imagem de saída a partir dos subespaços de imagens processadas.

Observa-se que se o passo 2 for aplicado indiscriminadamente em todas as imagens detalhes, seriam perdidos algumas estruturas de bordas e retas. Isto é resolvido através de uma seleção prévia das amplitudes a serem reduzidas, garantindo assim que ao redor de bordas não haja redução. Para teste do algoritmo utilizou-se o mesmo exemplo dos autores, ou seja, uma imagem contaminada com ruído "speckle" cuja distribuição segue a raiz quadrada da gama (4 visadas e em

amplitude) como mostra a imagem na **Figura 2.22a**. A **Figura 2.23** apresenta o resultado de filtragem usando "wavelets".

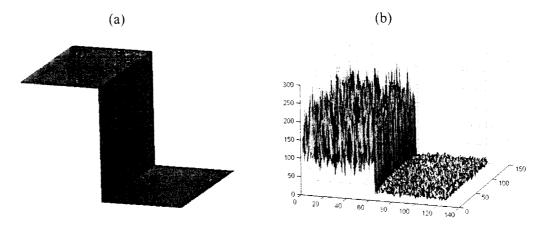


Figura 2.22 (a) Imagem original (b) imagem contaminada com ruído "speckle" com distribuição raiz de gama (4 "looks").

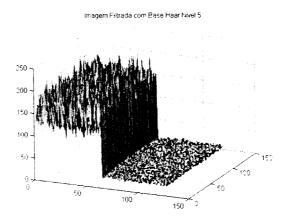


Figura 2.23 Filtragem baseada em "wavelets".

A **Figura 2.24a** apresenta a imagem *VILA* contaminada por ruído "speckle" com distribuição Rayleigh e a **Figura 2.24b** a sua respectiva versão filtrada por "wavelets".

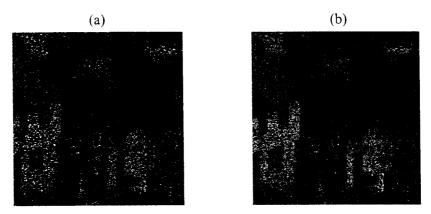


Figura 2.24 (a) Imagem ruidosa VILA (b) filtrada por "wavelets".

Na **Figura 2.25** são apresentadas as versões original e filtrada da imagem real *CAÇAPAVA* usando a técnica de filtragem baseada em "wavelets" e na **Figura 2.26** as versões ruidosa e filtrada pela técnica em "wavelets" da imagem real *JERS256*, ambas obtidas por detecção linear e com uma e três visadas respectivamente.



Figura 2.25 – (a) Imagem CAÇAPAVA (b) filtragem baseada em "wavelets".

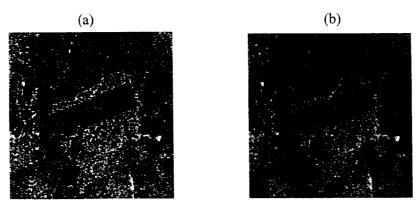


Figura 2.26 - (a) Imagem JERS256 (b) filtragem baseada em "wavelets".

2.6 Conclusão

Observa-se que na literatura existe um grande número de propostas de filtros redutores de "speckle" e cada um deles apresenta habilidades próprias, sejam elas de preservar bordas em determinadas direções, detalhes como alvos militares, não introduzir artefatos, melhoria visual, rapidez de processamento, etc. Existe um compromisso entre estes requisitos na escolha de um algoritmo de processamento e ela vai depender da aplicação a que se destina. Um exemplo são as aplicações militares que em geral exigem um processamento com elevada preservação da resolução das imagens.

Foram implementadas duas propostas recentes da literatura que não adotam modelo estatístico para o ruído (filtros baseados em "wavelets" [Fukuda & Hirosawa (1998)] e curvatura [Sethian (1999)]) e outros filtros que adotam o modelo multiplicativo para o ruído (Lee, Kuan e Frost). Observa-se através dos resultados de filtragem obtidos que os filtros implementados que adotam modelos estatísticos para o sinal e para o ruído "speckle" apresentam resultados bastante bons com relação à redução do ruído e preservação de detalhes. O filtro baseado em "wavelets" não discrimina bem as classes predominantes da imagem, enquanto que o filtro proposto por Sethian [Sethian (1999)] é capaz de discriminar bem as classes, embora descaracterize as diferentes texturas. Os filtros de Lee e Kuan são pontuais e não incorporam a correlação da imagem original. O filtro de Frost é o único filtro implementado que considera a correlação (do tipo exponencial) entre os pixels.

3 Principais Ferramentas Utilizadas Nesta Tese para Melhoria e Avaliação da Filtragem

3.1 Introdução

A avaliação de desempenho dos filtros de "speckle" sob diversos aspectos (melhoria da relação sinal-ruído, perda de resolução, forma do histograma de níveis de cinza, etc.) é necessária para justificar o acréscimo de novos algoritmos, muitas vezes sofisticados, à literatura. Dentre as ferramentas utilizadas para investigação da melhoria de desempenho dos filtros propostos estão o algoritmo de agrupamento ("clustering") k-médias e a técnica de crescimento de regiões. Estas ferramentas foram incorporadas aos algoritmos propostos e foram avaliadas as contribuições dos mesmos na área de filtragem.

A metodologia usada neste trabalho para avaliação do desempenho dos filtros considera vários fatores como redução da intensidade do "speckle" sobre regiões homogêneas, preservação de bordas, preservação da média e erro médio quadrático. Nesta tese é proposta uma nova medida para avaliação dos filtros com respeito à preservação de bordas e tem por base a transformada de Hough. A transformada de Hough é usada para extrair informação sobre o efeito da dispersão ao longo das bordas causado pela filtragem. Normalmente as estruturas feitas pelo homem apresentam linhas retas e algumas das imagens de teste contêm este tipo de estruturas, sugerindo o uso da transformada de Hough. A metodologia pode ser estendida aos casos gerais pelo fato de curvas digitais serem compostas por segmentos de retas digitais [Medeiros et al. (1998c)].

3.2 Algoritmo de K-Médias

Quando se deseja projetar um classificador e a única informação disponível consiste nas amostras não rotuladas, recorre-se às técnicas de agregação de dados ("clustering"). Estas técnicas tiveram origem nos processos de taxonomia numérica das ciências biológicas e, com o advento do computador digital, passaram a ser largamente utilizadas [Mascarenhas & Velasco (1989)]. Quando se utilizam essas técnicas, o problema de reconhecimento de padrões não consiste apenas em agrupar os dados em classes, mas também definir posteriormente as classes dos padrões disponíveis, pois é uma classificação não supervisionada. De um modo geral, os aglomerados são particionados em grupos de amostras segundo algum critério de similaridade entre elas. As técnicas de aglomeração baseiam-se frequentemente na minimização deste critério e o algoritmo de k-médias [Mascarenhas & Velasco (1989)] é uma técnica de reconhecimento de padrões não supervisionada, que utiliza a distância Euclidiana D como medida de similaridade. Esta medida envolve a soma dos erros quadráticos dada pela expressão:

$$D = \sum_{j=1}^{N_c} \sum_{\underline{x} \in G_j} \left| \underline{x} - \overline{m}_j \right|^2$$

$$\overline{m}_j = \frac{1}{N_j} \sum_{\underline{x} \in G_j} \underline{x}$$
(3.1)

onde N_c é o número de classes, x ∈ G_j indica as amostras pertencentes à classe ou grupo j, G_j é o j-ésimo grupo de amostras, N_j é o número de amostras do grupo j e m̄_j corresponde ao centro do agrupamento que é a média amostral do grupo. O algoritmo iterativo básico, conhecido por k-médias, para obter a minimização de D é descrito em [Mascarenhas & Velasco (1989)]:

- Passo 1. Selecione o número de agrupamentos iniciais k.
- Passo 2. Escolha uma partição do número total de amostras (M_k) em k agrupamentos. Compute as médias m_i , i=1,2,3,...k de cada agrupamento.
 - Passo 3. Calcule a distância do vetor de padrões \underline{x} a cada média m_i , i=1,2,3,...,k.
 - Passo 4. Atribua \underline{x} ao agrupamento cuja média esteja mais próxima de \underline{x} .

Passo 5. Se nenhuma das amostras mudou de agrupamento ou se o número máximo de iterações permitidas foi ultrapassado, pare.

Passo 6. Caso contrário, calcule as novas médias amostrais dos agrupamentos e volte ao passo 3.

Em geral, obtém-se um mínimo local de D, não havendo garantia de um mínimo global. Diferentes escolhas das partições iniciais levam a diferentes resultados e portanto a diferentes mínimos locais. Nesta tese a medida de similaridade entre os pixels é a distância Euclidiana e a razão das variâncias R é o atributo utilizado pelo k-médias unidimensional. A partir do histograma do atributo R na imagem selecionase o número de agrupamentos iniciais k do algoritmo como mostra o exemplo da **Figura 3.1b**. Este tipo de histograma de R, calculado para a imagem Caçapava, apresenta natureza bimodal sugerindo assim k=2.

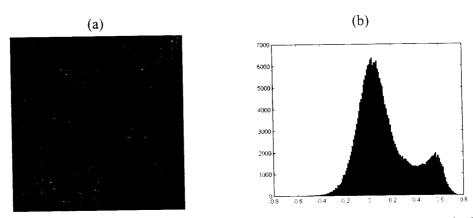


Figura 3.1 – (a) Imagem CAÇAPAVA e (b) seu respectivo histograma de R.

Observa-se que existem valores negativos de R. Para estes casos o modelo multiplicativo não é consistente, pois estes pixels configuram regiões extremamente homogêneas e portanto são atualizados pela média.

A idéia de incorporar este algoritmo de segmentação à estimação MAP consiste basicamente em adotar uma estratégia de filtragem baseada na segmentação. Nesta abordagem, uma imagem estatisticamente não estacionária é dividida em regiões aproximadamente estacionárias e estas são processadas por filtros ajustados de acordo com a estatística correspondente a cada região. A estimação dos parâmetros dos filtros é feita usando tamanhos distintos de janelas ditados pelo algoritmo de

segmentação. Uma visão global da utilização do algoritmo de aglomeração é ilustrado na **Figura 3.2**.

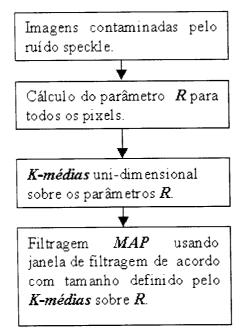


Figura 3.2 -Incorporação do algoritmo k-médias à filtragem.

3.2.1 Resultado de Aplicação do Algoritmo de K-Médias Combinado aos Algoritmos de Filtragem MAP

As imagens da **Figura 3.3** confirmam que o uso de janelas distintas de filtragem, para diferentes regiões da mesma, é uma boa estratégia para ser incorporada à filtragem, porque preserva detalhes e melhora a discriminação de classes. Nesta técnica que incorpora o algoritmo k-médias aos filtros MAP é definida para cada classe ("cluster") R da imagem uma janela de filtragem propondo uma maneira formal para escolha dos limiares e não heurística como propõe Li [Li (1988)].

Vale ressaltar que os histogramas de R calculados para as imagens de teste dos algoritmos não são bimodais e como o objetivo da incorporação do k-médias não visa a estimação de k (número de classes), foi adotado o número de classes, k, cujos resultados de filtragem apresentassem melhor relação sinal-ruído.

A imagem SAR580 resultante da aplicação do filtro MAP gama simples (uso de uma única janela de dimensão 5x5) e seu respectivo histograma são apresentados na

Figura 3.3a e na **Figura 3.4a**. O resultado de processamento para a imagem *SAR580* apresentado na **Figura 3.3b** e seu respectivos histograma (vide **Figura 3.4b**) foi obtido da aplicação do k-médias unidimensional sobre *R*, e cujos centros dos agrupamentos ("clusters") obtidos pelo método foram 0.0006 e 0.1277. As janelas de filtragem associadas a cada grupo para estimação dos parâmetros foram 9x9 para pixels cujos valores de *R* estivessem no grupo de centro 0.0006 e 7x7 para o outro grupo.

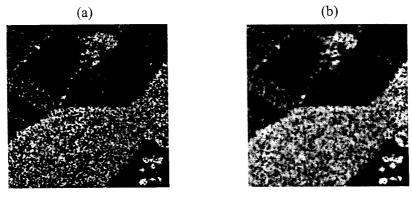


Figura 3.3 - Imagem (*SAR580*) filtrada pelos (a) MAP gama (b) MAP gama combinado ao k-médias.

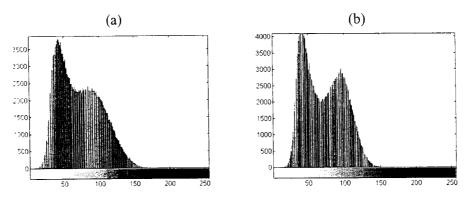


Figura 3.4 – Histogramas da imagem (*SAR580*) filtrada pelos (a) MAP gama (b) MAP gama combinado ao k-médias.

3.3 Crescimento de Regiões

A técnica de crescimento de região é uma das abordagens conceitualmente mais simples para segmentação de imagens. Uma região segmentada é formada por pixels vizinhos que satisfazem um critério de homogeneidade. Em geral as regras de crescimento de região incluem o critério de homogeneidade, tipo de conectividade e

as restrições ao tamanho da região. Estas regras dependem da complexidade do problema e da aplicação. Neste trabalho a utilização do crescimento de região tem por objetivo investigar a melhoria da filtragem do ruído "speckle", levantando-se as propriedades estatísticas (média e variância) do mesmo em uma vizinhança de tamanho e forma variável. O filtro com base na adaptatividade espacial que se propõe nesta tese usa o coeficiente de variação local (razão entre o desvio padrão e a média) para testar a uniformidade da região vizinha ao pixel. A implementação do algoritmo considera todos os pixels da imagem tratada como sementes e pesquisa todos os pixels 8-conectados a eles, não importando haver sobreposição de regiões. As regiões páram de crescer, quando não existir mais pixels espacialmente conectados que obedeçam ao critério de homogeneidade ou a região tenha atingido o tamanho máximo permitido. O critério de homogeneidade local (*CHL*) estabelecido neste trabalho é definido pela razão entre o desvio padrão local e a média local (chamado coeficiente de variação) acrescido de um pequeno valor não negativo(ζ), segundo as expressões [Medeiros et al. (1999)]:

$$\frac{\hat{\sigma}_z}{\hat{\mu}_z} \le \sigma_n + \zeta$$

$$\sigma_n = \frac{\hat{\sigma}_z}{\hat{\mu}_z}$$

$$\hat{\mu}_z = \frac{1}{N} \sum_{i=1}^N z_i$$

$$\hat{\sigma}_z = \sqrt{\frac{\sum_{i=1}^N (z_i - \hat{\mu}_z)^2}{N - 1}}$$
(3.2)

onde o valor ζ corresponde a uma tolerância positiva (intervalo de confiança), expressa em porcentagem, do desvio padrão teórico do ruído (σ_n) , z_i corresponde aos valores em níveis de cinza dos N pixels dentro da região, $\hat{\mu}_z$ é o estimador da média na região e $\hat{\sigma}_z$ é o estimador do desvio padrão local. Em regiões homogêneas, o coeficiente de homogeneidade local calculado deve estar próximo do valor do

desvio padrão do ruído "speckle" que dependerá do número de visadas ("looks") segundo mostra a Equação 2.26 para imagens obtidas por detecção linear. Este valor portanto, é atualizado sempre que entrar na região um novo pixel conectado. Caso o valor desta razão calculada sobre uma região que inclua o pixel candidato a entrar na região (por ser espacialmente conectado ao semente) esteja dentro de um intervalo uni-lateral cujo limite máximo de homogeneidade permitido é $\sigma_{\scriptscriptstyle n}$ + ζ , então o pixel conectado é aceito. Da expressão $\sigma_n + \zeta$ percebe-se que é permitido que a razão calculada sobre a região crescida exceda o valor do desvio padrão do ruído (σ_n) de um pequeno valor ζ . Se este valor ultrapassar o intervalo limite, significa que a homogeneidade da região foi atingida e o pixel candidato a entrar na mesma não será incluído, ou seja, a região pára de crescer. Em caso do número de pixels na região não exceder 5 pixels, utiliza-se uma janela fixa de tamanho 5x5 para o cálculo da média e desvio padrão. Sendo assim todos os pixels da imagem são pixels sementes cujo crescimento das regiões em torno deles se dá segundo o critério de homogeneidade local (CHL) definido segundo a Equação 3.2. A Figura 3.5a apresenta a imagem BLA artificialmente contaminada por ruído "speckle" com distribuição Rayleigh. Na Figura 3.5b está o resultado de filtragem da mesma usando a abordagem MAP ("a priori" Gaussiana) com incorporação da técnica de crescimento de regiões, CHL (ou limiar de rejeição da homogeneidade) igual a 0.5446 e número máximo de 25 pixels permitido para a região crescer em torno do pixel semente [Medeiros et al. (1999)].

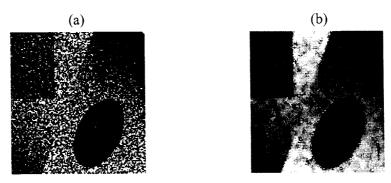


Figura 3.5 – Imagem *BLA* (a) artificialmente contaminada pelo "speckle" Rayleigh (b) filtrada pelo MAP Gaussiano com crescimento de região.

O gráfico na **Figura 3.6** corresponde à relação entre o limiar de homogeneidade da região crescida versus índice de redução do "speckle". Quando se ajusta este limiar (para a imagem *BLA*) ao valor máximo de 0.5446 obtém-se uma suavização de regiões homogêneas mais efetiva que para outros valores de limiar. Isto significa que existe um ponto ótimo neste limiar que é o limite de homogeneidade da região crescida.

Similarmente procurou-se nas imagens de múltiplas visadas o limite máximo da homogeneidade para crescimento das regiões.

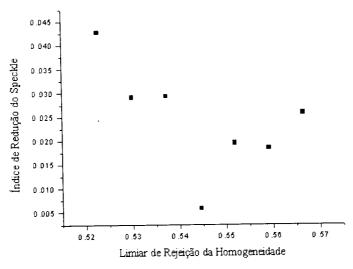


Figura 3.6 – Limiar de rejeição da Homogeneidade para a imagem BLA.

3.3.1 Resultado de Aplicação do Algoritmo de Crescimento de Região Combinado aos Algoritmos de Filtragem MAP

As imagens na **Figura 3.7** mostram o resultado de aplicação dos filtros MAP que usam o modelo "a priori" Gaussiano. A **Figura 3.7b** apresenta a imagem filtrada pelo MAP Gaussiano que utiliza crescimento de regiões, e cujo limiar de rejeição da homogeneidade utilizado foi 0.5446, ou seja, $\sigma_T \leq 0.5446$. Foi estabelecido um máximo de 49 pixels para compor as regiões crescidas, e sobre esta região são calculados os parâmetros do filtro. Em caso da região atingir um máximo de 5 pixels apenas, estabelecemos o uso de uma janela fixa 5x5 para estimação dos parâmetros de filtragem.

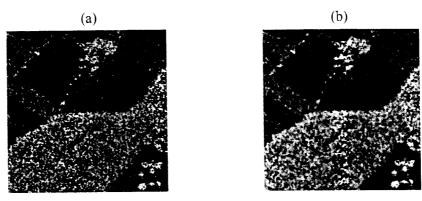


Figura 3.7 – Imagem (SAR580) filtrada pelos filtros (a) MAP Gaussiano (b)MAP Gaussiano combinado ao crescimento de regiões.

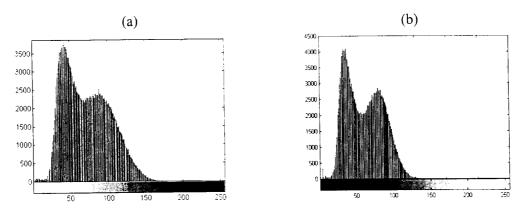


Figura 3.8 – Histograma da Imagem (*SAR580*) filtrada pelos filtros (a) MAP Gaussiano (b) MAP Gaussiano combinado ao crescimento de regiões.

3.4 Medidas de Avaliação Utilizadas nesta Tese

A análise de desempenho dos algoritmos de filtragem propostos nesta tese é feita com base em algumas medidas que são apresentadas nesta seção. Algumas delas avaliam a redução da intensidade do "speckle" na imagem após a filtragem através de várias medidas. Analisa-se também o efeito de borramento das bordas caracterizada por uma medida de dispersão das retas presentes na cena. Para a computação de algumas destas medidas de qualidade da filtragem são utilizadas as versões original, ruidosa e filtrada das cenas de teste. No caso das imagens SAR reais dispõe-se apenas da imagem ruidosa, não sendo, portanto, calculadas algumas medidas como erro médio quadrático, por exemplo.

a) O coeficiente de variação ou índice β mede a intensidade do ruído "speckle" presente sobre áreas homogêneas e é obtido da razão entre o desvio padrão (σ) e a média (μ) sobre estas regiões. Esta razão é constante sobre regiões homogêneas e indica que o "speckle" se comporta como ruído multiplicativo. Este coeficiente descreve o quanto uma imagem está contaminada por este tipo de ruído e no caso de imagens filtradas esta razão é usada para medir a redução do ruído em regiões homogêneas. Após a filtragem a tendência deste valor é cair, indicando redução da intensidade do ruído sobre estas regiões. O cálculo do coeficiente de variação para uma imagem filtrada é feito segundo a expressão:

$$\beta = \frac{\sqrt{\operatorname{var}(\hat{x})}}{E[\hat{x}]} \tag{3.3}$$

onde \hat{x} é o valor do pixel filtrado (estimado).

b) Uma outra medida bastante utilizada na literatura para avaliação de desempenho de filtros redutores de ruído "speckle" é o número equivalente de looks (ENL) que é definido em termos do coeficiente de variação. Nesta tese o ENL é calculado sobre regiões homogêneas em imagens amplitude com 1 e múltiplas visadas, antes e depois da filtragem, e é calculado segundo a **Equação 2.27**, repetida nesta seção por conveniência:

$$ENL_{A} = \left(0.5227/\beta\right)^{2} \tag{3.4}$$

onde 0.5227 representa o valor de σ_n para imagem SAR em amplitude e 1 visada.

c) Em [Oliver & Quegan (1998)] é apresentada a matriz r que é obtida da razão entre a imagem ruidosa, z, e a imagem estimada (ou filtrada) \hat{x} . Esta razão deve corresponder unicamente às flutuações do "speckle", com valor médio ($ratio_MED$) igual a 1. Através de medidas calculadas sobre esta matriz é possível avaliar a extensão das distorções radiométricas introduzidas pela filtragem, conferindo assim o quanto a estatística da imagem reconstruída se afasta da estatística esperada. Quando o valor médio observado difere significativamente de 1, isto é uma indicação de presença de distorção radiométrica na cena. Quando a reconstrução (imagem filtrada) é bem próxima da original o desvio padrão

(std_ratio) desta razão, nestas situações, deveria em princípio, ser menor que o esperado. Um exemplo de valor de desvio padrão esperado é o seguinte: quando a imagem original (no caso de detecção quadrática) tem um número efetivo de 2,2 visadas ("2,2 looks"), o desvio padrão esperado para a razão das imagens é 0.674. Na **Equação 3.5** são apresentadas as expressões para cálculo da razão ($r_{i,j}$), média ($ratio_MED$) e desvio padrão (std_ratio) da mesma, em se tratando de imagem amplitude e uma visada, considerando-se que N e M correspondem às dimensões da imagem.

$$r_{i,j} = \frac{z_{i,j}}{\hat{x}_{i,j}} \tag{3.5}$$

$$ratio_MED = \frac{1}{MN} \sum_{i,j=1}^{M,N} r_{i,j}$$

$$std_ratio = \sqrt{\frac{1}{MN} \left(\sum_{i,j=1}^{M,N} (r_{i,j} - 1) \right)^2}$$
(3.6)

Em caso de imagens amplitude e de múltiplas visadas a expressão que estima o desvio padrão teórico do ruído é dada na **Equação 2.25**.

d) Uma outra medida utilizada é o erro médio quadrático (MSE) calculado entre a imagem original sem ruído e a sua versão filtrada como segue

$$MSE = \frac{1}{MN} \sum_{i,j=1}^{M.N} \left[x(i,j) - \hat{x}(i,j) \right]^{2}$$
 (3.7)

onde x corresponde à imagem original sem ruído, \hat{x} é a imagem estimada, M e N são as dimensões da imagem. O erro médio quadrático de uma imagem (ruidosa ou filtrada) mede o desvio desta em relação à imagem original e assim é possível quantificar a perda de informação do sinal original decorrente da filtragem. Esta medida é muito popular, porque se relaciona razoavelmente com testes subjetivos de qualidade visual e por ser matematicamente tratável [Pratt (1991)].

e) Neste trabalho também foi utilizada como medida de avaliação da filtragem a raiz do erro quadrático médio normalizado (RMSNE). Em [Mascarenhas et al.

(1993)] a avaliação dos resultados de filtragem de ruído Poisson é feita segundo esta medida de erro definida pela expressão:

$$RMSNE = \sqrt{\frac{\sum_{i,j=1}^{M.N} (x_{i,j} - \hat{x}_{i,j})^2}{\sum_{i,j=1}^{M.N} x_{i,j}^2}}$$
(3.8)

onde $\hat{x}_{i,j}$ é o valor do pixel estimado e MxN é o número de pixels na imagem.

Este tipo de erro avalia a precisão da aproximação da imagem estimada (filtrada) ao valor verdadeiro. Quanto maior a diferença (erro) entre a imagem original e a filtrada considera-se que o nível de ruído é maior, e portanto, a relação sinal-ruído é menor [Sant'Anna (1995)] indicando a diminuição da quantidade do sinal original presente na imagem filtrada.

f) A preservação da média em regiões homogêneas da imagem filtrada em relação à imagem ruidosa é um importante aspecto de avaliação de desempenho da filtragem do "speckle" [Lee et al. (1994)]. Nesta tese os algoritmos de filtragem propostos são também avaliados sob este aspecto, escolhendo-se regiões homogêneas da imagem ruidosa e filtrada e calculando-se a média. Apresentamos nas imagens da Figura 3.9 um exemplo de região homogênea (pedaço de 54x54 pixels corresponde ao quadrado marcado na imagem) numa área de cultura na imagem *SAR580* sobre Freiburg – Alemanha e o respectivo histograma dos níveis de cinza presentes na região homogênea.

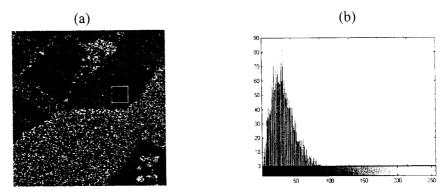


Figura 3.9 – (a) Imagem SAR580 (b) histograma da região homogênea.

g) Uma medida proposta nesta tese baseia-se na aplicação da transformada de Hough e visa analisar a dispersão ou borramento de linhas retas causado pela filtragem. Após a aplicação desta transformada é feito um pós-processamento chamado de "backmapping" cujo objetivo é ressaltar os elementos representativos da matriz acumuladora (vide Seção 3.4.1), eliminando assim possíveis picos oriundos do ruído de fundo, característico da transformada de Hough [Ishikawa (1996)]. A matriz acumuladora é construída na forma bidimensional e as células desse arranjo acumulador receberão votos resultantes do mapeamento de cada ponto (dos segmentos de reta) da imagem no espaço de Hough. Um dos incovenientes da transformada de Hough é a geração de ruído indesejável resultante da interferência entre pontos pertencentes a diferentes objetos e que contribuem para o incremento dos votos nas células. A medida S é calculada na matriz acumuladora após o "backmapping" e é obtida do valor médio das áreas de regiões vizinhas aos picos remanescentes do pós-processamento segundo a equação:

$$S = \frac{\sum_{i=1}^{N} C_i}{N} \tag{3.9}$$

onde C_i corresponde à area ao redor dos picos e N é o número de picos. O cálculo de S é obtido a partir de uma imagem como ilustra a **Figura 3.14**. Como esta medida se fundamenta na transformada de Hough maiores detalhes sobre a metodologia utilizada são apresentados na sub-seção seguinte.

3.4.1 Transformada de Hough

Em processamento de imagens a detecção automática de retas é de grande importância. Em imagens de sensoriamento remoto esse problema é de particular interesse, porque estas retas podem corresponder a rodovias, aeroportos, cursos de rios, etc. Em virtude da presença do ruído "speckle" a detecção de retas em imagens SAR torna-se uma tarefa particularmente difícil. Para investigar a perda de resolução das imagens resultantes da filtragem do "speckle", especialmente nas retas presentes nas mesmas utilizou-se neste trabalho a transformada de Hough.

O princípio básico da Transformada de Hough é o mapeamento de elementos de borda do espaço da imagem em um espaço de parâmetros, de forma que picos no espaço de parâmetros indiquem possíveis ocorrências de retas na imagem. A Transformada de Hough foi desenvolvida por Hough em 1962 [Hough (1962)]. Inicialmente a parametrização do tipo inclinação-interseção ("slope-intercept") foi utilizada para mapear um ponto na imagem usando a seguinte equação:

$$y = mx + b \tag{3.10}$$

onde m é a tangente do ângulo de inclinação da reta, ou seja, a inclinação e b é o ponto em que a reta corta o eixo y, ou seja, a interseção. O problema desta formulação é que tanto a inclinação como a interseção tendem para infinito quando uma reta se aproxima da vertical [Ishikawa (1996)]. Mais tarde, Duda e Hart [Duda & Hart (1972)] apresentaram uma parametrização normal que soluciona o problema da formulação original e portanto, torna a transformada de Hough mais eficiente na detecção de retas. Na Figura 3.10, itens (b) e (c) são apresentados conjuntos de retas possíveis de cruzar os pontos presentes na Figura 3.10a.

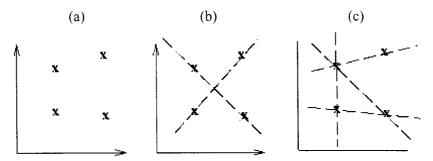


Figura 3.10- (a) Pontos no espaço de coordenadas (b) e (c) possíveis ajustes de retas aos pontos.

Na formulação proposta por [Duda & Hart (1972)] um segmento de reta pode ser descrito analiticamente pela Equação 3.11.

$$x\cos\theta + ysen\theta = r \tag{3.11}$$

onde (x,y) indicam a posição espacial do ponto na reta, ou mesmo um pixel em caso de se tratar de uma imagem, e r é a distância da origem ao pé da normal a esta reta e θ é a orientação de r com respeito ao eixo x, (vide **Figura 3.11**). Para qualquer ponto (x,y) numa reta os parâmetros r e θ são os mesmos.

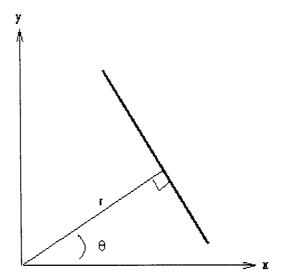


Figura 3.11 – Descrição paramétrica de uma reta.

Desta forma N pontos colineares em uma reta fornecerão N curvas senoidais que se interceptam na célula (r_i, θ_i) no espaço de parâmetros, sendo que o índice i referese à célula i no espaço de parâmetros.

A Figura 3.12a apresenta a reta a ser detectada que é composta de pontos colineares. As retas da Figura 3.12b têm um ponto de interseção que no espaço de parâmetros corresponde à inclinação e à interseção, que caracterizam a reta que passa pelos pontos colineares e estão na imagem.

A transformada de Hough divide o espaço de parâmetros em células, pela quantização das dimensões m e b em um número fixo de intervalos, gerando o espaço acumulador **Figura 3.12c**. Em geral, aplica-se esta transformada em uma imagem contendo as bordas detectadas na cena a ser analisada. Para cada elemento da borda (x,y) da imagem, uma senóide é traçada no espaço acumulador ou espaço de parâmetros, o qual contém a matriz acumuladora (ou arranjo acumulador). Cada ponto do espaço da imagem adiciona um voto nas células desta matriz por onde passa a reta a ela associada. Esta transformada destaca os segmentos de reta presentes na imagem mapeando-os em picos no espaço de parâmetros. Desta forma algumas observações podem ser feitas como sugere [**Duda & Hart (1972)**]:

- a) um ponto na imagem corresponde a uma curva senoidal no espaço paramétrico;
- b) um ponto no espaço paramétrico corresponde a um segmento de reta na imagem;
- c) pontos pertencentes ao mesmo segmento de reta na imagem correspondem a curvas que passam por um ponto em comum no espaço paramétrico;
- d) pontos pertencentes à mesma curva no espaço paramétrico correspondem a segmentos de reta através de um mesmo ponto na imagem.

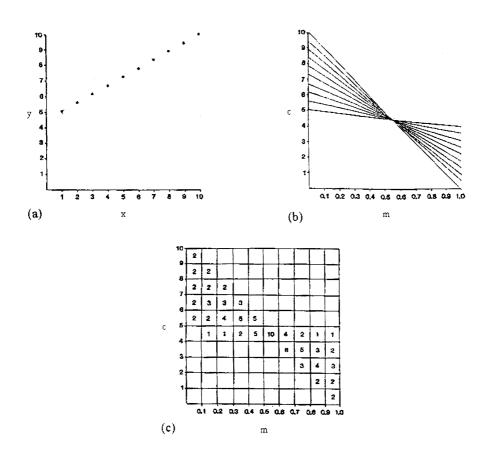


Figura 3.12-Transformada de Hough original para detecção de retas

(a) espaço da imagem (b) espaço de parâmetro (c) espaço acumulador.

[Illingworth & Kittler (1988)]

Nesta tese foi implementada a formulação sugerida por Duda & Hart [Duda & Hart (1972)] e para evitar ruído indesejável no espaço de parâmetros foi aplicado um algoritmo de pós-processamento no arranjo acumulador denominado rastreamento ("backmapping") [Gerig & Klein (1986)]. Este algoritmo de pós-processamento premia as células do arranjo acumulador com maior número de votos preservando-as, e penaliza aquelas com pequenos números de votos e que são mais prováveis de serem ruído, eliminando-as. Como são mantidos apenas os pontos mais prováveis de se encontrar segmentos de reta realmente significativos, é considerável a redução do tempo de análise do novo acumulador de Hough.

3.4.2 Resultados de Aplicação da Transformada de Hough na Obtenção da Medida S

Na Figura 3.13 estão os resultados de aplicação da transformada de Hough às imagens filtradas com o filtro MAP combinado ao k-médias proposto nesta tese, que utiliza o modelo Rayleigh para o "speckle" e o modelo gama para o conhecimento "a priori" e com o filtro de Kuan. As imagens que se observam são resultados das seguintes etapas de processamento: inicialmente filtra-se o ruído "speckle" da imagem ruidosa (neste exemplo a imagem SAR580) e em seguida classificam-se as imagens filtradas usando os algoritmos de máxima verossimilhança (MaxVer) ou ICM, finalmente aplica-se a transformada de Hough às imagens binarizadas e o algoritmo de rastreamento ("backmapping"). O resultado da aplicação do "backmapping" é mostrado nas imagens da Figura 3.14 onde é possível observar o efeito de borramento nos segmentos de reta das imagens filtradas, representado através da dispersão das ilhas de picos ou pontos nas imagens. Neste exemplo a imagem filtrada pelo algoritmo (Figura 3.14a) proposto nesta tese apresenta uma menor dispersão (borramento), ou seja, há uma maior concentração dos pontos nas ilhas que o filtro Kuan (Figura 3.14b).

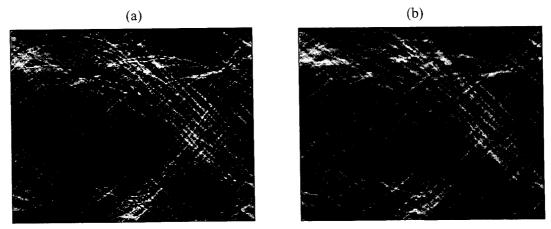


Figura 3.13 - Transformada de Hough aplicada a imagem (*SAR580*) filtrada pelos filtros (a) MAP gama com k-médias (b) Kuan.

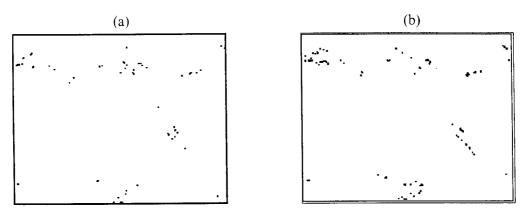


Figura 3.14 – "Backmapping" da transformada de Hough aplicada a imagem (SAR580) filtrada pelos filtros (a) MAP gama com k-médias (b) Kuan.

Na Figura 3.15 é mostrado o diagrama de blocos com os passos para cálculo da medida de dispersão S. Na sequência inicial são aplicados os algoritmos de filtragem MAP à imagem ruidosa, em seguida é feita a classificação usando o algoritmo ICM software SPRING [Apêndice E]. A imagem classificada é binarizada e em seguida aplica-se um algoritmo simples para detecção de bordas, que consiste em deslizar sobre todos os pixels da imagem uma janela de 4 pixels (2x2). No caso da soma dos elementos desta janela ser diferente de 0 ou 4 então marca-se o elemento como borda. Aplica-se, na próxima etapa, a transformada de Hough sobre esta imagem de bordas resultante. O algoritmo de "backmapping" consiste em considerar contribuições de células no arranjo acumulador que estejam acima de um determinado limiar (número de votos) e marcá-las com 1 (picos) e células com votos abaixo desse limiar são desconsideradas e marcadas com 0. O cálculo da medida de dispersão é feito sobre as ilhas de picos que se formam na matriz resultante do pósprocessamento por Hough. A perda de resolução é quantificada através da medida Scalculada sobre a matriz de ilhas de picos resultante do "backmapping". Calcula-se a área em torno dos picos somando-se os 8 pixels conectados a eles nesta matriz, e em seguida divide-se esta área pelo número de picos. Se a filtragem causar muito borramento na imagem, então os segmentos de reta detectados pela transformada de Hough & "backmapping" apresentarão ilhas de picos com maior dispersão, resultando assim em um maior valor de S. Dessa forma é possível avaliar o desempenho de diferentes filtros quanto à perda de resolução causada pela filtragem.

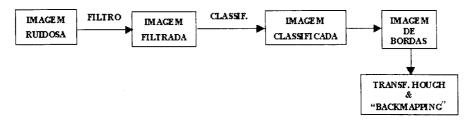


Figura 3.15 – Seqüência de passos para o cálculo da medida de dispersão.

3.5 Conclusão

Como o critério subjetivo de melhoria visual não é suficiente para avaliar o desempenho dos algoritmos, os mesmos foram avaliados através de algumas medidas clássicas, apresentadas neste capítulo, e que quantificam a intensidade de presença de "speckle" em regiões homogêneas e os efeitos da filtragem sobre as bordas. Foi introduzida nesta tese uma nova medida baseada na transformada de Hough e que avalia a perda de resolução em segmentos de retas presentes na imagem.

4 Abordagem MAP para Redução do Ruído "Speckle"

4.1 Introdução

A técnica "maximum a posteriori" (MAP) é particularmente promissora pois incorpora não somente as propriedades do "speckle" em imagens SAR como considera a estatística mais conveniente à modelagem do "backscatter". Isto significa que o método combina o conhecimento prévio ("a priori") com o modelo estatístico suposto para a variável observada (imagem ruidosa a ser filtrada) que é a distribuição condicional, não sendo necessário conhecer a distribuição total (f(z) na **Equação 2.55**). Considerando o modelo de imagem, a **Equação 2.33** e utilizando a regra de Bayes (vide **Equação 2.55**) a estimação MAP é obtida da maximização da função de densidade de probabilidade a "posteriori". É usual na derivação do estimador MAP aplicar o logaritmo, que é uma função monoticamente crescente, a f(x|z) e diferenciála com relação a x. O estimador MAP da variável x, como discutido anteriormente, é obtido como mostra a equação:

$$\frac{\partial \ln f(x \mid z)}{\partial x} = \frac{\partial \ln f(z \mid x)}{\partial x} + \frac{\partial \ln f(x)}{\partial x} \Big|_{x = \hat{x}_{MAP}} = 0 \tag{4.1}$$

pois a contribuição de f(z) é nula, ou seja, $\frac{\partial \ln f(z)}{\partial x} = 0$.

Vários filtros MAP usando diferentes distribuições a "priori" foram propostos em [Mascarenhas et al. (1996a)] com o objetivo de filtrar projeções tomográficas corrompidas por ruído Poisson. Como as imagens no presente trabalho são corrompidas pelo ruído "speckle" propõem-se outros filtros MAP considerando dois diferentes modelos para o ruído "speckle", ou seja, a distribuição condicional segue a distribuição raiz de gama em caso de imagem amplitude e múltiplas visadas distribuição Rayleigh em caso de detecção linear (amplitude) e uma visada e segue a.

O pixel ruidoso será atualizado com a solução da equação MAP, se a mesma estiver entre a média e a observação, ou mesmo pela média local em caso da razão de variâncias (R) indicar homogeneidade da região próxima ao pixel observado (ruidoso). O parâmetro R, como já foi mencionado em seções anteriores, é dado pela razão entre a variância da imagem original a ser estimada e a variância da imagem ruidosa observada e no caso de regiões onde o modelo de caminhada aleatória se aplica esta razão R varia normalmente de 0 a 1. Observou-se que valores de R<0, ou seja, regiões extremamente homogêneas e para as quais o modelo não se aplica, constituem um caso frequente em algumas imagens de teste. Algumas causas possíveis de R apresentar valores negativos são: baixo número de elementos refletores na célula de resolução; efeito da quantização sobre os dados, especialmente em baixas tonalidades, etc. No caso de regiões que apresentam baixa variância de "backscatter" em torno do pixel observado, esta razão apresenta valores muito próximos de 0, o que constitui indicativo de homogeneidade e portanto, a melhor estimativa para este pixel é a média dos seus vizinhos. Em caso desta razão apresentar valores muito próximos de 1, ou seja, a região apresentar uma variância de "backscatter" da ordem da variância do pixel observado a melhor estimativa do pixel ruidoso deve ser o próprio pixel (razão unitária), ou para valores próximos a 1 utilizar pequenas janelas. O cálculo da média é feito utilizando uma janela cujo tamanho é definido pelo algoritmo de k-médias sobre o parâmetro R. Esta técnica de aglomeração (vide Seção 3.2) classifica os diferentes grupos ("k-clusters") de texturas presentes na imagem. Uma vez identificadas as classes de texturas atribui-se a cada uma delas um tamanho de janela de filtragem, ou seja, uma janela na qual são estimados os parâmetros das supostas distribuições "a priori" assumidas para o "backscatter".

A contribuição deste capítulo é a investigação e proposta de filtros para redução do ruído "speckle" baseados na abordagem MAP.

4.2 Modelo de Filtro MAP Proposto para Imagens Detectadas em Amplitude e Uma Visada

Sabendo-se que o modelo para o ruído "speckle" em imagens SAR do tipo amplitude e uma visada obedece a uma distribuição Rayleigh (**Equação 4.2**) e que o modelo multiplicativo impõe média unitária ao ruído, obtém-se uma formulação para a distribuição do ruído com média unitária de acordo com a **Equação 4.3**.

$$f(g) = \frac{g}{\sigma^2} e^{-\left(\frac{g^2}{2\sigma^2}\right)}, \qquad g > 0$$

$$\sigma = \mu \sqrt{\frac{2}{\pi}}$$
(4.2)

onde σ é o parâmetro da Rayleigh que corresponde ao "backscatter" e μ representa a média.

$$f(n) = \frac{n\pi}{2}e^{-\left(\frac{n^2\pi}{4}\right)}, \qquad n > 0$$
(4.3)

O modelo de distribuição atribuído ao "speckle" considera que $E[f(z \mid x)] = x$, ou seja, E[n] = 1. Adotando-se o modelo Rayleigh para o padrão de "speckle" presente em imagens obtidas por deteção linear e uma visada, e derivando o logaritmo da distribuição $f(z \mid x)$ tem-se na **Equação 4.4 [Medeiros et al. (1998c)]** o modelo do ruído, que será utilizado no estimador MAP e posteriormente combinado às várias distribuições a "priori" propostas nesta tese. Os parâmetros das diversas distribuições são estimados pelo método dos momentos [**Apêndice B**].

$$f(z \mid x) = \frac{\pi}{2} \frac{z}{x^2} e^{-\frac{\pi z^2}{4x^2}}$$

$$\frac{\partial}{\partial x} \ln[f(z \mid x)] = -\frac{2}{x} + \frac{\pi z^2}{2x^3}$$
(4.4)

4.2.1 Densidade "a priori" Gaussiana

A função de densidade Gaussiana e seus parâmetros estimados pelo método dos momentos está expressa na **Equação 4.5**. O parâmetro μ_x é obtido através do estimador da média amostral sobre a imagem ruidosa e σ_x^2 pela variância amostral, ambos calculados em uma janela de w pixels centrada no elemento de imagem que se deseja filtrar. Ao longo deste trabalho foi utilizada para cálculo da variância da imagem original, a expressão de σ_x^2 derivada do modelo multiplicativo que é apresentada na **Equação 2.37**.

$$f(x) = \frac{1}{\sigma_x \sqrt{2\pi}} e^{-\frac{1}{2} \left(\frac{x-\mu}{\sigma_x}\right)^2}$$

$$\hat{\mu}_x = \frac{1}{N} \sum_{i=1}^N x_i$$

$$\hat{\sigma}_x^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \hat{\mu})^2$$
(4.5)

$$\frac{\partial}{\partial x} \ln f(x) = -\left(\frac{x - \mu_x}{\sigma_x^2}\right) \tag{4.6}$$

Combinando o modelo de distribuição do ruído "speckle" e a distribuição Gaussiana como suposto conhecimento a "priori" para a imagem original na equação que maximiza a distribuição a "posteriori" (Equação 4.1) tem-se a expressão do estimador MAP na equação seguinte[Medeiros et al. (1998a)]:

$$\frac{\partial}{\partial x} \ln f(x \mid z) = \frac{\partial}{\partial x} \ln f(x) + \frac{\partial}{\partial x} \ln f(z \mid x) = 0$$

$$-\left(\frac{x - \mu_x}{\sigma_x^2}\right) + \frac{2}{x} + \frac{\pi z^2}{2x^3} = 0$$
(4.7)

$$2x^{4} - 2\mu_{x}x^{3} + 4\sigma_{x}^{2}x^{2} - \sigma_{x}^{2}\pi z^{2} = 0$$
(4.8)

O parâmetro μ_x foi calculado sobre a imagem observada, pois o modelo multiplicativo impõe $\mu_x=\mu_z$ pelo fato do ruído ter média unitária. A raiz real e

positiva que estiver entre a média e o valor do pixel observado (ruidoso) é usada para atualizar o pixel a ser filtrado.

4.2.2 Densidade "a priori" gama

Considerando que o conhecimento a "priori" segue uma distribuição gama temse a função de densidade para todo $x \in \mathcal{H}_+$, a esperança matemática e a variância, dadas por [DeGroot (1975)].

$$f(x) = \frac{\sigma_x}{\Gamma(\lambda_x)} (\sigma_x x)^{n-1} e^{-(\sigma_x x)}$$

$$E[x] = \frac{\lambda_x}{\sigma_x}$$

$$Var[x] = \frac{\lambda_x}{\sigma_x^2}$$
(4.9)

Usando o mesmo procedimento do item anterior, ou seja, aplicando a regra de Bayes para obter a função f(x|z), aplica-se em seguida o logaritmo e maximiza-se a mesma com relação à variável x. Obtém-se desta forma o estimador local MAP gama que é dado pela solução da equação polinomial [Mascarenhas et al. (1997)]:

$$2\sigma_{x}x^{3} + x^{2}(6 - 2\lambda_{x}) - \pi z^{2} = 0$$
(4.10)

Os parâmetros $\lambda_x e \sigma_x$ são estimados pela média e variância amostral usando o método dos momentos segundo a **Equação 4.11** como em [Vieira (1996)]:

$$\hat{\lambda}_x = \frac{\hat{\mu}_x^2}{\hat{s}^2}$$

$$\hat{\sigma}_x = \frac{\hat{\mu}_x}{\hat{s}^2}$$
(4.11)

4.2.3 Densidade "a priori" chi-quadrado

Uma outra suposição do conhecimento "a priori" da imagem que se deseja estimar é que esta obedeça a uma distribuição chi-quadrado. Esta distribuição é um caso particular da distribuição gama em que os parâmetros σ e λ assumem

respectivamente os valores 1/2 e n/2, onde n é um inteiro positivo e representa o número de graus de liberdade [Gibra (1973)]. A função densidade de probabilidade, a esperança matemática e a variância estão expressas na Equação 4.12.

$$f(x) = \frac{1}{2^{\frac{n}{2}} \Gamma(n/2)} x^{\frac{n}{2} - 1} e^{-\frac{x}{2}}$$

$$E[x] = n$$

$$Var[x] = 2n$$
(4.12)

Novamente aplica-se na **Equação 4.1** a expressão de densidade "a priori", neste caso gama, e obtém-se a equação polinomial do estimador MAP [**Medeiros et al.** (1998c)], cuja raiz será usada na atualização do pixel ruidoso se esta estiver entre a média e a observação. O parâmetro n é estimado usando a média amostral .

$$x^{3} + x^{2}(6 - n) - \pi z^{2} = 0$$

$$\hat{n} = \hat{\mu}_{x} = \hat{\mu}_{z} = m$$
(4.13)

4.2.4 Densidade "a priori" exponencial

Supondo que o conhecimento "a priori" segue uma distribuição exponencial com parâmetro σ segundo a equação

$$f(x) = \sigma e^{-\sigma x} \qquad x > 0$$

$$E[x] = \frac{1}{\sigma}$$

$$Var[x] = \frac{1}{\sigma^2}$$
(4.14)

A distribuição exponencial é um caso particular da distribuição gama para $\lambda=1$. Aplicando-se o mesmo procedimento dos itens anteriores, obtém-se a equação do estimador MAP de x [Medeiros et al. (1998c)], onde o parâmetro σ_x é obtido da

média amostral:

$$2\sigma_{x}x^{3} + 4x^{2} - \pi z^{2} = 0$$

$$\hat{\sigma}_{x} = \frac{1}{\hat{\mu}_{x}} = \frac{1}{m}$$
(4.15)

4.2.5 Densidade "a priori" Rayleigh

Considerando que o conhecimento a "priori" segue uma distribuição Rayleigh, tem-se a função de densidade para todo $x \in \mathcal{H}_+$, a esperança matemática e a variância, dadas por [DeGroot (1975)].

$$f(x) = \frac{x}{\sigma_x^2} e^{-\frac{x^2}{2\sigma_x^2}}$$

$$E[x] = \frac{\sigma}{\sqrt{\frac{2}{\pi}}}$$

$$\sigma = E[x]\sqrt{\frac{2}{\pi}}$$
(4.16)

Aplicando esta expressão na **Equação 4.1** obtém-se o estimador local MAP Rayleigh [Medeiros et al. (1998c)], que é dado pela solução da equação polinomial:

$$2x^{4} + 2x^{2}\sigma_{x}^{2} - \pi z\sigma_{x}^{2}z^{2} = 0$$
(4.17)

onde o parâmetro σ_x é estimado pela média amostral como mostra a equação a seguir:

$$\hat{\sigma}_{x}^{2} = \hat{\mu}_{x} \sqrt{\frac{2}{\pi}} = \hat{\mu}_{z} \sqrt{\frac{2}{\pi}}$$
(4.18)

4.2.6 Densidade "a priori" beta

Uma variável aleatória Y que assume valores entre 0 e 1 possui uma distribuição beta com parâmetros α e β inteiros e positivos segundo a expressão [**DeGroot** (1975)]:

$$f(y;\alpha,\beta) = \frac{\Gamma(\alpha+\beta)}{\Gamma(\alpha)\Gamma(\beta)} y^{\alpha-1} (1-y)^{\beta-1}$$

$$E[y] = \frac{\alpha}{\alpha + \beta}$$

$$Var[y] = \frac{\beta}{(\alpha + \beta + 1)} \frac{\alpha}{(\alpha + \beta)^{2}}$$
(4.19)

Seja a variável aleatória X=kY, onde $k\in\Re_+$ então a sua densidade f(x) é dada por:

$$f(x;\alpha,\beta) = \frac{\Gamma(\alpha+\beta)}{\Gamma(\alpha)\Gamma(\beta)} k^{-\alpha} x^{\alpha-1} \left(1 - \frac{x}{k}\right)^{\beta-1}$$

$$E[x] = kE[y]$$

$$Var[x] = k^2 Var[y]$$
(4.20)

A distribuição beta foi redefinida neste trabalho pelo fato dos dados de teste estarem fora do intervalo [0,1] no qual está o suporte desta distribuição. Para o caso das imagens de teste foi atribuído à constante k o valor máximo de intensidade presente na imagem. No caso das imagens cujos níveis de cinza estão compreendidos entre 0 e 255 foi atribuído à constante k o valor máximo da representação em 8 bits para os níveis de cinza que a representam, ou seja, k=255.

Os parâmetros α e β da nova distribuição são estimados pelo método dos momentos utilizando as expressões:

$$\alpha = \frac{E^{2}[x]k - E^{3}[x] - Var[x]E[x]}{kVar[x]}$$

$$\beta = \frac{k \cdot \alpha}{E[x]} - \alpha$$
(4.21)

Aplicando logaritmo à densidade f(x) e derivando com relação à variável x temse:

$$\frac{\partial}{\partial x} \left(\ln f(x) \right) = \frac{\alpha - 1}{x} + \frac{1 - \beta}{k - x} \tag{4.22}$$

Utilizando a distribuição "a priori" dada pela **Equação 4.20** deriva-se o estimador MAP através da **Equação 4.1**, obtendo-se a equação polinomial:

$$x^{3}(8-2\alpha-2\beta)+x^{2}k(2\alpha-6)-x\pi z^{2}+\pi z^{2}k=0$$
(4.23)

4.2.7 Densidade "a priori" log-normal

Uma variável aleatória X possui uma distribuição log-normal se o logaritmo (lnx) é normalmente distribuído com parâmetros μ e σ [Gibra (1973)].

A densidade de uma variável deste tipo, a esperança matemática e variâncias são dadas pela expressão:

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} x^{-1} e^{\frac{1}{2\sigma^2}(\ln x - \mu)^2}$$

$$E[x] = e^{\mu + \left(\frac{\sigma^2}{2}\right)}$$

$$Var[x] = e^{(2\mu + \sigma^2)} \left(e^{\sigma^2} - 1\right)$$
(4.24)

onde μ é um número real e σ é real e positivo e são estimados pelo método dos momentos segundo as expressões:

$$\mu = \log \left(\frac{E^{2}[x]}{\sqrt{Var[x] + E^{2}[x]}} \right)$$

$$\sigma^{2} = \log \left(\frac{Var[x] + E^{2}[x]}{E^{2}[x]} \right)$$
(4.25)

Aplicando o mesmo procedimento dos itens anteriores para obtenção do estimador MAP obtém-se a equação polinomial com densidade "a priori" lognormal:

$$6\sigma^2 x^2 + 2x^2 \ln x - 2\mu x^2 - \sigma^2 \pi z^2 = 0$$
(4.26)

A busca da solução desta equação é feita utilizando o método de Newton-Raphson segundo a expressão:

$$\hat{x}_{n+1} = \hat{x}_n - \frac{(6\sigma^2 x^2 + 2x^2 \ln x - 2\mu x^2 - \sigma^2 \pi z^2)}{(12x\sigma^2 + 4x \ln x - 4\mu x + 2x)}$$
(4.27)

4.3 Modelo Proposto de Filtro MAP para Imagens Amplitude de N Visadas

No capítulo 2 foram apresentadas as duas alternativas para a obtenção de imagens com detecção linear (amplitude) e múltiplas (N) visadas. Neste trabalho foi utilizada a segunda alternativa que compreende a média de N imagens intensidade (x_I) e a posterior aplicação da raiz quadrada ao resultado como mostra a **Equação** 2.21. A distribuição da variável resultante segue a raiz quadrada da gama como mostra a **Equação** 2.22. O modelo considerado para o ruído "speckle" (n) em imagens SAR do tipo amplitude e múltiplas visadas segue uma distribuição raiz quadrada da gama. Como o modelo multiplicativo impõe média unitária ao ruído, obtém-se uma formulação para a densidade condicional da imagem ruidosa dada a não ruidosa, considerando que $E[f(z \mid x)] = x$, ou seja, E[n] = 1 segundo a expressão:

$$f(z \mid x) = \frac{2}{x^{2N} \Gamma^{2N}(N) \Gamma(N)} \Gamma^{2N}(N+1/2) z^{2N-1} e^{-\left(z^2 \frac{\Gamma^2(N+1/2)}{x^2 \Gamma^2(N)}\right)}$$
(4.28)

onde N corresponde ao número de visadas.

Adotando este modelo e derivando o logaritmo da distribuição $f(z \mid x)$ tem-se na **Equação 4.29** a expressão que será combinada às várias distribuições a "priori" propostas nesta tese e utilizada no estimador MAP.

$$\frac{\partial}{\partial x} \ln \left[f(z \mid x) \right] = -\frac{2N}{x} + \frac{2z^2 \Gamma^2 (N + 1/2)}{x^3 \Gamma^2 (N)} \tag{4.29}$$

4.3.1 Densidade "a priori" Gaussiana

A função de densidade Gaussiana e seus parâmetros estimados pelo método dos momentos estão expressos na **Equação 4.5** e a derivada do logaritmo da distribuição

expressa na **Equação 4.6**. Combinando o modelo de distribuição do ruído "speckle" e a distribuição Gaussiana como suposto conhecimento a "priori" para a imagem original na equação que maximiza a distribuição a "posteriori" tem-se a expressão do estimador MAP [**Medeiros et al. (1998b)**]:

$$\frac{\partial}{\partial x} \ln f(x \mid z) = \frac{\partial}{\partial x} \ln f(z \mid x) + \frac{\partial}{\partial x} \ln f(x) = 0$$

$$-\frac{2N}{x} + \frac{2z^2 \Gamma^2 (N + 1/2)}{x^3 \Gamma^2 (N)} - \left(\frac{x - \mu_x}{\sigma_x^2}\right) = 0$$
(4.30)

$$x^{4}\Gamma^{2}(N) - x^{3}\Gamma^{2}(N)\mu_{x} + x^{2}2N\Gamma^{2}(N)\sigma_{x}^{2} - \sigma_{x}^{2}2z^{2}\Gamma^{2}(N+1/2) = 0$$
 (4.31)

O parâmetro μ_x da equação polinomial (**Equação 4.31**) foi calculado sobre a imagem observada, pois o modelo multiplicativo impõe $\mu_x = \mu_z$ pelo fato do ruído ter média unitária. A raiz real e positiva que estiver entre a média e o valor do pixel observado (ruidoso) é usada para atualizar o pixel.

4.3.2 Densidade "a priori" gama

Considerando que o conhecimento a "priori" segue uma distribuição gama dada pela **Equação 4.9** e usando o mesmo procedimento do item anterior, ou seja, aplicando logaritmo à distribuição e derivando este resultado com relação à variável x, obtém-se a expressão:

$$\frac{\partial}{\partial x} \ln f(x) = -\sigma_x + \frac{\lambda - 1}{x} \tag{4.32}$$

Combinando o modelo do "speckle" a este conhecimento "a priori" segundo a expressão $\frac{\partial}{\partial x} \ln f(x \mid z) = \frac{\partial}{\partial x} \ln f(z \mid x) + \frac{\partial}{\partial x} \ln f(x) = 0$, obtém-se a equação do estimador local MAP [Medeiros et al. (1998b)]:

$$-\frac{2N}{x} + \frac{2z^2\Gamma^2(N+1/2)}{x^3\Gamma^2(N)} - \sigma_x + \frac{\lambda - 1}{x} = 0$$
 (4.33)

A raiz real do polinômio (**Equação 4.34**) que estiver entre a observação e a média será utilizada para atualização do pixel ruidoso.

$$x^{3}\sigma_{x}\Gamma^{2}(N) + x^{2}\Gamma^{2}(N)[2N - \lambda + 1] - 2z^{2}\Gamma^{2}(N + 1/2) = 0$$
 (4.34)

Os parâmetros $\lambda_x e \sigma_x$ são estimados pela média e variância amostrais usando o método dos momentos segundo a **Equação 4.11**.

4.3.3 Densidade "a priori" chi-quadrado

Uma outra expressão utilizando o conhecimento "a priori" da imagem que se deseja estimar como sendo do tipo chi-quadrado (**Equação 4.12**) é derivada seguindo os mesmos passos anteriores. O estimador é obtido da solução da equação polinomial resultante das equações:

$$\frac{\partial}{\partial x} \ln f(x \mid z) = \frac{\partial}{\partial x} \ln f(z \mid x) + \frac{\partial}{\partial x} \ln f(x) = 0$$

$$-\frac{2N}{x} + \frac{2z^2 \Gamma^2 (N + 1/2)}{x^3 \Gamma^2 (N)} - \frac{1}{2} + \frac{1}{x} \left(\frac{n}{2} - 1 \right) = 0$$
(4.35)

onde o parâmetro n é o número de graus de liberdade da distribuição chi-quadrado e é estimado da média amostral como mostra a **Equação 4.12**. O estimador MAP é a solução da equação polinomial [**Medeiros et al. (1998b)**] dada pela expressão:

$$x^{3}\Gamma^{2}(N) + x^{2}\Gamma^{2}(N)[4N - n + 2] - 4z^{2}\Gamma^{2}(N + 1/2) = 0$$
 (4.36)

4.3.4 Densidade "a priori" exponencial

Supondo que o conhecimento "a priori" segue uma distribuição exponencial com parâmetro σ como mostra a **Equação 4.14** e aplicando o mesmo procedimento dos itens anteriores, obtém-se a equação do estimador de x MAP [**Medeiros et al.** (1998b)], onde o parâmetro σ_x é obtido da média amostral:

$$\frac{\partial}{\partial x} \ln f(x \mid z) = \frac{\partial}{\partial x} \ln f(z \mid x) + \frac{\partial}{\partial x} \ln f(x) = 0$$

$$-\frac{2N}{x} + \frac{2z^2 \Gamma^2 (N + 1/2)}{x^3 \Gamma^2 (N)} - \sigma_x = 0$$
(4.37)

A equação polinomial resultante é dada por:

$$x^{3}\Gamma^{2}(N)\sigma_{x} + x^{2}\Gamma^{2}(N)2N - 2z^{2}\Gamma^{2}(N+1/2) = 0$$
 (4.38)

A raiz real do polinômio que estiver entre a observação e a média será utilizada para atualização do pixel ruidoso.

4.3.5 Densidade "a priori" Rayleigh

Considerando que o conhecimento a "priori" segue uma distribuição Rayleigh como na **Equação 4.16** e aplicando esta expressão na **Equação 4.1** obtém-se desta forma o estimador local MAP Rayleigh a partir das expressões:

$$\frac{\partial}{\partial x} \ln f(x \mid z) = \frac{\partial}{\partial x} \ln f(z \mid x) + \frac{\partial}{\partial x} \ln f(x) = 0$$

$$-\frac{2N}{x} + \frac{2z^2 \Gamma^2 (N + 1/2)}{x^3 \Gamma^2 (N)} + \frac{1}{x} - \frac{x}{\sigma_x^2} = 0$$
(4.39)

onde o parâmetro σ_x é estimado pela média amostral como mostra a equação a seguir:

$$\hat{\sigma}_{x}^{2} = \hat{\mu}_{x} \sqrt{\frac{2}{\pi}} = \hat{\mu}_{z} \sqrt{\frac{2}{\pi}}$$
 (4.40)

A equação polinomial resultante é dada por [Medeiros et al. (1998b)]:

$$x^{4}\Gamma^{2}(N) + x^{2}\Gamma^{2}(N)\sigma_{x}^{2}[2N-1] - 2\sigma_{x}^{2}z^{2}\Gamma^{2}(N+1/2) = 0$$
 (4.41)

Novamente o pixel ruidoso será atualizado com a raiz do polinômio que estiver entre a média e a observação.

4.3.6 Densidade "a priori" beta

Utilizando o resultado da aplicação da derivada ao logaritmo da distribuição beta (**Equação 4.22**) na expressão que maximiza a distribuição a posteriori (**Equação 4.1**) obtém-se a equação polinomial:

$$x^{3} (\Gamma^{2}(N)/k) (-\alpha + 2 - \beta + 2N) + x^{2} \Gamma^{2}(N) (\alpha - 1 - 2N) - x(2\Gamma^{2}(N+1/2)z^{2})/k + 2\Gamma^{2}(N+1/2)z^{2} = 0$$
(4.42)

Os parâmetros α e β são estimados pelo método dos momentos usando a (**Equação 4.21**) e N representa o número de visadas.

4.3.7 Densidade "a priori" log-normal

Para a obtenção do estimador MAP com distribuição "a priori" log-normal (**Equação 4.24**) repetem-se os mesmos passos dos itens anteriores e a equação polinomial resultante é dada por:

$$x^{2}\Gamma^{2}(N)(-2N\sigma_{x}^{2}-\sigma_{x}^{2}-\ln x+\mu_{x})+2z^{2}\Gamma^{2}(N+1/2)=0$$
 (4.43)

A solução desta equação é obtida pelo método de Newton-Raphson e é dada por:

$$\hat{x}_{n+1} = \hat{x}_n - \frac{(6\sigma^2 x^2 + 2x^2 \ln x - 2\mu x^2 - \sigma^2 \pi z^2)}{(12x\sigma^2 + 4x \ln x - 4\mu x + 2x)}$$
(4.44)

4.4 Síntese das Equações MAP

A **Tabela 4.1** resume os algoritmos MAP derivados a partir do modelo raiz de gama para o ruído speckle presente em imagens obtidas por deteção linear e múltiplas visadas. Nesta tabela a formulação do filtro MAP gama reúne as expressões derivadas para os filtros MAP exp e MAP chi, pois estas distribuições são casos particulares da distribuição gama. A distribuição exponencial é um caso particular da gama com parâmetro $\lambda_x = 1$ e a distribuição chi-quadrado é um outro caso particular com parâmetros $\sigma_x = 1/2$ e $\lambda_x = N/2$. As expressões dos filtros

MAP para imagens amplitude e uma visada são casos particulares das equações da **Tabela 4.1** considerando N=1.

Tabela 4.1 – Equações MAP para modelo de speckle presente em 1	magens obtidas
por deteção linear e múltiplas (N) visadas.	

Distribuição "a priori" f(x)	raiz de gama (N visadas) $f(z x)$
Gaussiana	$x^{4}\Gamma^{2}(N) - x^{3}\Gamma^{2}(N)\mu_{x} + x^{2}2N\Gamma^{2}(N)\sigma_{x}^{2} - \sigma_{x}^{2}2z^{2}\Gamma^{2}(N+1/2) = 0$
gama	$x^{3}\sigma_{x}\Gamma^{2}(N) + x^{2}\Gamma^{2}(N)[2N - \lambda + 1] - 2z^{2}\Gamma^{2}(N + 1/2) = 0$
Rayleigh	$x^{4}\Gamma^{2}(N) + x^{2}\Gamma^{2}(N)\sigma_{x}^{2}[2N-1] - 2\sigma_{x}^{2}Z^{2}\Gamma^{2}(N+1/2) = 0$
beta	$x^{3} (\Gamma^{2}(N)/k) (-\alpha + 2 - \beta + 2N) + x^{2} \Gamma^{2}(N) (\alpha - 1 - 2N) -$
	$x(2\Gamma^{2}(N+1/2)z^{2})/k + 2\Gamma^{2}(N+1/2)z^{2} = 0$
log-normal	$x^{2}\Gamma^{2}(N)(-2N\sigma_{x}^{2}-\sigma_{x}^{2}-\ln x+\mu_{x})+2z^{2}\Gamma^{2}(N+1/2)=0$

4.5 Implementação do Algoritmo MAP

Uma das vantagens da filtragem adaptativa consiste em utilizar as propriedades locais para ajustar os parâmetros do filtro à não estacionaridade da média e variância. Sendo assim bordas e detalhes são preservadas pois o processamento local considera informações de vizinhança tais como: variância local, razão de variâncias R, etc. Este trabalho propõe algoritmos adaptativos de filtragem de ruído "speckle" capazes de aplicar uma maior suavização sobre regiões homogêneas e reduzir a suavização sobre regiões de variância alta (Ex: bordas e detalhes). O algoritmo básico que implementa a filtragem adaptativa MAP aplicado às imagens amplitudes com 1 e múltiplas visadas segue o fluxograma da **Figura 4.1**. Para todo pixel da imagem observada (ruidosa) é centrada uma janela fixa (5x5) para o cálculo da média (\bar{z}) e da variância amostral (σ_z^2). De posse dessa informação estatística dos pixels ruidosos, estima-se a variância $\hat{\sigma}_x^2$ do pixel não ruidoso e calcula-se a razão de variâncias, R, como definida na **Equação 2.48**. Todos os pixels cujos valores da variância estimada, $\hat{\sigma}_x^2$, forem menores ou iguais a zero, ou seja, onde falha o modelo, devem ser atualizados

pela média, pois se caracterizam como sendo pixels pertencentes a regiões extremamente homogêneas. Caso contrário, é aplicado o algoritmo de classificação k-médias (unidimensional) sobre os parâmetros R, definindo assim as classes de texturas presentes na imagem e associando a cada classe um tamanho de janela de estimação de parâmetros. Estimados os parâmetros da distribuição "a priori" calculase a raiz do polinômio que atualizará o pixel ruidoso, caso a raiz esteja no intervalo compreendido pela média e o valor observado. Em situações nas quais as raízes do polinômio estão fora deste intervalo adotou-se de forma heurística a busca no conjunto de raízes reais e positivas daquela que estiver mais próxima da média ou da observação, usando-a como estimador.

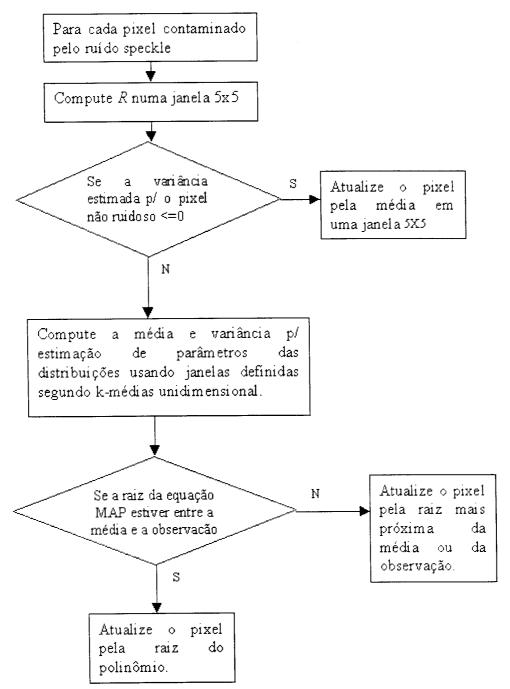


Figura 4.1 -Algoritmo MAP.

4.6 Conclusão

Neste capítulo foram derivados os vários filtros propostos neste trabalho para redução do ruído usando a abordagem MAP e estatísticas locais na estimação dos parâmetros do filtro. Isto torna o algoritmo capaz de suavizar as regiões homogêneas, às quais o modelo multiplicativo se ajusta, enquanto preserva bordas. O filtro MAP incorpora um modelo estatístico para o ruído "speckle", que não é o caso da abordagem por "wavelets", por exemplo. Os algoritmos são obtidos pela maximização do critério de Bayes supondo os modelos Rayleigh e raiz de gama, para o ruído "speckle", ou seja, estes modelos correspondem à distribuição condicional. Supõe-se ainda diferentes distribuições "a priori" para modelagem do "backscatter" nas imagens SAR. O método iterativo de Newton-Raphson é usado para achar a solução da equação do filtro MAP log-normal.

5 Resultados Experimentais

5.1 Introdução

Este capítulo tem a finalidade de apresentar os resultados experimentais obtidos a partir dos algoritmos propostos na tese e compará-los aos resultados de outros algoritmos de filtragem escolhidos da literatura. Em especial, os resultados foram avaliados quantitativamente com relação ao filtro de Kuan e ao filtro baseado em "wavelets". O filtro de Kuan foi escolhido dentre os vários disponíveis na literatura por apresentar bons resultados de filtragem com relação à redução de intensidade do "speckle" em regiões homogêneas e pela capacidade de preservar detalhes. Para análise qualitativa dos resultados de filtragem, ou seja, a melhoria do aspecto visual da imagem e discriminação das classes, são feitas algumas considerações que incluem o desempenho do filtro baseado em curvatura proposto por Sethian [Sethian (1999)] e o filtro baseado em "wavelets". Desta forma, pode-se avaliar as vantagens e limitações dos métodos propostos, sua contribuição e importância no contexto de filtragem do ruído "speckle" em relação a outras abordagens.

As medidas de avaliação quantitativa do desempenho dos diversos filtros MAP são apresentadas nas tabelas e gráficos das seções seguintes. Para comparação visual dos resultados, apresentamos no **Apêndice F** um conjunto de imagens processadas pelos diversos algoritmos e seus respectivos histogramas. As medidas de avaliação de desempenho são apresentadas em tabelas distintas e na seguinte ordem: imagens artificialmente contaminadas pelo ruído "speckle" e imagens reais SAR, sendo que os melhores resultados de filtragem são apresentados em gráficos de forma a facilitar a interpretação das tabelas. Os nomes dos filtros são compostos da palavra MAP (abordagem em que se baseiam) e de parte do nome da distribuição "a priori" utilizada na derivação dos mesmos. Por exemplo, o filtro MAP Gaus identifica o filtro que utiliza distribuição "a priori" Gaussiana.

5.2 Imagem Artificialmente Contaminada por Ruído "Speckle" com Estatística Rayleigh (Detecção Linear e 1 Visada)

Nesta seção, a **Tabela 5.1** apresenta o conjunto de medidas para avaliação de desempenho sobre a imagem APTO, artificialmente contaminada com "speckle". A avaliação dos algoritmos propostos é feita mediante a análise destas medidas. Observa-se na **Figura 5.1a** o bom desempenho dos algoritmos MAP em relação ao filtro de Kuan, permitindo concluir que a abordagem MAP combinada ao k-médias é a que mais reduz a intensidade do "speckle" (baixos valores do índice β) sobre regiões homogêneas [**Medeiros et al. (1998a)**]. A redução acentuada do "speckle" sempre introduz algum borramento; no entanto, este borramento não é muito intenso e até se aproxima do valor de borramento do filtro de Kuan. Neste caso, a técnica combinada ao crescimento de região constitui um grupo intermediário de desempenho com relação ao parâmetro S [**Medeiros et al. (1998c)**], sendo inferior à técnica combinada ao k-médias, mas superior ao MAP simples como mostra a **Figura 5.1b**.

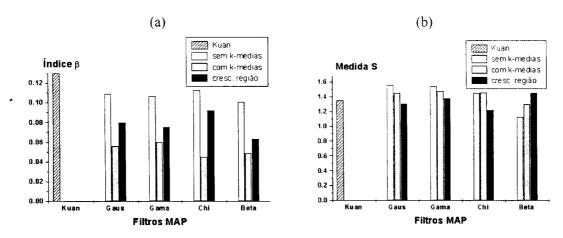


Figura 5.1 – Imagem APTO (a) Índices β (b) Medidas de perda de resolução espacial.

As medidas dos gráficos a seguir também são interessantes, pois avaliam a consistência na reconstrução da imagem original usando o modelo proposto. Os gráficos da **Figura 5.2** mostram as médias calculadas sobre as versões filtradas da imagem *APTO* que apresentaram os melhores resultados de preservação da média

geral (vide **Figura 5.2a**) e de retenção da média sobre regiões homogêneas, (vide **Figura 5.2b**). Uma das características do filtro de Kuan é a preservação da média em regiões homogêneas, como se vê na **Tabela 5.1**. Todos os filtros MAP presentes no gráfico apresentaram bons resultados com relação à preservação da média, como propõe o modelo multiplicativo.

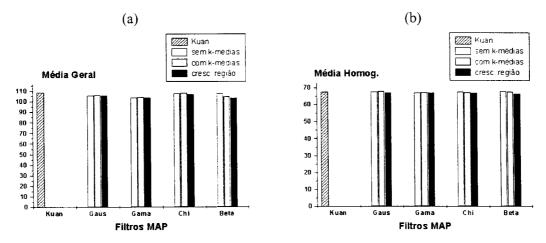


Figura 5.2 – Imagem APTO (a) média geral sobre a imagem APTO (b) média sobre região homogênea.

As medidas de média e variância das oscilações do "speckle" mostram que o filtro MAP Chi foi o que apresentou, no grupo, maior valor de variância na razão de imagens (**Figura 5.3b**); indicando que, neste grupo de distribuições apresentadas no gráfico, este filtro, especialmente quando combinado ao k-médias, é o que apresenta maior distorção nos resultados.

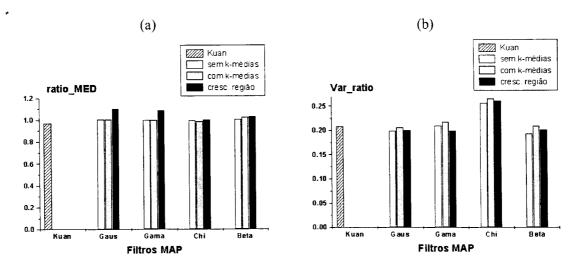


Figura 5.3 – Imagem APTO (a) média das oscilações do "speckle" (b) variância das oscilações do "speckle".

A **Tabela 5.1** mostra que os valores de médias e variâncias da razão de imagens para os filtros com distribuição "a priori" Rayleigh e exponencial superam os valores teóricos de média e variância impostas pelo modelo, indicando assim que os dois introduzem distorções nas imagens filtradas. No caso da filtragem baseada em "wavelets" também é observado um acréscimo desta variância (razão de imagens).

Observam-se na **Figura 5.4** os erros na reconstrução das imagens pelos filtros que apresentaram melhor desempenho geral e a técnica combinada ao k-médias é a que melhor reconstitui esta imagem original como mostram as medidas de erros (vide também a **Tabela 5.1**). Na **Tabela 5.1** observa-se que os filtros MAP propostos que utilizam conhecimento "a priori" Gaussiano, gama, chi-quadrado e beta apresentam menor erro na reconstrução que o filtro de Kuan. O filtro baseado em "wavelets" apresenta o maior valor de erro na reconstrução. Os autores desta nova abordagem Fukuda & Hirosawa [**Fukuda & Hirosawa (1998)**] recomendam um truncamento inicial de 50% do valor dos coeficientes de detalhes para pixels cujos níveis de cinza apresentem-se abaixo de um valor arbitrário de limiar. Este truncamento indiscriminado se reflete na má reconstrução da imagem como mostram as medidas de erros.

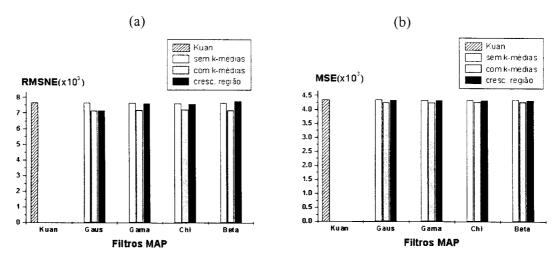


Figura 5.4 – Imagem APTO (a) RMSNE (b) MSE.

Imagem APTO (1 Visada)											
Filtro MAP	ratio_ Med (1.0)	Var_ Ratio (0.273)	S	Média em Reg. Homog. (67.730)	Média Geral (108.39)	MSE (x10 ³)	RMSNE (x10 ³)	β	ENL		
Gaus	1.004	0.199	1.565	67.423	105.775	7.633	4.347	0.109	22.99		
Gama	1.001	0.209	1.545	66.812	103.779	7.659	4.344	0.107	23.86		
Chi	0.992	0.257	1.451	67.583	107.621	7.637	4.331	0.113	21.39		
Exp	1.178	0.151	1.227	61.938	93.110	7.705	4.360	0.374	1.953		
Ray	1.086	0.133	1.186	63.416	97.058	7.708	4.610	0.323	2.618		
Beta	1.006	0.193	1.125	67.765	107.843	7.659	4.347	0.109	26.39		
Log	1.003	0.185	1.360	68.093	109.103	7.232	4.270	0.158	12.14		
Filtros MAP combinados ao algoritmo de k-médias											
Gaus	1.007	0.206	1.450	67.754	106.174	7.185	4.256	0.056	87.11		
Gama	1.025	0.217	1.478	67.242	104.147	7.193	4.265	0.060	75.88		
Chi	0.988	0.266	1.458	67.280	108.178	7.246	4.279	0.045	134.9		
Exp	1.194	0.152	1.675	61.551	92.027	7.263	4.295	0.322	2.63		
Ray	1.093	0.131	1.460	64.085	96.480	7.245	4.290	0.292	3.20		
Beta	1.026	0.210	1.296	67.584	104.470	7.207	4.266	0.049	113.7		
Log	1.003	0.197	1.454	67.746	109.083	7.173	4.246	0.100	27.32		
	Fi	ltros MAP	combina	idos ao algo	oritmo de cr	esciment	o de região)			
Gaus	1.105	0.200	1.304	66.958	105.563	7.613	4.329	0.080	42.68		
Gama	1.087	0.199	1.381	66.984	103.798	7.631	4.339	0.075	48.56		
Chi	1.002	0.261	1.222	66.782	106.471	7.608	4.326	0.092	32.27		
Exp	1.800	0.331	1.500	61.593	91.698	7.696	4.365	0.420	1.54		
Ray	1.505	0.291	1.647	62.838	95.606	7.678	4.357	0.299	3.055		
Beta	1.030	0.201	1.450	66.217	103.100	7.632	4.328	0.063	68.83		
Log	1.292	0.170	1.605	67.325	109.756	7.616	4.327	0.101	26.78		
Outros Filtros											
Kuan	0.969	0.208	1.3500	67.703	108.495	7.655	4.348	0.130	16.16		
Região da Imagem APTO (128x128) Filtrada por "Wavelets"											
Wavel.	0.934	0.903	1.500	17.607	61.920	6.190	5.423	0.561	0.81		

Tabela 5.1 – Medidas de desempenho calculadas sobre a imagem APTO.

5.3 Imagem Real SAR Obtida por Detecção Linear e com 1 Visada

Os resultados da avaliação de desempenho dos algoritmos MAP aplicados à imagem SAR580 são apresentados na **Tabela 5.2**. Dentre estes resultados, deve-se dar atenção especial às medidas mais diretamente relacionadas à redução do "speckle" (índice β) e ao borramento dos segmentos de reta em consequência da filtragem. Os índices (β) usados para avaliação de desempenho dos filtros foram calculados sobre uma região homogênea como destacado na **Figura 3.9**. A **Figura**

5.5a apresenta o histograma desta região após a aplicação do filtro MAP Gaussiano sem k-médias e a **Figura 5.5b** apresenta o resultado da aplicação do mesmo filtro combinado ao k-médias. Observa-se que, embora a região apresente baixo coeficiente de variação (homogênea), a abordagem MAP combinada ao algoritmo k-médias foi capaz de reduzir mais um pouco a variância do ruído.

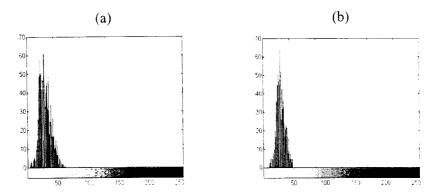


Figura 5.5 – Histograma de uma região homogênea filtrada pelo (a) MAP Gaussiano (b) MAP Gaussiano com k-médias.

A Figura 5.6a apresenta os melhores resultados dos índices de redução do "speckle" (β) calculados sobre regiões homogêneas das imagens filtradas. A Figura 5.6b apresenta as medidas S calculadas sobre as imagens filtradas e que sofreram menor dispersão. Observa-se que a medida S correspondente à combinação da abordagem MAP com o k-médias borra menos que o filtro de Kuan, embora borre mais que as duas outras técnicas propostas.

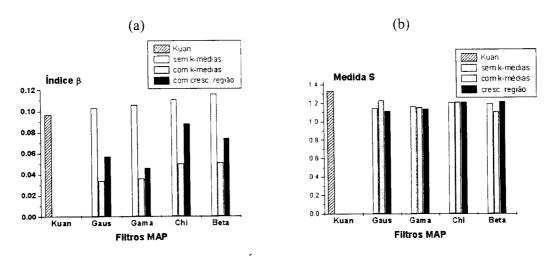


Figura 5.6 – Imagem SAR580 (a) Índices β (b) medidas de perda de resolução espacial.

Outras medidas como a média geral da imagem e a retenção da média, especialmente nas áreas de região uniforme, são interessantes, pois verificam um outro aspecto de validade do modelo multiplicativo para o ruído de média unitária (**Equação 2.34**).

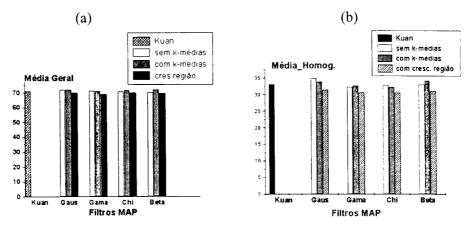


Figura 5.7 – Imagem *SAR580* (a) média geral sobre a imagem *SAR580* (b) média sobre região homogênea.

Como forma de medir as oscilações do ruído "speckle" presente na imagem, utilizam-se as medidas de variância e média da imagem resultante da razão entre as imagens ruidosa e original. Para imagens contaminadas pelo "speckle" modelado pela distribuição Rayleigh, espera-se que a variância desta razão entre as imagens esteja em torno do valor teórico 0.2732. A média desta razão deve estar em torno de 1, e os valores de média que excedem este limite indicam que a filtragem introduz distorções radiométricas.

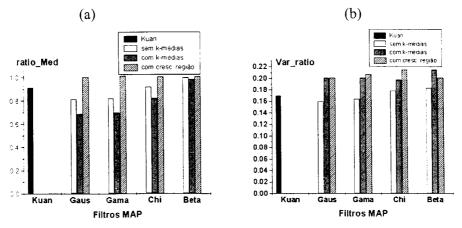


Figura 5.8 – Imagem *SAR580* (a) média das oscilações do "speckle" (b) variância das oscilações do "speckle".

Tabela 5.2 – Medidas de desempenho calculadas sobre a imagem SAR580.

Ima	agem SAR	580 (1 Visa	ida)								
Filtro MAP	ratio_ Med (1.0)	Var_ Ratio (0.273)	S	Média em Reg. Homog. (35.05)	Média Geral da Imagem (72.151)	β	ENL				
Gaus	0.812	0.164	1.141	34.980	72.234	0.103	25.75				
Gama	0.822	0.164	1.168	32.265	71.600	0.106	24.31				
Chi	0.919	0.178	1.204	32.814	71.000	0.111	22.17				
Exp	0.907	0.109	1.219	32.257	66.658	0.170	9.45				
Ray	0.865	0.116	1.278	33.336	68.315	0.201	6.76				
Beta	0.998	0.183	1.191	33.044	70.386	0.116	20.30				
Log	0.997	0.186	1.177	33.992	72.564	0.185	7.98				
Filtros MAP combinados ao algoritmo de k-médias											
Gaus	0.687	0.201	1.226	33.811	72.045	0.034	236.33				
Gama	0.699	0.201	1.156	32.691	71.294	0.036	210.80				
Chi	0.825	0.197	1.209	32.326	71.826	0.050	109.28				
Exp	0.795	0.122	1.271	29.229	65.000	0.098	28.44				
Ray	0.784	0.127	1.285	31.021	67.159	0.152	11.82				
Beta	0.985	0.215	1.109	34.286	72.237	0.051	105.06				
Log	1.011	0.193	1.228	33.817	71.722	0.093	31.57				
	Filt	ros MAP	combinad	os ao algoritm	o de crescimento	de região					
Gaus	1.003	0.201	1.114	31.437	69.993	0.057	84.08				
Gama	1.014	0.207	1.138	30.565	69.251	0.046	129.11				
Chi	1.005	0.215	1.211	30.598	70.154	0.088	35.27				
Exp	1.127	0.162	1.320	31.199	65.447	0.090	35.50				
Ray	1.065	0.146	1.326	31.395	67.309	0.101	26.78				
Beta	1.009	0.201	1.214	31.060	69.685	0.074	49.22				
Log	1.007	0.201	1.148	34.362	71.129	0.090	33.43				
	Outros Filtros										
Kuan	0.915	0.170	1.330	33.077	71.097	0.097	29.03				
Wavel.	0.914	0.093	1.229	35.520	72.413	0.369	2.00				

5.4 Imagem Artificialmente Contaminada por Ruído "Speckle" com Estatística Raiz de Gama (Detecção Linear e Múltiplas Visadas)

Na **Figura 5.9** são apresentados os melhores resultados de índice de redução de "speckle" e perda de resolução para a imagem *LENA* simulada com 4 visadas. Estas medidas de avaliação de desempenho calculadas sobre regiões homogêneas das imagens filtradas e apresentadas na **Figura 5.9a** mostram que o filtro MAP Beta foi o que mais suavizou o "speckle" em regiões homogêneas. A **Figura 5.9b** apresenta as medidas *S* calculadas sobre as imagens filtradas e que causaram menor dispersão. Observa-se que a medida *S* correspondente à combinação entre o k-médias e a abordagem MAP borra menos que o filtro de Kuan.

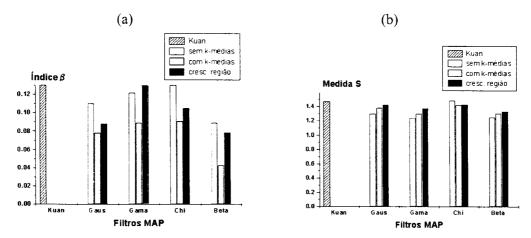


Figura 5.9 – Imagem *LENA* (a) Índices β (b) medidas de perda de resolução espacial.

O filtro de Kuan apresenta ótimos índices de preservação da média e a **Figura 5.10a** mostra que para os filtros MAP propostos, estes índices são similares ao filtro de Kuan.

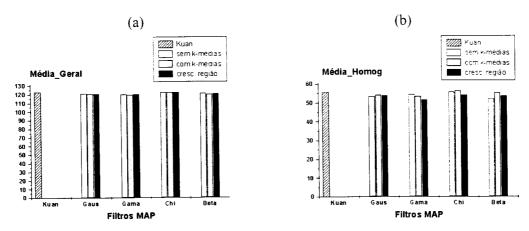


Figura 5.10 – Imagem *LENA* (a) média geral sobre a imagem *APTO* (b) média sobre região homogênea.

A **Figura 5.11** apresenta os resultados de médias e variâncias das oscilações do "speckle" obtida da razão das imagens ruidosa e filtrada.

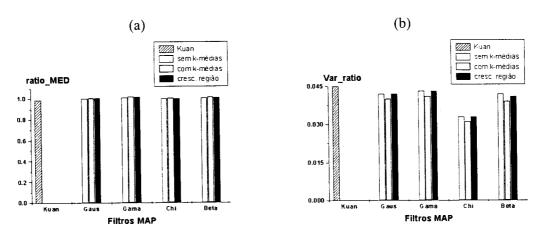


Figura 5.11 – Imagem *LENA* (a) média das oscilações do "speckle" (b) variância das oscilações do "speckle".

Observa-se que a abordagem MAP combinada ao k-médias apresenta os melhores resultados de reconstrução da imagem original como mostram as medidas de erro apresentadas na **Figura 5.12**.

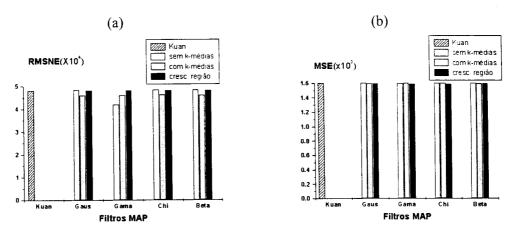


Figura 5.12 – Imagem LENA (a) RMSNE (b) MSE.

Tabela 5.3 – Medidas de desempenho calculadas sobre a imagem LENA.

						_ -					
Ima	agem LEN	A (4 Visa	das)								
Filtro MAP	ratio_ Med (1.0)	Var_ Ratio (0.068)	S	Média em Reg. Homog. (55.792)	Média Geral (122.74)	MSE (x10 ³)	RMSNE (x10 ⁴)	β	ENL		
Gaus	1.004	0.042	1.300	53.215	121.078	4.822	1.601	0.110	14.99		
Gama	1.013	0.043	1.238	54.267	120.141	4.813	1.594	0.122	18.35		
Chi	1.003	0.033	1.479	55.735	122.441	4.822	1.601	0.130	16.16		
Exp	1.059	0.022	1.377	52.088	116.262	4.877	1.619	0.193	7.34		
Ray	1.039	0.020	1.375	53.418	117.665	4.878	1.619	0.181	8.33		
Beta	1.008	0.042	1.250	54.629	120.895	4.822	1.600	0.089	39.46		
Log	1.000	0.033	1.362	55.198	122.793	4.823	1.601	0.201	6.76		
		Filtro	MAP c	ombinados	ao algoritm	o de k-mé	dias	,			
Gaus	1.008	0.040	1.378	54.234	120.486	4.588	1.598	0.078	44.90		
Gama	1.019	0.041	1.297	53.336	119.317	4.603	1.602	0.089	34.41		
Chi	1.005	0.031	1.420	56.356	122.370	4.611	1.603	0.091	32.99		
Exp	1.071	0.018	1.363	50.672	114.906	4.669	1.622	0.180	8.43		
Ray	1.032	0.034	1.364	52.967	118.844	4.604	1.597	0.119	19.29		
Beta	1.014	0.039	1.306	55.340	120.199	4.597	1.598	0.043	147.7		
Log	0.934	0.073	1.382	48.547	99.030	4.685	1.626	0.240	4.74		
	Fi	ltros MAI			oritmo de cr			· · · · · · · · · · · · · · · · · · ·			
Gaus	1.000	0.042	1.418	53.845	120.806	4.804	1.591	0.088	35.27		
Gama	1.015	0.043	1.372	51.573	119.791	4.797	1.587	0.098	28.44		
Chi	1.004	0.033	1.428	54.161	122.267	4.805	1.590	0.105	24.78		
Exp	1.066	0.020	1.295	49.470	115.447	4.872	1.613	0.252	4.302		
Ray	1.044	0.018	1.478	50.406	117.032	4.873	1.613	0.249	4.406		
Beta	1.010	0.041	1.333	53.595	120.560	4.807	1.593	0.079	43.77		
Log	1.001	0.033	1.387	55.741	122.660	4.806	1.591	0.193	7.46		
Outros Filtros											
Kuan	0.986	0.045	1.470	55.657	122.650	4.813	1.598	0.130	14.55		
Wavel.	0.967	0.034	1.271	57.783	122.740	5.066	1.627	0.238	5.593		

5.5 Imagem Real SAR Obtida por Detecção Linear e com Múltiplas Visadas

Os resultados experimentais sobre a imagem real JERS481 mostram através das medidas do índice β que as versões combinadas dos filtros MAP com as técnicas de k-médias e crescimento de região nesta classe de imagens (3 visadas) suavizam mais fortemente o "speckle" nas regiões homogêneas, especialmente quando os modelos "a priori" utilizados são Gaussiana e gama. Isto reforça a idéia de que o uso de vizinhança estatisticamente mais semelhante ao pixel a ser filtrado melhora os resultados de estimação dos parâmetros dos filtros e consequentemente a filtragem.

Como mostra a **Figura 5.13a**, o filtro de Kuan supera em termos de índice de redução do "speckle" os filtros MAP Gama e MAP Chi simples (sem a incorporação do k-médias e crescimento de região), para esta imagem teste. A filtragem baseada em "wavelets" pouco suaviza as regiões homogêneas e não é capaz de discriminar as classes presentes na imagem como mostram os histogramas da **Figura F.22d**.

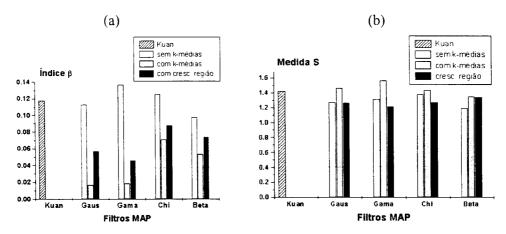


Figura 5.13 - (a) Índices β (b) medidas de perda de resolução espacial.

Observa-se na **Figura 5.14** que os filtros MAP propostos apresentaram bons resultados de preservação da média assim como o filtro de Kuan.

A **Tabela 5.4** mostra que as médias geral e sobre regiões homogêneas não são preservadas pelo filtro baseado em wavelet e pelos filtros MAP Exp e MAP Ray.

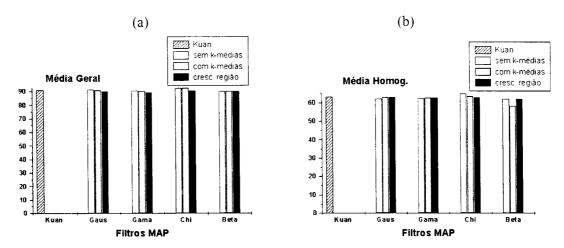


Figura 5.14 – Média (a) geral sobre a imagem JERS (b) sobre região homogênea.

Os gráficos da **Figura 5.15** apresentam as medidas de média e variância das oscilações do "speckle" que para esta imagem (*JERS*) teoricamente correspondem a 1 e 0.0865 respectivamente.

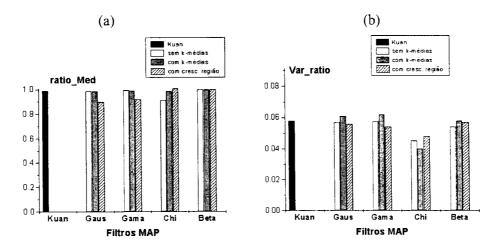


Figura 5.15 – Medidas das oscilações do "speckle" (a) média (b) variância.

Imagem JERS (3 Visadas) **ENL** Filtro ratio_ Var_ Média em Média Geral β MAP Med Ratio Reg. Homog. da Imagem (1) (0.086)(62.964)(91.658)1.270 0.113 21.39 Gaus 0.986 62.159 91.300 0.056 0.994 1.311 90.564 0.137 Gama 0.057 62.244 14.55 92.720 Chi 0.912 0.045 1.376 64.897 0.12617.20 0.999 0.028 1.534 59.538 0.200 Exp 86.612 6.83 Ray 1.041 0.030 1.466 60.225 87.944 0.1927.41 $0.9\overline{99}$ 62.031 90.278 0.099 27.87 0.055 1.193 Beta Log 91.230 1.057 0.054 1.315 62.805 0.169 9.12 Filtros MAP combinados ao algoritmo de k-médias 0.985 0.017 945.32 Gaus 0.061 1.461 62.793 91.143 0.999 1.156 62.533 90.149 0.019 756.78 Gama 0.062 63.591 92.747 0.071 54.19 0.985 0.040 1.433 Chi 1.377 Exp 1.004 0.026 58.2060 86.001 0.1828.24 Ray 0.999 0.0171.452 57.520 85.126 0.16210.41 0.999 Beta 0.058 1.348 90.052 0.054 93.69 62.806 11.08 Log 1.002 0.027 1.420 61.904 90.712 0.157 Filtros MAP combinados ao algoritmo de crescimento de região 0.901 0.056 62.789 90.175 0.06760.85 Gaus 1.260 0.921 0.054 1.211 62.482 89.390 0.052100.26 Gama 90.390 1.064 0.588 1.268 62.897 0.097 29.03 Chi 1.002 0.023 1.329 58.668 84.823 0.1689.67 Exp Ray 1.130 0.092 1.346 62.003 90.225 0.1867.89 1.049 0.0281.308 60.440 86.393 0.076 47.29 Beta Log 1.003 0.0481.304 63.220 91.026 0.169 9.16 **Outros Filtros** 63.172 90.903 0.992 0.057 1.419 0.118 19.62 Kuan Wavel. 1.308 0.695 1.403 47.883 81.209 0.231 5.08

Tabela 5.4 – Medidas de desempenho calculadas sobre a imagem *JERS481*.

5.6 Análise Comparativa dos Resultados

A avaliação qualitativa ou visual das imagens filtradas é subjetiva e varia de observador para observador. No entanto, este tipo de análise é válida quando associada a uma análise qualitativa dos resultados. Do ponto de vista visual, pode-se concluir que técnicas como a baseada em curvatura (vide **Figura 2.18** e **Figura 2.20**), apesar de permitirem uma boa discriminação das classes (observar a natureza bimodal do histograma) predominantes na imagem, suavizam fortemente a imagem para eliminar o ruído "speckle" comprometendo informações de alvos presentes na imagem, e não preservam a textura presente na mesma. Em outras palavras, isso significa que certos detalhes (alvos militares, por exemplo) não perceptíveis devido

ao "speckle", com este tipo de abordagem, serão eliminados e não perceptíveis da mesma forma. Das tabelas, pode-se observar que os filtros baseados em "wavelets" apresentam valores de medidas de dispersão em certos casos (Tabela 5.2 e Tabela 5.4) até menores que os filtros propostos e o de Kuan. Isso se deve ao fato dos mesmos reduzirem muito pouco a intensidade do ruído, e em consequência não apresentam boa discriminação das classes. A abordagem multi-escala proposta por Fukuda & Hirosawa [Fukuda & Hirosawa (1998)] mostra-se adequada na preservação de detalhes e bordas, mas não é efetiva na redução de ruído "speckle" em regiões homogêneas. Era de se esperar que os filtros MAP fossem mais eficazes na redução do "speckle" que o filtro baseado em "wavelets". Esta abordagem multi-escala não incorpora a estatística do ruído speckle presente na imagem e que nesta tese corresponde às estatísticas Rayleigh e raiz de gama em imagens amplitudes com 1 e múltiplas visadas obtidas de radar de abertura sintética. Entretanto, a abordagem MAP depende do modelo estatístico "a priori" da imagem original (tal modelo não é disponível) e então devem ser feitas suposições a este respeito.

Observa-se que os filtros com distribuições "a priori" exponencial melhoram muito pouco a relação sinal-ruído da imagem e isso é devido ao fato de que com o aumento da média da distribuição "a priori", a variância aumenta com o quadrado da mesma. Em consequência, o conhecimento "a priori" na estimação Bayesiana é fraco e o estimador MAP é praticamente dado pelo estimador de máxima verossimilhança (MLE) [Mascarenhas et al. (1996a)]. Os estimadores de máxima verossimilhança derivados a partir dos dois modelos estatísticos utilizados nesta tese para o ruído "speckle" são dados pelas equações:

a) modelo Rayleigh

$$\hat{x} = \frac{\sqrt{\pi}}{2} z \tag{5.1}$$

b) modelo raiz de gama:

$$\hat{x} = z \frac{1}{\sqrt{N}} \cdot \frac{\Gamma(N+1/2)}{\Gamma(N)} \tag{5.2}$$

onde z é o pixel ruidoso e N corresponde ao número de visadas.

A mesma observação feita para os filtros com distribuição "a priori" exponencial aplica-se também aos filtros com distribuição "a priori" Rayleigh. Este aspecto também foi verificado em [Mascarenhas et al. (1996a)] com o uso destas duas distribuições na derivação de filtros MAP para redução de ruído Poisson em imagens tomográficas. O desempenho destes filtros (MAP Ray e MAP Exp) pode ser observado a partir dos parâmetros das tabelas, tais como: média e variância das oscilações do "speckle" presente na imagem, não preservação de valores de média sobre regiões homogêneas e em toda a imagem (média geral).

A abordagem MAP associada às técnicas de crescimento de região e k-médias apresentam melhores resultados na suavização de ruído em regiões homogêneas que o filtro de Kuan e demais filtros MAP que não incorporam estas técnicas. Esta melhoria deve-se ao fato desta nova abordagem propor o uso de informação de homogeneidade estatística na vizinhança do pixel a ser filtrado. Esta vizinhança é utilizada na estimação dos algoritmos de filtragem através do uso de janelas distintas para grupos de pixels distintos (caso do k-médias) e em se tratando de crescimento de região a estimação dos parâmetros é feita em vizinhanças de tamanho e forma variáveis.

5.7 Conclusão

De um modo geral, os resultados obtidos pelos métodos propostos são satisfatórios para a classe de imagens utilizadas, especialmente com relação à redução da intensidade do "speckle" e à preservação de detalhes e bordas. As distribuições Gaussiana, gama e chi-quadrado apresentam resultados muito próximos e pode-se observar isso visualmente nas imagens, nos seus respectivos histogramas e nas medidas de desempenho. Isso era de se esperar, pois no caso da distribuição gama sabe-se que a mesma é resultado da soma de k variáveis identicamente distribuídas segundo uma distribuição exponencial de parâmetro λ. Pelo teorema central do limite esta distribuição tende para uma Gaussiana à medida que k aumenta. Os valores obtidos neste tipo de filtro para a imagem *SAR580* foram em torno de 89.99 com o filtro gama sem associação com k-médias ou crescimento de região, e 103.95 para o filtro gama combinado ao k-médias. Estes parâmetros são

obtidos para todos os pixels da imagem a ser filtrada e estes números apresentados correspondem à média desta matriz de parâmetros. Esta mesma análise se aplica à distribuição chi-quadrado de n graus de liberdade, que é um caso particular da distribuição gama e resultante da soma de n variáveis independentes e normalmente distribuídas. Para a imagem SAR580 a média destes valores n calculados para todos os pixels da imagem foi em torno de 71.13 e pelo teorema central do limite isto tende a uma Gaussiana. Os filtros com distribuições "a priori" Rayleigh e exponencial apresentaram resultados mais precários, ou seja, reduziram menos o "speckle" (como discutido na seção anterior), borraram mais, não preservaram a média geral e a média sobre regiões homogêneas e introduziram distorções nas imagens filtradas.

Os filtros propostos nesta tese apresentam um ganho na relação sinal-ruído sem introduzir perdas severas de resolução, inerentes ao processamento de múltiplas visadas. A preservação de bordas ocorre porque os filtros se adaptam às estatísticas locais da imagem, suavizando o ruído "speckle" com maior intensidade sobre regiões homogêneas.

6 Conclusão

6.1 Conclusões Gerais

Pode-se concluir que, dentre os vários algoritmos propostos, existem aqueles que apresentam melhor desempenho na filtragem com respeito à redução do ruído e preservação de borda, como é o caso dos filtros MAP que utilizam as distribuições Gaussiana, gama, chi-quadrado e beta na modelagem do conhecimento "a priori". Os filtros cujas distribuições "a priori" são exponencial e Rayleigh não apresentam bom desempenho geral, embora sejam capazes de melhorar a discriminação de classes comparados ao algoritmo de filtragem baseado em "wavelets".

Podemos concluir que o conceito de filtragem baseada na segmentação para redução de ruído "speckle" provê resultados de boa qualidade, comparados aos outros métodos discutidos neste trabalho, do ponto de vista da melhoria da relação sinal ruído, embora introduza um pouco de borramento.

A técnica de crescimento de região introduz uma discreta melhoria nos resultados e se configura como uma ferramenta promissora, merecendo mais investigação, principalmente dos parâmetros envolvidos. A justificativa teórica para esta melhoria consiste no fato de que com esta técnica são utilizados na estimação dos parâmetros de filtragem somente os pixels realmente semelhantes do ponto de vista estatístico. Os problemas nesta nova abordagem consistem na busca do limiar ótimo de rejeição da homogeneidade, na escolha da janela fixa em caso da região em torno do pixel não crescer, e na definição do número máximo de pixels permitido em cada região. Estes são pontos abertos e que merecem mais investigação.

A transformada de Hough constitui uma ferramenta valiosa neste trabalho, pois através do seu uso é possível analisar o borramento introduzido pela filtragem sobre os segmentos de retas presentes na imagem. Para comparar esta medida de dispersão entre várias imagens, deve-se escolher o limiar mais adequado a ser utilizado pelo

algoritmo de "backmapping" cujo objetivo é desconsiderar possíveis contribuições de ruído.

Os resultados obtidos nesta tese mostram que a filtragem MAP é uma abordagem bastante adequada na redução do ruído "speckle", e em especial, quando combinada a técnicas que tornem a estimação dos parâmetros de filtragem restrita à vizinhança estatisticamente mais semelhante ao pixel a ser filtrado com é o caso das técnicas propostas.

6.2 Contribuições deste Trabalho

A síntese das contribuições deste trabalho é a seguinte:

- a) Formulação e implementação de algoritmos de filtragem do ruído "speckle" baseados na abordagem "maximum a posteriori" considerando os modelos de "speckle" presentes em imagens SAR em amplitude com 1 e múltiplas visadas. Parte dos algoritmos propostos para filtragem MAP de imagens obtidas por deteção linear (modelo Rayleigh para o "speckle") e uma visada utilizam as mesmas distribuições "a priori" usadas na derivação dos filtros MAP propostos por Sant'Anna [Sant'Anna (1995)].
- b) Proposta de um método de redução do ruído "speckle" baseado na idéia de segmentar a imagem em regiões estatisticamente homogêneas (aproximadamente) e processá-las com base na informação da segmentação, ou seja, combinar a informação fornecida pelo algoritmo k-médias unidimensional sobre *R* ao algoritmo MAP para estimação da imagem original.
 - c) Proposta do uso combinado da abordagem MAP com a técnica crescimento de região com vistas à melhoria da estimação dos parâmetros de filtragem. Com esta nova abordagem a forma e o tamanho da vizinhança local são variáveis, resultando numa região de homogeneidade estatística (pixels estatisticamente semelhantes) para cálculo dos parâmetros de filtragem.
 - d) Proposta de uma nova medida baseada na transformada de Hough para avaliação da perda de resolução resultante da filtragem do ruído.
 - e) Análise comparativa da técnica de filtragem baseada em "wavelets" proposta em [Fukuda & Hirosawa (1998)] com a abordagem MAP, permitindo concluir que

as técnicas de filtragem de ruído "speckle" que incorporam o modelo estatístico do mesmo, como é o caso dos algoritmos MAP, são mais eficazes na redução do ruído sobre regiões homogêneas (onde o modelo se ajusta). Vale salientar que a técnica baseada em "wavelets" causa pouco borramento, mas isto não constitui uma vantagem, porque a eliminação do ruído efetuada é mínima.

f) Como resultado da revisão bibliográfica das técnicas disponíveis na literatura, aplicamos uma nova técnica de redução de ruído baseada em curvatura, proposta por Sethian [Sethian (1999)], às imagens contaminadas pelo ruído multiplicativo "speckle", constituindo uma linha para investigações futuras. Esta abordagem foi utilizada para comparação qualitativa dos filtros e foi verificado que ao ser aplicada em algumas imagens SAR reais do conjunto de teste, esta técnica apresentou bons resultados com relação à discriminação de classes, preservação de bordas, mas não preservou informação de textura.

6.3 Trabalhos Futuros

Para estudos futuros são listados alguns pontos:

- Estudar a aplicação dos algoritmos propostos em imagens médicas geradas por ultra-som, que também apresentam este tipo de ruído, com vistas à melhoria da qualidade das imagens e ajuda no diagnóstico de patologias.
- Uso da técnica de redução do ruído "speckle" baseada em curvatura como passo inicial para definição dos "clusters" dominantes na imagem e inicialização do k-médias.
- Desenvolver estudos comparativos de desempenho de filtragem entre os algoritmos MAP pontual, ICM e o método proposto por Sethian [Sethian (1999)].
- Investigar o uso iterativo dos algoritmos MAP propostos na redução do ruído multiplicativo. No caso de imagem com 1 visada e detecção linear vale lembrar que a estatística Rayleigh fica modificada a partir da segunda iteração envolvendo uma aproximação. O desvio padrão do ruído, neste caso, parte de 0.5227 na primeira iteração e vai caindo com as iterações, quando estimado sobre as regiões homogêneas.

- Para a avaliação da perda de resolução as imagens filtradas foram classificadas utilizando o algoritmo ICM sob a hipótese de normalidade para as classes. Pode-se investigar os resultados obtidos pelo uso deste mesmo classificador com o uso de distribuições mais ajustadas às classes presentes na imagem.
- Avaliar melhor os critérios de crescimento de região para cada imagem. Nesta tese foram levantados os critérios para uma única imagem representativa de cada estatística, a saber, Rayleigh e raiz de gama. Em seguida foram aplicados a todas as outras imagens com estatísticas semelhantes. Pode-se encontrar diferentes limiares de rejeição da homogeneidade para diferentes imagens, embora apresentem estatísticas semelhantes. O tamanho máximo de crescimento da região e o tipo de janela fixa utilizada, quando a região não cresce, poderiam ser diferentes para diferentes imagens.
- Aprimorar a implementação dos algoritmos com o objetivo de reduzir o tempo de execução dos mesmos.

7 Referências Bibliográficas

- [Arsenault & April (1976)] H. H. Arsenault; G. April; Properties of speckle integrated with a finite aperture and logarithmically, *Jour. Opt. Soc. Am.*, 66(11), 1160-1163, Nov., 1976.
- [Besag (1986)] J. Besag, On the statistical analysis of dirty pictures (with discussion), *Journal of the Royal Statistical Society B*, 48(3), 259-302, 1986.
- [DeGroot (1975)] M. H. DeGroot, *Probability and Statistics*, Menlo Park, CA, Addison-Wesley, 1975.
- [Daubechies (1992)] I. Daubechies, Ten Lectures on Wavelets, CBMS-NSF Regional Conference Series in Applied Mathematics, Philadelphia, 1992.
- [Duda & Hart (1972)] R. O. Duda; P.E. Hart, Use of the Hough Transformation to Detect Lines and Curves in Pictures, Communications of the ACM: Graphics and Image Processing, 15(1), 11-15, 1972.
- [Fisz (1963)] M. Fisz, Probability Theory and Mathematical Statistics, John Wiley, 1963.
- [Frery et al. (1997)] A. C. Frery; H. J. Müller; C. F. Yanasse; S. J. S. Sant'Anna; A Model for Extremely Heterogeneous Clutter, *IEEE Trans. Geosci. Remote Sensing*, 35(3), 648-659, 1997.
- [Frery (1993)] A. C. Frery, Algumas Ferramentas Estatísticas na Síntese, Processamento e Análise de Imagens de Radar de Abertura Sintética, INPE, São José dos Campos, São Paulo, 1993 (Tese de doutorado).
- [Frost et al. (1982)] V. S. Frost; J. A. Stiles; K. S. Shanmugan; J. C. Holtzman, A Model for Radar Image and Its Application to Adaptive Digital Filtering of Multiplicative Noise, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 4(2), 157-166, Mar., 1982.
- [Fukuda & Hirosawa (1998)] S. Fukuda; H. Hirosawa, Supression of Speckle in Synthetic Aperture Radar Images Using Wavelets, *Int. Journal of Remote Sensing*, 19(3), 507-519, 1998.

- [Gerig & Klein (1986)] G. Gerig; F. Klein, Fast Contour Identification Through Efficient Hough Transform and Simplified Interpretation Strategy, Proc. 8th Int. Conference on Pattern Recognition, Vol. 1, pp.498-500, Paris, France, October 27-31, 1986.
- [Gibra (1973)] I. N. Gibra, Probability and Statistical Inference for Scientists and Engineers, Prentice-Hall, 1973.
- [Goodman (1975)] J. W. Goodman, Statistical Properties of Laser Speckle Patterns, Topics in Applied Physics: Laser Speckle and Related Phenomena, In J. C. Dainty (Ed), Springer-Verlag, 9, 9-74, 1975.
- [Horgan (1994)] G. W. Horgan, Choosing Weight Functions for Filtering SAR, Int. Journ. Remote Sensing, 15(5), 1053-1064, 1994.
- [Hough (1962)] P. V. C. Hough, Method and Means for Recognizing Complex Patterns, U.S. Patent 3, 069, 654, Dec. 18, 1962.
- [Illingworth & Kittler (1988)] J. Illingworth; J. Kittler, A Survey of the Hough Transform, Computer Vision, Graphics, and Image Processing, 44, 87-116, 1988.
- [Ishikawa (1996)] S. H. Ishikawa, Avaliação Formal e Aplicações de Técnicas de Aproximação de Contornos em Imagens Digitais Através de Segmentos de Reta, *USP-IFSC*, São Carlos, SP, Brasil, 1996 (Dissertação de Mestrado).
- [James (1996)] B. R. James, *Probabilidade: Um Curso em Nível Intermediário*, Rio de Janeiro, Instituto de Matemática Pura e Aplicada, 1996.
- [Kay (1993)] S. M. Kay, Fundamentals of Statistical Signal Processing: Estimation Theory, Prentice-Hall, 1993.
- [Koroliuk (1981)] V. S. Koroliuk, Manual de la Teoria de Probabilidades y Estadística Matemática, Moscou, Editorial Mir, 1981.
- [Kuan et al. (1987)] D. T. Kuan; A. A. Sawchuck; T. C. Strand; P. Chavel, Adaptive Restoration of Images with Speckle, *IEEE Trans. on Acoustics, Speech and Signal Processing*, 35(3), 373-383, Mar.,1987.
- [Lagendijk & Biemond (1991)] R. L. Lagendijk; J. Biemond, Iterative Identification and Restoration of Images, Kluwer Acad. Pub., 1991.

- [Lee (1980)] J. S. Lee, Digital Image Enhancement and Noise Filtering by Use of Local Statistics, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2, 165-168, 1980.
- [Lee (1981)] J.S. Lee, Refined Filtering of Image Noise Using Local Statistics, Comput. Graphics Image Process., 15, 380-389, 1981.
- [Lee et al. (1994)] J. S. Lee; I. Jurkevich; P. Dewaele; P. Wambacq; A. Oosterlinck, Speckle Filtering of Synthetic Aperture Radar Images: A Review, Remote Sensing Reviews, Vol. 8, 313-340, 1994.
- [Li (1988)] C. Li, Two Adaptive Filters for Speckle Reduction in SAR Images by Using the Variance Ratio, *Int. Journ. of Remote Sensing*, Vol. 9, No.4, 641-653, 1988.
- [Li (1995)] S. Z. Li, Markov Random Field Modeling in Computer Vision, Springer-Verlag Tokyo, 1995.
- [Lopes et al. (1990)] A. Lopes; E. Nezry; R. Touzi; H. Laur, Maximum a Posteriori Speckle Filtering and First Order Texture Models in SAR Images, *Proceedings of Intern. Geoscience and Remote Sensing Symposium*, (IGARSS'90), 2409-2412, 1990.
- [Lopes et al. (1993)] A. Lopes; E. Nezry; R. Touzi; H. Laur, Structure Detection and Statistical Adaptive Speckle in SAR Images, *Int. Journ. of Remote Sensing*, 14(9), 1735-1758, 1993.
- , [Mascarenhas & Velasco (1989)] N. D. A. Mascarenhas; F. R. D. Velasco; *Processamento Digital de Imagens*, IV EBAI, Termas do Rio Hondo, Argentina, 2ª Edição, Ed. Kapelusz, 1989.
 - [Mascarenhas et al. (1991)] N. D. A. Mascarenhas; S. E. Ono; D. Fernandes; H. J. H. Kux; A Comparative Study of Speckle Reduction Filters in SAR Images and Their Application for Classification Performance Improvement, 24th Intern. Symposium on Remote Sensing of Environment, Rio de Janeiro, RJ, Brazil, Vol. II, 27-31 May, 1991.
 - [Mascarenhas et al. (1993)] N. D. A. Mascarenhas; S. S. Furuie; A. L. S. Portal, Global Projection Estimation Methods for the Tomographic Reconstruction of

- Images with Poisson Noise, *IEEE Trans. on Nuclear Science*, 40(6), 2008-2013, Part 2, December, 1993.
- [Mascarenhas & Frery (1994)] N. D. A. Mascarenhas; A. C. Frery, SAR Image Filtering with the ICM Algorithm, *Proceedings of Intern. Geoscience and Remote Sensing Symposium*, (IGARSS'94), 2185-2187, August, 1994.
- [Mascarenhas et al. (1996a)] N. D. A. Mascarenhas; S. S. L. Santos; P. E. Cruvinel, The Use of MAP Estimation Techniques in the Tomographic Reconstruction of Poisson Noise Images, *Proc. do IX Simpósio Brasileiro de Processamento de Imagens e Computação Gráfica (SIBGRAPI-96*, São Carlos-SP, 197-204, 1996.
- [Mascarenhas (1996b)] N. D. A. Mascarenhas, An Overview of Speckle Noise Filtering in SAR Images, *Primeras Jornadas Latinoamericanas de Percepción Remota por Radar*, Buenos Aires, Argentina, 71-79, Dec. 1996.
- [Mascarenhas et al. (1997)] N. D.A. Mascarenhas; L. F. Costa; F. N. S. Medeiros, Speckle Noise Filtering in SAR Images by MAP Approach, *X Simpósio Brasileiro de Processamento de Imagens e Computação Gráfica (SIBGRAPI-97*, Campos do Jordão, SP, Out. 1997), 1997.

 (http://www.visgraf.impa.br/sibgrapi97/aceitos.html#AND).
- [McConnell et al. (1995)] I. McConnell; R. White; C. Oliver; R. Cook, Radar Cross-Section Estimation of SAR Images, Europto Conf. on SAR Image Analysis, Simulation and Modelling, SPIE Proc., Vol. 2584, 164-175, 1995.
- [Medeiros et al. (1998a)] F. N. S. Medeiros, N. D.A. Mascarenhas; L. F. Costa, Combined Use of MAP Estimation and K-Means Classifier for Speckle Noise Filtering in SAR Images, *IEEE Southwest Symposium on Image Analysis and Interpretation*, Arizona, U.S.A., 250-255, April., 1998.
- [Medeiros et al. (1998b)] F. N. S. Medeiros, N. D. A. Mascarenhas; L. F. Costa, An Adaptive Clustering MAP Algorithm to Filter Speckle in Multilook SAR Images, Second Latino-American Seminar on Radar Remote Sensing, Santos, SP, 67-74, Sept., 1998.
- [Medeiros et al. (1998c)] F. N. S. Medeiros, N. D. A. Mascarenhas; L. F. Costa, Adaptive Speckle MAP Filtering for SAR Images Using Statistical Clustering,

- International Symposium on Computer Graphics, Image Processing and Vision, Rio de Janeiro, RJ, 303-310, Oct., 1998.
- [Medeiros et al. (1999)] F. N. S. Medeiros, N. D. A. Mascarenhas; L. F. Costa, Speckle Noise MAP Filtering Based on Local Adaptive Neighborhood Statistics, Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens, Campinas, São Paulo, 347-354, Out., 1999.
- [Nagao & Matsuyama (1979)] M. Nagao; T. Matsuyama, Edge Preserving Smoothing, Comput. Graphics Image Process., 9, 394-407, 1979.
- [Nathan & Curlander (1987)] K. S. Nathan; J. C. Curlander, Speckle Noise Reduction of 1-Look SAR Imagery, *Intern. Geoscience and Remote Sensing Symposium*, (IGARSS'87), 1457-1462, May, 1987.
- [Oliver & Quegan (1998)] C. Oliver; S. Quegan, *Understanding Synthetic Aperture Radar Images*, ArtechHouse, 1998.
- [Papoulis (1965)] A. Papoulis, *Probability, Random Variables, and Stochastic Processes*, McGraw-Hill, 1965.
- [Pitas (1995)] I. Pitas, Digital Image Processing Algorithms, Prentice-Hall, 1995.
- [Pratt (1991)] W. K. Pratt, *Digital Image Processing*, John Wiley & Sons, second edition, 1991.
- [Richards (1986)] J. A. Richards, Remote Sensing Digital Image Analysis: An Introduction, Springer-Verlag, 1986.
- [Sadjadi (1990)] F. A. Sadjadi, Perspective on techniques for enhancing speckled imagery, *Optical Engineering*, 29(1), 25-30, Jan., 1990.
- [Sant'Anna (1995)] S. J. S. Sant'Anna, Avaliação do Desempenho de Filtros Redutores de "Speckle" em Imagens de Radar de Abertura Sintética, São José dos Campos, SP, Brasil, 1995 (Dissertação de Mestrado).
- [Schalkoff (1989)] J. R. Schalkoff, Digital Image Processing and Computer Vision, John Wiley & Sons, 1989.
- [Sethian (1999)] J. A. Sethian, Level Set Methods and Fast Marching Methods, Cambridge University Press, 1999.
- [Therrien (1989)] C. W. Therrien, Decision, Estimation and Classification, John Wiley, 1989.

- [Tomita & Tsuji (1977)] F. Tomita; S. Tsuji, Extraction of Multiple Regions by Smoothing in Selected Neighborhoods, *IEEE Trans. Syst. Man and Cybernet.*, 7, 107-109, Feb., 1977.
- [Vieira (1996)] P. R. Vieira, Desenvolvimento de Classificadores de Máxima Verossimilhança para Imagens SAR, *INPE*, São José dos Campos, SP, Brasil, 1996 (Dissertação de Mestrado).
- [Wu & Maitre (1990)] Y. Wu; H. Maitre, A speckle supression method for SAR images using maximum homogeneous region filter, *Proceedings of Intern. Geoscience and Remote Sensing Symposium*, (IGARSS'90), 2413-2416, 1990.
- [Yanasse et al. (1995)] C. C. F. Yanasse; A. C. Frery; S. J. S. Sant'Anna, Stochastic Distributions and the Multiplicative Model: Relations, Properties, Estimators and Applications to SAR Images Analysis, Technical Report 5630-NTC/318, INPE, São José dos Campos, SP, Brazil, 1995.

Apêndice A

Conceitos Básicos em Probabilidade

Neste apêndice são apresentadas algumas definições básicas de estatística tais como variáveis aleatórias, esperança matemática e variância. O espaço de amostras (Ω) associado a uma experiência é o conjunto de todos os possíveis resultados da mesma. A função X que mapeia os pontos (ϖ) de Ω no conjunto dos números reais $\mathcal R$ é denominada variável aleatória (v.a.) real. As variáveis aleatórias serão descritas por letras maiúsculas (X) e suas ocorrências por letras minúsculas (x). Uma v.a real é uma função X cujo domínio é Ω e cujo contra-domínio é $\mathcal R$, podendo-se escrever:

$$X: \qquad \Omega \to \Re$$

$$\varpi \to X(\varpi) \tag{A.1}$$

A função distribuição de probabilidade (FDP) associada a uma v.a. real X é definida por:

$$F_x: \mathfrak{R} \to \mathfrak{R}$$

$$x \to F_X(x) \tag{A.2}$$

onde

$$F_X(x) = P(X \le x) \tag{A.3}$$

Para uma v.a. contínua X com FDP F_x , define-se como função densidade de probabilidade (fdp) a função f(x) dada por:

$$f_X(x) = \frac{dF_X(x)}{dx} \tag{A.4}$$

ou ainda,

$$F_{X}(x) = \int_{-\infty}^{\infty} f(x)dx \tag{A.5}$$

A fdp de uma v.a. X satisfaz às seguintes condições:

i)
$$F_X(x) = \int_{-\infty}^{\infty} f_X(u) du$$
.

- ii) $f(x) \ge 0$.
- iii) $\int_{-\infty}^{\infty} f(x)dx = 1$.

iv)
$$\int_a^b f_X(x) dx = \Pr(X \in (a, b])$$
.

Duas variáveis aleatórias X e Y são ditas independentes se a sua função de distribuição conjunta for descrita como o produto de suas respectivas distribuições individuais (marginais), para quaisquer valores reais de X e Y. Este resultado pode ser estendido para variáveis de dimensão n:

v)
$$F_{X_1,X_2,...X_n}(a_1,a_2,...a_n) = F_{X_1}(a_1)F_{X_2}(a_2)...F_{X_n}(a_n)$$
.

O valor esperado ou esperança matemática de uma v.a. contínua X, cuja função densidade de probabilidade é f(x) é definida por:

$$E[X] = \int_{-\infty}^{\infty} x f(x) dx$$
 (A.6)

desde que a integral exista.

Propriedades do valor esperado (E[X] ou μ) [DeGroot (1975)]:

- i) Se Y = aX + b, onde $a \in b$ são constantes, então E[Y] = aE[X] + b.
- ii) Se existe uma constante a tal que $\Pr(X \ge a) = 1$, então $E[X] \ge a$. Se existe uma constante b tal que $\Pr(X \le b) = 1$, então $E[X] \le b$.
- iii) Se $X_1 ... X_n$ são variáveis aleatórias tais que cada esperança $E[X_i], i=1...n$ existe, então $E[X_1+...+X_n]=E[X_1]+...+E[X_n]$.
- iv) Se $X_1 ldots X_n$ são variáveis aleatórias independentes, tais que cada esperança $E[X_i]$, i=1...n existe, então $E\left(\prod_{i=1}^n X_i\right) = \prod_{i=1}^n E[X_i]$, mas geralmente a independência de n variáveis implica em: $E[X_1X_2] = E[X_1]E[X_2]$ [James (1996)], considerando n=2.

A variância é uma medida de dispersão de uma distribuição em torno da média ou esperança. Uma v.a. contínua de média E[X] tem seu segundo momento (Var ou σ_x^2) definido por [**DeGroot** (1975)]:

$$Var[X] = E[X - \mu]^2 \tag{A.7}$$

ou ainda,

$$Var[X] = \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx$$
(A.8)

desde que a integral exista.

A seguir são apresentadas algumas propriedades da variância [Gibra (1973)]:

- i) Se C é uma constante qualquer então $Var[CX] = C^2 Var[X]$.
- ii) Se X e Y são variáveis aleatórias decorrelacionadas então Var[X+Y] = Var[X] + Var[Y], sabendo-se que a variância da soma de duas variáveis aleatórias em geral é dada pela expressão: $Var[X+Y] = Var[X] + Var[Y] + 2E\{[X-E(X)][Y-E(Y)]\}$ então para este caso o último termo é igual a zero [Gibra (1973)].

A covariância de X e Y por definição é dada por: Cov(X,Y)=E[XY]-E[X]E[Y]. Pode-se concluir desta expressão que a covariância de duas variáveis independentes é nula, mas a recíproca não é verdadeira, ou seja, duas v.a. cuja covariância é nula, isto é, são decorrelacionadas, não implica que as mesmas sejam independentes.

O momento de ordem k para qualquer variável aleatória X é definido como sendo o valor esperado $E[X^k]$. De acordo com esta terminologia a média de X corresponde ao primeiro momento de X. O k-ésimo momento de X é dado pela expressão [**DeGroot** (1975)]

$$E[X^k] = \int_{\Re} x^k f(x) dx \tag{A.9}$$

desde que a integral exista.

Apêndice B

Métodos de Estimação de Parâmetros

B.1 Método dos Momentos

O método geral mais antigo para estimação de um parâmetro desconhecido foi introduzido por Karl Pearson em 1894 e é conhecido como método dos momentos. A abordagem do método dos momentos é baseada na solução de uma equação teórica igualando os momentos amostrais aos momentos teóricos. Este método produz um estimador fácil de determinar e simples de implementar, embora não apresente propriedades de optimalidade, e é útil em caso do registro de dados ser suficientemente grande, porque o método dos momentos em geral é consistente [Kay (1993)].

Entende-se por população um conjunto ou coleção de elementos sob investigação. Define-se uma característica (X) destes elementos sob investigação de v.a. e a função de distribuição dessa v.a. de P_{θ} . Neste método de estimação o momento amostral serve como um estimador do momento correspondente da população e uma função de momentos amostrais serve como um estimador de parâmetros da população (e depende do parâmetro θ), a qual é a função correspondente dos momentos da mesma. Assim o k-ésimo momento amostral é um estimador do k-ésimo momento da população, por exemplo: o coeficiente de correlação para uma população bi-dimensional é estimado pelo coeficiente de correlação amostral e assim por diante. [Fisz (1963)].

Suponha que a distribuição P_{θ} pertence à família das distribuições $\{P_{\theta}, \theta \in \Theta\}$, onde Θ é um domínio em \Re^d , e que existam os primeiros d momentos de P_{θ} descritos pela expressão:

$$m_r(\theta) = \int_{\mathbb{R}^1} x^r P_{\theta}(dx), \qquad r = 1, 2 \dots, d.$$
(B.1)

onde \Re^1 é um espaço euclidiano unidimensional. Tendo-se n observações independentes $x_1, x_2... x_n$ da variável aleatória X constroem-se os momentos amostrais pela expressão [Koroliuk (1981)]:

$$\overline{m}_r = \frac{1}{n} \sum_{k=1}^n x_k^r, \qquad r = 1, 2, \dots d$$
 (B.2)

O método dos momentos consiste em igualar os momentos amostrais aos momentos teóricos, obtendo-se o sistema de equações com respeito a d incógnitas $\theta^1, \theta^2, \dots \theta^d$ [Koroliuk (1981)]:

$$m_r(\theta) = \overline{m}_r,$$
 $r = 1, 2, \dots d$ (B.3)

Se existe a solução única $\theta_r^*(x_1, x_2, ... x_n) = f_r(\overline{m}_1, \overline{m}_2, ... \overline{m}_d)$, r = 1, 2, ... d deste sistema e as funções f_r são contínuas, então a estimação que se obtém $\{\theta_r^*, r = 1, 2, ... d\}$ é uma estimação do parâmetro real θ [Koroliuk (1981)].

B.2 Método de Máxima Verossimilhança

O método de máxima verossimilhança (*MLE*) [Fisz (1963)] apresenta boas propriedades assintóticas tais como consistência e eficiência, o que assegura uma boa estimação à medida que o número de amostras cresce. Em geral um estimador é consistente se converge para o verdadeiro valor do parâmetro. Um estimador é dito eficiente com relação a outro se apresentar menor variância.

Seja F(x) a função de distribuição de uma variável aleatoria X e seja F(x) dependente de λ , que é um vetor de m parâmetros $\lambda_1, \lambda_2, ..., \lambda_m$ desconhecidos, os quais se deseja estimar tomando por base uma amostra de n elementos $x_1, x_2, ..., x_n$. Se X é uma variável aleatória do tipo discreta e $P(X=x_k:\lambda)=p_k(k=1,2...,n)$, a função de verossimilhança, supondo observações independentes, é dada pela fórmula:

$$L = p_1 p_2 \cdots p_n = \prod_{i=1}^n p_k$$
(B.4)

onde $p_k(k=1,2,...n)$ são funções dos parâmetros $\lambda_1, \lambda_2,...\lambda_m$.

Se X é uma variável aleatória do tipo contínua com densidade f(x) então a função de verossimilhança é dada pela fórmula:

$$L = f(x_1)f(x_2)\cdots f(x_n) = \prod_{i=1}^n f(x_i)$$
(B.5)

onde $f(x_k)$ (k=1,2,...n) são funções dos parâmetros $\lambda_1, \lambda_2,...\lambda_m$.

Os estimadores de máxima verossimilhança dos parâmetros $\lambda_1,\ \lambda_2,...\lambda_m$ são obtidos pela solução do sistema de m equações:

$$\frac{\partial L}{\partial \lambda_i} = 0 \qquad (i = 1, 2, \dots m). \tag{B.6}$$

A função L dada na **Equação B.5** é a probabilidade de obter a amostra observada (se X é do tipo contínua considera-se o elemento de probabilidade $Ldx_1,...dx_n$). Assim o princípio do método de estimação por máxima verossimilhança é tomar o estimador dos parâmetros desconhecidos que maximize a probabilidade de obter a amostra observada. Desde que L e logL assumam seus valores máximos para os mesmos valores de $\lambda_1, \lambda_2,...\lambda_m$, o sistema de equações dado pela **Equação B.5** ode ser substituído pelo sistema abaixo [**Fisz (1963)**] cuja solução produz a estimativa de máxima verossimilhança de λ_i :

$$\frac{\partial \log L}{\partial \lambda_i} = \frac{\partial \log L(x_1)}{\partial \lambda_i} + \frac{\partial \log L(x_2)}{\partial \lambda_i} + \dots + \frac{\partial \log L(x_n)}{\partial \lambda_i} = 0; (i = 1, 2...m),$$
(B.7)

Como existem vários (m) parâmetros a serem estimados calcula-se a mesma expressão obtida na **Equação B.7** para cada parâmetro e os resultados do sistema de equações são as estimativas de máxima verossimilhança dos parâmetros.

Apêndice C

Teorema Central do Limite

Neste apêndice será feita uma breve abordagem sobre um dos mais importantes resultados em probabilidade que é o teorema central do limite. Este teorema assegura que sob certas condições a soma de um grande número de variáveis aleatórias independentes e identicamente distribuídas tem uma distribuição aproximadamente normal. A descrição do teorema é feita a seguir de uma maneira mais formal, embora simplificada.

Sejam as variáveis aleatórias contínuas x_1, x_2, \dots, x_n independentes, identicamente distribuídas com densidades $f_i(x)$ e médias e variâncias dadas por:

$$E[x_1] = E[x_2] = \dots = E[x_n] = \mu$$

 $Var[x_1] = Var[x_2] = \dots = Var[x_n] = \sigma^2$ (C.1)

e a variável y, sua função densidade, f(y), média e variância definidas por:

$$y_{n} = \sum_{k=1}^{n} x_{k}$$

$$f(y) = f_{1}(x_{1}) * f_{2}(x_{2}) * ... * f_{n}(x_{n})$$

$$E[y] = m = E[x_{1}] + E[x_{2}] + ... + E[x_{n}]$$

$$m = n.\mu$$

$$Var[y] = \rho^{2} = Var[x_{1}] + Var[x_{2}] + ... + Var[x_{n}]$$

$$\rho^{2} = n.\sigma^{2}$$
(C.2)

onde * representa convolução.

O teorema central do limite diz que sob certas condições f(y) se aproxima de uma distribuição Gaussiana à medida que o número de variáveis n aumenta, com a distribuição a seguir:

$$f(y) \approx \frac{1}{\rho\sqrt{2\pi}} e^{\frac{(y-m)^2}{2\sigma^2}}$$
 (C.3)

Se y é propriamente escalado por $1/\sqrt{n}$ de tal modo que o limite da variância seja finito, então a **Equação** (C.3) se torna uma igualdade para $n \to \infty$. Se as densidades $f(x_i)$ são razoavelmente concentradas próximo a μ então a curva normal é uma boa aproximação de f(y) mesmo para valores moderados de n [Papoulis (1965)].

Apêndice D

Método de Newton-Raphson

O problema de estimação de variáveis desconhecidas por minimização (ou maximização) de uma função surge em vários contextos e aplicações e dentre as várias abordagens que buscam solução para o mesmo, estão presentes na literatura os métodos iterativos. Dentre estes destaca-se o método de Newton-Raphson que se baseia na expansão por série de Taylor e explora ambas as informações da primeira e segunda derivadas da função na determinação da direção de busca da solução do problema.

Nesta tese utiliza-se o método de Newton-Raphson para encontrar zeros de uma função, ou seja, encontrar a raiz da equação polinomial, f(x), que é o estimador MAP do pixel original. Deseja-se encontrar o valor de x para o qual f(x)=0, para os casos dos filtros MAP com distribuição "a priori" log-normal. A busca da raiz ou de um valor aproximado dela é feita pela formulação:

$$x_{k+1} = x_k - \frac{f(x_k)}{f'(x_k)}$$
 (D.1)

onde f'(x) corresponde à derivada primeira de f(x). O processo é iterativo e para inicializá-lo atribui-se uma primeira aproximação para x_k que é o próprio pixel ruidoso. Nota-se que f(x)=0, como se deseja, acontece quando $x_{k+1}=x_k$, ou seja, na convergência. O critério de parada neste trabalho, leva em conta o número máximo de iterações e a estabilização de x_{k+1} , isto é, quando o valor de x_{n+1} na iteração atual é o mesmo da iteração anterior.

D.1 Análise de Velocidade de Convergência

A velocidade de convergência de um algoritmo iterativo para convergir ao seu resultado pode ser medida em termos da ordem de convergência e da taxa de convergência. Um esquema iterativo converge geometricamente com ordem R se o

erro $\|\hat{f}_k - \hat{f}_\infty\|$ para um valor de k suficientemente grande for dado por [Lagendijk & Biemond (1991)]:

$$\left\|\hat{f}_{k+1} - \hat{f}_{\infty}\right\| \approx \kappa \left\|\hat{f}_{k} - \hat{f}_{\infty}\right\|^{R} \qquad R \ge 1$$
(D.2)

Assim sendo, $\kappa \ge 0$ corresponde à taxa de convergência. Um grande valor de κ corresponde a uma convergência lenta, enquanto que para um pequeno valor a convergência é rápida. Quanto maior a ordem de convergência de um algoritmo mais rápido ele converge. Para R=1 o processo é dito convergir linearmente e neste caso é conveniente escrever a **Equação D.2** da forma:

$$\left\|\hat{f}_{k} - \hat{f}_{\infty}\right\| \le \kappa^{k} \left\|\hat{f}_{0} - \hat{f}_{\infty}\right\| \tag{D.3}$$

e $0 \le \kappa \le 1$. Para $\kappa=0$ a convergência é dita ser superlinear ou em outras palavras o processo iterativo termina dentro de um número finito de iterações, enquanto $\kappa=1$ a convergência é sublinear [Lagendijk & Biemond (1991)]. O método de Newton-Raphson apresenta uma taxa de convergência quadrática.

Vários pontos podem ser destacados com relação ao método iterativo de Newton-Raphson, são eles:

- i) a iteração pode não convergir se a solução iterativa estiver distante da solução verdadeira.
- ii) mesmo que a iteração convirja, o ponto encontrado pode não ser o máximo global, mas possivelmente um máximo local ou mesmo um mínimo global. Para evitar estas possibilidades é melhor usar vários pontos de partida e na convergência escolher aquele que é máximo entre todos.

Apêndice E

Algoritmos de Classificação do Software SPRING Utilizados na Tese

Na etapa de classificação das imagens filtradas foi utilizado o software SPRING (Sistema de Processamento de Informações Georeferenciadas) desenvolvido no Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos, para obtenção dos resultados. O classificador pontual de Máxima Verossimilhança (MaxVer) e o classificador contextual ICM (Iterated Conditional Modes) foram utilizados na fase de classificação e posteriormente foi aplicada a transformada de Hough às imagens classificadas e binarizadas. A medida de avaliação da qualidade da filtragem proposta neste trabalho é obtida do resultado da aplicação desta transformada.

E.1 MaxVer

O algoritmo que descreve o método estatístico de Máxima Verossimilhança consiste das seguintes etapas [Frery (1993)]:

- Passo 1. Estabelecer o número de populações diferentes que aparecem na imagem *y*.
 - Passo 2. Estabelecer a distribuição de cada uma dessas populações.
 - Passo 3. Estimar os parâmetros relevantes para cada classe.
- Passo 4. Atribuir cada pixel à classe cujo valor de verossimilhança é máximo, usando a informação coletada.

A etapa 1 é realizada pela observação da imagem e o conhecimento prévio da mesma, se existir. Na etapa 2 as distribuições são estabelecidas conforme a análise das características físicas do processo de formação da imagem envolvido. Na etapa 3 são colhidas amostras representativas das classes estabelecidas na etapa 1 e levantadas algumas medidas estatísticas tais como a média amostral, variância amostral, etc. Na etapa 4 é feita a busca entre as classes estabelecidas na etapa 1, aquela que apresenta a máxima densidade, em cada valor de pixel analisado. Esta

técnica apresenta alguns incovenientes os quais podem levar o método a não funcionar adequadamente, por ser derivado de algumas hipóteses não necessariamente realísticas, tais como [Frery (1993)]:

- i) equiprobabilidade de classes, isto \acute{e} , dado que há K classes presentes, a probabilidade de que um pixel pertença a uma dada classe \acute{e} igual a dele pertencer a outra.
- ii) independência total, ou seja, a verdadeira classe de uma posição independe da verdadeira classe das posições vizinhas, e a observação em cada posição independe das observações nas vizinhas, dadas as respectivas verdades terrestres.

E.2 ICM

O algoritmo ICM foi originalmente proposto como uma forma de se obter uma solução MAP aproximada e mais tarde, ganhou o "status" de algoritmo com interesse próprio [Frery (1993)].

Seja a densidade condicional para o pixel observado y(k,l) dados os estados (ou classe) $s_{k,l}$ denotado por $p_{s_{k,l}}(y(k,l))$, e dada uma atribuição inicial para os estados de todos os pixels a busca iterativa de uma configuração de equilibrio pode ser feita pela regra de decisão:

$$p_1(y(k,l)) \Pr[1 \mid S_{k,l}] \stackrel{w_1}{\underset{w_2}{>}} p_2(y(k,l)) \Pr[2 \mid S_{k,l}]$$
 (E.1)

onde $S_{k,l}$ denota o conjunto dos estados para todos os pixels na vizinhança de y(k,l) e $\Pr[s_{k,l} \mid S_{k,l}]$ corresponde à probabilidade condicional do estado $s_{k,l}$ dados os estados na vizinhança de (k,l). A notação da regra de decisão expressa na **Equação E.1** denota que a escolha da classe $(w_1$ ou $w_2)$ ocorrerá mediante o maior valor da probabilidade "a posteriori" da classe, isto é, se o valor correspondente à classe 1 for maior que o valor da classe 2 então o pixel y(k,l) será rotulado como pertencente à classe 1 e vice-versa. A distribuição de $\Pr[s_{k,l} \mid S_{k,l}]$ é dada por [**Therrien (1989)**]:

$$\Pr\left[S_{k,l} \mid S_{k,l}\right] = \frac{1}{Z_s} \exp\left[-\frac{1}{T} \sum_{j} F_j(C_j(k,l))\right]$$
(E.2)

onde Z_s é uma constante de normalização determinada de tal forma que a soma das probabilidades seja 1 e T é o parâmetro denominado temperatura. Os termos $F_j(C_j)$ são funções dos estados dos pixels nos cliques C_j e a soma ocorre sobre todos os cliques que envolvem o pixel k,l [Therrien (1989)]. A Figura E.1 apresenta uma estrutura de vizinhança (4 pixels conectados) e o conjunto de cliques correspondente.

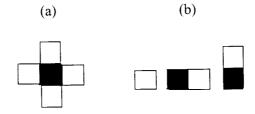


Figura E.1 – (a) Vizinhança de um pixel (b) correspondente conjunto de cliques.

O expoente da Equação E.2 para a estrutura de vizinhança apresentada na Figura E.1 é dado por:

$$-\frac{1}{T}s_{k,l}\left[\alpha+\beta_{1}\left(s_{k-1,l}+s_{k+1,l}\right)+\beta_{2}\left(s_{k,l-1}+s_{k,l+1}\right)\right] \tag{E.3}$$

No passo inicial um conjunto de classes é escolhido de acordo com a expressão (classes equiprováveis):

$$p_1(y(k,l)) > p_2(y(k,l))$$
 $< p_1(y(k,l))$
(E.4)

Os estados das iterações anteriores são usados para determinar os estados atuais e os valores correspondentes de $\Pr[s_{k,l} \mid S_{k,l}]$. Estes valores são usados na **Equação E.1** para determinar o novo conjunto de atribuição de classes. O procedimento finaliza quando a atribuição de classes não muda de uma iteração para outra [Therrien (1989)]. No software SPRING a parada acontece quando a percentagem de mudana de rótulos dos pixels, estabelecida pelo pelo usuário, é atingida.

A seguir apresentamos dois exemplos de classificação supervisionada da imagem *SAR580* filtrada pelo MAP gama em combinação ao k-médias utilizando os algoritmos MaxVer e ICM do software SPRING.





Figura E.2 -Algoritmos de Classificação (a) MaxVer (b) ICM.

Para a classificação da imagem *SAR580* (**Figura F.11a**) foram colhidos de conjuntos de amostras de treinamento das classes de cultura e floresta, que são predominantes na imagem. O número de amostras de treinamento em cada janela é diferente, pois no caso de florestas é possível adquirir conjuntos maiores que no caso de cultura. As dimensões dos conjuntos variaram de 35x35 a 100x100 pixels.

Com relação à imagem *JERS481* (**Figura F.21a**, primeira coluna) sobre a Floresta Nacional de Tapajós foram colhidas amostras de treinamento das classes floresta e não floresta (regeneração) com conjunto de amostras variando de 30x30 pixels a 100x100 pixels.

A imagem SAR real *ZONE* na (**Figura F.21a**, segunda coluna) é uma região plana de campos de agricultura bem definidos, estradas e canais. Na classificação foram definidas duas classes de cultura e não cultura, sendo que alguns conjuntos de amostras da classe não cultura variaram em torno de 15x15 pixels. Deve-se ressaltar que para um número pequeno de amostras de treinamento a variância dos estimadores das densidades condicionais aumenta.

Apêndice F

Resultados de Aplicação dos Algoritmos

Neste apêndice são apresentados os conjuntos de imagens utilizados para teste dos algoritmos. Na primeira seção são apresentadas as imagens reais SAR obtidas em amplitude e uma visada, em seguida o conjunto de imagens contaminadas artificialmente pelo ruído "speckle" cuja distribuição obedece a uma Rayleigh. Em seguida são apresentadas as imagens artificialmente contaminadas pelo "speckle" com estatística raiz de gama e na seção seguinte imagens SAR reais em amplitude e múltiplas visadas

F.1 Imagens Artificialmente Contaminadas pelo Ruído "Speckle" com Estatística de Imagens em Amplitude e Uma Visada

As imagens artificialmente contaminadas pelo ruído foram resultados da multiplicação ponto a ponto destas imagens originais com amostras de ruído com média unitária e que correspondem à estatística do "speckle" em amplitude e uma visada (Rayleigh). O "speckle" foi gerado utilizando a rotina *random 'rayl'* do software MATLAB com parâmetro ('backscatter'') 0.7963 [Medeiros et al. (1999)]. No caso de geração de "speckle" cuja estatística corresponde à raiz quadrada da gama foi utilizado o mesmo processo para geração de amostras que seguem a distribuição Rayleigh, e calculamos a média de N distribuições Rayleigh obtendo-se uma aproximação da função densidade de probabilidade que descreve a raiz quadrada da gama. A geração do padrão de "speckle" presente em imagens amplitude com múltiplas visadas poderia ter sido feita gerando diretamente uma distribuição raiz quadrada da gama, no entanto, sem razões especiais adotou-se a mesma rotina de geração de "speckle" com distribuição Rayleigh para gerar a raiz quadrada da gama.

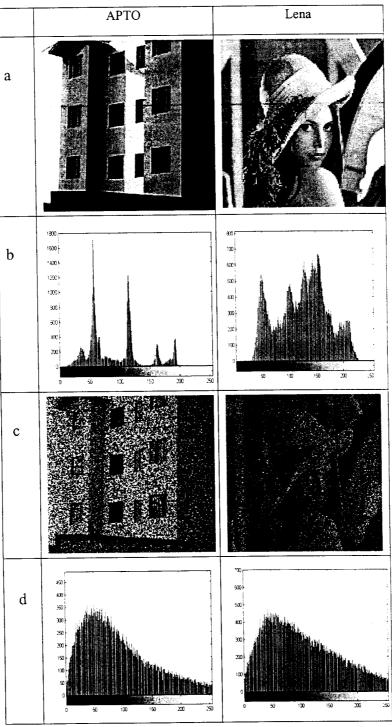


Figura F.3 – (a) Imagem original e (b) seu respectivo histograma (c) imagem contaminada pelo ruído "speckle" e (d) seu respectivo histograma.

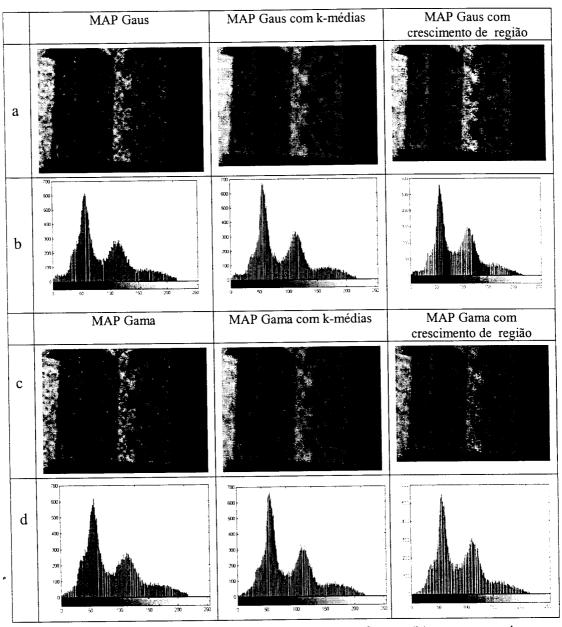
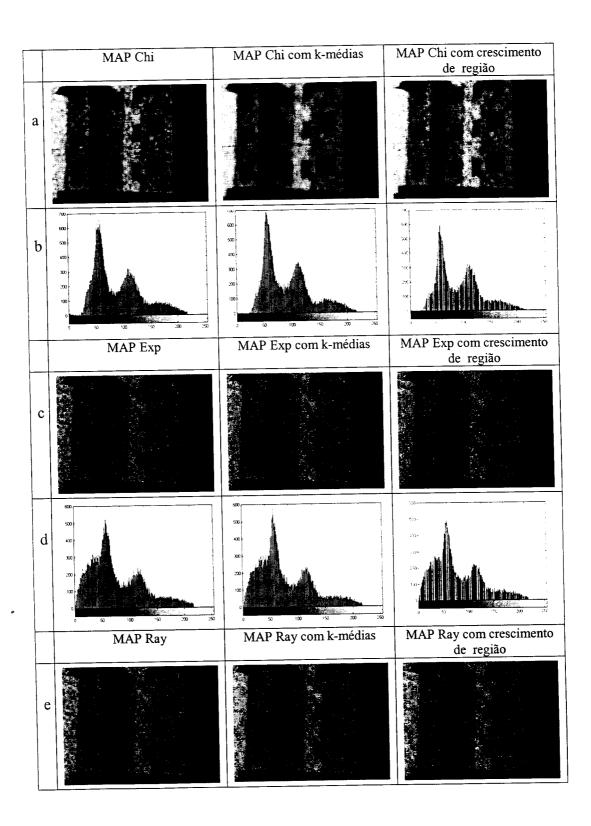


Figura F.4 – Imagem *APTO* filtrada pelo (a) MAP Gaus e (b) seus respectivos histogramas (c) MAP Gama e (d) seus respectivos histogramas.



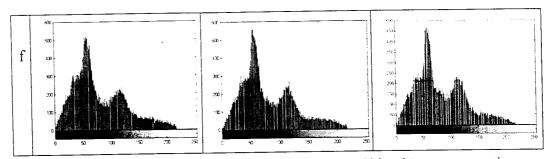


Figura F.5 – Imagem *APTO* filtrada pelo (a) MAP Chi e (b) seus respectivos histogramas (c) MAP Exp e (d) seus respectivos histogramas (c) MAP Ray e (d) seus respectivos histogramas.

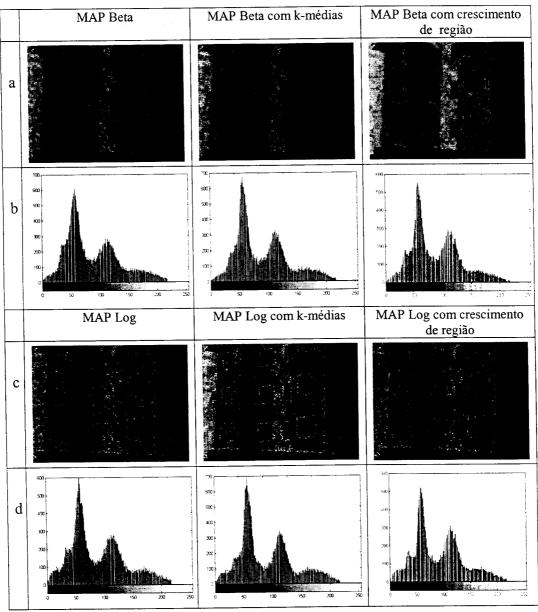


Figura F.6 – Imagem *APTO* filtrada pelo (a) MAP Beta e (b) seus respectivos histogramas (c) MAP Log e (d) seus respectivos histogramas.

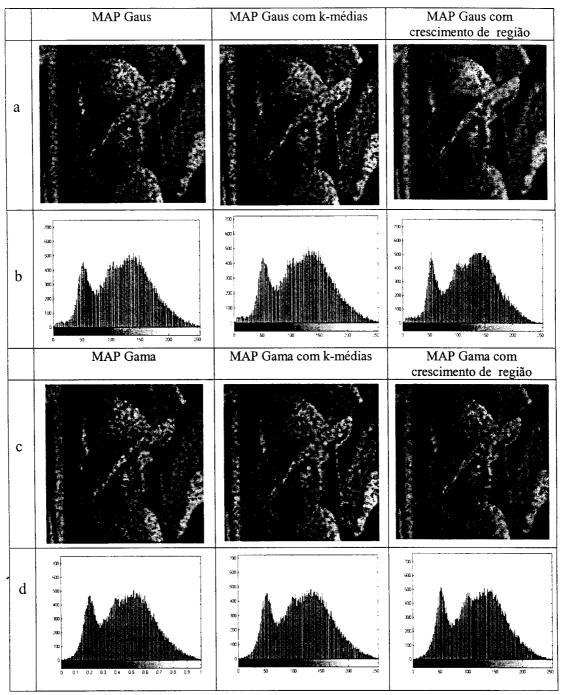


Figura F.7 – Imagem *LENA* filtrada pelo (a) MAP Gaus e (b) seus respectivos histogramas (c) MAP Gama e (d) seus respectivos histogramas.

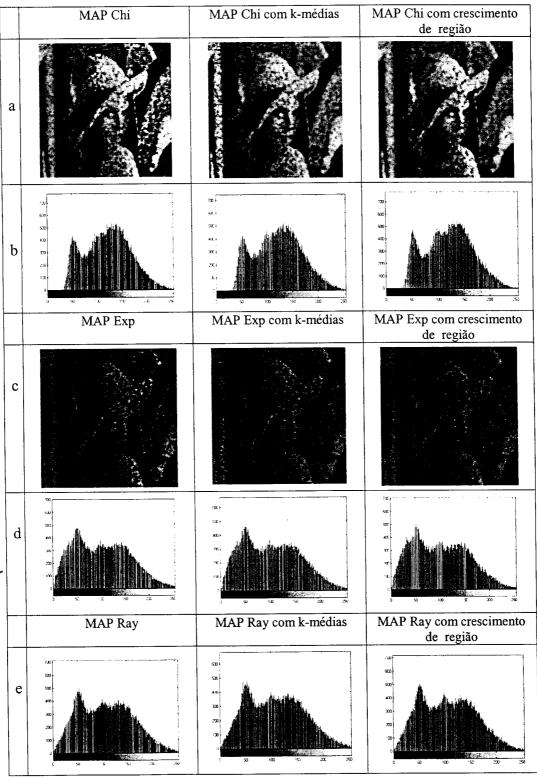


Figura F.8 – Imagem *LENA* filtrada pelo (a) MAP Chi e (b) seus respectivos histogramas (c) MAP Exp e (d) seus respectivos histogramas (d) MAP Ray e (e) seus respectivos histogramas.

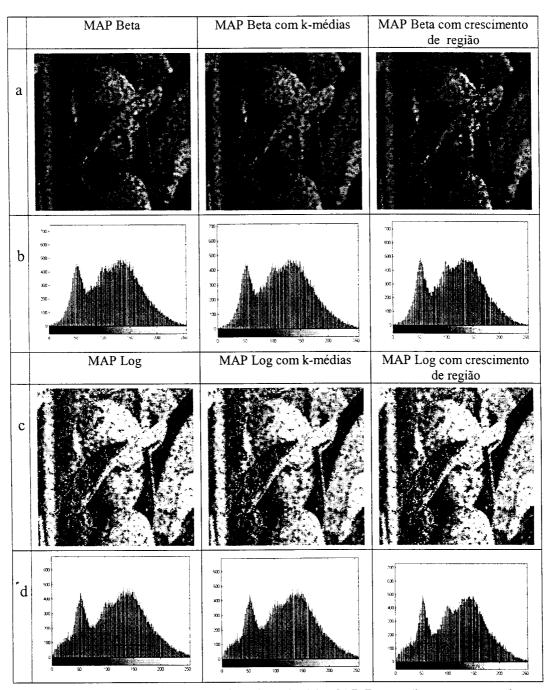


Figura F.9 – Imagem *LENA* filtrada pelo (a) MAP Beta e (b) seus respectivos histogramas (c) MAP Log e (d) seus respectivos histogramas.

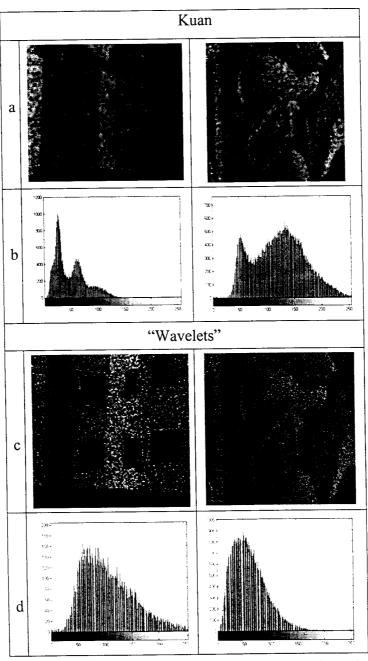


Figura F.10 – Imagens artificialmente contaminadas e filtradas pelo (a) Kuan e (b) seus respectivos histogramas (c) "wavelets" e (d) seus respectivos histogramas.

F.2 Imagens Reais SAR em Amplitude e 1 Visada

As imagens reais SAR utilizadas para exemplos e testes dos filtros propostos nesta tese e apresentadas na **Figura F.11a** são as seguintes:

- i) A imagem real foi obtida por um sistema aerotransportado (*SAR580*) sobre a região de Freiburg na Alemanha, e corresponde a um pedaço da imagem de 512x512 pixels, banda L, 1 visada e detecção linear com resolução de 1,5m/pixel.
- ii) A imagem real da **Figura 2.7c** foi cedida pelo IEAv-CTA através do ITA e corresponde a uma pequena imagem da região de Caçapava (Vale do Paraíba-SP). Esta é uma imagem amplitude de 1 visada obtida pelo RADARSAT em novembro de 1998. Na imagem vê-se o Rio Paraíba e uma grande mancha mais escura que se trata provavelmente de cultura de arroz.

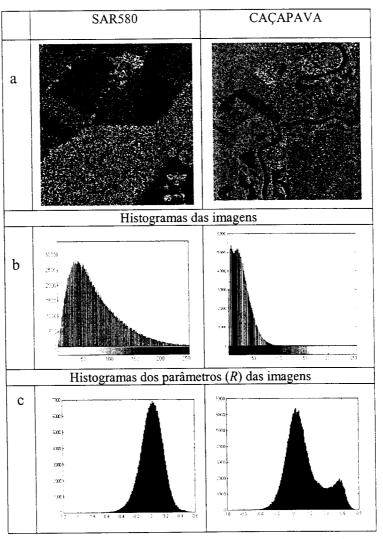


Figura F.11 – Imagens reais SAR em amplitude e 1 visada (a) ruidosa e (b) seu respectivo histograma (c) histograma de (R).

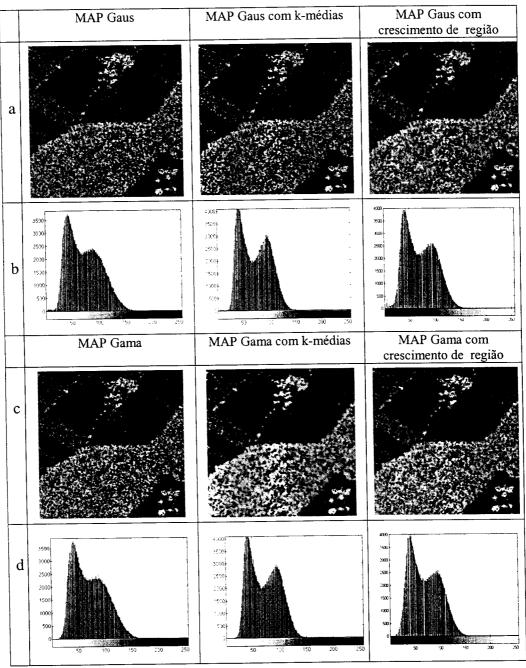


Figura F.12 – Imagem SAR580 filtrada pelo (a) MAP Gaus e (b) seus respectivos histogramas (c) MAP Gama e (d) seus respectivos histogramas.

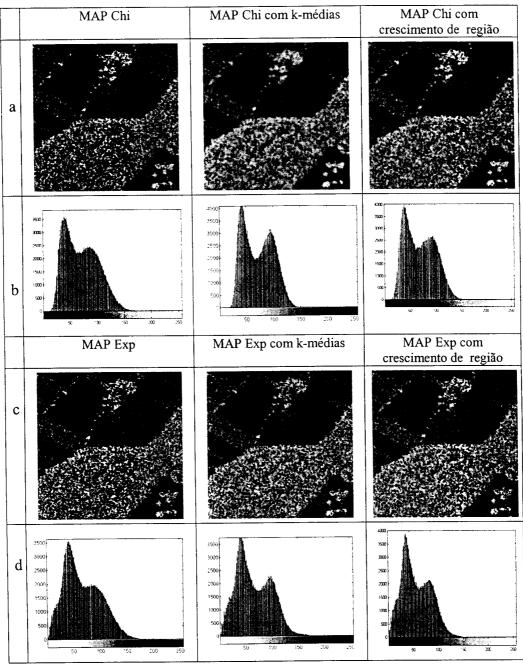


Figura F.13 – Imagens reais SAR580 filtradas pelo (a) MAP Chi e (b) seus respectivos histogramas (c) MAP Exp e (d) seus respectivos histogramas.

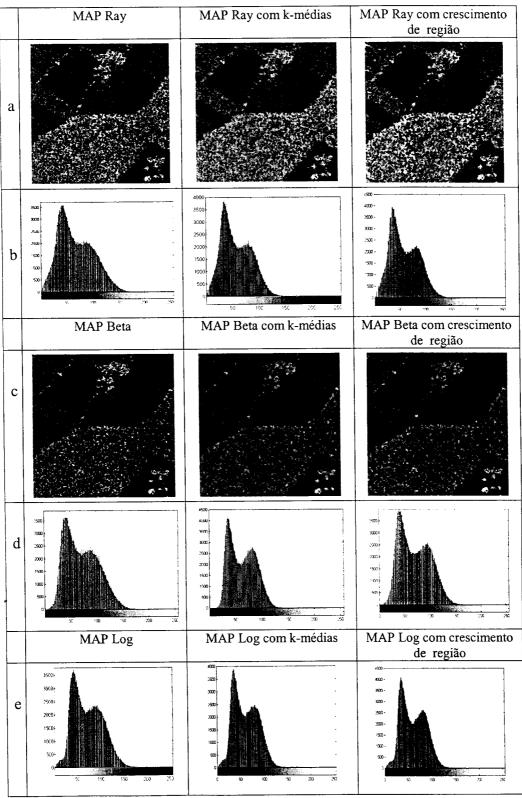


Figura F.14 – Imagens reais SAR580 filtradas pelo (a) MAP Ray e (b) seus respectivos histogramas (c) MAP Beta e (d) seus respectivos histogramas (e) histogramas das imagens filtradas pelo MAP Log.

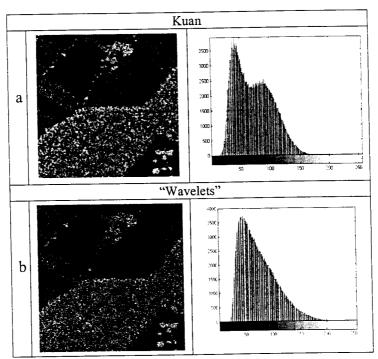


Figura F.15 – Imagem real SAR filtrada pelo (a) Kuan e seu respectivo histograma (b)"wavelets" e seu respectivo histograma.

F.3 Imagem Artificialmente Contaminada por "Speckle" em Amplitude e Múltiplas Visadas

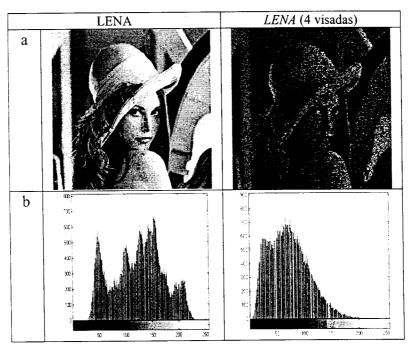


Figura F.16 – (a) Imagens original e ruidosa e (b) seus respectivos histogramas.

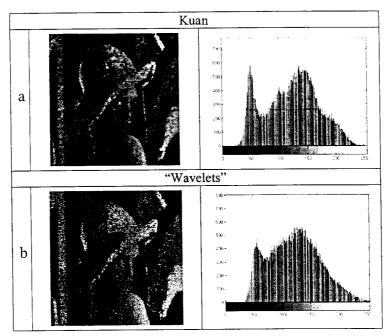


Figura F.17 – Imagem *LENA* filtrada pelo (a) Kuan e seu respectivo histograma (b) "wavelets" e seu respectivo histograma.

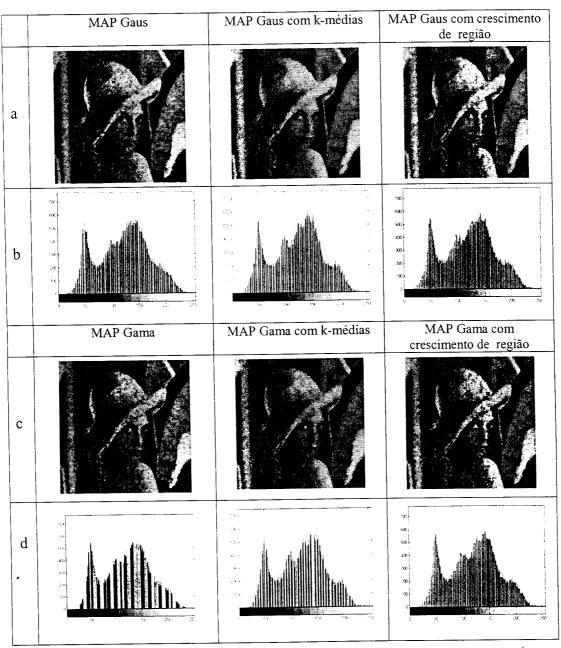
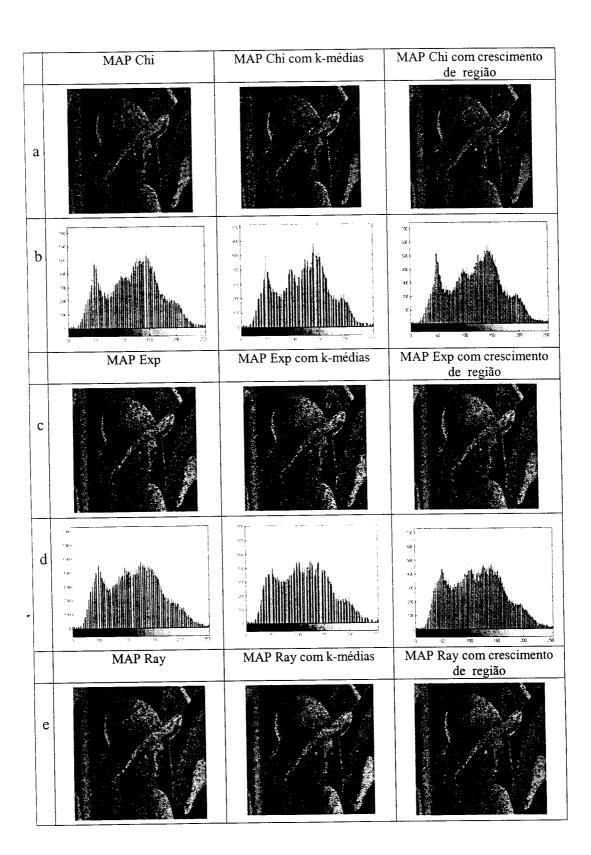


Figura F.18 – Imagem *LENA* filtrada pelo (a) MAP Gaus e (b) seus respectivos histogramas (c) MAP Gama e (d) seus respectivos histogramas.



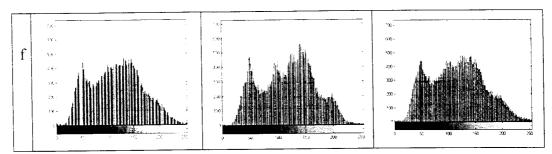


Figura F.19 – Imagem *LENA* filtrada pelo (a) MAP Chi e (b) seus respectivos histogramas (c) MAP Exp e (d) seus respectivos histogramas (e) MAP Ray e (f) respectivos histogramas.

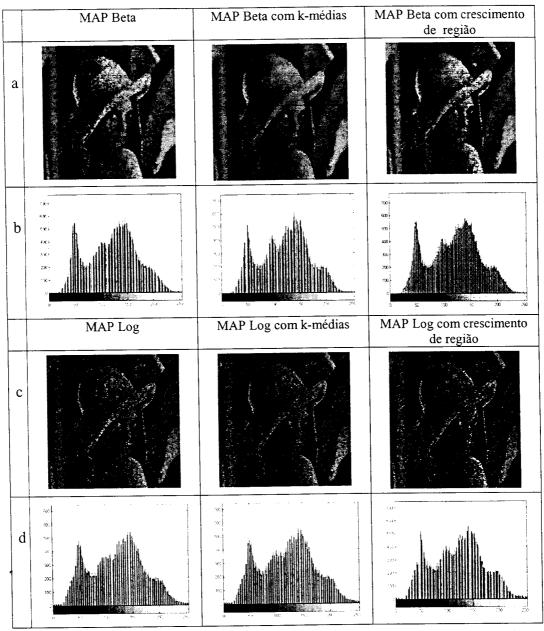


Figura F.20 – Imagem *LENA* filtrada pelo (a) MAP Beta e (b) seus respectivos histogramas (c) MAP Log e (d) seus respectivos histogramas.

F.4 Imagens SAR Reais em Amplitude e Múltiplas Visadas

As imagens reais SAR em amplitude e múltiplas visadas utilizadas para teste dos filtros propostos nesta tese e apresentadas na **Figura F.21a** são as seguintes:

- i) A imagem *JERS481* é uma parte da imagem de 3 visadas sobre a Floresta Nacional de Tapajós, Pará, Brasil, obtida em 26 de junho de 1993 pelo satélite JERS-
- ii) A imagem *ZONE* obtida por detecção linear pelo ERS-1 apresenta 3 visadas teóricas e é parte de uma imagem captada sobre uma região rural plana na Holanda. Esta imagem apresenta estruturas lineares como estradas e canais.

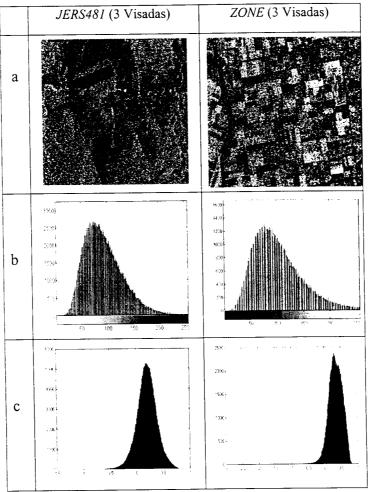


Figura F.21 –Imagens reais SAR em amplitude e com múltiplas visadas (a) versões ruidosas das imagens *JERS481* e *ZONE* (b) seus respectivos histogramas (c) seus respectivos histogramas da razão de variâncias *R*.

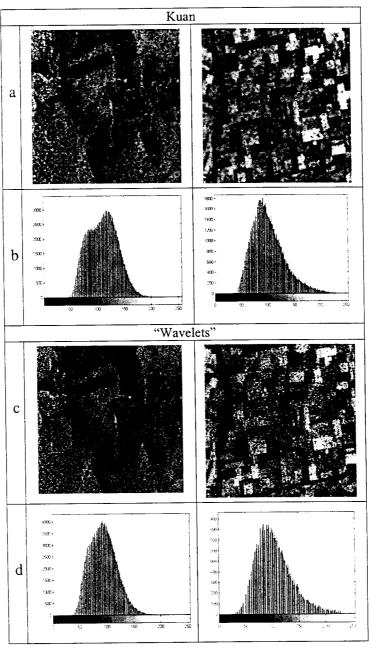


Figura F.22 – Imagens reais SAR filtradas pelo (a) Kuan e (b) seus respectivos histogramas (c) "wavelets" e (d) seus respectivos histogramas.

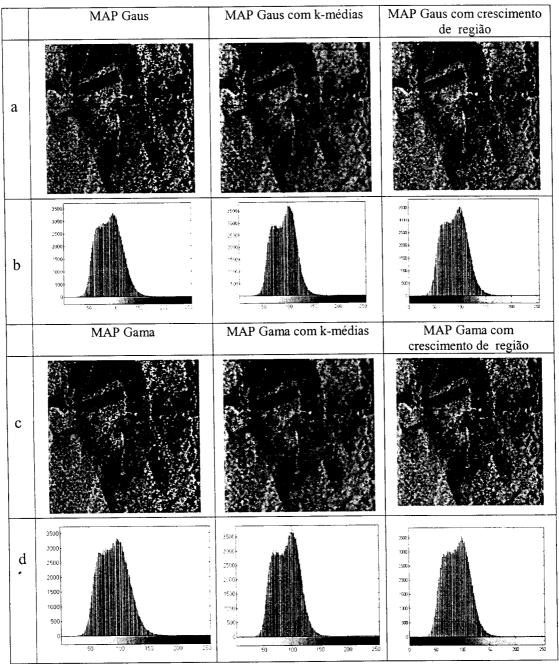


Figura F.23 – Imagem *JERS481* filtrada pelo (a) MAP Gaus e (b) seus respectivos histogramas (c) MAP Gama e (d) seus respectivos histogramas.

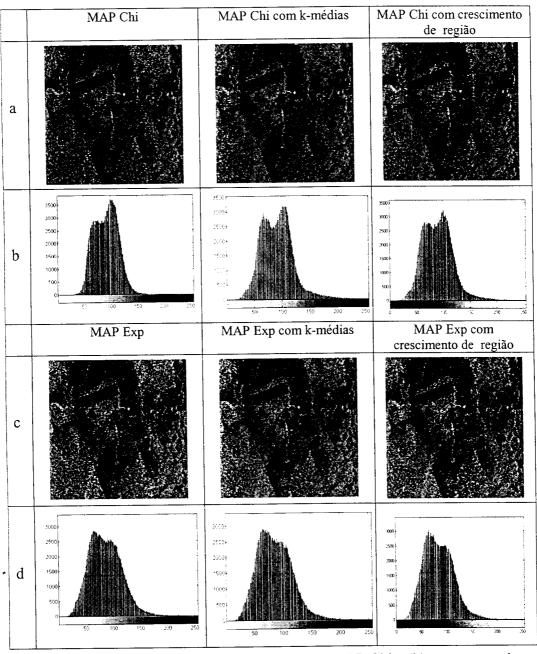


Figura F.24 – Imagem *JERS481* filtrada pelo (a) MAP Chi e (b) seus respectivos histogramas (c) MAP Exp e (d) seus respectivos histogramas.

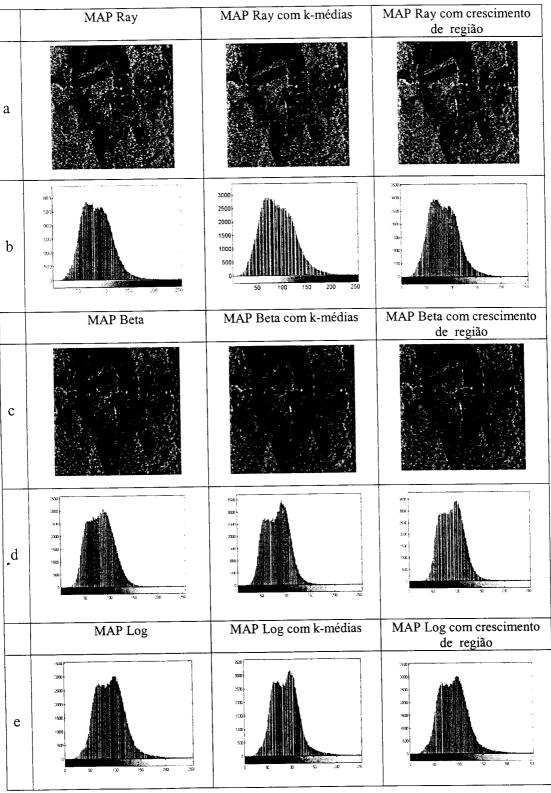


Figura F.25 – Imagem reais *JERS481* filtrada pelos (a) MAP Ray e (b) seus respectivos histogramas (c) MAP Beta e (d) seus respectivos histogramas (e) histogramas das imagens filtradas pelo MAP Log.

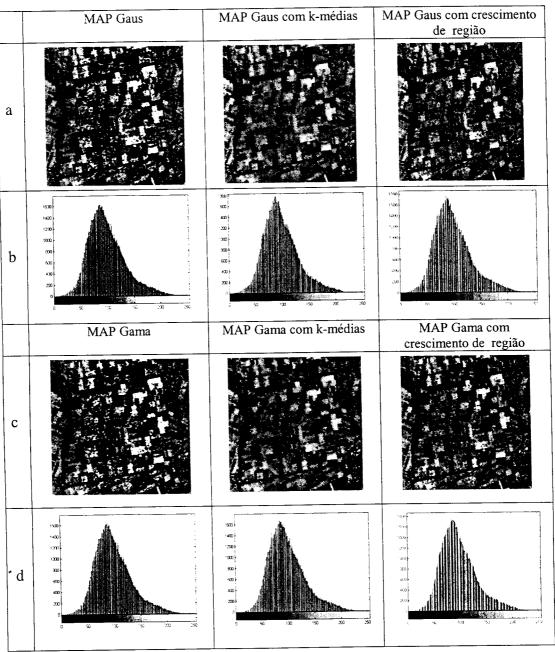


Figura F.26 – Imagem *ZONE* filtrada pelo (a) MAP Gaus e (b) seus respectivos histogramas (c) MAP Gama e (d) seus respectivos histogramas.

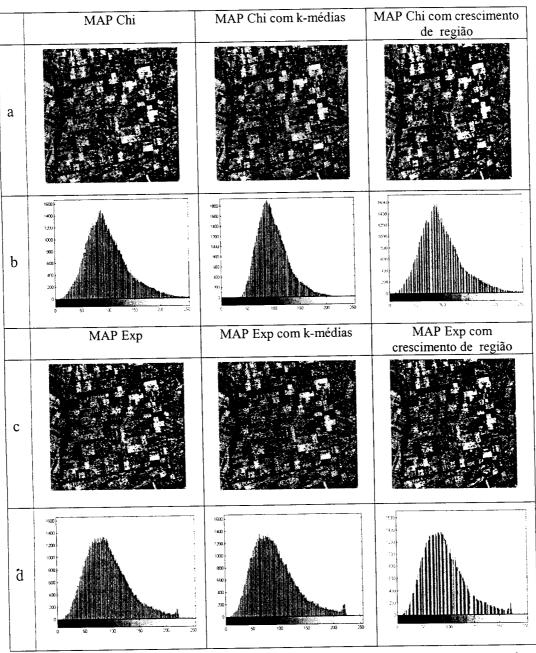


Figura F.27 – Imagem *ZONE* filtrada pelo (a) MAP Chi e (b) seus respectivos histogramas (c) MAP Exp e (d) seus respectivos histogramas.

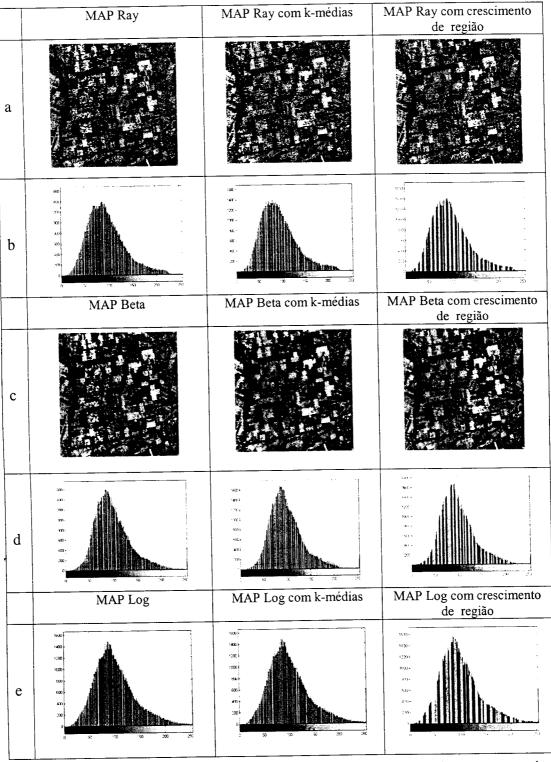


Figura F.28 – Imagem reais *ZONE* filtrada pelos (a) MAP Ray e (b) seus respectivos histogramas (c) MAP Beta e (d) seus respectivos histogramas (e) histogramas das imagens filtradas pelo MAP Log.