



Ministério da
**Ciência, Tecnologia
e Inovação**



sid.inpe.br/mtc-m19/2013/02.20.16.22-TDI

**CLASSIFICAÇÃO DE REGIÕES DE IMAGENS
UTILIZANDO TESTES DE HIPÓTESE BASEADOS EM
DISTÂNCIAS ESTOCÁSTICAS: APLICAÇÕES A
DADOS POLARIMÉTRICOS**

Wagner Barreto da Silva

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Corina da Costa Freitas, e Alejandro César Frery, aprovada em 06 de março de 2013.

URL do documento original:

<<http://urlib.net/8JMKD3MGP7W/3DJMB48>>

INPE
São José dos Campos
2013

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

Fax: (012) 3208-6919

E-mail: pubtc@sid.inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE (RE/DIR-204):

Presidente:

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Membros:

Dr. Antonio Fernando Bertachini de Almeida Prado - Coordenação Engenharia e Tecnologia Espacial (ETE)

Dr^a Inez Staciarini Batista - Coordenação Ciências Espaciais e Atmosféricas (CEA)

Dr. Gerald Jean Francis Banon - Coordenação Observação da Terra (OBT)

Dr. Germano de Souza Kienbaum - Centro de Tecnologias Especiais (CTE)

Dr. Manoel Alonso Gan - Centro de Previsão de Tempo e Estudos Climáticos (CPT)

Dr^a Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação

Dr. Plínio Carlos Alvalá - Centro de Ciência do Sistema Terrestre (CST)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon - Coordenação de Observação da Terra (OBT)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Yolanda Ribeiro da Silva Souza - Serviço de Informação e Documentação (SID)

EDITORAÇÃO ELETRÔNICA:

Maria Tereza Smith de Brito - Serviço de Informação e Documentação (SID)

Luciana Manacero - Serviço de Informação e Documentação (SID)



Ministério da
**Ciência, Tecnologia
e Inovação**



sid.inpe.br/mtc-m19/2013/02.20.16.22-TDI

**CLASSIFICAÇÃO DE REGIÕES DE IMAGENS
UTILIZANDO TESTES DE HIPÓTESE BASEADOS EM
DISTÂNCIAS ESTOCÁSTICAS: APLICAÇÕES A
DADOS POLARIMÉTRICOS**

Wagner Barreto da Silva

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Corina da Costa Freitas, e Alejandro César Frery, aprovada em 06 de março de 2013.

URL do documento original:

<<http://urlib.net/8JMKD3MGP7W/3DJMB48>>

INPE
São José dos Campos
2013

Dados Internacionais de Catalogação na Publicação (CIP)

Si38c Silva, Wagner Barreto da.
Classificação de regiões de imagens utilizando testes de hipótese baseados em distâncias estocásticas: aplicações a dados polarimétricos / Wagner Barreto da Silva. – São José dos Campos : INPE, 2013.
xxii + 143 p. ; (sid.inpe.br/mtc-m19/2013/02.20.16.22-TDI)

Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013.
Orientadores : Drs. Corina da Costa Freitas, e Alejandro César Frery.

1. classificação por regiões 2. distâncias estocásticas 3. testes de hipótese 4. polarimetria.. I.Título.

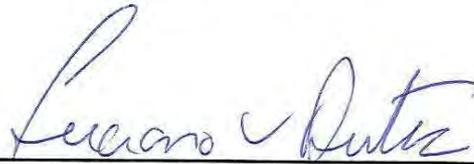
CDU 528.854

Copyright © 2013 do MCT/INPE. Nenhuma parte desta publicação pode ser reproduzida, armazenada em um sistema de recuperação, ou transmitida sob qualquer forma ou por qualquer meio, eletrônico, mecânico, fotográfico, reprográfico, de microfilmagem ou outros, sem a permissão escrita do INPE, com exceção de qualquer material fornecido especificamente com o propósito de ser entrado e executado num sistema computacional, para o uso exclusivo do leitor da obra.

Copyright © 2013 by MCT/INPE. No part of this publication may be reproduced, stored in a retrieval system, or transmitted in any form or by any means, electronic, mechanical, photocopying, recording, microfilming, or otherwise, without written permission from INPE, with the exception of any material supplied specifically for the purpose of being entered and executed on a computer system, for exclusive use of the reader of the work.

Aprovado (a) pela Banca Examinadora
em cumprimento ao requisito exigido para
obtenção do Título de **Doutor(a)** em
Sensoriamento Remoto

Dr. Luciano Vieira Dutra



Presidente / INPE / SJC Campos - SP

Dra. Corina da Costa Freitas



Orientador(a) / INPE / SJC Campos - SP

Dr. Alejandro Cesar Frery Orgambide



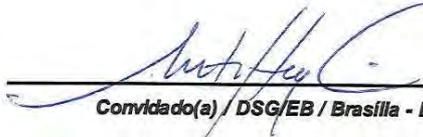
Orientador(a) / UFAL / Maceló - AL

Dr. Sidnei João Siqueira Sant'Anna



Membro da Banca / INPE / São José dos Campos - SP

Dr. Antônio Henrique Correia



Convidado(a) / DSG/EB / Brasília - DF

Dr. Abraão David Costa do Nascimento



Convidado(a) / UFPE / Pernambuco - PE

Este trabalho foi aprovado por:

maioria simples

unanimidade

Aluno (a): **Wagner Barreto da Silva**

São José dos Campos, 06 de Março de 2013

*“You can do a lot in a lifetime
If you don’t burn out too fast
You can make the most of the distance
First you need endurance -
First you’ve got to last...”*

NEIL PEART
em “Marathon”, 1985

*Dedico a minha amada esposa, Kelly, a meus filhos, Raphael, João Pedro e Maria
Clara, e a meu pai José Luiz.*

AGRADECIMENTOS

À Dra. Corina da Costa Freitas, do INPE, pela orientação extremamente segura e profissional, pelos ensinamentos, amizade, paciência e generosidade ao estar sempre disponível a me passar o conhecimento.

Ao Dr. Alejandro César Frery, da UFAL, pela orientação, didática, disponibilidade em prontamente me ajudar quando solicitado e pela experiência no campo da pesquisa científica.

Ao Dr. Sidnei João Siqueira Sant'Anna, do INPE, pela ajuda no transcorrer do desenvolvimento da tese, com críticas e sugestões que auxiliaram a melhorar a qualidade do trabalho e pela inestimável ajuda na implementação em IDL.

Ao Dr. Luciano Vieira Dutra, pelas sugestões e ajuda.

Ao Dr. Abraão David da Costa Nascimento, pelo conhecimento passado por meio de inúmeras discussões, ao longo do desenvolvimento do trabalho, sobre a utilização das distâncias estocásticas e dos testes de hipótese associados.

Ao Dr. Antônio Henrique Correia, pelo exemplo de determinação e compromisso com o trabalho, pela amizade e pelo apoio prestado.

Ao Instituto Nacional de Pesquisas Espaciais, pela oportunidade de realização da tese de doutorado.

À Diretoria de Serviço Geográfico (DSG) por conceder-me uma grande oportunidade de aprimoramento técnico-científico e profissional, por intermédio da realização do doutorado em sensoriamento remoto no INPE.

A Rogério Galante Negri, pela amizade e pelo auxílio no desenvolvimento do trabalho, especialmente na implementação em IDL.

A Carlos Alberto Pires de Castro Filho, pela amizade e pelo apoio “logístico” em São José dos Campos.

Aos amigos da “senzala” e da turma 2008 de pós-graduação em Sensoriamento Remoto.

Aos integrantes da Seção de Engenharia Cartográfica do Instituto Militar de Enge-

nharia (IME), pelo apoio na etapa final do trabalho.

A minha amada esposa, Kelly, pelo amor incondicional, paciência e segurança.

A meu pai, pelo constante incentivo ao estudo e ao aprimoramento intelectual.

RESUMO

Este trabalho tem por objetivo a proposição, desenvolvimento e avaliação de um classificador por regiões com base em distâncias estocásticas e seus testes de hipótese associados. O classificador é organizado em três módulos, divididos segundo a modelagem estatística e o tipo de imagem para a qual o módulo é destinado. O primeiro módulo destina-se à classificação de imagens de radar de abertura sintética polarimétrico (PolSAR) e adota a distribuição de Wishart complexa escalonada para modelagem das matrizes de covariância; o segundo módulo, o qual se destina à classificação de pares de imagens SAR em intensidade *multi-look*, adota a distribuição Par de Intensidades *multi-look*, desenvolvida por Lee et al. (1994a); o terceiro módulo, que se destina à classificação de imagens SAR multivariadas em amplitude e imagens de sensores óticos, utiliza a distribuição gaussiana multivariada. Foram utilizadas distâncias estocásticas disponíveis na literatura, específicas para cada módulo, obtidas segundo o procedimento formal da família de divergências $h-\phi$, desenvolvido por Salicru et al. (1994). A partir das expressões para as distâncias, foram desenvolvidas expressões para as estatísticas de teste a serem utilizadas na classificação. Ao final do processo de classificação, são gerados a imagem classificada e um mapa indicativo que mostra os segmentos para os quais a hipótese nula do teste não foi rejeitada ao nível de significância de 5%. Com a utilização de dados simulados com autocorrelação espacial, foi verificada a alta influência da autocorrelação no desempenho do teste. Com a finalidade de avaliar o classificador, aplicações foram feitas segundo duas abordagens. Na primeira, com dados simulados segundo a distribuição de Wishart complexa escalonada com 4 visadas. Para a maioria das distâncias disponíveis entre distribuições Wishart: Bhattacharyya, Kullback-Leibler, Hellinger e Rényi de ordem β , os resultados de classificação foram idênticos entre si e muito próximos do esperado teoricamente. Aplicações em dados simulados em amplitude multivariada e em pares de intensidade alcançaram resultados de classificação e de taxas de rejeição do teste de hipótese ligeiramente inferiores aos dos dados PolSAR, mas ainda próximos do esperado. Na segunda abordagem, o classificador foi aplicado a dados PolSAR reais, em que foram utilizadas imagens polarimétricas *multi-look* (HH, HV e VV) da missão SIR-C/X-SAR, nas bandas L e C. Os resultados de classificação foram avaliados a partir dos valores da acurácia global e do coeficiente de concordância *kappa* ($\hat{\kappa}$). Esses resultados de classificação, de modo geral, foram considerados excelentes para a banda L, com valores de $\hat{\kappa}$ maiores do que 0,82, e muito bons para a banda C, com valores de $\hat{\kappa}$ maiores do que 0,70. Os resultados com os dados SAR em amplitude multivariada e pares de imagens SAR em intensidade mostraram-se valiosos pela possibilidade da indisponibilidade de dados PolSAR. Os resultados de classificação de dados PolSAR reais, dos dois conjuntos de dados, foram comparados com resultados obtidos por um classificador pontual/contextual, que utiliza o algoritmo *Iterated Conditional Modes* (ICM) (CORREIA, 1998). Desta

comparação pôde-se observar que a classificação por regiões supera significativamente a contextual, em ambos os casos. No caso da banda L, o classificador por regiões superou o pontual/contextual em aproximadamente 4% e no caso da banda C, em aproximadamente 20%.

CLASSIFICATION OF IMAGE REGIONS USING HYPOTHESIS TESTS BASED ON STOCHASTIC DISTANCES: APPLICATIONS TO POLARIMETRIC DATA

ABSTRACT

This work aims at the proposal, developing and evaluation of a region based classifier based on stochastic distances and hypothesis tests. The classifier is organized into three modules, divided according to the assumed statistical model and to the image type used. The first module is intended to the polarimetric synthetic aperture radar (PolSAR) data classification and assumes the scaled complex Wishart distribution for covariance matrices modeling; the second one, which is intended to the classification of SAR images pairs in intensity, assumes the *multi-look* Intensity-Pair distribution developed by Lee et al. (1994a); the third one, which is intended to the classification of multivariate SAR images in amplitude and images from optical sensors, assumes a multivariate Gaussian model. Stochastic distances available in the literature were applied. Such distances were obtained according to the h - ϕ class of divergences proposed by Salicru et al. (1994). From the applied distances, expressions for the test statistics to be used in classification were developed. At the end of the classification process, the classified image and an indicative map which shows the segments for which the null hypothesis was not rejected at the significance level of 5% are obtained. Using simulated data with spatial correlation, was verified the high influence of such contamination on the hypothesis test performance. Aiming at the classifier evaluation, applications were conducted under two approaches. In the first one, with complex scaled Wishart simulated data with 4 looks. For most distances between Wishart distribution: Bhattacharyya, Kullback-Leibler, Hellinger and Rényi of order β , the classification results were identical and very close to the theoretically expected value. Applications to simulated data in multivariate amplitude format and intensity pairs with use of the Bhattacharyya distance between appropriate distributions achieved classification results and null hypothesis rejection rates slightly lower than the data PolSAR data results, but still close to theoretical expectations. In the second approach, the classifier was applied to real PolSAR data, when polarimetric *multi-look* images (HH, HV and VV), bands L and C, were used. The classification results were evaluated using the overall accuracy and *kappa* ($\hat{\kappa}$) coefficient of agreement. These classification results, in general, were considered excellent for the L band data, with $\hat{\kappa}$ greater than 0,82, and very good for C band data, with $\hat{\kappa}$ greater than 0,70. The multivariate amplitude SAR data results and intensity pair data results were valuable considering of the real possibility of data PolSAR absence in practical situations. The classification results of real PolSAR data, from the two data set, were compared with results obtained by a punctual/contextual approach classifier which uses a *Iterated Conditional Modes* (ICM) (CORREIA, 1998) algorithm. From this analysis, we observed that the region based classification significantly outperforms the contextual classification. In the L band case, the region based classifier outperformed the punctual/contextual approximately in 4% and in the C band case, in approximately in 20%.

LISTA DE FIGURAS

	<u>Pág.</u>
2.1 Classificação por regiões e pontual.	32
3.1 Interface gráfica do classificador por regiões	40
3.2 Imagem PolSAR e exemplos de produtos gerados pelo classificador - exemplos.	43
3.3 Classificador por regiões: módulo para imagens PolSAR	44
3.4 Regiões modeladas por distribuições <i>Par de Intensidades Multilook</i>	48
3.5 Classificador por regiões: módulo para pares de imagens em intensidade.	51
3.6 Classificador por regiões: módulo para imagens óticas e SAR em amplitude.	52
4.1 Correlação espacial unidimensional em função do <i>lag</i> para diferentes va- lores de α	57
4.2 Composição colorida com componentes de intensidade SIR-C, banda L e C (HH(R), HV(G), VV(B)).	69
4.3 Composição colorida com componentes de intensidade SIR-C, banda L, (HH(R), HV(G), VV(B)) e localização das amostras de treinamento e teste.	70
4.4 Imagem simulada: composição colorida das componentes em amplitude - HH(R), HV(G), VV(B).	76
4.5 Imagens segmentadas com diferentes tamanhos de segmentos: (a) 5×5 pixels, (b) 10×10 pixels, (c) 15×15 pixels e (d) 30×30 pixels	78
4.6 Amostras de treinamento 30×30 para classificação	79
4.7 Resultados de classificação - Modelo Wishart (PolSAR) com segmentos de tamanho 5×5 pixels.	81
4.8 Resultados de classificação - Modelo Gaussianao com segmentos de ta- manho 5×5 pixels.	82
4.9 Mapas binários de estimativas de p -valor para classificações das imagens simuladas, distâncias de Bhattacharyya, Kullback-Leibler e Hellinger - segmentos em branco tem hipótese nula não rejeitada ($p \geq 0,05$).	83
4.10 Mapas binários de estimativas de p -valor para classificações das imagens simuladas, distâncias de Rényi de ordem β , χ^2 e Bhattacharyya gaussiana - segmentos em branco tem hipótese nula não rejeitada ($p \geq 0,05$).	84
4.11 Imagens SAR simuladas em intensidade.	85

4.12	Classificações dos pares de imagem SAR em intensidade com distância de Bhattacharyya (solução numérica), por tamanho de segmento.	87
4.13	Mapas binários de p -valores para classificações dos pares de imagens SAR em intensidade, HH,HV; HH,VV; HV,VV - segmentos em branco tem hipótese nula aceita ($p \geq 0.05$).	88
4.14	Segmentação da imagem PolSAR SIR-C, banda L.	90
4.15	Resultados de classificação utilizando distâncias entre distribuições Wishart	93
4.16	Resultados de classificação utilizando distâncias entre distribuições gaussianas multivariadas e entre distribuições Par de intensidades <i>multi-look</i> .	94
4.17	Mapas binários de p -valores para classificações da imagem SIR-C banda L - distâncias entre distribuições Wishart - segmentos em branco tem hipótese nula não rejeitada ($p \geq 0,05$).	99
4.18	Mapas binários de p -valores para classificações da imagem SIR-C banda L - distâncias entre distribuições gaussianas multivariadas e entre distribuições Par de intensidades <i>multi-look</i> - segmentos em branco tem hipótese nula não rejeitada ($p \geq 0,05$).	100
4.19	Matriz de confusão - Distância de Bhattacharyya - Wishart.	102
4.20	Matriz de confusão - Classificador ICM - Modelagem Wishart.	103
4.21	Matriz de confusão - Distância de Bhattacharyya - Gaussiana.	104
4.22	Matriz de confusão - Distância de Bhattacharyya - Par de intensidades HVVV.	105
4.23	Resultados de classificação utilizando distâncias entre distribuições Wishart	107
4.24	Resultados de classificação utilizando distâncias entre distribuições gaussianas multivariadas e entre distribuições Par de intensidades <i>multi-look</i> .	108
4.25	Classe Soja 2 nas classificações por regiões dos dados PolSAR utilizando distância de Bhattacharyya entre distribuições Wishart. Amostras de teste são superpostas: (a) banda C e (b) banda L	111
4.26	Mapas binários de p -valores para classificações da imagem SIR-C banda C - distâncias entre distribuições Wishart - segmentos em branco tem hipótese nula não rejeitada ($p \geq 0,05$).	113
4.27	Mapas binários de p -valores para classificações da imagem SIR-C banda C - distâncias entre distribuições gaussianas multivariadas e entre distribuições Par de intensidades <i>multi-look</i> - segmentos em branco tem hipótese nula não rejeitada ($p \geq 0,05$).	114
A.1	Criação do projeto IDL.	133
A.2	Lista de projetos IDL.	134

A.3	Janela de importação do projeto.	135
A.4	janela de importação dos arquivos a partir do sistema de arquivos.	136
A.5	Escolha das imagens de entrada e saída na geração da matriz de covariância.	138
A.6	Reamostragem em linha e coluna (processamento <i>multi-look</i>).	139
A.7	139
A.8	Classificador por regiões: módulo para imagens PolSAR.	140
A.9	Descrição das informações para classificação.	141
A.10	Classificador por regiões: módulo para pares de imagens em intensidade.	142
A.11	Classificador por regiões: módulo para imagens óticas e imagens SAR multivariadas em amplitude.	143

LISTA DE TABELAS

	<u>Pág.</u>
2.1 Distâncias h - ϕ e funções h e ϕ correspondentes (NASCIMENTO et al., 2010; NASCIMENTO, 2012)	27
2.2 Matriz de Confusão.	35
2.3 Níveis do coeficiente $kappa(\kappa)$ associados a diferentes termos qualitativos.	36
3.1 Módulos do classificador por regiões.	39
4.1 Parâmetros dos modelos gaussianos simulados.	59
4.2 Resultados do experimento ($\alpha = 1$ e 2).	61
4.3 Resultados do experimento ($\alpha = 3$ e 4).	62
4.4 Resultados do experimento ($\alpha = 5$ e 6).	63
4.5 Tamanho do teste com correlações baixas entre as variáveis.	65
4.6 Tamanho do teste com correlações diversas entre as variáveis.	66
4.7 Tamanho do teste com correlações altas entre as variáveis.	67
4.8 Informações da imagem PolSAR SIR-C e da área de estudo	69
4.9 Descrição das amostras de treinamento e teste.	71
4.10 Valores de determinante e traço das matrizes de covariância estimadas.	74
4.11 Resultados de distâncias de Hellinger entre as matrizes de covariância amostrais das classes.	75
4.12 Porcentagem de segmentos cuja hipótese H_0 não foi rejeitada ao nível de significância de 5 %, para o caso dos dados simulados (PolSAR e amplitude).	82
4.13 Valores de acurácia global para classificações dos pares de intensidade utilizando distância de Bhattacharyya.	86
4.14 Porcentagem de segmentos cuja hipótese H_0 não foi rejeitada ao nível de significância de 5 %, para o caso dos dados simulados (pares de intensidade).	86
4.15 Resultados de classificação por regiões para a imagem PolSAR SIR-C banda L, imagem amplitude multivariada, pares de intensidade e classificação pontual MaxVer/ICM.	92
4.16 Resultados de teste de igualdade entre matrizes de confusão - Banda L. Parte triangular superior: p -valores - Parte triangular inferior: estatísticas Z	96
4.17 Porcentagem de segmentos da imagem SIR-C banda L que não tiveram a hipótese H_0 rejeitada ao nível de significância 5 %.	98

4.18	Resultados de classificação por regiões para a imagem PolSAR SIR-C banda C, imagem amplitude multivariada, pares de intensidade e classificação pontual MaxVer/ICM.	106
4.19	Resultados de teste de igualdade entre matrizes de confusão - Banda C. Parte triangular superior: p -valores - Parte triangular inferior: estatísticas Z	110
4.20	Porcentagem de segmentos da imagem SIR-C banda C que não tiveram a hipótese H_0 rejeitada ao nível de significância 5%.	115

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Contextualização	1
1.2 Motivação	2
1.3 Hipótese	4
1.4 Objetivos	4
1.4.1 Objetivo geral	4
1.4.2 Objetivos específicos	4
1.5 Organização do trabalho	4
1.6 Contribuição da tese	5
1.6.1 Conteúdo	5
1.6.2 Produção bibliográfica	6
2 REVISÃO BIBLIOGRÁFICA E FUNDAMENTAÇÃO TEÓRICA 9	9
2.1 Representação e Modelagem Estatística de Dados SAR Polarimétricos . .	9
2.1.1 Representação dos dados PolSAR	9
2.1.2 Modelagem estatística dos dados	13
2.1.2.1 Distribuição Wishart Complexa Escalonada	14
2.1.2.2 Distribuição para o Par de Intensidades <i>Multi-look</i>	17
2.1.2.3 Distribuição Gaussiana Multivariada	20
2.2 Divergências e Distâncias Estocásticas	21
2.3 Testes de Hipótese com Base na Classe h - ϕ de Distâncias	28
2.4 Classificação por Regiões	30
2.5 Avaliação da Classificação	34
3 CLASSIFICADOR POR REGIÕES DESENVOLVIDO	39
3.1 Introdução	39
3.2 Módulo para Imagens Polarimétricas	43
3.3 Módulo para Pares de Imagens em Intensidade	46
3.4 Módulo para Imagens Óticas e Imagens SAR Multivariadas em Amplitude	51
3.5 Comentários Complementares Sobre a Contribuição do Classificador por Regiões	53

4	APLICAÇÕES E AVALIAÇÃO DO CLASSIFICADOR	55
4.1	Avaliação da Influência da Autocorrelação Espacial no Desempenho do Teste de Hipóteses $h-\phi$	55
4.1.1	Autocorrelação espacial	55
4.1.2	Descrição do Experimento e Resultados	56
4.2	Aplicação do Classificador por Regiões	68
4.2.1	Descrição dos dados PolSAR	68
4.2.1.1	Descrição dos dados reais	68
4.2.1.2	Descrição dos dados simulados	71
4.2.2	Aplicação em dados PolSAR Simulados	77
4.2.3	Aplicação em dados PolSAR SIR-C reais	89
4.2.3.1	Resultados obtidos com os dados PolSAR da banda L	91
4.2.3.2	Resultados obtidos com os dados PolSAR da banda C	106
5	CONCLUSÕES E SUGESTÕES	117
5.1	Conclusões	118
5.2	Sugestões	123
	REFERÊNCIAS BIBLIOGRÁFICAS	125
	APÊNDICE A - CLASSIFICADOR POR REGIÕES COM BASE EM DISTÂNCIAS ESTOCÁSTICAS E TESTES DE HIPÓTESE - GUIA DE UTILIZAÇÃO	133
A.1	Classificador por Regiões - Instalação	133
A.1.1	Criação do projeto	133
A.1.2	Importação dos arquivos do projeto	134
A.2	Classificador por Regiões - Utilização	136
A.2.1	Descrição do classificador	136
A.2.2	Geração do arquivo de imagem polarimétrica no formato de matriz de covariância	137
A.2.3	Utilização do classificador	138
A.2.3.1	Módulo polarimétrico (imagens no formato matriz de covariância)	139
A.2.3.2	Módulo par de imagens em intensidade	140
A.2.3.3	Módulo imagens óticas	140
A.2.3.4	Produtos gerados pelo classificador	141

1 INTRODUÇÃO

1.1 Contextualização

As imagens geradas por radares de abertura sintética (SAR) consolidam-se atualmente como uma importante alternativa à extração de informações sobre a superfície terrestre, com aplicações diversificadas. A maior disponibilidade de sensores SAR traz grandes possibilidades de utilização das suas imagens nas atividades de Sensoriamento Remoto. Em contrapartida, uma consequência inevitável é a necessidade do desenvolvimento de ferramentas mais avançadas visando à plena utilização dos novos dados.

A capacidade de geração de imagens polarimétricas (PolSAR) mostra-se como uma das mais relevantes funcionalidades dos sensores SAR. Esta capacidade fornece ao usuário de Sensoriamento Remoto a possibilidade de uma melhor identificação dos alvos terrestres, pela combinação das imagens obtidas nas diferentes polarizações disponíveis. Considerando a classificação digital de imagens, cada imagem correspondendo a uma configuração de polarizações transmitida e recebida é utilizada como um atributo, assemelhando-se ao caso em que há imagens correspondentes a diferentes intervalos de frequência, situação comum em sensores ópticos.

A pesquisa relativa à modelagem estatística de dados SAR e PolSAR alcançou um significativo desenvolvimento, tanto para dados univariados quanto multivariados. Em [Frery et al. \(1997\)](#), [Lee et al. \(1994\)](#), [Freitas et al. \(2005\)](#) e [Gao \(2010\)](#), identifica-se grande parte desse esforço, no estudo e desenvolvimento de modelos estatísticos para dados com ruído *speckle*, nas diversas formas de aquisição.

A classificação digital de imagens representa uma das mais importantes etapas do processamento de imagens obtidas pelo Sensoriamento Remoto. Diversos trabalhos vêm sendo desenvolvidos há vários anos na implementação de classificadores digitais apropriados às características específicas das imagens SAR. No que diz respeito sobretudo à utilização dos dados PolSAR, este desenvolvimento vem avançando em duas grandes frentes: classificadores por decomposição de alvos ([CLOUDE; POTTIER, 1997](#); [LEE et al., 1999](#); [LEE; POTTIER, 2009](#)) e classificadores por modelagem estatística dos dados SAR ([MEJAIL et al., 2003](#); [LEE; GRUNES, 1992](#); [FRERY et al., 2007](#)). Os classificadores de imagens SAR apresentados na literatura utilizam normalmente a abordagem pontual, também denominada “por pixel”. Um classificador por modela-

gem estatística para imagens SAR e PolSAR, que não se limita a resolver o problema utilizando apenas a informação de cada elemento de imagem (pixel) separadamente, mas procura também aproveitar a informação do contexto foi desenvolvido por [Correia \(1998\)](#) e utilizado por [Correia et al. \(1998\)](#) e [Frery et al. \(2007\)](#). Este classificador funciona de forma pontual utilizando a máxima verossimilhança com distribuições específicas para as imagens SAR polarimétricas e, em sequência, aplica a técnica de Modas Condicionais Iterativas (ICM) à primeira classificação, fornecendo um tratamento contextual à classificação das imagens. Os resultados alcançados por essa abordagem mostram-se significativamente superiores aos demais classificadores pontuais, conforme mostrado por [Correia \(1998\)](#), ao comparar resultados de classificação contextual com resultados obtidos pelo método pontual da máxima verossimilhança. A abordagem contextual representa assim o estado da arte nas pesquisas com classificação por modelagem estatística.

Entretanto, a classificação das imagens SAR com a abordagem “por pixel” é fortemente influenciada pela ocorrência do ruído característico das imagens obtidas por sensores que utilizam iluminação coerente, como é o caso dos sistemas SAR. Este ruído, conhecido como *speckle*, confere às imagens um aspecto granuloso, prejudicando tanto sua interpretação visual quanto as operações digitais. Os resultados de classificação pontual de imagens SAR apresentam inevitavelmente pequenas áreas isoladas. Este problema é diminuído pela classificação contextual utilizada por [Correia \(1998\)](#) e [Frery et al. \(2007\)](#), mas não totalmente eliminado.

1.2 Motivação

Da análise da literatura referente à classificação de imagens SAR e PolSAR, verifica-se que a abordagem por regiões é ainda uma área pouco explorada. A classificação por regiões exige a utilização de imagens segmentadas, em que os pixels da imagem estejam agrupados em conjuntos homogêneos (regiões) segundo algum critério. Possivelmente, resultados melhores de classificação de dados PolSAR em relação aos atuais possam ser alcançados utilizando-se imagens segmentadas (classificação por regiões). Uma das mais clássicas abordagens empregadas na classificação por regiões utiliza distâncias estocásticas entre as distribuições estatísticas que modelam regiões pré segmentadas nas imagens e as distribuições que modelam as amostras de treinamento, representantes das classes. No caso de dados PolSAR, por exemplo, essas distâncias podem então ser definidas entre pares de distribuições Wishart complexas escalonadas. Esta modelagem estatística mostra-se adequada a dados PolSAR,

sobretudo quando as regiões da cena representada apresentam retroespalhamento homogêneo.

O desenvolvimento de distâncias entre distribuições de probabilidade (distâncias estocásticas) está estreitamente ligada à *Teoria da Informação*, ramo da matemática que envolve a quantificação da informação. Em 1948, Shannon contribuiu para definir rigorosamente a *Teoria da Informação*, com a conceituação dos termos *Informação* e *Entropia* (SHANNON, 1948). Este desenvolvimento progrediu com o desenvolvimento conceitual de outras medidas que se tornaram importantes na utilização conjunta de variáveis aleatórias como a entropia conjunta, entropia condicional, informação mútua e entropia relativa ou divergência de Kullback-Leibler (COVER; THOMAS, 1991).

Com base nos conhecimentos fixados pela *Teoria da Informação*, famílias de divergências foram desenvolvidas analiticamente. Este desenvolvimento possibilitou a obtenção de inúmeras medidas de dissimilaridade, com potencial aplicação em várias áreas do conhecimento. Dentre essas áreas, destaca-se para o escopo deste trabalho o processamento digital de imagens e especificamente a classificação de imagens. Em Csizsár (1967) é desenvolvida a família de divergências ϕ e, em uma abordagem semelhante, em Salicru et al. (1994), é desenvolvida a família de divergências $h-\phi$ e suas distribuições estatísticas assintóticas, propiciando a utilização de intervalos de confiança e testes de hipótese derivados dessas medidas.

A partir da formulação analítica da família de divergências $h-\phi$, a pesquisa evoluiu para a obtenção de medidas de dissimilaridade adequadas estatisticamente às imagens SAR utilizando modelos estatísticos diversos, e para o desenvolvimento de testes de hipótese derivados. Nascimento et al. (2010) desenvolveram distâncias estocásticas entre distribuições estatísticas \mathcal{G}_I^0 e os respectivos testes de hipótese. Cintra et al. (2011) avaliaram estes testes de hipótese conjuntamente com um teste não paramétrico, obtido a partir da distância de Kolmogorov-Smirnov. Em Frery et al. (in press), foram derivadas distâncias estocásticas para dados PolSAR modelados pela distribuição de Wishart complexa escalonada e, a partir dessas distâncias, Frery et al. (2011a) avaliaram o desempenho de testes de hipóteses para analisar similaridades e diferenças entre regiões utilizando tanto imagens reais quanto simuladas.

1.3 Hipótese

Dentro do contexto da pesquisa com as distâncias estocásticas e testes de hipótese associados, provenientes da *Teoria da Informação*, é possível a obtenção de resultados de classificação por regiões com melhores indicadores de qualidade do que os apresentados por classificadores que atualmente representam o estado da arte em classificação de imagens SAR e PolSAR por modelagem estatística.

1.4 Objetivos

1.4.1 Objetivo geral

Este trabalho tem por objetivo a proposição, desenvolvimento e teste de um classificador de segmentos de imagens SAR polarimétricas utilizando as distâncias estocásticas disponíveis e os testes de hipóteses derivados das mesmas.

1.4.2 Objetivos específicos

- Implementação do classificador de segmentos para imagens PolSAR, pares de imagens em intensidade e imagens óticas;
- Avaliação do desempenho das diversas distâncias estocásticas disponíveis e dos testes de hipótese derivados das mesmas;
- Avaliação do classificador aplicando-o em imagens SAR e óticas reais e simuladas;
- Analisar o desempenho do teste de hipótese utilizado para a classificação sob presença de autocorrelação espacial.

1.5 Organização do trabalho

Além dessa introdução, no capítulo 1, a tese está organizada da seguinte forma: No Capítulo 2, é feita uma revisão bibliográfica a respeito do estado da arte do desenvolvimento de classificadores por modelagem estatística para imagens PolSAR. Para isso, também são estudados temas teóricos como representação e modelagem estatística de dados SAR, distâncias estocásticas e testes de hipóteses derivados das distâncias, classificação por regiões e avaliação da classificação. O Capítulo 3 apresenta a descrição do classificador proposto e implementado, com suas características e funcionalidades. O Capítulo 4 apresenta um estudo sobre a influência

da presença de autocorrelação espacial nos dados sobre os testes de hipótese $h-\phi$ apresenta também os resultados de aplicações do classificador com a utilização de imagens simuladas e reais. No Capítulo 5, são desenvolvidas discussões a respeito dos resultados encontrados nas aplicações práticas do classificador, são formuladas conclusões e propostos temas ainda não abordados como sugestões para trabalhos futuros.

1.6 Contribuição da tese

1.6.1 Conteúdo

A partir dos resultados de trabalhos que utilizaram testes de hipótese advindos da família de divergências $h-\phi$ para identificação de similaridades e diferenças em imagens SAR e PolSAR (NASCIMENTO et al., 2010; CINTRA et al., 2011; FRERY et al., 2011a; NASCIMENTO, 2012; FRERY et al., in press), identificam-se relevantes possibilidades de contribuição para as áreas de Sensoriamento Remoto e Processamento de Imagens SAR, a saber:

- Proposição, desenvolvimento e implementação de um classificador por regiões para imagens SAR, utilizando a abordagem de distâncias estocásticas e de testes de hipótese derivados dessas distâncias para a classificação. Esse tipo de classificador é inédito na literatura.
- A aplicação prática de distâncias estocásticas entre modelos estocásticos apropriados às imagens SAR e PolSAR, dentre eles a distribuição Par de Intensidades *multi-look* (LEE et al., 1994a) e a distribuição de Wishart complexa multivariada escalonada. A aplicação com a distribuição gaussiana multivariada, modelo de utilização mais consolidada, é também uma possibilidade importante.
- A utilização dos testes de hipótese, derivados das distâncias, para geração de produtos indicativos espacializados (mapas) de p -valor da classificação, que fornecem informações acerca da confiança da classificação obtida.
- A utilização da estatística de teste para classificação, o que pode trazer melhores resultados quando comparada à utilização simples do valor da distância estocástica, uma vez que a estatística de teste utiliza no seu cômputo os valores de números de amostras dos segmentos e das amostras

das classes;

1.6.2 Produção bibliográfica

Com relação aos assuntos tratados na tese, alguns artigos foram publicados em anais de eventos científicos, um artigo foi submetido a periódico e foi aceito para publicação e alguns artigos estão previstos para submissão a outros periódicos. Esses artigos são relacionados a seguir:

Artigo para periódico (aceito):

SILVA, W. B.; FREITAS, C. C.; SANT'ANNA, S. J. S.; FRERY, A. C. Classification of segments in PolSAR imagery by minimum stochastic distances between Wishart distributions. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, vol. 6, no. 3, june 2013.

Artigos publicados em anais de congressos:

SILVA, W. B.; FRERY, A. C.; FREITAS, C. C.; NEGRI, R. G.; SANT'ANNA, S. J. S. Classificador por regiões de imagens SAR com base em distâncias estocásticas derivadas da densidade de probabilidade do par de intensidades multi-look. **Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, Curitiba, PR, Brasil, 30 de abril a 05 de maio de 2011, INPE. p. 8326-8333.

SILVA, W. B.; PEREIRA, L. O.; SANT'ANNA, S. J. S.; FREITAS, C. C.; GUIMARÃES, R. J. P. S.; FRERY, A. C. Land cover discrimination at Brazilian Amazon using region based classifier and stochastic distance. **2011 IEEE International Geoscience and Remote Sensing Symposium (IGARSS) Proceedings**, Vancouver, p. 2900-2903.

SILVA, W. B.; FREITAS, C. C.; SANT'ANNA, S. J. S.; FRERY, A. C. PolSAR region classifier based on stochastic distances and hypothesis tests. **2012 IEEE International Geoscience and Remote Sensing Symposium (IGARSS) Proceedings**, 2012, Munique, p. 1473-1476.

Artigos para submissão a periódicos (em produção):

SILVA, W. B.; FREITAS, C. C.; SANT'ANNA, S. J. S.; FRERY, A. C. **Spatial correlation influence in the performance of h - ϕ hypothesis tests.**

SILVA, W. B.; FREITAS, C. C.; SANT'ANNA, S. J. S.; FRERY, A. C. **Comparison of PolSAR image classification approaches using h - ϕ hypothesis tests and target decomposition.**

SILVA, W. B.; FREITAS, C. C.; SANT'ANNA, S. J. S.; FRERY, A. C. **PolSAR imagery post classification with region based approach and h - ϕ hypothesis tests.**

2 REVISÃO BIBLIOGRÁFICA E FUNDAMENTAÇÃO TEÓRICA

2.1 Representação e Modelagem Estatística de Dados SAR Polarimétricos

2.1.1 Representação dos dados PolSAR

Os dados polarimétricos podem ser representados pela matriz de espalhamento complexa, formada por componentes que contém informações sobre a radiação transmitida por uma antena SAR e retroespalhada pelos alvos nas diversas combinações de polarizações lineares. A equação (2.1) apresenta a matriz de espalhamento complexa $[\mathbf{S}]$.

$$[\mathbf{S}] = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix}. \quad (2.1)$$

Os índices subscritos dos elementos da matriz referem-se a cada par de polarizações possíveis aos sinais transmitido e recebido. Cada um dos elementos S_{pq} da matriz $[\mathbf{S}]$ é um número complexo composto pela amplitude e fase do sinal. A letra p corresponde à polarização de transmissão e a letra q à polarização de recepção da antena SAR. O termo co-polarizado é utilizado para os elementos da matriz $[\mathbf{S}]$ cujos subscritos são os mesmos (HH e VV), e o termo polarização cruzada, em inglês *cross-polarized*, é utilizado quando a polarização do sinal transmitido é diferente da referente ao sinal recebido (HV e VH). Como mencionado por [Woodhouse \(2006\)](#), um sistema de radar que mede a amplitude e a fase dos quatro termos da matriz de espalhamento é chamado de totalmente polarimétrico. A matriz de espalhamento $[\mathbf{S}]$ relaciona os vetores campo elétrico transmitido $\mathbf{E}^i(\mathbf{r})$ e recebido $\mathbf{E}^s(\mathbf{r})$ nas polarizações lineares horizontal e vertical conforme a equação (2.2).

$$\begin{bmatrix} E_H^s \\ E_V^s \end{bmatrix} = \frac{e^{-jkr}}{r} \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix} \cdot \begin{bmatrix} E_H^i \\ E_V^i \end{bmatrix}. \quad (2.2)$$

em que E_H e E_V são, respectivamente, as componentes horizontal e vertical do vetor campo elétrico, o termo $\frac{e^{-jkr}}{r}$ leva em conta os efeitos de propagação tanto em amplitude quanto em fase ([LEE; POTTIER, 2009](#)), j é a unidade imaginária, k é o número de onda e r é a distância da antena ao alvo na direção de propagação.

No contexto dos processos de observação da Terra, torna-se comum a adoção da hipótese da condição de reciprocidade. Segundo [Ulaby e Elachi \(1990\)](#), a condição de reciprocidade pode ser considerada válida para o espalhamento proveniente de partículas simples ou para um volume de muitas partículas quando nenhuma consideração sobre o meio de propagação é feita. A reciprocidade, associado à configuração de sistema SAR monoestático, onde a mesma antena alterna-se nas tarefas de emissão e recepção dos sinais eletromagnéticos, implica que a matriz de espalhamento $[\mathbf{S}]$ seja simétrica, com $S_{HV} = S_{VH}$, conforme a equação (2.3).

$$[\mathbf{S}] = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{HV} & S_{VV} \end{bmatrix}. \quad (2.3)$$

O desenvolvimento teórico das demais representações de dados polarimétricos e da modelagem estatística de dados polarimétricos será feita a partir deste ponto considerando-se a suposição de reciprocidade e sistema SAR monoestático, para fins de simplificação. A matriz de espalhamento $[\mathbf{S}]$ pode ser representada na forma vetorial, dando origem ao vetor de espalhamento \mathbf{k} . O vetor \mathbf{k} é definido pela equação (2.4):

$$\mathbf{k} = \frac{1}{2} \text{Tr}([\mathbf{S}]\Psi), \quad (2.4)$$

em que $\text{Tr}(\cdot)$ é o traço da matriz e Ψ é um conjunto de bases ortogonais matriciais complexas 2×2 .

Uma das possíveis bases ortogonais Ψ é a base linear de *Borgeaud* (lexicográfica), apresentada na equação (2.5)

$$\Psi_B = \left\{ 2 \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix}, 2 \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix}, 2 \begin{bmatrix} 0 & 0 \\ 1 & 0 \end{bmatrix}, 2 \begin{bmatrix} 0 & 0 \\ 0 & 1 \end{bmatrix} \right\}, \quad (2.5)$$

com a qual se desenvolve uma expansão lexicográfica da matriz de espalhamento $[\mathbf{S}]$, resultando no chamado vetor de espalhamento \mathbf{k}_B na representação de *Borgeaud* (lexicográfica). Para a suposição de sistema SAR monoestático e meio recíproco, o vetor de espalhamento na representação lexicográfica é descrito como ([LEE; POTTIER, 2009](#)):

$$\mathbf{k}_B = \begin{bmatrix} S_{HH} & \sqrt{2}S_{HV} & S_{VV} \end{bmatrix}^T, \quad (2.6)$$

Em que o $(\cdot)^\top$ denota a transposição do vetor ou matriz.

Uma outra possibilidade é a utilização da base de *Pauli*, apresentada na equação (2.7)

$$\Psi_P = \left\{ \sqrt{2} \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix}, \sqrt{2} \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}, \sqrt{2} \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}, \sqrt{2} \begin{bmatrix} 0 & -j \\ j & 0 \end{bmatrix} \right\}, \quad (2.7)$$

Com a suposição de reciprocidade e sistema SAR monoestático, a matriz $[\mathbf{S}]$ pode então ser expandida segundo a base de *Pauli*, gerando o vetor de espalhamento \mathbf{k}_P (LEE; POTTIER, 2009), apresentado na equação (2.8).

$$\mathbf{k}_P = \frac{1}{\sqrt{2}} \begin{bmatrix} S_{HH} + S_{VV} & S_{HH} - S_{VV} & 2S_{HV} \end{bmatrix}^\top. \quad (2.8)$$

A partir dos vetores de espalhamento nas bases ortogonais complexas de *Borgeaud* (lexicográfica) e de *Pauli*, um outro tipo de representação dos dados polarimétricos pode ser definido. Nessa nova representação, os pixels da imagem PolSAR contém, ao invés de vetores na base lexicográfica ou de *Pauli*, matrizes de covariância $[\mathbf{C}]$ e de coerência $[\mathbf{T}]$, respectivamente. De acordo com Woodhouse (2006), essas matrizes registram o inter-relacionamento estatístico entre os diferentes canais de polarização transmitidos e recebidos pela antena SAR, ao invés da informação de apenas cada canal separadamente. A matriz de covariância em cada pixel da imagem PolSAR é calculada pelo produto entre o vetor de espalhamento na base lexicográfica \mathbf{k}_B e o seu complexo conjugado transposto, denotado por \mathbf{k}_B^\dagger , como apresentada na equação (2.9).

$$\mathbf{C} = \mathbf{k}_B \mathbf{k}_B^\dagger. \quad (2.9)$$

A matriz de covariância $[\mathbf{C}]$ é hermitiana, seus elementos são formados por produtos entre os elementos complexos das matrizes de espalhamento $[\mathbf{S}]$. Os elementos de sua diagonal principal são números reais positivos e correspondem aos valores de intensidade SAR. Os elementos fora da diagonal principal são números complexos e contém, além das informações do produto entre amplitudes das componentes polarimétricas, as informações de diferença de fase entre os sinais transmitidos e recebidos nas diferentes polarizações.

Analogamente à definição da matriz de covariância, a matriz de coerência $[\mathbf{T}]$ é calculada pelo produto entre o vetor de espalhamento na base de *Pauli* \mathbf{k}_P e o seu complexo conjugado transposto \mathbf{k}_P^\dagger . A matriz de coerência é fundamental na teoria de decomposição de alvos por autovetores e autovalores. As matrizes de covariância e coerência, no caso monoestático e considerando meio recíproco, são relacionadas de acordo com a transformação mostrada pela equação (2.10)(CLOUDE; POTTIER, 1996).

$$[\mathbf{C}] = \frac{1}{2} \begin{bmatrix} 1 & 1 & 0 \\ 0 & 0 & \sqrt{2} \\ 1 & -1 & 0 \end{bmatrix} [\mathbf{T}] \begin{bmatrix} 1 & 0 & 1 \\ 1 & 0 & -1 \\ 0 & \sqrt{2} & 0 \end{bmatrix} \quad (2.10)$$

Segundo Cloude e Pottier (1996), as matrizes de covariância e de coerência são hermitianas, positivas e semi-definidas. Como a transformação apresentada em (2.10) é de similaridade e unitária, as duas matrizes têm os mesmos autovalores e seus autovetores formam um conjunto de vetores ortonormais. Essas matrizes satisfazem ainda a igualdade $\text{Tr}([\mathbf{C}]) = \text{Tr}([\mathbf{T}])$.

Nos últimos anos, verifica-se um expressivo número de trabalhos científicos publicados com a utilização da teoria de decomposição de alvos a partir da matriz de coerência $[\mathbf{T}]$. Muitos desses trabalhos tem a finalidade de desenvolvimento de classificadores para imagens PolSAR. Uma das mais proeminentes abordagens empregadas é a decomposição de alvos a partir dos autovalores e autovetores da matriz $[\mathbf{T}]$. Nesta abordagem, os dados SAR são decompostos em parâmetros polarimétricos que têm relação com os mecanismos físicos de espalhamento da radiação eletromagnética. Alguns desses importantes resultados e discussões podem ser consultados em Cloude e Pottier (1997), Lee et al. (1999), Lee e Pottier (2009).

Neste trabalho, será utilizado apenas o vetor de espalhamento na base lexicográfica (\mathbf{k}_B) e a matriz de covariância ($[\mathbf{C}]$), tendo em vista que o processo de classificação de imagens ora desenvolvido baseia-se em distâncias estocásticas derivadas analiticamente da modelagem estatística para dados SAR representados pela matriz de covariância.

Visando à diminuição do efeito causado pelo ruído *speckle*, muitas vezes são amostradas diversas estimativas independentes do retroespalhamento (LEE; POTTIER, 2009).

Este processo pode ser feito na fase de processamento inicial dos dados SAR, quando divide-se a abertura sintética inicial em aberturas menores e cada conjunto de dados é utilizado separadamente no processamento para posterior obtenção do valor médio. Outra possibilidade, já dispondo-se dos dados processados e transformados em imagens complexas, é realizar a média entre uma quantidade específica de pixels da imagem original, chamada *single-look* ou de uma visada, em intensidade, e atribuir este valor resultante ao novo pixel, que corresponderá espacialmente ao conjunto de pixels amostrados. Este processamento chama-se *multi-look* ou de múltiplas visadas. Supondo-se que sejam utilizadas L amostras estatisticamente independentes, o processamento *multi-look* degrada a resolução espacial por um fator L e reduz o desvio padrão e o coeficiente de variação do *speckle* por um fator de \sqrt{L} . As imagens originais, que não passaram pelo processamento *multi-look* são referidas como imagem *1-look* e, estando no formato complexo e guardando portanto a informação de fase, são chamadas de *single-look complex (SLC)*.

A matriz de covariância *multi-look* é denotada neste trabalho pela letra \mathbf{Z} e é obtida de acordo com a equação (2.11).

$$\mathbf{Z} = \frac{1}{L} \sum_{i=1}^L \mathbf{k}_{B_i} \mathbf{k}_{B_i}^\dagger = \frac{1}{L} \sum_{i=1}^L \begin{bmatrix} |S_{HH}|_i^2 & S_{HHi} S_{HVi}^\dagger & S_{HHi} S_{VVi}^\dagger \\ S_{HVi} S_{HHi}^\dagger & |S_{HV}|_i^2 & S_{HVi} S_{VVi}^\dagger \\ S_{VVi} S_{HHi}^\dagger & S_{VVi} S_{HVi}^\dagger & |S_{VV}|_i^2 \end{bmatrix} \quad (2.11)$$

Conforme ressaltado em [Massonnet e Souyris \(2008\)](#), a geração de imagens *multi-look* é fundamentada em somas incoerentes de amostras de imagens *SLC*, as quais reduzem o *speckle*, degradando a resolução espacial, com a consequente perda da informação de fase, dada a natureza incoerente dessas adições.

2.1.2 Modelagem estatística dos dados

Neste trabalho, a descrição da modelagem estatística terá seu enfoque nos dados SAR polarimétricos (PolSAR), tendo em vista que as distâncias utilizadas pelo classificador desenvolvido são derivadas do modelo estatístico adequado à matriz de covariância *Multi-look* $[\mathbf{Z}]$. O estudo de modelos estatísticos adequados a dados SAR univariados, tanto em intensidade quanto em amplitude, foi tema de muitos trabalhos concernentes à modelagem estatística de dados SAR. Alguns importantes exemplos podem ser encontrados nos trabalhos de [Frery et al. \(1997\)](#), [Freitas et al.](#)

(2005), Mejail et al. (2003), Oliver e Quegan (2004) e Gao (2010).

A seguir, são apresentados três modelos utilizados para dados PolSAR e SAR multivariados em situações diversificadas. A distribuição Wishart complexa escalonada, modelo utilizado para dados PolSAR, especialmente em áreas de textura homogênea; a distribuição do Par de Intensidades *Multi-look*, derivada por Lee et al. (1994a) a partir da reparametrização da densidade para a distribuição Wishart complexa escalonada e a distribuição gaussiana multivariada, útil na modelagem de diversos tipos de dados, como imagens de sensores óticos ou por imagens SAR multivariadas em amplitude com grande número de visadas.

2.1.2.1 Distribuição Wishart Complexa Escalonada

Sob determinadas condições (GOODMAN, 1963), o vetor de espalhamento na base lexicográfica (\mathbf{k}_B) de dimensão q segue uma distribuição gaussiana complexa multivariada, com média igual a zero e matriz de covariância hermitiana positiva definida $\Sigma_{\mathbf{k}_B}$. A função densidade de probabilidade associada ao vetor aleatório \mathbf{k}_B é dada pela equação (2.12).

$$f_{\mathbf{k}_B}(\mathbf{k}_B; q, \Sigma_{\mathbf{k}_B}) = \frac{1}{\pi^q |\Sigma_{\mathbf{k}_B}|} \exp \left\{ -\mathbf{k}_B^\dagger \Sigma_{\mathbf{k}_B}^{-1} \mathbf{k}_B \right\}, \quad (2.12)$$

em que $|\cdot|$ denota o determinante da matriz e $(\cdot)^{-1}$ denota a matriz inversa.

Segundo Goodman (1963), a matriz de covariância amostral dada pela equação (2.13), com base em uma amostra aleatória de tamanho N , é o estimador de máxima verossimilhança para o parâmetro $\Sigma_{\mathbf{k}_B}$.

$$\hat{\Sigma}_{\mathbf{k}_B} = \frac{1}{N} \sum_{i=1}^N \mathbf{k}_{B_i} \mathbf{k}_{B_i}^\dagger \quad (2.13)$$

Com vistas à modelagem estatística de dados SAR, supõe-se que as partes real e imaginária de cada componente do vetor \mathbf{k}_B obedecem a uma distribuição gaussiana circular (GOODMAN, 1963). Sejam $a = \Re(\mathbf{k}_B)$ e $b = \Im(\mathbf{k}_B)$ as partes real e imaginária do vetor \mathbf{k}_B e seja $k_{B_i} = a_i + jb_i$ o i -ésimo elemento complexo do vetor de espalhamento \mathbf{k}_B . Conforme Lee et al. (1994b), a suposição de distribuição gaussiana circular requer que a_i e b_i tenham uma distribuição gaussiana conjunta

satisfazendo as seguintes condições:

$$\begin{aligned} \mathbb{E}[a_i] &= \mathbb{E}[b_i] = 0 \\ \mathbb{E}[a_i b_i] &= 0 \\ \mathbb{E}[a_i a_k] &= \mathbb{E}[b_i b_k] \\ \mathbb{E}[b_i a_k] &= -\mathbb{E}[a_i b_k], \end{aligned}$$

em que \mathbb{E} é o operador esperança matemática e os índices i e k denotam elementos diferentes do vetor de espalhamento complexo \mathbf{k}_B .

Goodman (1963) apresenta a distribuição Wishart complexa multivariada que modela a matriz de covariância hermitiana $\mathbf{C} = L\mathbf{Z}$, em que L é o número equivalente de *looks* e \mathbf{Z} é a matriz de covariância *multi-look*, dada pela equação (2.11).

A matriz de covariância *multi-look* \mathbf{Z} corresponde aos valores de ruído *speckle* observados nas imagens PolSAR. A variável aleatória \mathbf{Z} segue a distribuição Wishart complexa escalonada com os parâmetros L (forma) e matriz de covariância $\boldsymbol{\Sigma}_{\mathbf{k}_B}$ (escala) (ANFINSEN, 2010). Essa distribuição é denotada por $\mathbf{Z} \sim \mathcal{W}(\boldsymbol{\Sigma}_{\mathbf{k}_B}, L)$.

A função densidade de probabilidade associada à matriz de covariância *multi-look* \mathbf{Z} é dada pela equação (2.14) (GOODMAN, 1963).

$$f_{\mathbf{Z}}(Z; \boldsymbol{\Sigma}_{\mathbf{k}_B}, L) = \frac{L^q |Z|^{L-q}}{|\boldsymbol{\Sigma}_{\mathbf{k}_B}|^L \Gamma_q(L)} \exp \{ -L \operatorname{Tr}(\boldsymbol{\Sigma}_{\mathbf{k}_B}^{-1} Z) \}, \quad (2.14)$$

em que $\Gamma_q(L) = \pi^{q(q-1)/2} \prod_{i=0}^{q-1} \Gamma(L-i)$, $L \geq q$ e $\Gamma(\cdot)$ é a função Gama.

O estimador de máxima verossimilhança do parâmetro matriz de covariância $\hat{\boldsymbol{\Sigma}}_{\mathbf{k}_B}$, para o caso dos dados *multi-look*, é dado pela média amostral (GOODMAN, 1963), de forma similar à adotada na equação (2.13). A quantidade q representa a ordem da matriz de covariância complexa.

A distribuição Wishart complexa escalonada é amplamente utilizada para modelar estatisticamente os dados PolSAR, como pode ser verificado em inúmeros trabalhos científicos, como por exemplo (LEE; GRUNES, 1992; LEE et al., 1994a; LEE et

al., 1999; LEE et al., 2001) principalmente para áreas homogêneas. Em áreas com maior grau de heterogeneidade, o modelo Wishart escalonado não apresenta uma solução plenamente satisfatória, sendo muitas vezes necessária a utilização de modelos mais complexos. Encontram-se propostos, na literatura, diversos outros modelos de maior complexidade, que buscam representar mais adequadamente os dados PolSAR. Dentre esses modelos, destaca-se a família de modelos \mathcal{G}_P , que apresenta como casos particulares as distribuições \mathcal{K}_P e \mathcal{G}_P^0 , para áreas com textura heterogênea e extremamente heterogênea, respectivamente (FREITAS et al., 2005; FRERY et al., 2007); os modelos derivados da chamada *Scale Mixture of Gaussians*, analisados por Doulgeris et al. (2008), Doulgeris e Eltoft (2010); e o modelo \mathcal{U} e outros derivados da hipótese multiplicativa (VASILE et al., 2011; BOMBRUN et al., 2011; ANFINSEN et al., 2011).

A distribuição de Wishart é um caso particular desses modelos, que são mais flexíveis, mas têm associadas densidades dependentes de funções especiais, tais como as funções modificadas de Bessel, o que, em certa medida, compromete seu tratamento analítico. Apesar da já mencionada restrição, a distribuição Wishart complexa escalonada será utilizada neste trabalho como modelo para os dados PolSAR, tendo em vista sua menor complexidade analítica e devido à atual indisponibilidade de expressões fechadas para distâncias estocásticas entre os modelos mais complexos. A decisão por utilização da distribuição Wishart complexa escalonada se justifica pelo fato de as distâncias estocásticas e os testes de hipótese assintóticos associados serem o cerne da pesquisa relativa a esta tese, sendo portanto elementos imprescindíveis. Cabe observar que soluções numéricas para obtenção dos valores das distâncias neste caso seriam inviáveis no domínio das matrizes hermitianas. O mesmo não ocorre quando se trata do modelo utilizado para pares de imagens em intensidade, a ser descrito na subseção 2.1.2.2, que modela duas variáveis pertencentes ao domínio dos números reais.

Uma outra observação importante com relação à utilização da distribuição de Wishart complexa é que, analiticamente, a mesma não se reduz ao caso 1 *look*, devido a presença, na equação (2.14), da função $\Gamma_q(L)$. Para esse caso particular, foi desenvolvida por Khan e Guida (2012) a distribuição \mathcal{G} polarimétrica *single-look*, fundamentando-se no modelo multiplicativo, com a textura seguindo distribuição gaussiana inversa generalizada e o ruído speckle a distribuição gaussiana complexa multivariada com média zero. Esse modelo é útil quando o processamento *multi-look*

torna-se prejudicial por causar degradação da resolução espacial, como por exemplo em imagens de resolução muito alta com alvos de extrema heterogeneidade, como em áreas urbanas. O classificador desenvolvido não utiliza este modelo específico para dados em 1 *look*.

Em dados SAR reais, as amostras espacialmente próximas apresentam correlação espacial inerente ao processo de geração das imagens. Conseqüentemente, ao se utilizarem L amostras de uma imagem SAR real para obtenção de uma imagem *multi-look*, o número efetivo de amostras utilizadas, levando-se em conta a correlação espacial, será menor do que o de amostras selecionadas no processo. Este valor é chamado número equivalente de *looks*. Ao se utilizar a modelagem estatística teórica apresentada com dados SAR reais, deve-se então, a partir dos dados disponíveis, estimar o número equivalente de visadas ou *looks*, como parâmetro da distribuição caracterizada pela densidade mostrada na equação (2.14). Para esse trabalho, a partir deste ponto, o número equivalente de *looks* passa a ser denotado pela letra L . Existem algumas formas de estimação do parâmetro L .

Conforme discutido por Lee e Pottier (2009), em imagens intensidade, o número equivalente de *looks* pode ser obtido através do cálculo do coeficiente de variação.

Anfinsen et al. (2009) avaliam alguns métodos para estimação de L para o caso de dados polarimétricos. São avaliadas soluções que utilizam o método dos momentos e da máxima verossimilhança. No caso das soluções pelo método dos momentos, são avaliadas a estimativa por momentos fracionários (*Fractional Moment Estimate*) (FRERY et al., 2007) e a que utiliza o momento de segunda ordem do traço da matriz de covariância. Como estimativa por máxima verossimilhança, é apresentada e avaliada a solução numérica não supervisionada, derivada pelos autores.

2.1.2.2 Distribuição para o Par de Intensidades *Multi-look*

Lee et al. (1994a) e Lee et al. (1994b) derivaram, a partir da distribuição de Wishart complexa multivariada escalonada, densidades univariadas e bivariadas que modelavam variáveis aleatórias correspondentes aos elementos da matriz de covariância complexa *multi-look*. As densidades univariadas derivadas foram a diferença de fase, o produto entre as amplitudes e razão de intensidades e amplitudes. Para elementos bivariados foram desenvolvidas as densidades do par de intensidades e do par intensidade-diferença de fase.

As distribuições associadas essas densidades mostram-se de grande importância na modelagem de dados polarimétricos incompletos, quando algumas das polarizações ou a informação de fase não estão disponíveis, o que representa o modo operacional de diversos sistemas sensores SAR. Alguns desses exemplos podem ser citados: o sistema Radarsat-2, que fornece imagens em intensidade nas polarizações HH, VV, HV e VH; sistemas que fornecem configurações de polarizações duais, como o Envisat (HH,HV ou VV,VH) e o Cosmos Skymed (HH,HV ou HH,VV); o sistema japonês ALOS-PALSAR que, apesar de potencialmente gerar imagens polarimétricas completas, tem como modo operacional a geração de pares de imagens polarimétricas nas polarizações HH e HV (ROSENQVIST et al., 2007). Uma dos modelos para esses tipos de dados, que vem apresentando melhores resultados, sobretudo para áreas da Floresta Amazônica, é a do Par de Intensidades *multi-look*. Um exemplo desse bom desempenho pode ser observado no trabalho de Negri (2009), no qual verificou-se que, para determinado número de classes de uso e cobertura da Terra, a classificação com base no modelo par de intensidades obteve resultados significativamente similares à obtida pelos dados polarimétricos completos. Como esta distribuição será utilizada no desenvolvimento prático deste trabalho, faz-se necessário a apresentação formal de sua densidade, de seus parâmetros e estimação.

Sejam duas variáveis aleatórias R_1 e R_2 , representando duas imagens em intensidade, obtidas a partir das componentes da diagonal principal da matriz de covariância complexa *multi-look* $[\mathbf{Z}]$, a densidade do par de intensidades *multi-look* pode ser definida como (LEE et al., 1994a):

$$f_{R_1, R_2}(r_1, r_2; L, h_{11}, h_{22}, |\rho_c|) = \frac{L^{L+1} (r_1 r_2)^{\frac{L-1}{2}} \exp \left\{ -\frac{L(r_1/h_{11} + r_2/h_{22})}{1 - |\rho_c|^2} \right\}}{(h_{11} h_{22})^{\frac{L+1}{2}} \Gamma(L) (1 - |\rho_c|^2) |\rho_c|^{L-1}} I_{L-1} \left(\frac{2L |\rho_c|}{1 - |\rho_c|^2} \sqrt{\frac{r_1 r_2}{h_{11} h_{22}}} \right), \quad (2.15)$$

em que L é o número equivalente de *looks*,

$$h_{11} = E[R_1], \quad (2.16)$$

$$h_{22} = E[R_2], \quad (2.17)$$

e ρ_c é o coeficiente de correlação complexo. Sendo S_i e S_j duas componentes da

matriz de espalhamento complexa, o coeficiente de correlação complexa ρ_c é dado por:

$$\rho_c = \frac{E[S_i S_j^*]}{\sqrt{E[|S_i|^2] E[|S_j|^2]}} = |\rho_c| \exp\{j\theta\}, \quad (2.18)$$

em que $0 \leq |\rho_c| \leq 1$ (LEE et al., 1994b) e θ é a diferença de fase entre os retornos de cada polarização ($-\pi \leq \theta \leq \pi$). A função I_{L-1} é a função modificada de Bessel de ordem $L - 1$. De acordo com Abramowitz e Stegun (1972), a função modificada de Bessel de ordem ν (I_ν) é uma das soluções da equação diferencial modificada de Bessel, apresentada na equação (2.19):

$$x^2 \frac{d^2 y}{dx^2} + x \frac{dy}{dx} - (x^2 + \nu^2) y = 0. \quad (2.19)$$

As propriedades e representações sob forma de integral da função modificada de Bessel de ordem ν (I_ν) podem ser encontradas em Gradshteyn e Ryzhik (2007). Uma dessas representações pode ser observada na equação (2.20)

$$I_\nu(x) = \frac{\left(\frac{x}{2}\right)^\nu}{\Gamma(\nu + 1/2)\Gamma(1/2)} \int_0^\pi \cosh(x \cos \theta) \sin^{2\nu} \theta d\theta \quad \left[\operatorname{Re}(\nu + \frac{1}{2}) > 0 \right]. \quad (2.20)$$

Como descrito em Correia (1998), os parâmetros h_{11} , h_{22} e $|\rho_c|$ podem ser estimados através da utilização de uma amostra de tamanho t , da seguinte forma:

$$\hat{h}_{11} = \hat{m}[R_1], \quad (2.21)$$

$$\hat{h}_{22} = \hat{m}[R_2], \quad (2.22)$$

$$|\hat{\rho}_c| = \sqrt{\frac{\sum_{i=1}^t \left[\left(R_{1i} - \hat{h}_{11} \right) \left(R_{2i} - \hat{h}_{22} \right) \right]}{\left[\sum_{i=1}^t \left(R_{1i} - \hat{h}_{11} \right)^2 \right] \left[\sum_{i=1}^t \left(R_{2i} - \hat{h}_{22} \right)^2 \right]}}, \quad (2.23)$$

em que \hat{m} é a média amostral dos elementos da amostra de tamanho t . \hat{h}_{11} e \hat{h}_{22} são estimadores de máxima verossimilhança e o estimador $|\hat{\rho}_c|$ para o módulo do coeficiente de correlação complexa, apresentado na equação (2.23), é estimado pelo método dos momentos. Frery et al. (2007) levantam a questão acerca do acentuado

viés do estimador dados pela equação 2.23, conforme comentado em Kendall e Stuart (1963), principalmente para valores absolutos próximos de zero. Os autores apresentam uma fórmula de correção de viés para esse estimador, desenvolvida por Olkin e Pratt (1958), objetivando a obtenção de melhores resultados de estimação.

2.1.2.3 Distribuição Gaussiana Multivariada

No escopo deste trabalho, torna-se importante definir formalmente a distribuição gaussiana multivariada, tendo em vista que a mesma é utilizada na implementação do classificador por regiões, objeto da presente tese. Quando da utilização de imagens multiespectrais de sensores óticos ou de imagens SAR em amplitude *multi-look* em diversas polarizações, o classificador desenvolvido dispõe de uma solução que utiliza distâncias estocásticas entre distribuições gaussianas multivariadas.

Sejam o vetor aleatório $\mathbf{y} = (Y_1, Y_2, \dots, Y_q)^\top$, $q \in \mathbb{N}$, cujos componentes são variáveis aleatórias independentes e igualmente distribuídas tais que $Y_i \sim \mathcal{N}(0,1)$ para todo $1 \leq i \leq q$, a matriz real não singular $\mathbf{M}_{q \times q}$ e $\boldsymbol{\mu}_{N \times 1} \in \mathbb{R}^q$. O vetor aleatório $\mathbf{x}^\top = \mathbf{y}^\top \mathbf{M} + \boldsymbol{\mu}^\top$ possui uma distribuição gaussiana N -variada com vetor de médias $\boldsymbol{\mu}$ e matriz de covariância $\boldsymbol{\Sigma} = \mathbf{M}^\top \mathbf{M}$, denotada por $\mathbf{x} \sim \mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\Sigma})$. A densidade do vetor aleatório $\mathbf{x} \in \mathbb{R}^q$, é dada pela equação (2.24).

$$f_x(\mathbf{x}; \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{(\sqrt{2\pi})^q} |\boldsymbol{\Sigma}|^{-\frac{1}{2}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}) \right\}. \quad (2.24)$$

Os estimadores de máxima verossimilhança para os parâmetros $\boldsymbol{\mu}$ e $\boldsymbol{\Sigma}$ são dados, respectivamente, pelas equações (2.25) e (2.26).

$$\hat{\boldsymbol{\mu}} = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i \quad (2.25)$$

e

$$\hat{\boldsymbol{\Sigma}} = \frac{1}{N} \sum_{i=1}^N (\mathbf{x}_i - \hat{\boldsymbol{\mu}})^\top (\mathbf{x}_i - \hat{\boldsymbol{\mu}}), \quad (2.26)$$

em que N é o número de observações de uma amostra.

2.2 Divergências e Distâncias Estocásticas

As definições de divergência e distância estocástica estão diretamente relacionadas com o desenvolvimento da *Teoria da Informação*, que tem a sua formalização proposta por [Shannon \(1948\)](#), em que foram definidos os conceitos de *Informação* e a *Entropia*. Com base nesses conceitos, derivaram-se medidas que vieram a se tornar importantes na utilização conjunta de variáveis aleatórias. Dentre essas medidas, podem-se relacionar a entropia conjunta, entropia condicional, informação mútua e entropia relativa, conhecida também como divergência de Kullback-Leibler. Os conceitos formais de *Informação* e *Entropia* podem ser consultados em [Cover e Thomas \(1991\)](#). A Entropia Relativa ou Divergência de Kullback-Leibler ([KULLBACK; LEIBLER, 1951](#)) pode ser utilizada como medida de separabilidade entre distribuições de probabilidade. A partir do desenvolvimento de medidas de divergência, podem ser obtidas distâncias entre distribuições de probabilidade, exemplificando a adaptação das medidas originadas da Teoria da Informação para utilização em outras áreas, dentre as quais podem ser destacadas as relativas ao processamento de imagens de sensores remotos.

[Csiszár \(1967\)](#) desenvolveu a família de divergências ϕ , que se caracteriza por um procedimento analítico formalizado com vistas à obtenção de medidas de divergência a partir da escolha conveniente de uma função ϕ . Com o emprego de duas densidades que caracterizam distribuições de uma mesma família e de uma função ϕ , podem-se obter diversas expressões de divergência existentes.

Sejam X e Y duas variáveis aleatórias definidas sobre um mesmo suporte S , caracterizadas pelas densidades $f_X(x; \theta_1)$ e $f_Y(x; \theta_2)$, em que θ_1 e θ_2 são vetores de parâmetros das duas distribuições de probabilidade. A divergência ϕ é dada pela equação (2.27).

$$D_\phi(X, Y) = \int_S \phi \left(\frac{f_X(x; \theta_1)}{f_Y(x; \theta_2)} \right) f_Y(x; \theta_2) dx, \quad (2.27)$$

em que $\phi : (0, \infty) \rightarrow [0, \infty)$ é uma função convexa tal que

$$0 \times \phi \left(\frac{0}{0} \right) = 0 \quad \text{e} \quad 0 \times \phi \left(\frac{x}{0} \right) = \lim_{x \rightarrow \infty} \frac{\phi(x)}{x}$$

Salicru et al. (1994) propuseram uma extensão do procedimento formal desenvolvido por Csiszár (1967), quando se desenvolveu um método analítico similar ao da divergência ϕ , pela inserção de uma nova função h . Trabalho similar foi desenvolvido, de forma independente, em Ali e Silvey (1966). Essa família de divergências ficou conhecida como h - ϕ . A partir da utilização da família de divergências h - ϕ , há a possibilidade de obtenção de expressões para um maior número de divergências conhecidas em relação às obtidas pela família de divergências ϕ . Sejam as mesmas variáveis aleatórias X e Y definidas sobre um mesmo suporte S , caracterizadas pelas densidades $f_X(x; \boldsymbol{\theta}_1)$ e $f_Y(x; \boldsymbol{\theta}_2)$, a divergência h - ϕ é dada pela equação (2.28)

$$D_\phi^h(X, Y) = h \left(\int_S \phi \left(\frac{f_X(x; \boldsymbol{\theta}_1)}{f_Y(x; \boldsymbol{\theta}_2)} \right) f_Y(x; \boldsymbol{\theta}_2) dx \right), \quad (2.28)$$

em que $h : [0, \infty) \rightarrow [0, \infty)$ é uma função estritamente crescente tal que $h(0) = 0$ e $h'(x) > 0, \forall x \in \mathbb{R}_+$.

A partir de uma escolha criteriosa das funções ϕ e h , podem-se derivar diversas medidas de divergência conhecidas. Como observado por Nascimento et al. (2010), algumas das medidas derivadas a partir da formulação apresentada na equação (2.28) não podem ser consideradas distâncias pois não apresentam a propriedade de simetria. Se a medida também guardar a propriedade da desigualdade triangular, recebe o nome de métrica (DEZA; DEZA, 2006). Para o caso de não simetria, há a possibilidade de um processo de “simetrização”, dado pela equação (2.29).

$$d_\phi^h(X, Y) = \frac{D_\phi^h(X, Y) + D_\phi^h(Y, X)}{2}, \quad (2.29)$$

com o que é obtida uma medida $d_\phi^h(X, Y)$, chamada de distância.

Em Nascimento et al. (2010), a partir da expressão apresentada na equação (2.28) e da escolha de funções h e ϕ apropriadas, foram obtidas expressões de divergência h - ϕ entre distribuições \mathcal{G}_I^0 , adequadas à modelagem de dados SAR em intensidade. As divergências obtidas foram: Kullback-Leibler, Rényi de ordem β , Hellinger, Bhattacharyya, Jensen-Shannon, aritmética-geométrica, triangular e média harmônica. Dessas medidas, quatro já apresentavam a propriedade de simetria e foram consideradas distâncias (Hellinger, Bhattacharyya, triangular e média harmônica).

Para as outras quatro, em que a propriedade de simetria não se observava, foi feito o processo de simetrização mostrado na equação (2.29), obtendo-se as expressões de distância.

No contexto evolução da pesquisa por expressões de distâncias estocásticas entre modelos estatísticos a partir da equação (2.28), Nascimento (2012) desenvolveu cinco expressões fechadas para distâncias estocásticas entre distribuições Wishart complexas escalonadas. As distâncias estocásticas derivadas entre distribuições Wishart complexas escalonadas foram as de Bhattacharyya, Kullback-Leibler, Hellinger, Rényi de ordem β e Qui-quadrado (χ^2). As funções h e ϕ identificadas por Nascimento et al. (2010) e por Nascimento (2012) para obtenção das distâncias desenvolvidas são apresentadas na Tabela 2.1.

Nascimento et al. (2010) e Nascimento (2012) obtiveram fórmulas das distâncias em função de integrais para obtenção das expressões finais das distâncias estocásticas com que trabalharam, facilitando a obtenção dessas expressões, que dependem unicamente das densidades envolvidas. Algumas dessas expressões, em função de integrais, são apresentadas nas equações (2.30)–(2.35), com a supressão, para fins de simplificação, da dependência da variável x e do suporte da integração. Apesar dos autores mencionados desenvolverem fórmulas em função das integrais para as nove distâncias mencionadas, foram escolhidas para apresentação neste trabalho apenas seis, pois são as distâncias utilizadas no classificador por regiões, nos seus diferentes módulos conforme descrito no capítulo 3.

Distância de Kullback-Leibler:

$$d_{KL}(X,Y) = \frac{1}{2} \int (f_X - f_Y) \log \left(\frac{f_X}{f_Y} \right), \quad (2.30)$$

Distância de Rényi de ordem β ($0 < \beta < 1$):

$$d_R^\beta(X,Y) = \frac{1}{\beta - 1} \log \left(\frac{\int f_X^\beta f_Y^{1-\beta} + \int f_X^{1-\beta} f_Y^\beta}{2} \right), \quad (2.31)$$

Distância de Hellinger:

$$d_H(X,Y) = 1 - \int \sqrt{f_X f_Y}, \quad (2.32)$$

Distância de Bhattacharyya:

$$d_B(X,Y) = -\log \left(\int \sqrt{f_X f_Y} \right), \quad (2.33)$$

Distância do Qui Quadrado (χ^2):

$$d_{\chi^2}(X,Y) = \frac{1}{2} \left[\int \frac{(f_X - f_Y)^2}{2f_X} + \int \frac{(f_X - f_Y)^2}{2f_Y} \right], \quad (2.34)$$

Distância Triangular:

$$d_T(X,Y) = \int \frac{(f_X - f_Y)^2}{f_X + f_Y}. \quad (2.35)$$

Conforme afirmado por Nascimento et al. (2010), as distâncias estocásticas entre duas distribuições de mesmo tipo passam a ser distâncias entre os parâmetros das distribuições. Sejam duas variáveis aleatórias X e Y , seguindo distribuições de Wishart complexas escalonadas, representadas por $X \sim \mathcal{W}(\Sigma_1, L_1)$ e $Y \sim \mathcal{W}(\Sigma_2, L_2)$, em que Σ_1 e Σ_2 (matrizes de covariância) e L_1 e L_2 (números equivalentes de *looks*) são parâmetros das distribuições. Considerando o caso particular, comum às aplicações em Sensoriamento Remoto, em que o número equivalente de *looks* é o mesmo para toda a imagem SAR, tomando portanto $L_1 = L_2 = L$, as cinco distâncias estocásticas entre as duas distribuições Wishart escalonadas são relacionadas nas equações (2.36)–(2.40)(NASCIMENTO, 2012).

$$d_{\text{WKL}}(\Sigma_1, \Sigma_2) = L \left[\frac{\text{Tr}(\Sigma_1^{-1} \Sigma_2 + \Sigma_2^{-1} \Sigma_1)}{2} - q \right] \quad (2.36)$$

$$d_{\text{WB}}(\Sigma_1, \Sigma_2) = L \left[\frac{\log |\Sigma_1| + \log |\Sigma_2|}{2} - \log \left| \left(\frac{\Sigma_1^{-1} + \Sigma_2^{-1}}{2} \right)^{-1} \right| \right] \quad (2.37)$$

$$d_{\text{WH}}(\Sigma_1, \Sigma_2) = 1 - \left[\frac{|2^{-1}(\Sigma_1^{-1} + \Sigma_2^{-1})^{-1}|}{\sqrt{|\Sigma_1| |\Sigma_2|}} \right]^L \quad (2.38)$$

$$\begin{aligned}
d_{\text{WR}}^\beta(\boldsymbol{\Sigma}_1, \boldsymbol{\Sigma}_2) &= \frac{\log 2}{1 - \beta} + \frac{1}{\beta - 1} \log \left\{ [|\boldsymbol{\Sigma}_1|^{-\beta} |\boldsymbol{\Sigma}_2|^{\beta-1} |(\beta \boldsymbol{\Sigma}_1^{-1} + (1 - \beta) \boldsymbol{\Sigma}_2^{-1})^{-1}|]^L \right. \\
&\quad \left. + [|\boldsymbol{\Sigma}_1|^{\beta-1} |\boldsymbol{\Sigma}_2|^{-\beta} |(\beta \boldsymbol{\Sigma}_2^{-1} + (1 - \beta) \boldsymbol{\Sigma}_1^{-1})^{-1}|]^L \right\} \quad (2.39)
\end{aligned}$$

$$\begin{aligned}
d_{\text{W}\chi^2}(\boldsymbol{\Sigma}_1, \boldsymbol{\Sigma}_2) &= \frac{1}{4} \left[\left(\frac{|\boldsymbol{\Sigma}_1|}{|\boldsymbol{\Sigma}_2|^2} \text{abs}(|(2\boldsymbol{\Sigma}_2^{-1} - \boldsymbol{\Sigma}_1^{-1})^{-1}|) \right)^L \right. \\
&\quad \left. + \left(\frac{|\boldsymbol{\Sigma}_2|}{|\boldsymbol{\Sigma}_1|^2} \text{abs}(|(2\boldsymbol{\Sigma}_1^{-1} - \boldsymbol{\Sigma}_2^{-1})^{-1}|) \right)^L - 2 \right], \quad (2.40)
\end{aligned}$$

em que $\text{abs}(\cdot)$ denota o valor absoluto e q é a ordem da matriz de covariância. Em termos de utilização prática, os valores dos parâmetros são estimados a partir dos dados disponíveis. $\hat{\boldsymbol{\Sigma}}_1$ e $\hat{\boldsymbol{\Sigma}}_2$ são estimados por máxima verossimilhança utilizando-se a equação (2.13) e o parâmetro número equivalente de *looks* - \hat{L} - pode ser estimado por algum dos métodos descritos em Anfinsen et al. (2009). Verifica-se que as equações (2.36)–(2.40) dependem de apenas duas operações com matrizes hermitianas: a matriz inversa e o determinante. Este trabalho apresenta como uma das principais contribuições o desenvolvimento de uma ferramenta computacional para classificação de imagens de sensores remotos, tendo por base as distâncias estocásticas desenvolvidas a partir da metodologia proposta pela formalização da família de divergências h - ϕ .

Em alguns casos práticos, conforme descrito na subseção 2.1.2.2, apenas elementos da diagonal principal da matriz de covariância L -*looks* estão disponíveis. Um modelo multivariado Gama poderia, em princípio, ser derivado como distribuição marginal da distribuição de Wishart escalonada, caracterizada pela densidade mostrada na equação (2.14). Na prática tal distribuição marginal foi derivada para o caso bivariado (Par de intensidades *multi-look*) por (LEE et al., 1994a, Eq. (30)) e para o caso trivariado por (HAGEDORN et al., 2006, Eq. (17)), que desenvolvem uma distribuição Qui-quadrada trivariada. A densidade que caracteriza a distribuição bivariada mencionada é apresentada na equação (2.15). A densidade relativa a distribuição trivariada apresentada por Hagedorn et al. (2006) não é utilizada no contexto deste trabalho pois apresenta uma complexidade matemática mais acentuada na derivação de distâncias estocásticas. Entretanto, ressalta-se que seria de extrema relevância o esforço para obtenção de soluções para esse caso, o que poderia representar um passo

na utilização simultânea de três imagens SAR em intensidade.

É também comum a disponibilidade de dados SAR em amplitude multivariados com número de *looks* elevados. Dados como esses podem ser modelados pela distribuição gaussiana multivariada.

Theodoridis e Koutroumbas (2008) derivaram analiticamente as distâncias de Kullback-Leibler e de Bhattacharyya entre distribuições gaussianas multivariadas, com parâmetros $\boldsymbol{\mu}_i$ e $\boldsymbol{\Sigma}_i$, $i = \{1,2\}$, cuja formulação é apresentada nas equações (2.41) e (2.42).

$$d_{\text{GKL}} = \frac{1}{2}(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^\top (\boldsymbol{\Sigma}_1^{-1} + \boldsymbol{\Sigma}_2^{-1})(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2) + \frac{1}{2} \text{Tr}(\boldsymbol{\Sigma}_1^{-1}\boldsymbol{\Sigma}_2 + \boldsymbol{\Sigma}_2^{-1}\boldsymbol{\Sigma}_1 - 2I_q). \quad (2.41)$$

$$d_{\text{GB}} = \frac{1}{8}[(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^\top \left(\frac{\boldsymbol{\Sigma}_1 + \boldsymbol{\Sigma}_2}{2}\right)^{-1} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)] + \frac{1}{2} \log \frac{|\frac{\boldsymbol{\Sigma}_1 + \boldsymbol{\Sigma}_2}{2}|}{\sqrt{|\boldsymbol{\Sigma}_1||\boldsymbol{\Sigma}_2|}}. \quad (2.42)$$

A utilização de distâncias estocásticas entre distribuições gaussianas é um procedimento comum nas tarefas de processamento de imagens de sensoriamento remoto. Theodoridis e Koutroumbas (2008) desenvolveram uma análise sobre a utilização da divergência (distância de Kullback-Leibler) e da distância de Bhattacharyya na seleção de atributos. A classificação por regiões é também uma dessas tarefas. Um importante exemplo de ferramenta disponível à comunidade de Sensoriamento Remoto pode ser encontrado no “software” SPRING (CAMARA et al., 1996), que fornece um classificador por regiões que utiliza, como critério, o menor valor de distância estocástica de Bhattacharyya (Eq.(2.42)). Uma evolução com relação ao estado da arte seria a utilização de testes de hipótese derivados dessas distâncias para fazer, dentre outros procedimentos possíveis, a classificação das imagens. Essa abordagem possui a vantagem de trazer uma medida de confiabilidade da classificação realizada, através da análise de p -valores dos testes utilizados.

Tabela 2.1 - Distâncias h - ϕ e funções h e ϕ correspondentes (NASCIMENTO et al., 2010; NASCIMENTO, 2012)

distâncias h - ϕ	$h(y)$	$\phi(x)$
<i>Kullback-Leibler</i>	$\frac{y}{2}$	$(x-1)\log(x)$
<i>Renyi (ordem β)</i>	$\frac{1}{\beta-1}\log((\beta-1)y+1)$, $0 \leq y \leq \frac{1}{1-\beta}$	$\frac{x^{1-\beta} + x^\beta - \beta(x-1) - 2}{2(\beta-1)}$, $0 < \beta < 1$
<i>Hellinger</i>	$\frac{y}{2}$, $0 \leq y \leq 2$	$(\sqrt{x}-1)^2$
<i>Bhattacharyya</i>	$-\log(-y+1)$, $0 \leq y < 1$	$-\sqrt{x} + \frac{x+1}{2}$
<i>Jensen-Shannon</i>	$\frac{y}{2}$	$x \log\left(\frac{2}{x+1}\right) + \log\left(\frac{2}{x+1}\right)$
Aritmética-geométrica	y	$\left(\frac{x+1}{2}\right)\log\left(\frac{x+1}{2}\right) + \frac{x-1}{2}$
Triangular	$y, 0 \leq y \leq 2$	$\frac{(x-1)^2}{x+1}$
Média harmônica	$-\log(-y/2+1)$, $0 \leq y \leq 2$	$\frac{(x-1)^2}{x+1}$
χ^2	$\frac{y}{4}$	$\frac{(x-1)^2(x+1)}{x}$

2.3 Testes de Hipótese com Base na Classe h - ϕ de Distâncias

Com base no desenvolvimento analítico formal proposto por Salicru et al. (1994), que possibilitou a derivação de expressões para diversas distâncias estocásticas, obtém-se a estatística de teste de hipótese s_ϕ^h , conforme a equação (2.43).

$$s_\phi^h(\widehat{\boldsymbol{\theta}}_1, \widehat{\boldsymbol{\theta}}_2) = \frac{2mnv}{m+n} d_\phi^h(\widehat{\boldsymbol{\theta}}_1, \widehat{\boldsymbol{\theta}}_2), \quad (2.43)$$

em que $\widehat{\boldsymbol{\theta}}_1 = (\widehat{\theta}_{11}, \dots, \widehat{\theta}_{1M})$ e $\widehat{\boldsymbol{\theta}}_2 = (\widehat{\theta}_{21}, \dots, \widehat{\theta}_{2M})$ são os estimadores de máxima verossimilhança de $\boldsymbol{\theta}_1$ e $\boldsymbol{\theta}_2$ com M parâmetros, baseados em amostras independentes de tamanhos m e n e $v = 1/[h'(0)\phi''(1)]$ é constante para uma mesma distância e depende das funções h e ϕ , específicas para a distância estocástica utilizada, conforme a Tabela 2.1. $[h'$ é a derivada de primeira ordem da função h e ϕ'' é a derivada de segunda ordem da função ϕ .

Obedecendo determinadas condições de regularidade, definidas por Salicru et al. (1994), se $m, n \rightarrow \infty$, e $\boldsymbol{\theta}_1 = \boldsymbol{\theta}_2$, então

$$\frac{2mnv}{m+n} d_\phi^h(\widehat{\boldsymbol{\theta}}_1, \widehat{\boldsymbol{\theta}}_2) \xrightarrow{\mathcal{D}} \chi_M^2, \quad (2.44)$$

em que $\xrightarrow{\mathcal{D}}$ denota convergência em distribuição e χ_M^2 é a distribuição Qui-quadrado com M graus de liberdade, que corresponde ao número de parâmetros em θ_i para algum i .

De acordo com o que foi proposto por Salicru et al. (1994) e apresentado por Nascimento et al. (2010), para valores suficientemente grandes de m e n , a hipótese nula ($H_0 : \boldsymbol{\theta}_1 = \boldsymbol{\theta}_2$) pode ser rejeitada ao nível de significância η se $Pr(\chi_M^2 > s) \leq \eta$.

Alguns trabalhos relevantes vêm utilizando essa metodologia no desenvolvimento de testes de hipóteses para verificação de contraste em imagens SAR. Nascimento et al. (2010), desenvolveram e avaliaram estatísticas de teste para oito distâncias estocásticas obtidas a partir da metodologia h - ϕ entre modelos \mathcal{G}_I^0 . Frery et al. (2011b), desenvolveram e avaliaram estatísticas de teste para cinco distâncias estocásticas analiticamente fechadas entre modelos Wishart, considerando diferentes matrizes de covariância e diferentes números equivalentes de *looks* entre os dois grupos de dados a serem comparados. Esses trabalhos mostraram grande potencialidade na aplicação

dos testes de hipótese com base na estatística s_ϕ^h para verificação de contraste em imagens SAR.

Para o desenvolvimento deste trabalho, foram utilizadas estatísticas de teste obtidas a partir das distâncias estocásticas entre modelos Wishart complexos, derivadas por Nascimento (2012) e apresentadas nas equações (2.36)–(2.40), a saber: Bhattacharyya, Kullback-Leibler, Hellinger, Rényi de ordem β e χ^2 , além das estatísticas obtidas a partir das distâncias entre distribuições Par de intensidade *multi-look* - por solução numérica- e entre distribuições gaussianas multivariadas. Com a suposição de que as diferentes regiões da imagem a serem comparadas apresentam em comum o número equivalente de *looks* L , que se supõe também conhecido, a hipótese nula sob a qual a estatística s_ϕ^h segue uma distribuição χ^2 é $H_0 : \Sigma_1 = \Sigma_2$. As estatísticas derivadas a partir das cinco distâncias estocásticas listadas nas equações (2.36)–(2.40) são apresentadas nas equações (2.45)– eqrefTestChi2 citeteseabraao.

$$S_{\text{WKL}}(\widehat{\Sigma}_1, \widehat{\Sigma}_2) = \frac{2mn}{m+n} L \left[\frac{\text{Tr}(\widehat{\Sigma}_1^{-1} \widehat{\Sigma}_2 + \widehat{\Sigma}_2^{-1} \widehat{\Sigma}_1)}{2} - q \right]. \quad (2.45)$$

$$S_{\text{WB}}(\widehat{\Sigma}_1, \widehat{\Sigma}_2) = \frac{8mn}{m+n} L \left[\frac{\log |\widehat{\Sigma}_1| + \log |\widehat{\Sigma}_2|}{2} - \log \left| \left(\frac{\widehat{\Sigma}_1^{-1} + \widehat{\Sigma}_2^{-1}}{2} \right)^{-1} \right| \right]. \quad (2.46)$$

$$S_{\text{WH}}(\widehat{\Sigma}_1, \widehat{\Sigma}_2) = \frac{8mn}{m+n} \left\{ 1 - \left[\frac{|2^{-1}(\widehat{\Sigma}_1^{-1} + \widehat{\Sigma}_2^{-1})^{-1}|}{\sqrt{|\widehat{\Sigma}_1| |\widehat{\Sigma}_2|}} \right]^L \right\}. \quad (2.47)$$

$$S_{\text{WR}}^\beta(\widehat{\Sigma}_1, \widehat{\Sigma}_2) = \frac{2mn}{\beta(m+n)} \left\{ \frac{\log 2}{1-\beta} + \frac{1}{\beta-1} \log \left\{ \begin{aligned} & [|\widehat{\Sigma}_1|^{-\beta} |\widehat{\Sigma}_2|^{\beta-1} |(\beta \widehat{\Sigma}_1^{-1} + (1-\beta) \widehat{\Sigma}_2^{-1})^{-1}|]^L \\ & + [|\widehat{\Sigma}_1|^{\beta-1} |\widehat{\Sigma}_2|^{-\beta} |(\beta \widehat{\Sigma}_2^{-1} + (1-\beta) \widehat{\Sigma}_1^{-1})^{-1}|]^L \end{aligned} \right\} \right\}. \quad (2.48)$$

$$S_{W\chi^2}(\widehat{\Sigma}_1, \widehat{\Sigma}_2) = \frac{mn}{2(m+n)} \left[\left(\frac{|\widehat{\Sigma}_1|}{|\widehat{\Sigma}_2|^2} \text{abs}(|(2\widehat{\Sigma}_2^{-1} - \widehat{\Sigma}_1^{-1})^{-1}|) \right)^L + \left(\frac{|\widehat{\Sigma}_2|}{|\widehat{\Sigma}_1|^2} \text{abs}(|(2\widehat{\Sigma}_1^{-1} - \widehat{\Sigma}_2^{-1})^{-1}|) \right)^L - 2 \right], \quad (2.49)$$

No caso da disponibilidade de dados SAR multivariados em amplitude ou dados de sensores óticos, as imagens podem ser modeladas pela distribuição gaussiana multivariada. As estatísticas de teste (S_{GKL}) e (S_{GB}) foram derivadas nesta tese, com a utilização, respectivamente, das distâncias estocásticas de Kullback-Leibler (Eq. (2.41)) e de Bhattacharyya (Eq. (2.42)) e da equação (2.43) e são apresentadas pelas equações (2.50) e (2.51).

$$S_{\text{GKL}} = \frac{mn}{m+n} \left[(\widehat{\mu}_1 - \widehat{\mu}_2)^\top (\widehat{\Sigma}_1^{-1} + \widehat{\Sigma}_2^{-1}) (\widehat{\mu}_1 - \widehat{\mu}_2) + \text{Tr}(\widehat{\Sigma}_1^{-1} \widehat{\Sigma}_2 + \widehat{\Sigma}_2^{-1} \widehat{\Sigma}_1 - 2I_q) \right], \quad (2.50)$$

$$S_{\text{GB}} = \frac{mn}{m+n} \left[(\widehat{\mu}_1 - \widehat{\mu}_2)^\top \left(\frac{\widehat{\Sigma}_1 + \widehat{\Sigma}_2}{2} \right)^{-1} (\widehat{\mu}_1 - \widehat{\mu}_2) + 4 \log \frac{|\frac{\widehat{\Sigma}_1 + \widehat{\Sigma}_2}{2}|}{\sqrt{|\widehat{\Sigma}_1| |\widehat{\Sigma}_2|}} \right], \quad (2.51)$$

em que I_q denota a matriz identidade de ordem q .

2.4 Classificação por Regiões

A classificação de imagens digitais pode ser compreendida de uma forma simplificada como um processo em que se busca atribuir aos diferentes elementos da imagem (pixels), um determinado rótulo, correspondente a uma dada classe. Esse processo pode ser caracterizado segundo diversos critérios. Um desses critérios refere-se à utilização dos atributos de um único pixel ou de um conjunto de pixels para classificação, quando os processos recebem, respectivamente, os nomes de classificação pontual (por pixel) ou por regiões. A classificação por regiões, ao contrário da pontual, caracteriza-se por atribuir simultaneamente um rótulo a um conjunto de pixels da imagem contidos em um mesmo segmento. Para esse procedimento, pressupõem-

se então que a imagem passe por um processo prévio de segmentação.

A cena R correspondente à imagem a ser classificada precisa ser particionada em r segmentos disjuntos C_1, \dots, C_r . Este resultado é obtido na prática utilizando-se um processo de segmentação de imagens. Gonzalez e Woods (2010) definem segmentação de uma imagem como o processo que particiona a imagem C em r subregiões C_1, C_2, \dots, C_r de tal forma que

- a) $\cup_{i=1}^r C_i = R$
- b) C_i é um conjunto conectado, $i = 1, 2, \dots, r$
- c) $C_i \cap C_j = \emptyset, \forall i, j, i \neq j$
- d) $Q(C_i) = VERDADEIRA$ para $i = 1, 2, \dots, r$
- e) $Q(C_i \cup C_j) = FALSA$ para quaisquer regiões adjacentes C_i e C_j ,

em que $Q(C_k)$ é uma propriedade lógica definida sobre os pontos do conjunto C_k e \emptyset é o conjunto vazio.

Para a segmentação de dados SAR, está disponível o software SegSAR (SOUSA-JÚNIOR, 2005), que foi desenvolvido para tarefas de segmentação com imagens de radar e óticas. Utilizando técnicas de crescimento e junção de regiões, detecção de bordas, seleção de área mínima e testes de homogeneidade, o software possui algumas características interessantes como segmentação multi-nível e hierárquica e testes de homogeneidade multi-modelos.

O software SegSAR utiliza como modelagem para as áreas homogêneas das imagens SAR a distribuição gama, tendo em vista que as imagens SAR a serem segmentadas no processamento devem ser do formato intensidade. Dados multivariados em intensidade podem ser utilizados, sendo que o SegSAR utiliza distribuições gama separadas para cada imagem em intensidade. Caso haja a disponibilidade de imagens polarimétricas, pode-se aplicar o SegSAR às componentes em intensidade, que correspondem aos elementos da diagonal principal da imagem no formato matriz de covariância.

Programas para segmentação de imagens PolSAR estão em desenvolvimento, utilizando medidas que comparam matrizes de covariância complexas. Importantes

avanços foram obtidos nesse sentido com a obtenção por [Conradsen et al. \(2003\)](#) de uma estatística de teste, com hipótese de igualdade entre matrizes de covariância complexas e uma distribuição assintótica associada. Tal estatística pode ser utilizada na detecção de mudanças entre regiões de imagens PolSAR modeladas pela distribuição complexa de Wishart e na identificação de bordas nessas imagens, com a potencialidade de segmentação das imagens PolSAR.

O processo de classificação por regiões a partir da segmentação de uma imagem pode ser ilustrado pela Figura 2.1, em que é mostrada também a diferença entre essa abordagem e a pontual ou “por pixel”.

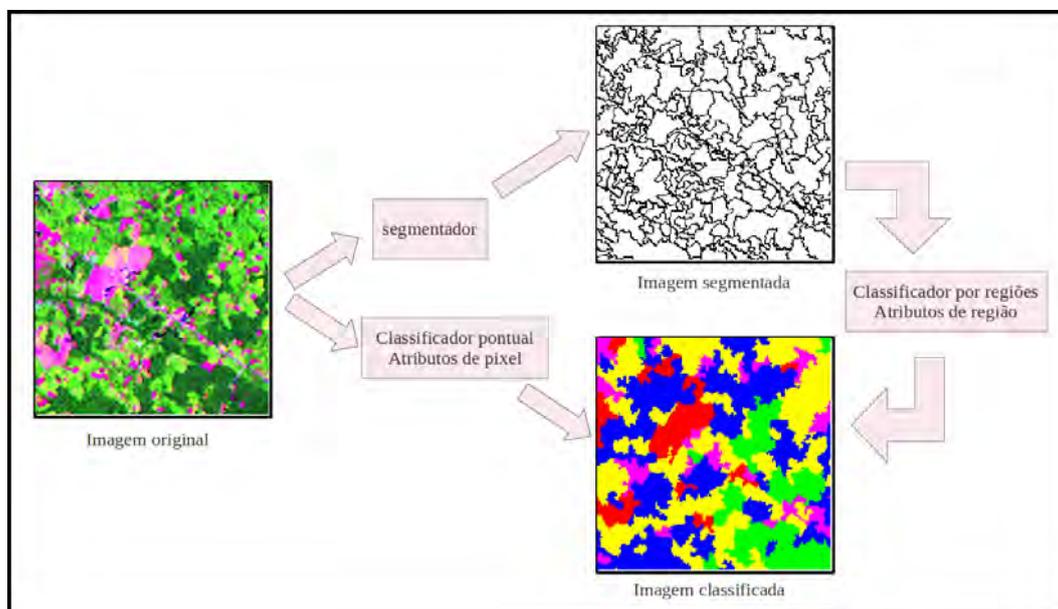


Figura 2.1 - Classificação por regiões e pontual.

Com a imagem segmentada, pode-se classificar simultaneamente todos os pixels contidos em cada segmento a partir de características (atributos) de todos esses pixels. Esses atributos podem ser relativos aos valores radiométricos dos pixels, valores de textura extraídos do conjunto de pixels contido no segmento e, alternativamente, pode-se utilizar atributos de forma do polígono formado pelo segmento. Essa última opção tornou-se recentemente importante na classificação de imagens óticas de alta resolução espacial, sobretudo em densas áreas urbanas, área de pesquisa em que o termo “classificação baseada em objetos” tornou-se comum.

A classificação por regiões aplicada a imagens PolSAR é ainda uma área relativamente pouco explorada. Entretanto, alguns recentes trabalhos que utilizam essa abordagem vêm apresentando resultados consistentes. Dentre esses trabalhos pode-se citar a pesquisa desenvolvida por Qi et al. (2012). Neste trabalho, a abordagem por regiões é aplicada a diversos resultados de decomposição polarimétrica de alvos, com a utilização de um classificador por árvore de decisão. As imagens polarimétricas originais são do sistema RADARSAT-2. A classificação por regiões alcança resultados consideravelmente superiores aos obtidos pelo classificador por Máxima Verossimilhança pontual Wishart. Em outro relevante trabalho, utilizando imagens PolSAR do sensor AIRSAR, Li et al. (2008) desenvolveram e testaram uma metodologia com base nas técnicas *Statistical Region Merging* (SRM), para segmentação e *Support Vector Machine* (SVM), para classificação por regiões. Os resultados obtidos mostraram que a abordagem por regiões superou a abordagem pontual SVM.

Uma das possíveis soluções a serem utilizadas na classificação por regiões, especialmente sob o viés de classificação por modelagem estatística, consiste na utilização de distâncias estocásticas. neste caso, a atribuição de determinada classe a cada segmento se dá pela menor distância estocástica entre o modelo estatístico que representa o conjunto de pixels contidos no segmento em questão e o que representa o conjunto de pixels nas amostras de treinamento, para o caso da classificação por regiões supervisionada. Um dos exemplos mais importantes desse tipo de classificador está disponível no “software” SPRING (CAMARA et al., 1996) que fornece, além de uma ferramenta de segmentação, um classificador por regiões por menor distância de Bhattacharyya entre distribuições gaussianas multivariadas, como a que foi apresentada na equação (2.42). Verifica-se, portanto, que essa solução disponível é adequada a dados produzidos por sensores óticos. O software SPRING dispõe também de um classificador por regiões fundamentado na abordagem não supervisionada, o ISOSEG, que utiliza a distância de Mahalanobis entre distribuições gaussianas para realizar o agrupamento de segmentos de uma imagem em determinado número de classes. Bins et al. (1993) descrevem detalhadamente o algoritmo utilizado pelo ISOSEG.

Para a utilização da abordagem por regiões na classificação de imagens SAR e PolSAR, com a solução de distâncias estocásticas, verifica-se a grande relevância da disponibilização de expressões analíticas para as distâncias entre modelos estatísticos adequados aos dados. As distâncias classicamente utilizadas são frequentemente

obtidas entre distribuições gaussianas, o que frequentemente não traz resultados satisfatórios quando da utilização em dados SAR e PolSAR. Conforme comentado na Seção 2.2, Nascimento et al. (2010) obtiveram expressões para distâncias entre distribuições \mathcal{G}_I^0 , adequadas aos dados SAR em intensidade, e Nascimento (2012) entre distribuições de Wishart complexas escalonadas, adequadas a modelagem de dados PolSAR, especialmente em alvos com resposta homogênea. A utilização dessas novas medidas em ferramentas de classificação por regiões pode representar um significativo ganho para as aplicações de Sensoriamento Remoto por radar. Adicionalmente, a utilização das estatísticas derivadas das distâncias e suas distribuições assintóticas, como apresentados na Seção 2.3, pode representar uma melhoria ao processo de classificação por regiões, por permitir obter um indicativo de confiabilidade da classificação de cada segmento da imagem, através da informação do p -valor de cada teste de hipótese. O presente trabalho, no seu desenvolvimento, vai abordar a utilização dessas melhorias para geração de imagens classificadas por regiões.

2.5 Avaliação da Classificação

Ao término do processo de classificação, dispõe-se de um produto que será utilizado como um mapa temático para diversas aplicações, dentre as quais pode ser relacionada, por exemplo, a cartografia temática. Essas aplicações normalmente exigem uma qualidade específica com respeito aos insumos que estão sendo utilizados. Torna-se então imperativa a avaliação da exatidão dos resultados da classificação e o conhecimento da mesma. Para a avaliação da exatidão dos resultados de classificação, a matriz de confusão ou matriz de erros é largamente utilizada. Segundo afirmado em Congalton e Green (2009), a matriz de confusão é uma das formas mais eficientes de representar a exatidão de uma classificação, pois é capaz de descrever tanto os erros de inclusão (comissão) quanto os de exclusão (omissão). Ela é construída a partir da utilização das amostras de avaliação ou teste, que são obtidas da chamada “verdade de campo”.

As amostras podem ser realmente levantadas indo-se a campo ou através de algum documento confiável, como um mapa atualizado ou uma outra imagem atual com melhor qualidade espacial e espectral. Com as amostras de teste em posição conhecida na imagem classificada, pode-se verificar os erros de comissão, que consiste na inclusão de uma área dentro de uma classe à qual ela não pertence, e de omissão, que refere-se à exclusão de uma área da classe à qual ela pertence.

A acurácia do usuário ou do consumidor refere-se ao erro de comissão, enquanto a acurácia do produtor refere-se ao erro de omissão. Uma matriz de confusão genérica é representada na Tabela 2.2, em que, para uma dada classe ω_i , a quantidade n_{ij} representa o “número de amostras” classificadas na classe i , sendo que são ocorrências da classe j , n_{i+} e n_{+i} representam respectivamente as proporções marginais com relação a coluna (referência) i e linha (classificação) i , e N o número total de amostras.

Tabela 2.2 - Matriz de Confusão.

		Referência				
		ω_1	ω_2	\cdots	ω_k	
C l a s s	ω_1	n_{11}	n_{12}	\cdots	n_{1k}	n_{1+}
	ω_2	n_{21}	n_{22}	\cdots	n_{2k}	n_{2+}
	\vdots	\vdots	\vdots	\ddots	\vdots	\vdots
	ω_k	n_{k1}	n_{k2}	\cdots	n_{kk}	n_{k+}
		n_{+1}	n_{+2}	\cdots	n_{+k}	N

A partir da obtenção da matriz de confusão, podem-se calcular medidas de concordância entre classificações. Isto permite então que se possa obter indicativos de qualidade de uma determinada classificação quando se dispõe de uma outra classificação confiável, tratada como referência. A classificação de referência é obtida pelo uso das amostras de avaliação coletadas em campo. Um dessas principais medidas é o Coeficiente de Concordância $kappa(\kappa)$. A formulação para o estimador do $kappa$ ($\hat{\kappa}$) pode ser observada na equação (2.52)(CONGALTON; GREEN, 2009):

$$\hat{\kappa} = \frac{P_o - P_c}{1 - P_c}, \quad (2.52)$$

em que $P_o = \frac{\sum_{i=1}^k n_{ii}}{N}$ e $P_c = \frac{\sum_{i=1}^k n_{i+} n_{+i}}{N^2}$. P_o é conhecido como Acurácia Global. Outra importante medida de informação de qualidade é a variância amostral do $kappa$ ($var(\hat{\kappa})$), que pode ser estimada pela equação (2.53)(CONGALTON; GREEN, 2009):

$$var(\hat{\kappa}) = \frac{1}{N} \left(\frac{\theta_1(1-\theta_1)}{(1-\theta_1)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2 - \theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4 - 4\theta_2)^2}{(1-\theta_2)^4} \right), \quad (2.53)$$

em que

$$\theta_1 = \frac{1}{N} \sum_{i=1}^k n_{ii} \qquad \theta_2 = \frac{1}{N^2} \sum_{i=1}^k n_{i+}n_{+i}$$

$$\theta_3 = \frac{1}{N^2} \sum_{i=1}^k n_{ii} (n_{i+} + n_{+i}) \qquad \theta_4 = \frac{1}{N^3} \sum_{i=1}^k \sum_{j=1}^k n_{ij} (n_{j+} + n_{+i})$$

Um valor de coeficiente de concordância *kappa* é estimado para cada matriz de confusão obtida, consistindo em um valor que representa quão bem a classificação resultante concorda com a classificação dos dados de referência. Uma classificação por intervalos de valores do coeficiente relacionados a níveis nominais de qualificação foi proposta por Landis e Koch (1977) e é apresentada na Tabela 2.3

Tabela 2.3 - Níveis do coeficiente *kappa*(κ) associados a diferentes termos qualitativos.

κ	Qualificação
$\kappa \leq 0$	Péssimo
$0 < \kappa \leq 0,2$	Ruim
$0,2 < \kappa \leq 0,4$	Razoável
$0,4 < \kappa \leq 0,6$	Bom
$0,6 < \kappa \leq 0,8$	Muito Bom
$0,8 < \kappa \leq 1$	Excelente

Em Congalton e Green (2009), são apresentados dois testes de hipótese com utilização de estatísticas que seguem uma distribuição normal padrão, derivadas do

coeficiente de concordância *kappa*. O primeiro deles permite verificar se a hipótese de que um determinado κ seja igual a zero possa ser rejeitada a um nível de significância especificado. O outro, utilizado quando se dispõe de dois ou mais valores estimados de coeficiente de concordância *kappa* (duas matrizes de confusão), permite verificar se a hipótese de que dois desses valores de coeficientes sejam iguais possa ser rejeitada a um nível de significância especificado. Essa segunda opção torna-se muito importante quando da comparação entre duas avaliações distintas de duas classificações, e será utilizada várias vezes nesse trabalho, tendo em vista que muitas classificações serão feitas sob diversas condições e avaliadas utilizando-se referências comuns. Esses resultados serão então comparados através desse tipo de teste de hipótese.

Sejam $\hat{\kappa}_1$ e $\hat{\kappa}_2$ os estimadores do coeficiente *kappa* para as matrizes de confusão 1 e 2, respectivamente. Sejam $\widehat{var}(\hat{\kappa}_1)$ e $\widehat{var}(\hat{\kappa}_2)$ os estimadores correspondentes das variâncias dos coeficientes *kappa*, calculados conforme a equação (2.53). A estatística de teste utilizada para verificar se duas matrizes de confusão são significativamente diferentes é dada pela equação (2.54) (CONGALTON; GREEN, 2009).

$$Z = \frac{|\hat{\kappa}_1 - \hat{\kappa}_2|}{\sqrt{\widehat{var}(\hat{\kappa}_1) + \widehat{var}(\hat{\kappa}_2)}} \quad (2.54)$$

A estatística Z segue distribuição normal padrão. Com a hipótese nula $H_0 : \hat{\kappa}_1 - \hat{\kappa}_2 = 0$ e a hipótese alternativa $H_1 : \hat{\kappa}_1 - \hat{\kappa}_2 \neq 0$, H_0 é rejeitada se $Z \geq z_{\frac{\alpha}{2}}$ e $Z \leq -z_{\frac{\alpha}{2}}$, sendo α o nível de significância considerado.

3 CLASSIFICADOR POR REGIÕES DESENVOLVIDO

3.1 Introdução

Este capítulo tem por objetivo descrever o classificador por regiões desenvolvido que utiliza distâncias estocásticas e testes de hipótese. O algoritmo de classificação foi implementado utilizando-se a linguagem de programação *Interactive Data Language* (IDL), versão 7.1 (EXELIS, 2009).

O classificador dispõe de três módulos, cada um apropriado à modelagem estatística mais adequada a diferentes tipos de dados. A Tabela 3.1 apresenta uma descrição sucinta dos módulos do classificador, com as distâncias implementadas disponíveis, a modelagem estatística considerada e o tipo de solução adotada para o cálculo das distâncias em questão (analítica ou numérica).

Tabela 3.1 - Módulos do classificador por regiões.

Módulo	Modelagem estatística	Distâncias estocásticas	Solução
Imagens Polarimétricas	Wishart complexa escalonada	Bhattacharyya Kullback-Leibler Hellinger Rényi Qui-quadrado (χ^2)	Analítica
Par de imagens SAR em intensidade	Par de intensidades	Bhattacharyya Triangular	Numérica
Imagens óticas e SAR multivariadas em amplitude	Gaussiana	Bhattacharyya Kullback-Leibler	Analítica

Com relação às distâncias com expressões fechadas (solução analítica), para os casos entre modelos complexos de Wishart, foram utilizadas as expressões disponíveis em Frery et al. (2011b), adaptando-se para o caso particular em que o número equivalente de *looks* é considerado igual para as diversas regiões da imagem, expressões essas correspondentes às equações (2.36)–(2.40). Para o caso entre modelos Gaussianos multivariados, foram utilizadas as expressões disponíveis em Theodoridis e Koutroumbas (2008), como nas equações (2.41) e (2.42). No caso das distâncias entre distribuições Par de intensidades *multi-look*, foi utilizada uma função da linguagem IDL para solução numérica de integrais duplas. Essa função é denominada

Int_2D e utiliza o método de Quadratura Gaussiana Iterativa. Procedeu-se uma pequena alteração na função para que se ajustasse os valores de limites de integração de modo que os limites utilizados sejam pré-determinados a partir dos dados que estão sendo classificados.

O classificador por regiões implementado está disponível com uma interface gráfica (Fig. 3.1) que apresenta três abas, para que o usuário possa selecionar entre um dos módulos de classificação disponível, conforme a Tabela 3.1. Em primeiro plano, está a aba do módulo para imagens polarimétricas, que utiliza como modelagem estatística a distribuição de Wishart complexa escalonada.

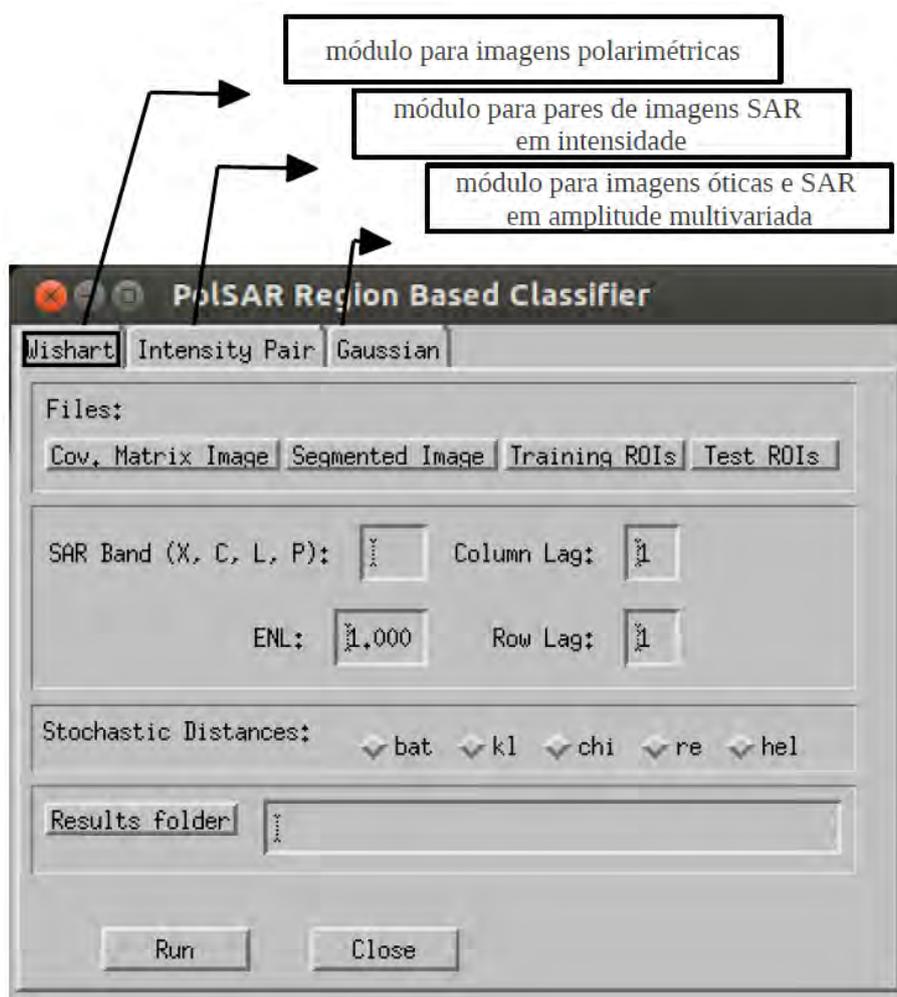


Figura 3.1 - Interface gráfica do classificador por regiões

Para as três opções de classificação disponíveis, que correspondem por sua vez a três modelagens estatísticas e três tipos de dados diferentes, o princípio do classificador é o mesmo: procede-se a classificação dos segmentos pelo menor valor de estatística de teste s_ϕ^h . As formulações para as estatística s_ϕ^h , para cada modelo utilizado são apresentadas nas equações: (2.45)–(2.49), para o modelo Wishart escalonado; (2.50)–(2.51), para o modelo gaussiano multivariado; e, no caso do modelo par de intensidades *multi-look*, a equação (2.43) é aplicada ao valor de distância de Bhattacharyya e Triangular, obtidas numericamente com as expressões em função de integrais correspondentes (Eq. (2.33) e (2.35)).

Identifica-se portanto uma importante contribuição deste trabalho: a utilização da teoria de testes $h-\phi$ no desenvolvimento de uma ferramenta útil às atividades de classificação de imagens segmentadas. Em um problema de classificação de imagens, o teste $h-\phi$ pode permitir que duas regiões, modeladas por duas distribuições de probabilidade da mesma família, possam ser consideradas de classes distintas se a hipótese nula for rejeitada. Em contrapartida, quando a hipótese nula não for rejeitada, os dados comparados podem ser modelados pela mesma distribuição e pertencerem à mesma classe.

A descrição a seguir tratará da concepção básica do classificador por regiões, utilizando distâncias estocásticas e estatísticas de teste derivadas. Serão ainda definidos dois produtos básicos desse processo de classificação: a imagem classificada por menor estatística de teste e um “mapa” de p -valores estimados.

O princípio da ferramenta é o mesmo para os outros módulos, que serão descritos individualmente nas subseções 3.2, 3.3 e 3.4. Suponha uma imagem com r segmentos disjuntos C_1, \dots, C_r . Para cada segmento C_i , com $1 \leq i \leq r$, os vetores de parâmetros $\hat{\theta}_i$ são estimados pelo método de máxima verossimilhança. A classificação ocorre de forma supervisionada. O usuário seleciona k classes de interesse em forma de amostras, com as quais estimam-se por máxima verossimilhança os parâmetros $\hat{\theta}_\ell$, $1 \leq \ell \leq k$.

São computadas $r \times k$ estatísticas de teste para verificação da hipótese nula $H_0 : \hat{\theta}_i = \hat{\theta}_\ell$ para cada segmento $1 \leq i \leq r$ e cada classe $1 \leq \ell \leq k$.

A classificação com base na mínima estatística de teste consiste em atribuir ao segmento C_i a t -ésima classe se

$$S_{\phi}^h(\widehat{\boldsymbol{\theta}}_i, \widehat{\boldsymbol{\theta}}_t) < S_{\phi}^h(\widehat{\boldsymbol{\theta}}_i, \widehat{\boldsymbol{\theta}}_{\ell}), \quad (3.1)$$

$\forall t \neq \ell$. Uma vez que o segmento C_i foi rotulado com a classe t , o p -valor do teste de hipóteses é calculado por

$$p_{i,t} = \Pr(\chi_{\nu}^2 > s_{\phi}^h(\widehat{\boldsymbol{\theta}}_i, \widehat{\boldsymbol{\theta}}_t)), \quad (3.2)$$

em que ν corresponde ao número de parâmetros do modelo estatístico considerado: $\nu = q^2$ para o caso da distribuição Wishart, $\nu = q(q + 3)/2$ para a distribuição Gaussiana multivariada com q variáveis e $\nu = 2$ para a distribuição par de intensidades. O p -valor fornece um indicativo de confiabilidade da decisão. A partir da obtenção dos p -valores para cada segmento classificado, é gerado um mapa em que se mostra, para cada segmento, uma tonalidade de cinza correspondente ao p -valor calculado no teste de hipótese. Esse mapa apresenta visualmente portanto um indicativo de confiabilidade da classificação obtida para certa imagem. Além disso, adotando-se um determinado nível de significância, como por exemplo 5%, obtém-se um novo produto que indica os segmentos cuja hipótese nula não foi rejeitada ao nível de confiança considerado. Este produto pode ser tomado como indicativo da qualidade da classificação.

A Figura 3.2 é apresentado um exemplo simples de classificação por regiões para ilustrar os produtos obtidos pelo classificador por regiões desenvolvido. Nas Figuras 3.2(a), 3.2(b), 3.2(c) e 3.2(d) são apresentadas, respectivamente, uma imagem PolSAR original, um exemplo de imagem classificada, um mapa de p -valores correspondente à imagem classificada (tonalidades de cinza) e um mapa indicativo dos segmentos cuja hipótese nula H_0 não foi rejeitada ao nível de significância de 5% (em branco).

Os módulos do classificador, com suas características, potencialidades e limitações serão descritos nas próximas subseções.

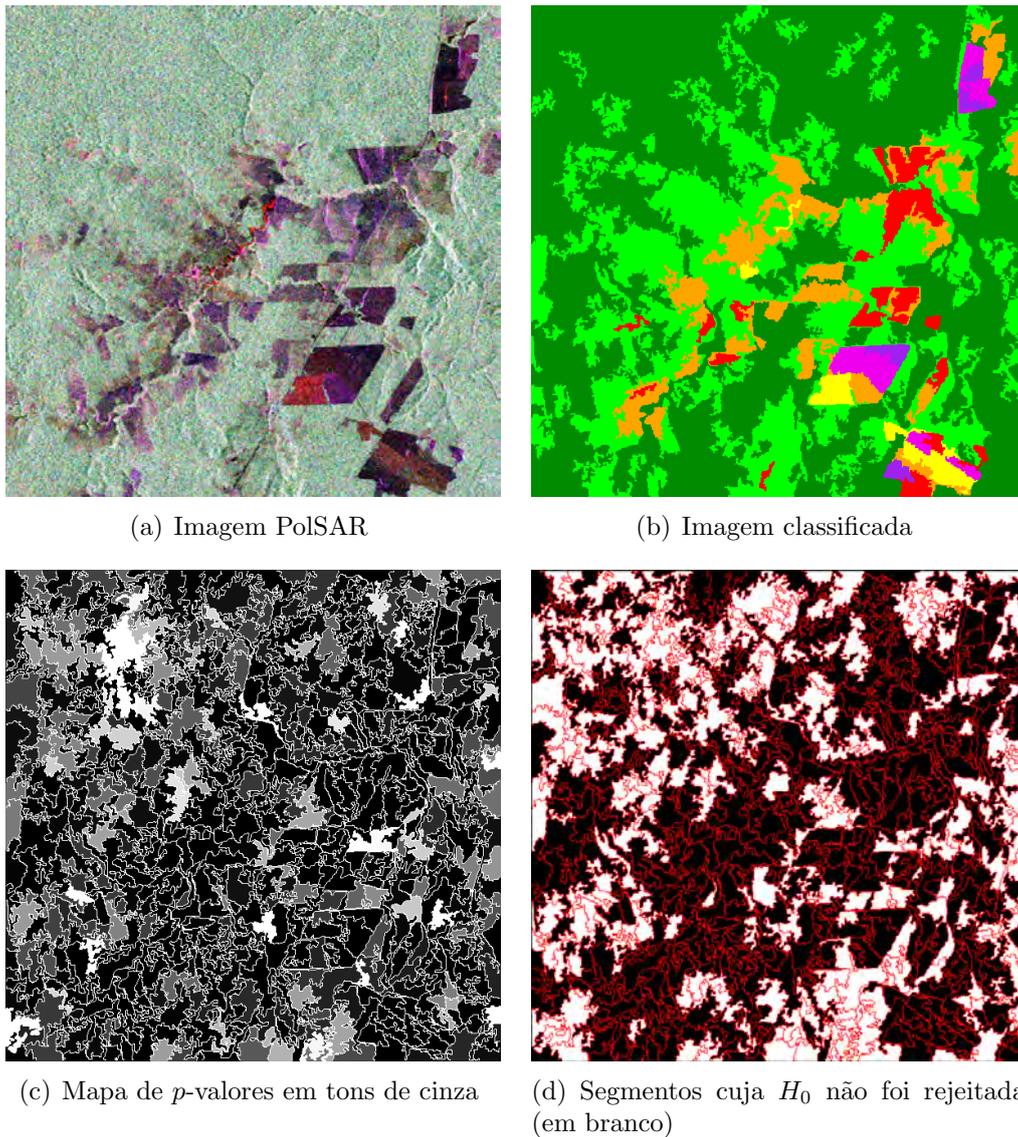


Figura 3.2 - Imagem PolSAR e exemplos de produtos gerados pelo classificador - exemplos.

3.2 Módulo para Imagens Polarimétricas

O módulo para as imagens polarimétricas utiliza como modelagem estatística a distribuição de Wishart complexa escalonada, com base no fato de que a matriz de covariância hermitiana segue essa distribuição, conforme discutido na seção 2.1.2.1. A aba do classificador que corresponde a esse módulo é apresentada na Figura 3.3.

Para a utilização do módulo para imagens polarimétricas são necessários os seguintes insumos: o arquivo correspondente à imagem polarimétrica no formato matriz

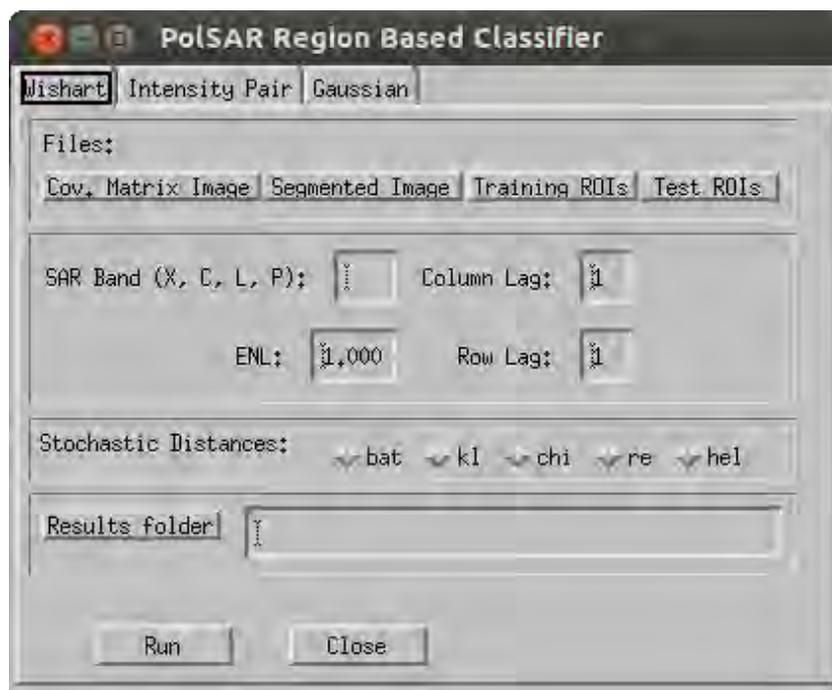


Figura 3.3 - Classificador por regiões: módulo para imagens PolSAR

de covariância em formato *Tagged Image File Format* (.TIF ou .TIFF) e do tipo complexo (*complex*) ou complexo de dupla precisão (*double complex*); o arquivo correspondente à imagem segmentada, cujos valores correspondam a identificadores das regiões, também no formato .TIF, do tipo inteiro longo (*long integer*); um arquivo, no formato ASCII para as amostras de treinamento e um arquivo ASCII para as amostras de teste.

A imagem polarimétrica no formato matriz de covariância precisa ser transformada para um formato de vetor contendo os elementos da diagonal principal da matriz (imagens em intensidade) e os elementos superiores à diagonal principal. Portanto o arquivo da imagem PolSAR utilizada terá menos elementos do que a matriz de covariância original. Juntamente com o classificador por regiões, é disponibilizado um programa em IDL para geração da imagem PolSAR no formato apropriado à entrada no classificador a partir de um arquivo com as bandas PolSAR originais (vetor de espalhamento), com possibilidade de processamento *multi-look*, com a amostragem desejada. Esse arquivo com as bandas originais PolSAR, por sua vez, precisa ser do formato do “software ENVI”, acompanhado do arquivo auxiliar no formato .HDR.

As amostras de treinamento e teste, independentemente do módulo do classifica-

dor utilizado, devem ser no formato ASCII. Essas amostras podem ser selecionadas através da ferramenta de seleção de regiões de interesse (ROIs) do ENVI e salvas no formato ASCII. Para o correto funcionamento do classificador por regiões, as amostras (ROIs) devem ser armazenadas somente com a informação de posição lexicográfica. No caso de armazenamento de quaisquer outro tipo de informações nesses arquivos ASCII das amostras, como o número índice do pixel ou as informações das bandas polarimétricas, serão ocasionados erros no funcionamento do classificador. Portanto, somente a posição dos pixels das amostras é relevante.

Um guia de utilização do classificador por regiões, com descrição das tarefas para obtenção correta dos insumos, a operacionalização do “software” e a descrição dos produtos obtidos acompanha este trabalho no apêndice A.

Ao se observar a interface do módulo para imagens polarimétricas, além dos insumos de entrada já comentados, pode-se atentar para a necessidade de se informarem alguns dados nos outros espaços disponíveis. Na ordem em que aparecem na interface (Fig. 3.3), as informações necessárias são:

- a banda SAR relativa às imagens utilizadas (SAR Band: X, C, L, P). Essa informação é apenas para compor o nome da imagem, com a informação relativa a banda SAR da imagem. A mesma pode ser omitida, caso em que o nome dos arquivos resultantes não irão conter a informação;
- o valor do número equivalente de *looks* (ENL) que deve ser previamente estimado para a imagem. Essa estimativa pode ser feita por alguns dos métodos aos quais se fez referência na subseção 2.1.2.1. Cabe ressaltar que este parâmetro, como se considera conhecido a priori, não acrescenta número de graus de liberdade ao teste $h-\phi$ a ser utilizado na classificação. Futuramente, pretende-se incorporar ao classificador uma solução de estimação de máxima-verossimilhança para o ENL, de forma não supervisionada, quando será então considerado mais um grau de liberdade no teste de hipótese.
- os valores de “lag” nas direções linha e coluna da imagem. Esses valores vão determinar uma subamostragem nos dados que serão utilizados na estimação dos parâmetros da modelagem estatística para os segmentos e para as classes.

A funcionalidade de subamostragem deve-se ao fato de existir correlação espacial entre os pixels espacialmente próximos em imagens reais. Como a teoria de estimação de parâmetros e o teste de hipótese utilizado para a classificação pressupõem independência dos dados, torna-se importante a utilização de amostras não correlacionadas, com vistas a maior aproximação com a teoria. A subamostragem minimiza ou até elimina a correlação. Entretanto, há redução da quantidade de amostras utilizadas, sendo essa redução maior a medida que os valores de lag são maiores. Essa redução pode acarretar prejuízo aos testes de hipótese tendo em vista que a estatística de teste segue uma distribuição assintótica e a quantidade de amostras utilizadas deve tender ao infinito. Existe então uma solução de compromisso entre o grau de subamostragem (valor do “lag”) e a quantidade de amostras utilizadas na estimação dos parâmetros, para que a aplicação do teste de hipótese seja ainda viável. No Capítulo 4, será apresentado um estudo sobre o impacto correlação espacial no teste de hipótese $h-\phi$, com utilização de dados gaussianos multivariados simulados e distância de Bhattacharyya.

Ainda na interface apresentada na Fig. 3.3, deve ser selecionada a distância a ser utilizada pelo classificador dentre as cinco distâncias disponíveis, Bhattacharyya, Kullback-Leibler, Rényi de ordem β , Hellinger e do Qui-quadrado (χ^2). O parâmetro β da distância de Rényi pode variar de acordo com a definição da distância. Entretanto, na implementação do classificador por regiões desenvolvido foi utilizado somente o valor de β igual a 0,9. Por fim, deve ser informado o diretório em que serão armazenados os produtos a serem gerados pelo classificador e ativado o botão *Run*, que dará início ao processo de classificação.

3.3 Módulo para Pares de Imagens em Intensidade

A motivação para o desenvolvimento de um módulo para pares de imagens SAR em intensidade pode ser relacionada com três evidências:

- A existência de modelagem estatística potencialmente apropriada a este tipo de dado SAR, supondo áreas homogêneas, desenvolvida por Lee et al. (1994a), pela derivação de um modelo Gama bivariado como distribuição marginal da distribuição Wishart Complexa, resultando na expressão da equação (2.15).
- Frequentemente, em situações práticas, dados polarimétricos completos

(quando se dispõe de toda informação de todas as polarizações, inclusive com as fases) não estão disponíveis ao usuário de Sensoriamento Remoto. Os dados polarimétricos completos são produtos muitas vezes específicos levando-se em conta o modo operacional dos sistemas SAR atuais, além de serem bem mais caros. Alguns sistemas satélites/sensores SAR orbitais podem ser citados como exemplos: o Radarsat-2, que fornece as intensidades nas polarizações HH, VV, HV e VH, enquanto configurações duais de intensidade são disponíveis do Envisat (HH,HV ou VV,VH) e do Cosmos Skymed (HH,HV ou HH,VV). Nesses casos, somente os elementos da diagonal principal da matriz de covariância são fornecidos.

- Alguns resultados encontrados na literatura mostram que, para determinadas classes específicas, os dados incompletos, como imagens em intensidade, podem alcançar resultados de classificação estatisticamente iguais aos obtidos quando da utilização de dados polarimétricos completos. Em [Lee et al. \(1995\)](#) e [Lee et al. \(2001\)](#) foram obtidos resultados compatíveis com essa conclusão para classes de crescimento florestal, utilizando-se classificação por máxima verossimilhança pontual com a modelagem da equação (2.15). Em [Negri \(2009\)](#), com a utilização da mesma modelagem, com classificação pontual e contextual por máxima verossimilhança/ICM ([FRERY et al., 2007](#)), foram obtidos resultados estatisticamente iguais de classificação entre dados polarimétricos completos e pares de imagens SAR em intensidade.

Diante dessas justificativas teóricas e práticas advindas da literatura, identificou-se um grande potencial de aplicação de um classificador por regiões utilizando-se a modelagem para pares de intensidade, quando da disponibilidade de dados polarimétricos incompletos, especificamente imagens SAR em intensidade *multi-look*.

A partir da densidade do Par de intensidades *multi-look*, derivada por [Lee et al. \(1994a\)](#), expressa na equação (2.15), deve-se então obter, utilizando-se a metodologia para obtenção de distâncias estocásticas desenvolvida por [Salicru et al. \(1994\)](#), uma solução para distâncias estocásticas entre modelos Par de intensidade *multi-look*.

Para explicação deste procedimento, será utilizado um exemplo de cálculo de separabilidade entre duas distribuições Par de intensidades, que modelam respectivamente duas regiões de um par de imagens em intensidade. Na Figura 3.4, mostra-se esque-

maticamente um par de imagens em intensidade (R_1, R_2) onde duas regiões **I** e **II** delimitadas são modeladas por distribuições Par de Intensidades, com parâmetros $h_{11}(\mathbf{I})$, $h_{22}(\mathbf{I})$ e $|\rho_c|(\mathbf{I})$ e densidade $f_{\mathbf{I}}(r_1, r_2)$, para a região **I**, e $h_{11}(\mathbf{II})$, $h_{22}(\mathbf{II})$ e $|\rho_c|(\mathbf{II})$ e densidade $f_{\mathbf{II}}(r_1, r_2)$, para a região **II**.

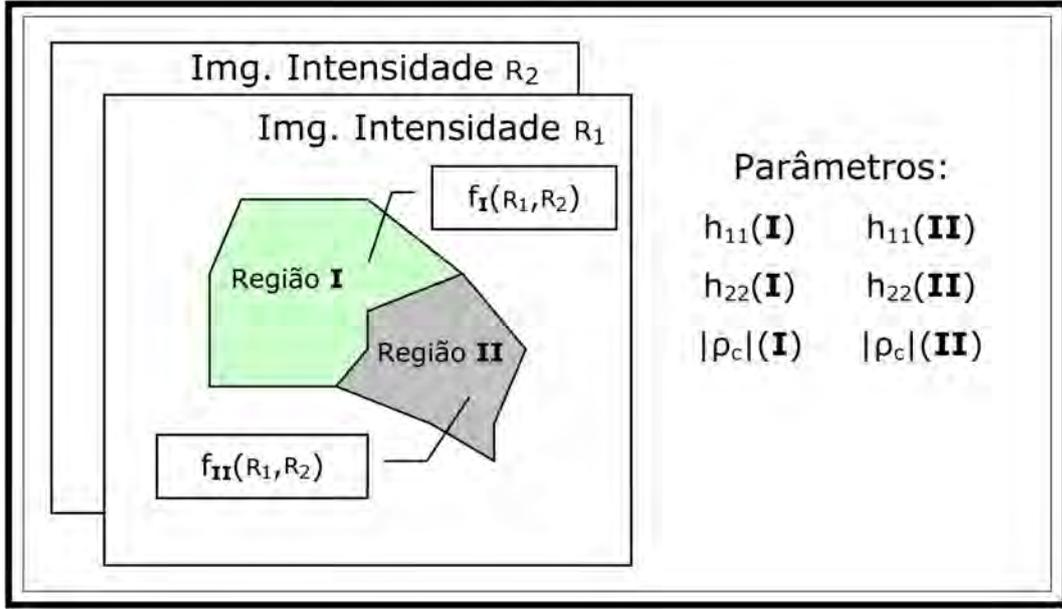


Figura 3.4 - Regiões modeladas por distribuições *Par de Intensidades Multilook*.

Será então desenvolvida a solução para a seguinte equação genérica que aplica a divergência h - ϕ (equação (3.3)) às duas densidades do Par de Intensidades *multilook* $f_{\mathbf{I}}(r_1, r_2)$ e $f_{\mathbf{II}}(r_1, r_2)$. Para fins de simplificação da notação, as densidades serão identificadas, respectivamente, por $f_{\mathbf{I}}$ e $f_{\mathbf{II}}$ e, além disso serão omitidos o suporte de integração e os integradores.

$$D_{\phi}^h(f_{\mathbf{I}}, f_{\mathbf{II}}) = h \left(\iint \phi \left(\frac{f_{\mathbf{I}}}{f_{\mathbf{II}}} \right) f_{\mathbf{II}} \right) \quad (3.3)$$

Com o objetivo do cálculo das distâncias estocásticas por métodos numéricos, podem-se utilizar as expressões em função de integrais obtidas em Nascimento et al. (2010), apresentadas nas equações (2.30)–(2.35). Tomando-se por exemplo as distâncias de Bhattacharyya (Eq. (2.33)) e triangular (Eq. (2.35)), pode-se tomar essa tarefa como a resolução das expressões apresentadas na equações (3.4) e (3.5).

$$d_{\text{PIB}}(f_{\mathbf{I}}, f_{\mathbf{II}}) = -\log \left(\iint \sqrt{f_{\mathbf{I}} f_{\mathbf{II}}} \right), \quad (3.4)$$

$$d_{\text{PIT}}(f_{\mathbf{I}}, f_{\mathbf{II}}) = \iint \frac{(f_{\mathbf{I}} f_{\mathbf{II}})^2}{f_{\mathbf{I}} + f_{\mathbf{II}}}. \quad (3.5)$$

É importante ressaltar na discussão acerca do emprego deste módulo para a classificação uma observação quanto à estimação dos parâmetros e ao teste de hipótese. A distribuição do Par de Intensidades *Multi-Look* tem, além do número equivalente de *looks*, que se considera conhecido neste trabalho, mais três parâmetros. São duas médias das intensidades (h_{11} e h_{22}), cujo estimador, apresentado pelas equações (2.21) e (2.22), tem por base o método de máxima verossimilhança, e o módulo do coeficiente de correlação complexa ($|\rho_c|$), que é apresentado na equação (2.23) e é estimado pelo método dos momentos. A estimativa do módulo do coeficiente de correlação complexa pelo método dos momentos impossibilita a contabilização desse parâmetro no número de graus de liberdade da distribuição Qui-quadrado utilizada no teste de hipótese da classificação. Portanto, o teste de hipótese utiliza uma distribuição Qui-quadrado com apenas dois graus de liberdade tendo em vista que, pela teoria do teste de hipótese h - ϕ , o estimador dos parâmetros deve ser o de máxima verossimilhança. Futuramente, pretende-se obter um estimador por máxima verossimilhança para o parâmetro $|\rho_c|$ e computá-lo no número de graus de liberdade do teste.

Levando-se em conta a complexidade analítica que envolve o procedimento para obtenção de medidas da classe h - ϕ de divergências (Eq. (2.28)) com a densidade associada à distribuição Par de Intensidades, apresentada na equação (2.15), pode-se concluir que a tarefa de derivação analítica de uma expressão fechada para distância estocástica entre essas densidades constitui-se em uma árdua tarefa. Algumas tentativas foram feitas com vistas a obtenção dessa expressão fechada para as distâncias, cujas fórmulas em função de integrais estão disponíveis. Entretanto, devido à dependência da função modificada de Bessel de ordem $L - 1$ (I_{L-1}), em que L é o número equivalente de visadas, a resolução da integral dupla resultante foi, até então, mal sucedida. Portanto, não se dispõe atualmente de uma expressão fechada para qualquer distância estocástica entre densidades do Par de intensidades *multi-look*.

Portanto, neste trabalho, a solução adotada para a obtenção da distância estocástica entre duas densidades do Par de Intensidades foi a utilização de um método numérico. Conforme já comentado, utilizou-se a função da linguagem IDL conhecida como *Int_2D*, que tem por base o método de Quadratura Gaussiana Iterativa, com uma modificação para adequação dos limites de integração ao domínio das densidades envolvidas. Neste caso, trata-se de duas densidades que caracterizam distribuições gama, cujo suporte varia de zero a infinito. Na prática, foi criada uma função para obtenção do valor das variáveis r_1 e r_2 que correspondessem aos valores de função de distribuição acumulada de 0,999. Admitiu-se que este valor de função de distribuição acumulada seriam relativos a valores de r_1 e r_2 que poderiam ser considerados como tendendo ao infinito para fins práticos. Para cada segmento e classe de interesse, este procedimento de obtenção dos limites de integração é feito, levando a um elevado custo computacional para esta solução, além do elevado custo computacional devido ao método numérico iterativo de solução de integrais duplas. Portanto, a classificação de imagens com este módulo demora, em média, aproximadamente dez vezes mais do que com os outros dois módulos, que utilizam uma expressão fechada para cálculo da distância.

A interface do módulo para pares de imagens em intensidade é bastante semelhante ao módulo para imagens polarimétricas e é apresentada na Fig. 3.5

Para a utilização do módulo para pares de imagens em intensidade são necessários os seguintes insumos: o arquivo no formato *Tagged Image File Format* (.TIF ou .TIFF) com as duas imagens de intensidade; o arquivo correspondente à imagem segmentada também no formato .TIF, do tipo inteiro longo (*long integer*); um arquivo, no formato ASCII para as amostras de treinamento e um arquivo ASCII para as amostras de teste. Além desses insumos necessários ao processo de classificação, deve-se selecionar a distância estocástica a ser utilizada no processo de classificação. Existem duas opções para esses módulo, a distância de Bhattacharyya e a distância Triangular. A solução para o cálculo dos valores das distâncias é numérica, portanto várias outras distâncias poderiam ser implementadas utilizando-se as fórmulas de distâncias em função de integrais relacionadas nas equações (2.30)–(2.35). A escolha, inicialmente, pela implementação das distâncias de Bhattacharyya e Triangular se deu pelas seguintes razões: a primeira é uma medida tradicionalmente utilizada nos problemas de processamento de imagens de sensores remotos, em tarefas de classificação e seleção de atributos, por exemplo. Assim, decidiu-se por disponibilizar essa

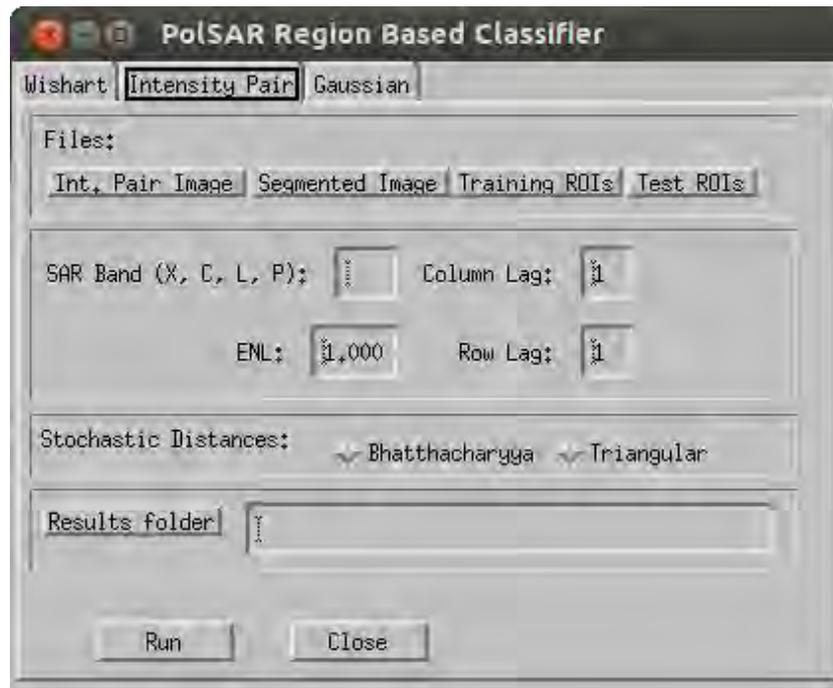


Figura 3.5 - Classificador por regiões: módulo para pares de imagens em intensidade.

distância em uma ferramenta de aplicação a dados de sensores remotos. A segunda foi escolhida em função dos resultados obtidos por Nascimento et al. (2010), em que a distância Triangular, dentre oito distâncias avaliadas, obteve os melhores resultados com relação ao tamanho do teste utilizando-se a modelagem estatística \mathcal{G}_I^0 . Futuramente, outras distâncias serão implementadas utilizando-se solução numérica e disponibilizadas no classificador por regiões.

Por fim, pode-se reconhecer que o módulo para classificação de pares de imagem em intensidade se constitui em uma ferramenta destinada a uma importante aplicação, servindo-se de modelagem estatística apropriada aos dados SAR bivariados, atendendo a uma significativa demanda atual do Sensoriamento Remoto.

3.4 Módulo para Imagens Óticas e Imagens SAR Multivariadas em Amplitude

Classificadores por regiões utilizando distâncias estocásticas entre distribuições gaussianas são ferramentas já disponíveis na comunidade do Sensoriamento Remoto. O classificador por regiões do “software” SPRING é um bom exemplo. A motivação para a implementação, neste classificador por regiões, de um módulo utilizando

distâncias estocásticas entre distribuições gaussianas está baseada em duas evidências: a primeira pelo fato de estarem disponíveis expressões fechadas para algumas dessas distâncias entre modelos gaussianos multivariados, a saber, a distância de Bhattacharyya e a de Kullback-Leibler. A segunda evidência seria o fato de, com a utilização do teste de hipóteses $h-\phi$, haver a possibilidade da geração de um produto que fornece a confiabilidade da classificação ao se utilizarem os p -valores do teste para geração de um mapa associado a cada classificação.

Portanto, foi implementado o módulo de classificação utilizando-se distâncias entre modelos gaussianos multivariados, que seria adequado a dados óticos em geral e a imagens SAR em amplitude, sobretudo quando decorrentes de processamento *multi-look* com elevado número de visadas.

A interface do módulo que utiliza modelagem gaussiana está ilustrada pela Fig. 3.6.



Figura 3.6 - Classificador por regiões: módulo para imagens óticas e SAR em amplitude.

Com relação à interface deste módulo, percebe-se que os insumos são bastante similares aos dos outros dois módulos, ressaltando-se a diferença com relação à imagem a ser classificada. O arquivo que contém a imagem multivariada deve ser do formato .TIFF, com todas as bandas da imagem.

As expressões apresentadas pelas equações (2.50) e (2.51) são utilizadas no módulo

do classificador por regiões para dados SAR multivariados em amplitude *multi-look* e para dados óticos, supondo-se que esses possam ser modelados pela distribuição gaussiana multivariada.

Este módulo do classificador por regiões ora proposto representa uma contribuição importante tendo em vista que, além de utilizar distâncias estocásticas entre dois modelos gaussianos, utiliza o resultado do cálculo de uma estatística de teste que leva em conta também as quantidades de amostras, além da distância $h-\phi$.

3.5 Comentários Complementares Sobre a Contribuição do Classificador por Regiões

O presente trabalho apresenta um classificador que se fundamenta no cálculo da mínima estatística de teste $h-\phi$ entre as distribuições que modelam cada segmento e as classes de interesse selecionadas pelo usuário (classificação supervisionada), com a produção adicional de um indicador da qualidade através do cálculo do p -valor para cada teste de hipótese realizado. O classificador proposto utiliza, para cada imagem a ser processada, uma estimativa para medida de distância e, conseqüentemente, uma estimativa para estatística de teste de cada vez. Identificam-se contribuições importantes no trabalho ora desenvolvido:

- O classificador por regiões para imagens SAR polarimétricas, tendo em vista que as pesquisas realizadas tem se concentrado na busca por classificadores pontuais e contextuais;
- A utilização da estatística de teste para classificação, o que pode trazer melhores resultados quando comparada à utilização simples do valor da distância estocástica para classificação, uma vez que a estatística de teste utiliza no seu cômputo os valores de números de amostras dos segmentos e das amostras das classes;
- A geração de mapas de p -valor, que funcionam como indicativo da confiabilidade da classificação resultante.

A título de complementação, pode-se ressaltar que a regra fornecida pela desigualdade da equação (3.1) traz ainda um número de alternativas interessantes a serem investigadas e possivelmente implementadas. Dentre elas, pode-se destacar a possibilidade de utilização de todas as estatísticas disponíveis, com a classificação feita

pelo voto da maioria, o que poderia trazer melhores resultados em relação à utilização de uma única medida. Outra observação importante diz respeito à informação fornecida pela equação (3.2), que poderia também ser utilizada em uma classificação por lógica nebulosa, com o conceito de classificação imprecisa (DRUMMOND; SANDRI, 2006). Cada segmento poderia ser classificado em diferentes classes, com graus de pertinência diferenciados, desde que os valores de p -valor das classificações obtidos superem determinado limite mínimo. Essas alternativas poderão vir a ser implementadas e avaliadas em trabalhos futuros.

4 APLICAÇÕES E AVALIAÇÃO DO CLASSIFICADOR

4.1 Avaliação da Influência da Autocorrelação Espacial no Desempenho do Teste de Hipóteses $h-\phi$.

4.1.1 Autocorrelação espacial

Sabe-se que as imagens provenientes de sensores remotos, tanto óticos quanto SAR, normalmente apresentam significativa correlação espacial entre os dados. Este efeito é inerente à formação das imagens. Não muito raramente, a classificação de imagens de sensoriamento remoto por modelagem estatística, em que intrinsecamente está envolvida a estimação de parâmetros, é realizada negligenciando-se essa questão.

A correlação espacial muitas vezes é também denominada autocorrelação, e sua interpretação é desenvolvida sob o viés de séries temporais. De acordo com [Everitt e Skrondal \(2010\)](#), autocorrelação seria a correlação interna das observações em uma série temporal, usualmente expressada como uma função do atraso temporal (conhecido pelo termo *lag*) entre observações. Em um contexto ligeiramente distinto, recebe de forma comum o termo autocorrelação espacial, quando sua medida é calculada entre pontos distanciados em um conjunto de dados espaciais, como no caso de uma imagem. Esta abordagem consiste no caso de interesse para este trabalho, em que estuda-se o valor da autocorrelação entre pixels da imagem que distam entre si de um certo valor de *lag* (espacial) em determinada direção. A questão multidirecional na abordagem espacial representa uma importante diferença com relação ao contexto das séries temporais, tendo em vista que as possibilidades de cálculo de autocorrelação são muito maiores naquele contexto do que em relação a este último.

De acordo com as suposições apresentadas por [Priestley \(1982\)](#), e com adaptação para o contexto espacial, a autocorrelação de *lag* (x,y) , $\gamma(x,y)$, pode ser expressa matematicamente pela equação (4.1):

$$\gamma(x,y) = \frac{\text{E}[(X_{ij} - \mu)(X_{i+x,j+y} - \mu)]}{\text{E}(X_{ij} - \mu)^2}, \quad (4.1)$$

em que X_{ij} são os valores dos pixels em determinada posição (i,j) , μ é a média desses pixels e $\text{E}(\cdot)$ é o valor esperado. A autocorrelação, em uma imagem de dimensões $N_x \times N_y$, pode ser estimada através de uma amostra de acordo com a equação 4.2:

$$\hat{\gamma}(x,y) = \frac{\sum_{i=k_x}^{K_x} \sum_{j=k_y}^{K_y} [(X_{ij} - \hat{\mu})(X_{i+x,j+y} - \hat{\mu})]}{\sum_{i=1}^{N_x} \sum_{j=1}^{N_y} (X_{ij} - \hat{\mu})^2}, \quad (4.2)$$

em que

$$k_x = \max(1, 1 - x), \quad k_y = \max(1, 1 - y), \quad (4.3)$$

$$K_x = \min(N_x, N_x - x), \quad K_y = \min(N_y, N_y - x), \quad (4.4)$$

e $\hat{\mu}$ é a média dos valores observados. A relação do valor da autocorrelação em função do valor de *lag* recebe o nome de função de autocorrelação.

Uma análise prática a respeito da influência da autocorrelação em dados simulados sobre o teste de hipótese $h-\phi$ será desenvolvida na subseção 4.1.2.

4.1.2 Descrição do Experimento e Resultados

O teste de hipóteses descrito na subseção 2.3 tem por base teórica a utilização de amostras independentes. Com o intuito de se verificar quantitativamente a influência da autocorrelação no desempenho do teste de hipótese será desenvolvido nesta seção um experimento em que dados simulados, com diferentes graus de correlação e sob diversas configurações de parâmetros estatísticos, serão submetidos ao teste de hipótese $h-\phi$. O desempenho do teste será verificado por meio da observação dos valores de estimativas para o tamanho do teste.

Os dados foram gerados seguindo a distribuição gaussiana multivariada, e com uma estrutura de correlação espacial com base no método da decomposição da matriz de covariância por autovalores e autovetores, conforme descrito em Freitas (1991). A função de autocorrelação bidimensional utilizada é expressa pela equação (4.5).

$$\gamma(x,y) = \exp \{ -\alpha(x - y)^2 \}, \quad (4.5)$$

em que x e y são as distâncias (*lags*) nas direções horizontal e vertical, respectivamente, e o parâmetro $\alpha \in \mathbb{R}_+$ controla o grau de autocorrelação. Para pequenos valores de α , a autocorrelação é alta, e diminui a medida que se aumenta o α .

Com a finalidade de visualização da variação do grau de correlação a medida que se altera o valor do parâmetro α , foram geradas curvas da autocorrelação espacial unidimensional ($\gamma(x)$) para diferentes valores de α . Essas curvas são apresentadas na Figura 4.1.

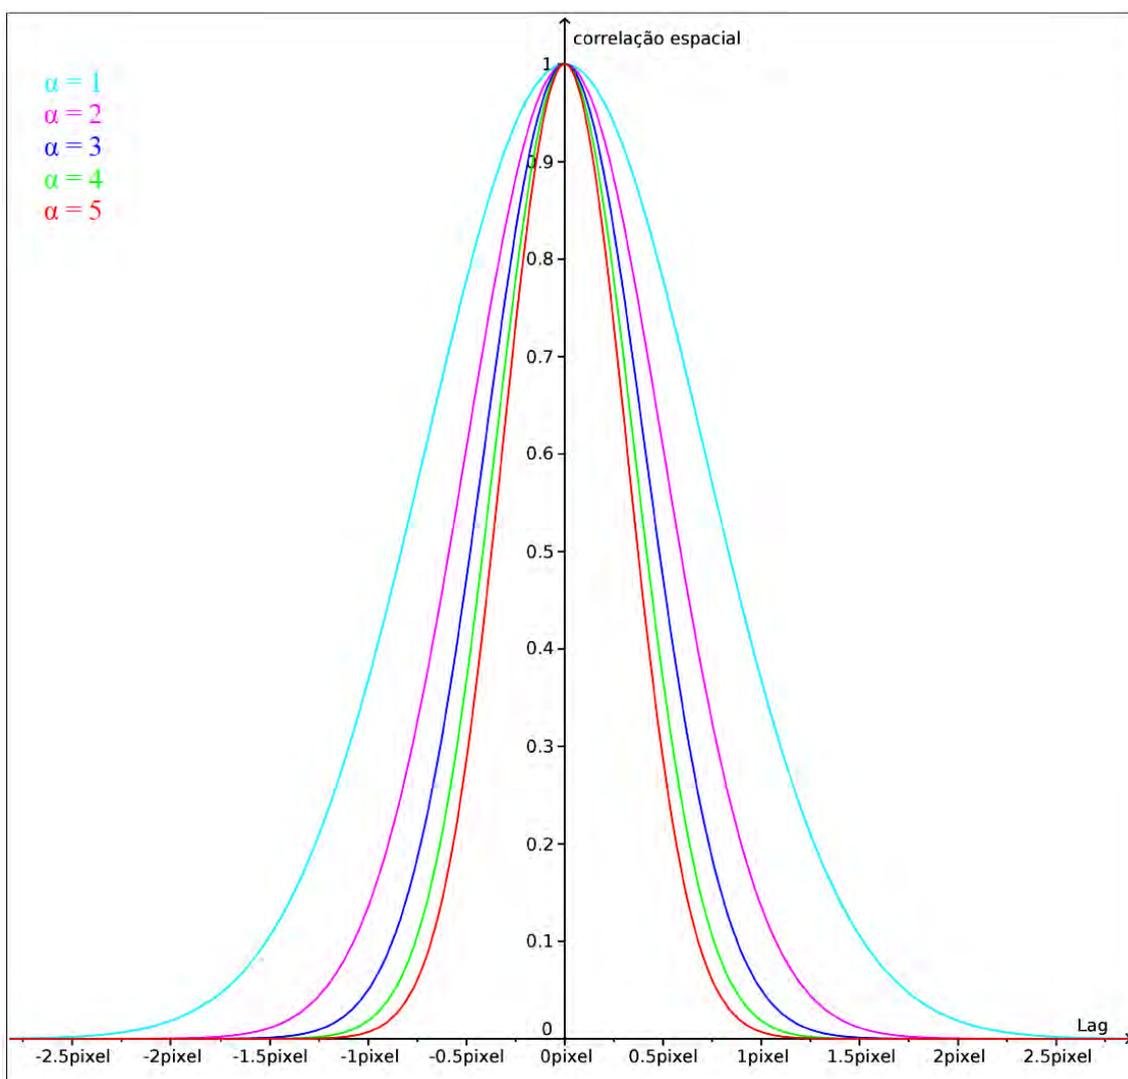


Figura 4.1 - Correlação espacial unidimensional em função do *lag* para diferentes valores de α .

A partir da Figura 4.1, algumas observações podem ser feitas sobre curvas de autocorrelação espacial unidimensional. Observa-se que a curva referente a $\alpha = 1$ apresenta um valor de aproximadamente 0,4 de autocorrelação para a distância correspondente ao *lag* de 1pixel. Para o mesmo valor de *lag*, na curva referente ao

parâmetro $\alpha = 2$, o valor da correlação é de aproximadamente 0,13. O valor da autocorrelação espacial decresce a medida que se aumenta o valor do α . Verificam-se valores muito baixos para a autocorrelação com o *lag* de 1 pixel, para $\alpha > 3$. Nesses casos os dados podem ser considerados praticamente descorrelacionados quando as curvas referentes aos $\alpha = 3, 4$ e 5 apresentam valores de autocorrelação, respectivamente, de 0,05; 0,02 e 0,007.

Em Sant'Anna e Freitas (2005), foi utilizado o mesmo método de simulação de processos aleatórios gaussianos correlacionados baseado na decomposição da matriz de covariância por autovalores e autovetores. Neste método admite-se que o processo bidimensional seja separável, ou seja, a matriz de covariância V deste processo pode ser escrita na forma de um produto de Kronecker entre as matrizes de covariância nas direções ortogonais x e y ($V = V_x \otimes V_y$). Assim, a realização de um processo bidimensional gaussiano correlacionado a pode ser descrita por um produto de matrizes dado pela equação (4.6):

$$a = P\Lambda^{\frac{1}{2}}\epsilon_{ij}, \quad (4.6)$$

com $P = P_x \otimes P_y$ e $\Lambda = \Lambda_x^{\frac{1}{2}} \otimes \Lambda_y^{\frac{1}{2}}$, em que ϵ_{ij} ($i = 1, \dots, n_x$ e $j = 1, \dots, n_y$) é uma realização de um processo gaussiano com média zero e variância unitária, Λ_x e Λ_y são as matrizes diagonais dos autovalores de V_x e V_y , respectivamente, e P_x e P_y são matrizes de dimensão $n_x \times n_x$ e $n_y \times n_y$ de autovetores ortonormais de V_x e V_y , respectivamente.

O experimento se desenvolveu segundo as seguintes configurações:

- número de simulações em cada configuração de parâmetros: 5000;
- modelagem estatística dos dados: gaussiana multivariada. Foram feitas simulações com dados com uma até quatro variáveis;
- seis valores para o parâmetro α são utilizados: 1, 2, 3, 4, 5 e 6;
- os valores dos parâmetros dos modelos gaussianos simulados são apresentados na Tabela 4.1;
- números de amostras: 100, 225 e 400 amostras para cada grupo de dados gerado.

Tabela 4.1 - Parâmetros dos modelos gaussianos simulados.

Parâmetros	Número de variáveis			
	1 variável	2 variáveis	3 variáveis	4 variáveis
Médias utilizadas (dois valores para cada variável)	10 e 100	10 e 100 15 e 150	10 e 100 15 e 150 25 e 500	10 e 100 15 e 150 25 e 500 55 e 750
Desvios padrões utilizados (três para cada valor de média)	2,5; 10; e 20 25; 100; e 200	2,5; 10; e 20 25; 100; e 200 3,75; 15; e 30 37,5; 150; e 300	2,5; 10; e 20 25; 100; e 200 3,75; 15; e 30 37,5; 150; e 300 6,25; 25; e 50 125; 500; e 1000	2,5; 10; e 20 25; 100; e 200 3,75; 15; e 30 37,5; 150; e 300 6,25; 25; e 50 125; 500; e 1000 13,75; 55; e 110 187,5; 750; e 1500
Matriz de correlação entre variáveis		$\begin{bmatrix} 1 & 0,6 \\ 0,6 & 1 \end{bmatrix}$	$\begin{bmatrix} 1 & 0,5 & 0,9 \\ 0,5 & 1 & 0,2 \\ 0,9 & 0,2 & 1 \end{bmatrix}$	$\begin{bmatrix} 1 & 0,5 & 0,6 & 0,8 \\ 0,5 & 1 & 0,7 & 0,3 \\ 0,6 & 0,7 & 1 & 0,55 \\ 0,8 & 0,3 & 0,55 & 1 \end{bmatrix}$

Disponha-se então, para cada conjunto de parâmetros, para cada um dos números de variáveis diferentes, duas possibilidades de valores de médias, três possibilidades de valores de desvio padrão, três valores de tamanho de amostras e seis valores de α , que controlam a correlação. Esta quantidade resulta então em dezoito resultados de tamanho do teste diferentes para cada valor de α .

Foram realizadas então 5000 repetições do experimento para cada um desses conjuntos de parâmetros. O experimento consistia em simular dois conjuntos de dados com parâmetros iguais, inclusive o número de amostras, e fazer o teste de hipótese $h-\phi$, registrando se a hipótese nula (igualdade entre os parâmetros) havia sido rejeitada. O índice de rejeição da hipótese nula, ou seja, a razão entre o número de realizações do experimento em que a hipótese foi rejeitada e o número total de experimentos, indica o tamanho do teste. A estatística de teste s_{ϕ}^h utilizada foi a obtida a partir da distância de Bhattacharyya entre modelos gaussianos, expressa pela equação (2.51). Para os testes de hipótese aplicados, foi utilizado o valor de nível de significância de 5%. Esperava-se, portanto, que os tamanhos de teste encontrados pelo experimento fossem iguais a esse valor.

Os resultados de tamanho do teste encontrados, organizados em função dos parâmetros dos experimentos, estão divididos em três tabelas para uma melhor apresen-

tação. Os resultados relativos aos valores de α iguais a 1 e 2 estão apresentados na Tabela 4.2, os relativos aos valores de α iguais a 3 e 4 estão apresentados na Tabela 4.3 e os relativos aos valores de α iguais a 5 e 6 estão apresentados na Tabela 4.4. Nas colunas das tabelas supramencionadas referentes aos parâmetros média e desvio padrão, são apresentados os valores para o caso dos dados com quatro variáveis, para fins de ilustração. Para os outros casos, com menos variáveis, basta suprimir os últimos valores, adequadamente.

Pode-se observar, analisando as Tabelas 4.2–4.4 que os valores de tamanho de teste variam consideravelmente em função de alguns dos parâmetros enquanto outros parâmetros não têm influência significativa. A primeira análise pode ser feita com relação ao parâmetro α , que está relacionado com o grau de correlação espacial entre os dados, conforme ilustrado pela equação (4.5). Para os menores valores de α utilizados, que representam elevados valores de autocorrelação espacial, o índice de rejeição do teste (tamanho do teste) foi bem maior do que o valor teórico esperado, o nível de significância do teste, que no caso era de 5%. Com α igual a 1, foram obtidos tamanhos de teste em torno de 26% para dados univariados, 37% para dados com duas variáveis, 50% para dados com três variáveis e 60% para dados com quatro variáveis. Valores bem maiores do que o esperado para o tamanho do teste também foram encontrados para valores de α iguais a 2 e 3.

Os resultados de tamanho do teste mostram a influência da autocorrelação nos dados no desempenho do teste de hipótese $h-\phi$, uma vez que em dados com alto grau de correlação, simulados neste caso com a escolha de baixos valores do parâmetro α , o teste tende a rejeitar mais a hipótese nula do que seria esperado. Com valores de α entre 4 e 6, os valores de tamanho de teste são mais próximos do nível de significância, mostrando que em dados menos correlacionados, ou sem correlação, o teste de hipótese tem desempenho compatível com o teoricamente esperado, principalmente quando da utilização de dados com menos variáveis, como será analisado a seguir.

O número de variáveis é outro parâmetro de interesse a ser analisado. Verifica-se, a partir dos resultados nas tabelas, que o tamanho do teste, para um mesmo valor de α , é maior para dados com mais variáveis e que, portanto, o teste de hipóteses $h-\phi$ é mais influenciado pela autocorrelação com dados de maior dimensão.

Os outros parâmetros não mostram evidência de influência no desempenho do teste. A variação de valores de média, de desvio-padrão e de número de amostras não

Tabela 4.2 - Resultados do experimento ($\alpha = 1$ e 2).

Alfa	n° de amostras	valor dos parâmetros		índice de rejeição (%) - Tamanho do teste			
		médias	desvios padrão	1 banda	2 bandas	3 bandas	4 bandas
1	100	10; 15; 25; 55	2,5; 3,75; 6,25; 13,75	26,48	37,62	48,68	59,48
			10; 15; 25; 55	26,14	38,12	49,68	59,64
			20; 30; 50; 110	25,28	37,64	48,96	60,00
		100; 150; 500; 750	25; 375; 125; 187,5	26,36	37,50	48,16	58,54
			100; 150; 500; 750	24,66	38,86	48,20	61,48
			200; 300; 1000; 1500	24,10	38,06	47,72	59,72
	225	10; 15; 25; 55	2,5; 3,75; 6,25; 13,75	25,82	39,62	49,70	61,20
			10; 15; 25; 55	25,96	39,14	49,94	60,22
			20; 30; 50; 110	25,46	38,24	49,90	59,58
		100; 150; 500; 750	25; 375; 125; 187,5	26,02	39,56	50,06	60,08
			100; 150; 500; 750	25,42	38,72	48,78	60,00
			200; 300; 1000; 1500	26,30	38,46	48,98	60,76
	400	10; 15; 25; 55	2,5; 3,75; 6,25; 13,75	26,74	39,46	49,56	61,20
			10; 15; 25; 55	26,36	39,28	51,06	60,90
			20; 30; 50; 110	26,92	39,50	50,86	60,48
		100; 150; 500; 750	25; 375; 125; 187,5	26,64	40,52	50,36	60,54
			100; 150; 500; 750	27,16	38,92	50,76	59,70
			200; 300; 1000; 1500	26,72	38,58	49,72	61,16
2	100	10; 15; 25; 55	2,5; 3,75; 6,25; 13,75	10,70	13,12	13,72	16,32
			10; 15; 25; 55	11,76	12,82	14,34	16,08
			20; 30; 50; 110	11,28	13,22	14,22	16,44
		100; 150; 500; 750	25; 375; 125; 187,5	10,38	12,16	13,98	16,90
			100; 150; 500; 750	10,08	13,06	14,30	15,72
			200; 300; 1000; 1500	11,02	13,10	14,56	16,72
	225	10; 15; 25; 55	2,5; 3,75; 6,25; 13,75	9,72	11,92	13,60	16,40
			10; 15; 25; 55	10,42	12,64	14,28	16,06
			20; 30; 50; 110	10,70	12,52	14,60	16,34
		100; 150; 500; 750	25; 375; 125; 187,5	10,10	12,46	14,86	15,48
			100; 150; 500; 750	10,30	12,86	13,76	16,10
			200; 300; 1000; 1500	10,00	12,34	13,54	15,80
	400	10; 15; 25; 55	2,5; 3,75; 6,25; 13,75	10,68	12,54	14,50	15,94
			10; 15; 25; 55	10,70	12,30	13,64	15,02
			20; 30; 50; 110	10,18	12,50	13,48	14,98
		100; 150; 500; 750	25; 375; 125; 187,5	10,40	11,72	14,90	15,80
			100; 150; 500; 750	11,20	13,44	14,74	15,32
			200; 300; 1000; 1500	10,48	13,14	12,96	15,34

Tabela 4.3 - Resultados do experimento ($\alpha = 3$ e 4).

Alfa	n° de amostras	valor dos parâmetros		índice de rejeição (%) - Tamanho do teste			
		médias	desvios padrão	1 banda	2 bandas	3 bandas	4 bandas
3	100	10; 15; 25; 55	2,5; 3,75; 6,25; 13,75	7,18	7,78	8,42	8,94
			10; 15; 25; 55	6,84	7,60	8,26	8,08
			20; 30; 50; 110	6,56	7,68	7,62	9,24
		100; 150; 500; 750	25; 375; 125; 187,5	7,38	8,20	7,60	7,68
			100; 150; 500; 750	6,48	8,04	8,62	8,70
			200; 300; 1000; 1500	6,66	7,72	7,54	8,88
	225	10; 15; 25; 55	2,5; 3,75; 6,25; 13,75	6,30	7,64	7,20	7,82
			10; 15; 25; 55	6,78	7,26	7,48	7,12
			20; 30; 50; 110	7,12	7,48	7,46	8,16
		100; 150; 500; 750	25; 375; 125; 187,5	6,68	6,90	7,74	7,94
			100; 150; 500; 750	7,38	6,60	7,92	8,36
			200; 300; 1000; 1500	7,02	6,98	7,00	7,80
	400	10; 15; 25; 55	2,5; 3,75; 6,25; 13,75	6,36	7,46	7,56	7,56
			10; 15; 25; 55	6,76	6,90	7,14	7,60
			20; 30; 50; 110	7,00	6,72	7,56	6,92
		100; 150; 500; 750	25; 375; 125; 187,5	6,46	6,44	7,76	7,48
			100; 150; 500; 750	6,88	6,86	7,72	7,66
			200; 300; 1000; 1500	6,72	7,16	7,06	7,44
4	100	10; 15; 25; 55	2,5; 3,75; 6,25; 13,75	5,84	5,34	6,38	7,24
			10; 15; 25; 55	5,82	5,70	7,16	7,54
			20; 30; 50; 110	5,88	6,10	6,16	6,50
		100; 150; 500; 750	25; 375; 125; 187,5	5,24	6,64	6,36	6,70
			100; 150; 500; 750	5,48	6,22	6,64	7,04
			200; 300; 1000; 1500	5,68	6,10	6,36	7,30
	225	10; 15; 25; 55	2,5; 3,75; 6,25; 13,75	5,70	5,44	6,50	5,88
			10; 15; 25; 55	6,46	5,88	5,58	6,58
			20; 30; 50; 110	5,58	5,86	5,82	6,44
		100; 150; 500; 750	25; 375; 125; 187,5	5,80	6,02	6,04	6,66
			100; 150; 500; 750	5,96	5,28	6,40	6,40
			200; 300; 1000; 1500	5,44	5,70	5,74	6,34
	400	10; 15; 25; 55	2,5; 3,75; 6,25; 13,75	6,20	5,64	5,82	5,90
			10; 15; 25; 55	6,20	5,94	6,04	6,38
			20; 30; 50; 110	5,52	5,32	5,82	6,28
		100; 150; 500; 750	25; 375; 125; 187,5	5,66	5,70	5,58	6,02
			100; 150; 500; 750	5,62	5,96	5,74	5,98
			200; 300; 1000; 1500	6,06	6,16	5,48	6,14

Tabela 4.4 - Resultados do experimento ($\alpha = 5$ e 6).

Alfa	n° de amostras	valor dos parâmetros		índice de rejeição (%) - tamanho do teste			
		médias	desvios padrão	1 banda	2 bandas	3 bandas	4 bandas
5	100	10; 15; 25; 55	2,5; 3,75; 6,25; 13,75	5,98	5,38	5,98	6,48
			10; 15; 25; 55	5,80	6,52	5,92	6,06
			20; 30; 50; 110	5,50	5,58	5,84	6,88
		100; 150; 500; 750	25; 375; 125; 187,5	5,62	5,10	5,76	5,64
			100; 150; 500; 750	5,44	5,52	5,98	6,78
			200; 300; 1000; 1500	5,32	6,70	5,84	5,92
	225	10; 15; 25; 55	2,5; 3,75; 6,25; 13,75	5,62	5,30	5,74	5,70
			10; 15; 25; 55	5,42	5,60	5,58	5,74
			20; 30; 50; 110	4,80	6,00	5,48	6,02
		100; 150; 500; 750	25; 375; 125; 187,5	5,22	5,76	6,04	5,64
			100; 150; 500; 750	5,04	5,48	5,28	5,98
			200; 300; 1000; 1500	5,66	4,88	5,36	6,20
	400	10; 15; 25; 55	2,5; 3,75; 6,25; 13,75	5,26	5,42	4,96	5,48
			10; 15; 25; 55	5,32	5,66	5,52	5,70
			20; 30; 50; 110	5,74	4,88	5,54	5,42
		100; 150; 500; 750	25; 375; 125; 187,5	5,08	5,24	5,44	5,10
			100; 150; 500; 750	4,70	5,30	5,14	5,66
			200; 300; 1000; 1500	5,16	4,98	5,14	5,22
6	100	10; 15; 25; 55	2,5; 3,75; 6,25; 13,75	5,26	6,06	5,44	6,04
			10; 15; 25; 55	5,26	4,88	5,82	6,56
			20; 30; 50; 110	5,28	5,76	5,70	6,50
		100; 150; 500; 750	25; 375; 125; 187,5	4,88	5,28	5,58	6,24
			100; 150; 500; 750	5,16	5,68	5,40	6,32
			200; 300; 1000; 1500	4,90	5,86	5,02	6,92
	225	10; 15; 25; 55	2,5; 3,75; 6,25; 13,75	5,22	5,48	5,18	5,14
			10; 15; 25; 55	5,14	5,42	5,48	5,50
			20; 30; 50; 110	4,98	5,12	5,48	5,34
		100; 150; 500; 750	25; 375; 125; 187,5	5,28	4,96	5,50	5,62
			100; 150; 500; 750	4,92	5,46	5,04	5,62
			200; 300; 1000; 1500	4,98	5,16	5,16	5,66
	400	10; 15; 25; 55	2,5; 3,75; 6,25; 13,75	4,96	4,72	5,44	5,24
			10; 15; 25; 55	5,44	5,36	5,42	5,66
			20; 30; 50; 110	5,34	5,14	5,08	5,54
		100; 150; 500; 750	25; 375; 125; 187,5	5,48	4,54	4,84	5,28
			100; 150; 500; 750	4,86	5,52	5,26	5,30
			200; 300; 1000; 1500	5,26	5,60	5,08	5,50

acarreta variação dos resultados de tamanho do teste, que permanecem aproximadamente constantes para um mesmo α e um mesmo número de variáveis.

Um outro fator importante a ser analisado na utilização de dados multivariados é a possibilidade de influência da correlação entre as variáveis no teste de hipótese. Até este ponto, somente a correlação entre os dados de uma mesma variável (autocorrelação) foi investigada, concluindo-se sobre uma forte influência desta no desempenho do teste. Com intuito de inserir correlações entre as variáveis, as matrizes de correlação apresentadas na Tabela 4.1 foram criadas aleatoriamente. Com a simulação de novos dados, um estudo adicional foi desenvolvido, utilizando-se diferentes matrizes de correlação entre as variáveis. Para essa investigação específica, foram utilizadas 3 variáveis. Três conformações diferentes de matrizes de correlação foram utilizadas, procurando estabelecer correlações diversificadas entre as três variáveis. A primeira matriz é utilizada na geração de dados com baixa correlação entre variáveis, a segunda, correlações diversificadas e a terceira, altas correlações. As três matrizes de correlação de ordem 3 são apresentadas a seguir:

$$\begin{bmatrix} 1 & 0,1 & 0,01 \\ 0,1 & 1 & 0,001 \\ 0,01 & 0,001 & 1 \end{bmatrix}, \quad \begin{bmatrix} 1 & 0,5 & 0,9 \\ 0,5 & 1 & 0,2 \\ 0,9 & 0,2 & 1 \end{bmatrix} \quad \text{e} \quad \begin{bmatrix} 1 & 0,9 & 0,85 \\ 0,9 & 1 & 0,8 \\ 0,85 & 0,08 & 1 \end{bmatrix}$$

Com essas três matrizes de correlação apresentadas e com os parâmetros idênticos aos utilizados até então, foi desenvolvido um experimento similar ao realizado anteriormente, com objetivo de obter tamanhos de teste com as diversas configurações de parâmetros disponíveis. Os resultados de tamanho do teste são apresentados em três tabelas, relativas a cada uma das matrizes de diferentes correlações. A Tabela 4.5 apresenta os resultados para os dados em que a correlação entre variáveis é baixa, a Tabela 4.6 apresenta os resultados para os dados que sofrem com correlações diversificadas entre as variáveis e a Tabela 4.7 apresenta os resultados para os dados com altas correlações entre as variáveis. Nas tabelas mencionadas são apresentados apenas os resultados para um dos dois conjuntos de valores de média apresentados anteriormente, por simplificação. Entretanto, os outros valores apresentados anteriormente também foram utilizados e resultados similares foram alcançados. Também para fins de simplificação, são apresentados nas tabelas apenas os resultados relativos aos valores de parâmetro α iguais a 1, 3 e 6.

Tabela 4.5 - Tamanho do teste com correlações baixas entre as variáveis.

Alfa	Parâmetros			Tamanho do teste
	n° de amostras	médias	desvios padrão	com três variáveis
1	100	10; 15; 25	2,5; 3,75; 6,25	49,60
			10; 15; 25	50,40
			20; 30; 50	49,12
	225	10; 15; 25	2,5; 3,75; 6,25	50,18
			10; 15; 25	51,54
			20; 30; 50	49,54
	400	10; 15; 25	2,5; 3,75; 6,25	50,06
			10; 15; 25	49,96
			20; 30; 50	49,10
3	100	10; 15; 25	2,5; 3,75; 6,25	7,78
			10; 15; 25	8,56
			20; 30; 50	7,38
	225	10; 15; 25	2,5; 3,75; 6,25	7,66
			10; 15; 25	6,78
			20; 30; 50	7,30
	400	10; 15; 25	2,5; 3,75; 6,25	8,10
			10; 15; 25	7,70
			20; 30; 50	7,16
6	100	10; 15; 25	2,5; 3,75; 6,25	5,84
			10; 15; 25	5,74
			20; 30; 50	5,56
	225	10; 15; 25	2,5; 3,75; 6,25	5,78
			10; 15; 25	5,24
			20; 30; 50	4,82
	400	10; 15; 25	2,5; 3,75; 6,25	4,96
			10; 15; 25	5,20
			20; 30; 50	5,64

Tabela 4.6 - Tamanho do teste com correlações diversas entre as variáveis.

Alfa	Parâmetros			Tamanho do teste
	nº de amostras	médias	desvios padrão	com três variáveis
1	100	10; 15; 25	2,5; 3,75; 6,25	48,68
			10; 15; 25	49,68
			20; 30; 50	48,96
	225	10; 15; 25	2,5; 3,75; 6,25	49,70
			10; 15; 25	49,94
			20; 30; 50	49,90
	400	10; 15; 25	2,5; 3,75; 6,25	49,56
			10; 15; 25	51,06
			20; 30; 50	50,86
3	100	10; 15; 25	2,5; 3,75; 6,25	8,42
			10; 15; 25	8,26
			20; 30; 50	7,62
	225	10; 15; 25	2,5; 3,75; 6,25	7,20
			10; 15; 25	7,48
			20; 30; 50	7,46
	400	10; 15; 25	2,5; 3,75; 6,25	7,56
			10; 15; 25	7,14
			20; 30; 50	7,56
6	100	10; 15; 25	2,5; 3,75; 6,25	5,44
			10; 15; 25	5,82
			20; 30; 50	5,70
	225	10; 15; 25	2,5; 3,75; 6,25	5,18
			10; 15; 25	5,48
			20; 30; 50	5,48
	400	10; 15; 25	2,5; 3,75; 6,25	5,44
			10; 15; 25	5,42
			20; 30; 50	5,08

Tabela 4.7 - Tamanho do teste com correlações altas entre as variáveis.

Alfa	Parâmetros			Tamanho do teste
	n° de amostras	médias	desvios padrão	com três variáveis
1	100	10; 15; 25	2,5; 3,75; 6,25	49,06
			10; 15; 25	49,28
			20; 30; 50	50,12
	225	10; 15; 25	2,5; 3,75; 6,25	49,54
			10; 15; 25	49,42
			20; 30; 50	50,26
	400	10; 15; 25	2,5; 3,75; 6,25	49,84
			10; 15; 25	51,7
			20; 30; 50	50,28
3	100	10; 15; 25	2,5; 3,75; 6,25	8,1
			10; 15; 25	7,86
			20; 30; 50	7,96
	225	10; 15; 25	2,5; 3,75; 6,25	7,66
			10; 15; 25	7,2
			20; 30; 50	8,26
	400	10; 15; 25	2,5; 3,75; 6,25	7,92
			10; 15; 25	7,72
			20; 30; 50	7,7
6	100	10; 15; 25	2,5; 3,75; 6,25	5,84
			10; 15; 25	5,96
			20; 30; 50	6,18
	225	10; 15; 25	2,5; 3,75; 6,25	5,34
			10; 15; 25	5,28
			20; 30; 50	6,46
	400	10; 15; 25	2,5; 3,75; 6,25	5,52
			10; 15; 25	5,2
			20; 30; 50	4,72

Ao observar os resultados apresentados pelas Tabelas 4.5–4.7, a principal evidência que surge consiste nos valores de tamanho do teste, os quais são muito similares entre as três situações investigadas, considerando-se os mesmos valores para todos os outros parâmetros. Como a correlação entre as variáveis é o único fator que se altera entre as três situações, pode-se entender que a mesma não têm influência significativa no desempenho do teste, ao contrário da autocorrelação entre os dados, conforme analisado anteriormente.

4.2 Aplicação do Classificador por Regiões

O classificador por regiões foi aplicado às imagens PolSAR, com vistas a avaliar a potencialidade de utilização do mesmo. As aplicações realizadas podem ser divididas segundo duas abordagens: utilização de dados PolSAR reais e utilização de dados PolSAR simulados. A descrição dos dados PolSAR é feita na subseção 4.2.1, a estratégia de simulação dos dados é descrita na subseção 4.2.1.2, os resultados da classificação dos dados simulados e reais são apresentados e discutidos nas subseções 4.2.2 e 4.2.3, respectivamente.

4.2.1 Descrição dos dados PolSAR

4.2.1.1 Descrição dos dados reais

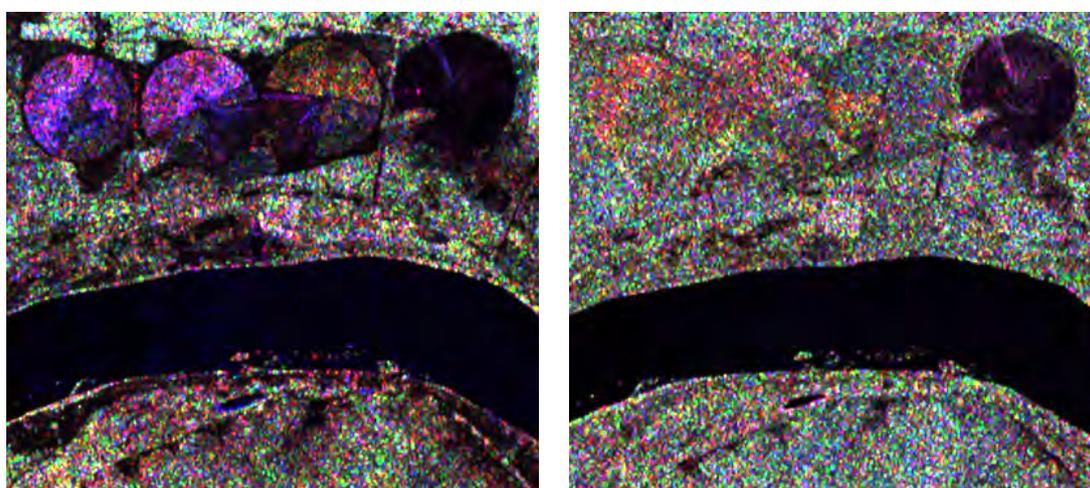
Para avaliação do classificador por regiões com dados reais, foram utilizados dados PolSAR gerados pelo instrumento *Spaceborne Imaging Radar-C/X-band* (SIR-C/X-band) (WAY et al., ; JORDAN et al., 1995), nas bandas C e L. O instrumento SIR-C funcionou a bordo do ônibus espacial *Endeavour* em duas missões de imageamento, no ano de 1994. A cena polarimétrica do sensor SIR-C utilizada corresponde a um recorte que abrange uma área de cultivo agrícola localizada próxima à cidade de Petrolina-PE. A Tabela 4.8 apresenta informações sobre a localização da área de estudo e as características básicas da imagem PolSAR SIR-C.

A Figuras 4.2(a) e 4.2(b) apresentam composições coloridas RGB das componentes em intensidade extraídas dos dados polarimétricos nas bandas de frequência L e C, respectivamente.

As principais classes de cobertura observadas sobre a imagem foram Rio, Solo Preparado, Soja em três diferentes estágios de crescimento, Restolho e Milho em dois diferentes estágios de crescimento. As amostras de treinamento e de teste são apre-

Tabela 4.8 - Informações da imagem PolSAR SIR-C e da área de estudo

Localização da área de estudo	09°07' S, 40°18' W (coordenada central), aproximadamente 40 Km a nordeste da cidade de Petrolina-PE
Data de aquisição	14 de abril de 1994
Tamanho da imagem (pixels)	407 × 370
Número de visadas nominal	4,785
Frequências	banda C - 5,304 GHz e banda L - 1,254 GHz
Espaçamento dos pixels	12,5 m × 12,5 m
Ângulo de incidência	49,496°
Direção da órbita	descendente



(a) Banda L

(b) Banda C

Figura 4.2 - Composição colorida com componentes de intensidade SIR-C, banda L e C (HH(R), HV(G), VV(B)).

sentadas nas Figuras 4.3(a) e 4.3(b), e a legenda das classes na Figura 4.3(c). Essas amostras foram propriamente subamostradas com vistas a minimização da diminuição da autocorrelação espacial, conforme discussão desenvolvida na Seção 4.1. A subamostragem foi feita com valores de *lag* igual a 2 em linha e coluna. A quantidade de pixels utilizada por amostra de treinamento, após a subamostragem, é apresentada na Tabela 4.9.

As seleção das classes de uso e cobertura da cena utilizada, suas descrições, bem como as amostras selecionadas foram obtidas do trabalho de [Correia \(1998\)](#), em

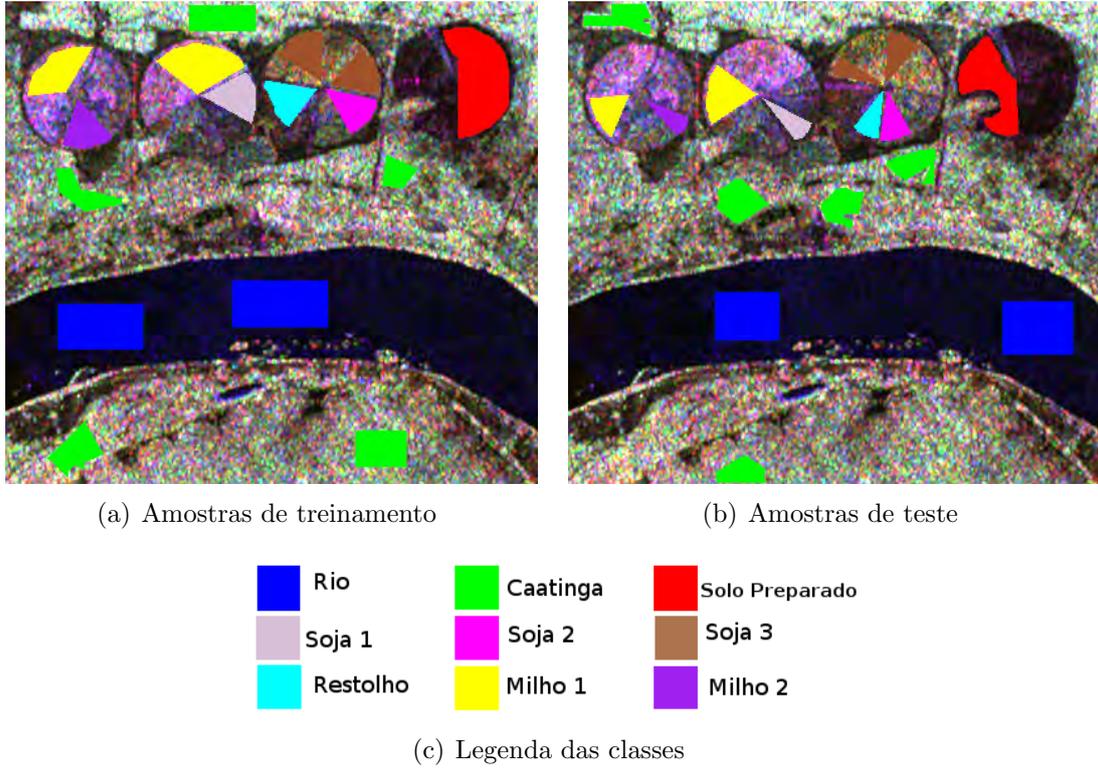


Figura 4.3 - Composição colorida com componentes de intensidade SIR-C, banda L, (HH(R), HV(G), VV(B)) e localização das amostras de treinamento e teste.

que as mesmas imagens foram utilizadas.

Frery et al. (2007) concluíram que, para os dados da banda L, com exceção da classe “Rio”, as amostras apresentadas na Figura 4.3, não seguem a distribuição de Wishart complexa, mas são melhor modeladas pelas distribuições \mathcal{K}_P e \mathcal{G}_P^0 . No caso dos dados da banda C, Frery et al. (2007) mostraram que a maioria das amostras selecionadas seguem distribuição Wishart complexa escalonada, com exceção apenas da classe Soja 1, que segue a distribuição \mathcal{G}_P^0 e da classe Solo Preparado, que segue a distribuição \mathcal{K}_P .

Não há atualmente expressões fechadas disponíveis para distâncias estocásticas entre distribuições \mathcal{K}_P e \mathcal{G}_P^0 e um processo de integração por método numérico seria impraticável no domínio das matrizes Hermitianas positivas definidas. Não obstante a inviabilidade da utilização da modelagem mais ajustada aos dados PolSAR reais disponíveis, principalmente nos dados da banda L, acredita-se que a adoção da distribuição Wishart complexa escalonada para a classificação desses dados possa ainda

Tabela 4.9 - Descrição das amostras de treinamento e teste.

Classe	Descrição	# Treinamento	# Teste
Rio	Corpo d'água	1192	976
Caatinga	Vegetação composta por árvores baixas e arbustos espinhosos, encontrada em áreas de pouca chuva	1006	820
Solo preparado	Solo preparado para o plantio	715	442
Soja 1	Soja com aproximadamente 52 dias após o plantio	212	99
Soja 2	Soja com aproximadamente 66 dias após o plantio	174	117
Soja 3	Soja com aproximadamente 113 dias após o plantio	390	216
Restolho	Resíduos agrícolas	181	98
Milho 1	Milho com menos do que 124 dias após o plantio	661	364
Milho 2	Milho com aproximadamente 133 dias após o plantio	191	77

trazer resultados de classificação de boa qualidade, segundo os critérios de acurácia.

4.2.1.2 Descrição dos dados simulados

Os dados simulados foram gerados sob a suposição de simetria circular (GOODMAN, 1963), conforme explicado na subseção 2.1.2.1.

A simulação tem por objetivo a obtenção de realizações de matrizes de covariância complexas aleatórias que seguem a distribuição Wishart complexa escalonada com um número determinado de *looks* (L). Inicialmente são gerados dados polarimétricos de um *look*, que nesta seção são representados por um vetor aleatório gaussiano \mathbf{y}_q , de dimensão q . Supondo que \mathbf{y}_q siga uma distribuição gaussiana complexa de dimensão q , denotada por $\mathbf{y}_q \sim \mathcal{CN}_q(0, \mathbf{\Sigma}_q)$, a simulação é feita amostrando-se vetores reais \mathbf{x} de dimensão $2q$, tais que $\mathbf{x}_{2q} \sim \mathcal{N}_{2q}(0, \mathbf{\Sigma}'_{2q})$, em que, sob a suposição de simetria circular e de acordo com Goodman (1963) e Picinbono (1996), $\mathbf{\Sigma}'_{2q}$ é tal que:

$$\boldsymbol{\Sigma}'_{2q} = \frac{1}{2} \begin{bmatrix} \Re(\boldsymbol{\Sigma}_q) & -\Im(\boldsymbol{\Sigma}_q) \\ \Im(\boldsymbol{\Sigma}_q) & \Re(\boldsymbol{\Sigma}_q) \end{bmatrix}, \quad (4.7)$$

em que \Re e \Im denotam as partes reais e imaginárias de um número complexo, respectivamente.

Os primeiros q elementos de \boldsymbol{x}_{2q} são tomados como as partes reais dos elementos do vetor complexo \boldsymbol{y}_q enquanto os últimos q elementos de \boldsymbol{x}_{2q} formam as partes imaginárias. Este processo é repetido tantas vezes quantas forem o número de amostras requeridas para a simulação, sendo cada amostra representante de um valor de pixel da imagem a ser simulada.

Em seguida, são obtidos os elementos simulados no formato matriz de covariância *multi-look*, de acordo com a equação (4.8).

$$\mathbf{Z} = \frac{1}{L} \sum_{i=1}^L \boldsymbol{y}_i \boldsymbol{y}_i^\dagger. \quad (4.8)$$

O processo de simulação descrito foi utilizado para produzir imagens correspondentes a nove classes diferentes. Tais classes foram observadas nos dados PolSAR reais na banda L e descritas na Tabela 4.9. Utilizando-se as imagens PolSAR reais e as amostras selecionadas para todas as nove classes, as matrizes de covariância representantes dessas nove classes relativas à imagem da banda L foram estimadas e utilizadas como base para a simulação. Essas matrizes estimadas correspondem à matriz $\boldsymbol{\Sigma}_q$, da qual se extrai os elementos para formação da matriz $\boldsymbol{\Sigma}'_{2q}$. As matrizes de covariância obtidas na estimação são apresentadas nas equações (4.9)–(4.17).

$$\boldsymbol{\Sigma}_{\text{Rio}} = \begin{bmatrix} 2,98 \cdot 10^{-3} & 5,31 \cdot 10^{-6} + j 8,11 \cdot 10^{-5} & 3,47 \cdot 10^{-3} + j 3,42 \cdot 10^{-4} \\ & 3,40 \cdot 10^{-4} & 4,47 \cdot 10^{-6} + j 1,39 \cdot 10^{-4} \\ & & 1,19 \cdot 10^{-2} \end{bmatrix} \quad (4.9)$$

$$\boldsymbol{\Sigma}_{\text{Caatinga}} = \begin{bmatrix} 1,11 \cdot 10^{-1} & -3,10 \cdot 10^{-3} - j 1,58 \cdot 10^{-3} & 1,98 \cdot 10^{-2} + j 1,65 \cdot 10^{-3} \\ & 3,40 \cdot 10^{-2} & -1,41 \cdot 10^{-3} + j 1,87 \cdot 10^{-3} \\ & & 9,47 \cdot 10^{-2} \end{bmatrix} \quad (4.10)$$

$$\Sigma_{\text{Solo Prep}} = \begin{bmatrix} 1,05 \cdot 10^{-2} & -5,39 \cdot 10^{-6} - j 2,37 \cdot 10^{-4} & 7,53 \cdot 10^{-3} + j 1,75 \cdot 10^{-3} \\ & 8,46 \cdot 10^{-4} & -3,38 \cdot 10^{-5} + j 1,32 \cdot 10^{-4} \\ & & 1,14 \cdot 10^{-2} \end{bmatrix} \quad (4.11)$$

$$\Sigma_{\text{Soja 1}} = \begin{bmatrix} 3,40 \cdot 10^{-2} & -1,79 \cdot 10^{-3} - j 1,86 \cdot 10^{-3} & -3,6 \cdot 10^{-4} - j 7,58 \cdot 10^{-3} \\ & 5,16 \cdot 10^{-3} & 4,38 \cdot 10^{-4} + j 4,28 \cdot 10^{-4} \\ & & 5,38 \cdot 10^{-2} \end{bmatrix} \quad (4.12)$$

$$\Sigma_{\text{Soja 2}} = \begin{bmatrix} 4,31 \cdot 10^{-2} & -1,76 \cdot 10^{-3} - j 1,32 \cdot 10^{-3} & -1,78 \cdot 10^{-4} - j 1,73 \cdot 10^{-3} \\ & 9,26 \cdot 10^{-3} & 6,55 \cdot 10^{-4} + j 1,27 \cdot 10^{-3} \\ & & 4,35 \cdot 10^{-2} \end{bmatrix} \quad (4.13)$$

$$\Sigma_{\text{Soja 3}} = \begin{bmatrix} 7,53 \cdot 10^{-2} & -4,25 \cdot 10^{-3} - j 7,66 \cdot 10^{-3} & 5,87 \cdot 10^{-4} - j 1,36 \cdot 10^{-3} \\ & 1,47 \cdot 10^{-2} & -2,18 \cdot 10^{-4} + j 1,21 \cdot 10^{-3} \\ & & 3,70 \cdot 10^{-2} \end{bmatrix} \quad (4.14)$$

$$\Sigma_{\text{Restolho}} = \begin{bmatrix} 3,53 \cdot 10^{-2} & 1,20 \cdot 10^{-3} + j 1,02 \cdot 10^{-4} & 1,64 \cdot 10^{-2} - j 2,65 \cdot 10^{-3} \\ & 3,05 \cdot 10^{-3} & 4,48 \cdot 10^{-4} + j 1,88 \cdot 10^{-4} \\ & & 3,29 \cdot 10^{-2} \end{bmatrix} \quad (4.15)$$

$$\Sigma_{\text{Milho 1}} = \begin{bmatrix} 1,15 \cdot 10^{-1} & -3,95 \cdot 10^{-3} - j 3,57 \cdot 10^{-3} & 9,13 \cdot 10^{-3} - j 4,86 \cdot 10^{-3} \\ & 1,33 \cdot 10^{-2} & 3,34 \cdot 10^{-3} + j 2,83 \cdot 10^{-3} \\ & & 1,47 \cdot 10^{-1} \end{bmatrix} \quad (4.16)$$

$$\Sigma_{\text{Milho 2}} = \begin{bmatrix} 4,19 \cdot 10^{-2} & 1,08 \cdot 10^{-3} - j 1,01 \cdot 10^{-3} & 9,24 \cdot 10^{-3} - j 3,68 \cdot 10^{-3} \\ & 1,02 \cdot 10^{-2} & 2,43 \cdot 10^{-4} + j 3,31 \cdot 10^{-4} \\ & & 5,71 \cdot 10^{-2} \end{bmatrix} \quad (4.17)$$

Foram calculados os valores do determinante e do traço da matriz das matrizes de covariância estimadas a partir dos dados para cada classe. Esses valores são apresentados na Tabela 4.10.

Tabela 4.10 - Valores de determinante e traço das matrizes de covariância estimadas.

Classe	Determinante	Traço
Rio	$7,84 \cdot 10^{-9}$	$1,52 \cdot 10^{-2}$
Caatinga	$3,43 \cdot 10^{-4}$	$2,40 \cdot 10^{-1}$
Solo Preparado	$5,00 \cdot 10^{-8}$	$2,27 \cdot 10^{-2}$
Soja 1	$8,81 \cdot 10^{-6}$	$9,30 \cdot 10^{-2}$
Soja 2	$1,70 \cdot 10^{-5}$	$9,58 \cdot 10^{-2}$
Soja 3	$3,77 \cdot 10^{-5}$	$1,27 \cdot 10^{-1}$
Restolho	$2,66 \cdot 10^{-6}$	$7,12 \cdot 10^{-2}$
Milho 1	$1,89 \cdot 10^{-4}$	$2,76 \cdot 10^{-1}$
Milho 2	$2,33 \cdot 10^{-5}$	$1,09 \cdot 10^{-1}$

Pode-se verificar que os valores de determinante e traço das matrizes de covariância estimados a partir das amostras das nove classes podem indicar que alguns pares de classes apresentam maior semelhança entre si quando comparadas a outras. Este é o caso por exemplo das classes Soja 2 e Milho 2, que apresentam valores de determinante e traço da matriz bastante próximos. A fim de observar o grau de separabilidade entre as amostras de treinamento selecionadas para as nove classes (Figura 4.3(a)), foi calculada uma matriz de distâncias de Hellinger (Equação (2.38)), que é limitada entre 0 e 1, entre as matrizes de covariância hermitianas estimadas a partir das imagens da banda L. Esta matriz de distância de Hellinger é apresentada na Tabela 4.11.

A partir da análise da Tabela 4.11, pode-se observar que as matrizes de covariância amostrais relativas às classes Soja 2 e Milho 2 apresentam entre si o menor valor de distância de Hellinger (0,07), destacado na Tabela em negrito. Com a utilização da fórmula expressa pela equação (2.43), pode-se calcular o valor da estatística s_{ϕ}^h resultante da distância obtida. A partir dos números de amostras utilizadas após subamostragem das classes Soja 2 e milho 2, contidos na Tabela 4.9, calcula-se, para este caso de menor distância, o valor de 51,886 para s_{ϕ}^h . Este valor da estatística corresponde a um p -valor de $4,75 \cdot 10^{-8}$, que pode ser considerado aproximadamente igual a zero. A conclusão é que a hipótese nula, que considera igualdade entre as matrizes de covariância, é rejeitada, e as classes Soja 2 e Milho 2 são separáveis.

Tabela 4.11 - Resultados de distâncias de Hellinger entre as matrizes de covariância amostrais das classes.

	Rio	Caatinga	Solo Preparado	Soja 1	Soja 2	Soja 3	Restolho	Milho 1	Milho 2
Rio	0	1,000	0,630	0,995	0,998	0,999	0,981	1,000	0,999
Caatinga		0	0,999	0,844	0,680	0,499	0,945	0,407	0,617
Solo Preparado			0	0,965	0,982	0,993	0,851	0,999	0,986
Soja 1				0	0,178	0,499	0,426	0,686	0,249
Soja 2					0	0,195	0,527	0,585	0,071
Soja 3						0	0,731	0,539	0,276
Restolho							0	0,902	0,558
Milho 1								0	0,516
Milho 2									0

Entretanto, dado o pequeno valor de distância, sobretudo quando comparado aos outros valores da Tabela ??, espera-se que na fase de classificação das imagens, tanto as simuladas quanto as reais, possa haver confusão entre as duas classes consideradas.

A simulação foi realizada com 4 visadas ($L = 4$) e considerando três polarizações, HH, HV e VV. Para cada classe, foram obtidas imagens de 150×150 pixels. A imagem final, com as nove classes, foi obtida por um processo de mosaico das imagens relativas a cada classe, totalizando 450×450 pixels, uma vez que as imagens relativas às classes foram agrupadas em uma configuração 3×3 . A Figura 4.4 ilustra o resultado da simulação, apresentando uma composição colorida RGB dos canais de amplitude extraídos da imagem matriz de covariância simulada.

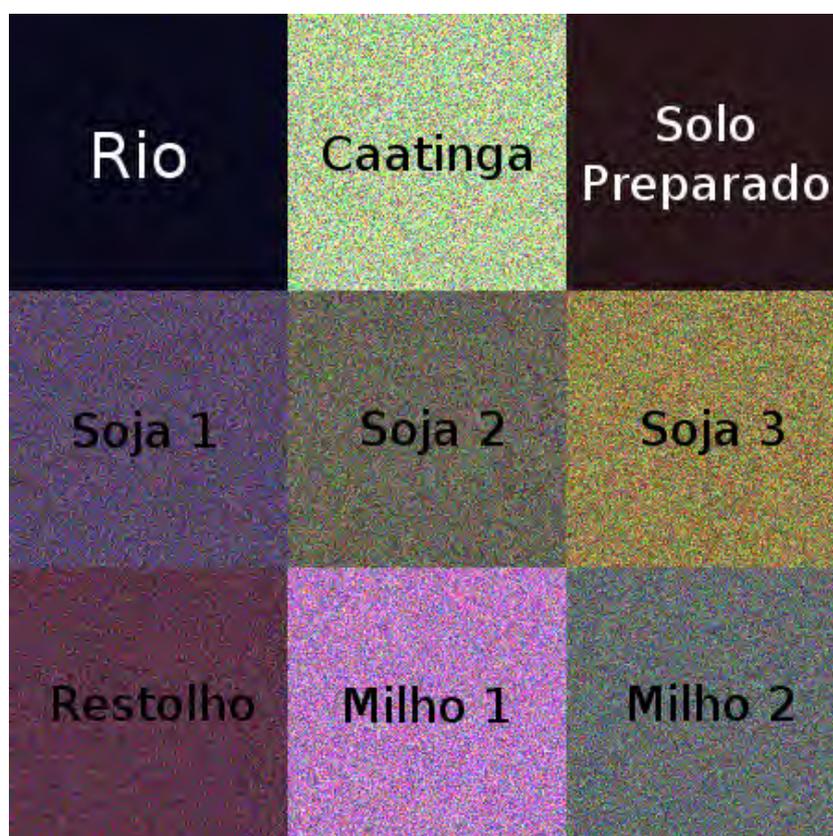


Figura 4.4 - Imagem simulada: composição colorida das componentes em amplitude - HH(R), HV(G), VV(B).

4.2.2 Aplicação em dados PolSAR Simulados

O procedimento de classificação por regiões nas imagens simuladas foi realizado utilizando-se, separadamente, quatro segmentações diferentes. Essas segmentações foram obtidas artificialmente através de um programa desenvolvido na linguagem IDL, versão 7.1. As imagens segmentadas resultantes, em formato .TIF e contendo os índices de segmentos, caracterizavam-se por apresentar regiões quadradas de tamanhos variáveis: 5×5 pixels, 10×10 pixels, 15×15 pixels e 30×30 pixels. Estas imagens segmentadas contêm, respectivamente, 900, 225, 100 e 25 regiões em cada uma das nove classes. As imagens segmentadas com as quatro configurações de segmentação são apresentadas nas Figura 4.5.

As amostras de treinamento de cada classe de interesse foram posicionadas na região central da imagem segmentada. A obtenção das amostras de treinamento foi feita em outra imagem gerada por processo de simulação idêntico, para garantir que quando da realização do teste de hipótese, utilizando-se dados da mesma região central, esses dados relativos aos segmentos e às amostras de treinamento fossem completamente independentes, sem haver influência na obtenção dos p -valores. A Figura 4.6 apresenta as amostras de treinamento juntamente com a imagem simulada.

As classificações envolvendo dados simulados tiveram por objetivo a avaliação do procedimento de classificação desenvolvido sob condições de modelagem estatística rigorosamente controladas. Os dados foram simulados a partir da distribuição Wishart complexa escalonada, sem autocorrelação e em grande quantidade, garantindo assim que os mesmos obedecem aos requisitos teóricos do teste de hipótese utilizado. Resultados adicionais de classificação foram obtidos com utilização de outros módulos do classificador para fins de comparação. Uma imagem amplitude multivariada foi extraída da imagem de matriz de covariância complexa, assim como três pares de imagens em intensidade (HH,HV; HH,VV e HV,VV). A primeira imagem foi classificada com o módulo para imagens óticas e SAR multivariadas em amplitude e as últimas três, com o módulo para pares de imagens em intensidade *multi-look*. Nesses casos, foi utilizada apenas a estatística s_h^ϕ calculada a partir da distância de Bhattacharyya. Para os dados em amplitude, foi utilizada a expressão apresentada na equação (2.51) e para os dados em intensidade, o processo numérico descrito na Seção 3.3.

Há quatro imagens segmentadas diferentes, e nove opções de classificação. Essas

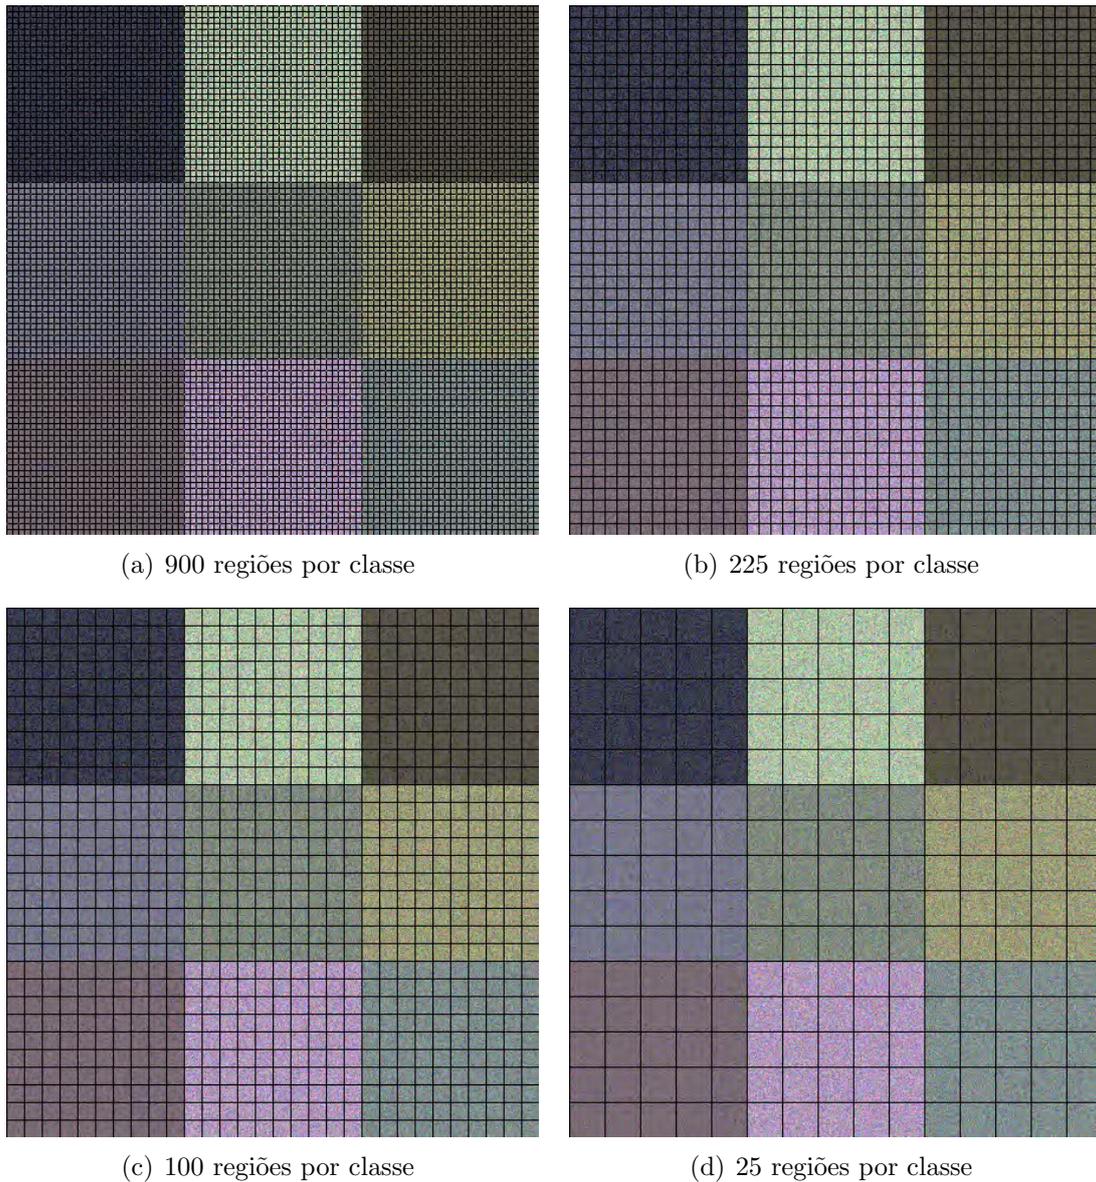


Figura 4.5 - Imagens segmentadas com diferentes tamanhos de segmentos: (a) 5×5 pixels, (b) 10×10 pixels, (c) 15×15 pixels e (d) 30×30 pixels

opções são referentes a cinco distâncias entre modelos Wishart, uma distância entre gaussianas multivariadas e três classificações entre pares diferentes de imagens em intensidade (utilizando a distância de Bhattacharyya). Todas essas opções totalizam trinta e seis classificações diferentes.

Para as classificações que modelam estatisticamente os dados pela distribuição de Wishart complexa, tendo como base de avaliação a imagem perfeitamente classifi-

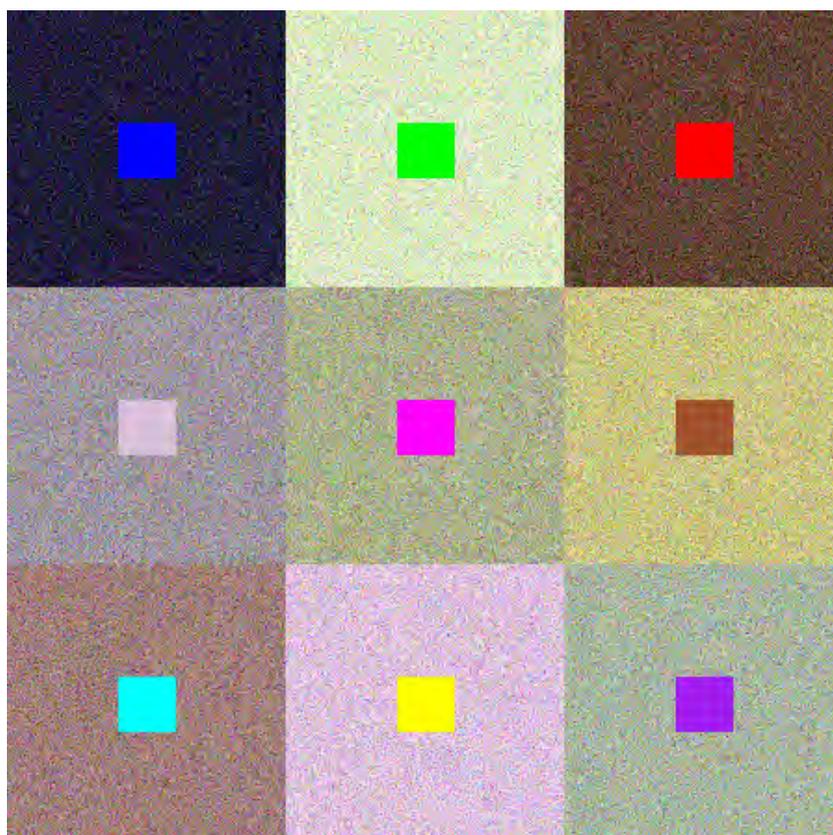


Figura 4.6 - Amostras de treinamento 30×30 para classificação

cada, os resultados alcançados com segmentos de tamanhos de 10×10 , 15×15 e 30×30 pixels alcançaram acurácia global de 100%. As classificações com segmentos de tamanho 5×5 pixels alcançaram acurácias de 99,81% para as distâncias de Bhattacharyya, Kullback-Leibler, Hellinger e Rényi e de 99,58% para a distância χ^2 . O valor de acurácia global para a distância χ^2 é estatisticamente inferior às acurácias obtidas utilizando as demais distâncias entre distribuições Wishart. Nestes casos de regiões muito pequenas (25 pixels), houve uma confusão entre segmentos das classes Soja 2 e Milho 2. Esses resultados mostram a alta qualidade do classificador proposto, quando as suposições teóricas são perfeitamente satisfeitas, especialmente para segmentos com grande quantidade de pixels (igual ou maior do que 100 pixels). A implementação da distância de Rényi de ordem β no classificador por regiões considera apenas o valor 0,9 para o parâmetro β . Em próximas versões do classificador, estará disponível a opção de escolha desse parâmetro. Trabalhos futuros serão desenvolvidos no intuito de se avaliar a influência da modificação do β nas classificações.

A Figura 4.7 apresenta os resultados de classificação utilizando as cinco distâncias estocásticas entre distribuições de Wishart complexas, para o caso dos segmentos de 5×5 pixels, em que a acurácia global não foi de 100%. A leve confusão entre as classes Soja 2 e Milho 2 pode ser observada na Figura 4.7, assim como em alguns segmentos da classe Caatinga, classificados como Milho 1, quando utilizada a distância χ^2 (Figura 4.7(e)).

Utilizando o módulo para imagens óticas e SAR multivariadas em amplitude, com a distância de Bhattacharyya, foi classificada uma imagem SAR em amplitude multivariada extraída da imagem matriz de covariância. Os resultados dessa classificação, com segmentos de 5×5 apresentam acurácia global de 98.35%, o qual é estatisticamente inferior aos valores encontrados quando se utilizam as distâncias entre distribuições Wishart. Com as demais segmentações, a acurácia global alcançada foi de 100%, a exemplo das classificações obtidas com o módulo para imagens polarimétricas. No caso da modelagem gaussiana, verificou-se um nível de confusão maior entre as classes Soja 2 e Milho 2 do que a observada com a modelagem Wishart. Esse resultado reforça a importância da correta modelagem dos dados. Na Figura 4.8, é apresentado o resultado da classificação da imagem multivariada em amplitude com segmentos de 5×5 pixels.

As classificações PolSAR e amplitude multivariada passaram também pelo processo de geração de mapas de p -valores. Os mapas de p -valores servem como indicadores da confiabilidade da classificação. Os mapas gerados são apresentados na Figura 4.9, para as distâncias de Bhattacharyya, Kullback-Leibler e Hellinger, e na Figura 4.10, para as distâncias de Rényi de ordem β , χ^2 e Bhattacharyya gaussiana. Nos mapas, as posições em branco assinalam os segmentos para os quais a hipótese nula não foi rejeitada ao nível de significância de 5%. As porcentagens de segmentos cuja hipótese H_0 não foi rejeitada, para cada caso de tamanho de segmento e distância estocástica utilizada, são apresentadas na Tabela 4.12.

Os resultados apresentados nas Figuras 4.9 e 4.10 e na Tabela 4.12 são compatíveis com os valores teoricamente esperados. As taxas de rejeição dos testes de hipótese foram aproximadamente 5% para todas as configurações de segmentação e distâncias estocásticas utilizadas, exceto para o caso da distância χ^2 , e Bhattacharyya entre modelos gaussianos, para segmentos menores (5×5 pixels). As taxas de rejeição para a distância χ^2 foram maiores do que os valores teóricos esperados em todas as configurações de segmentação, alcançando o valor aproximado de 24.5% para o

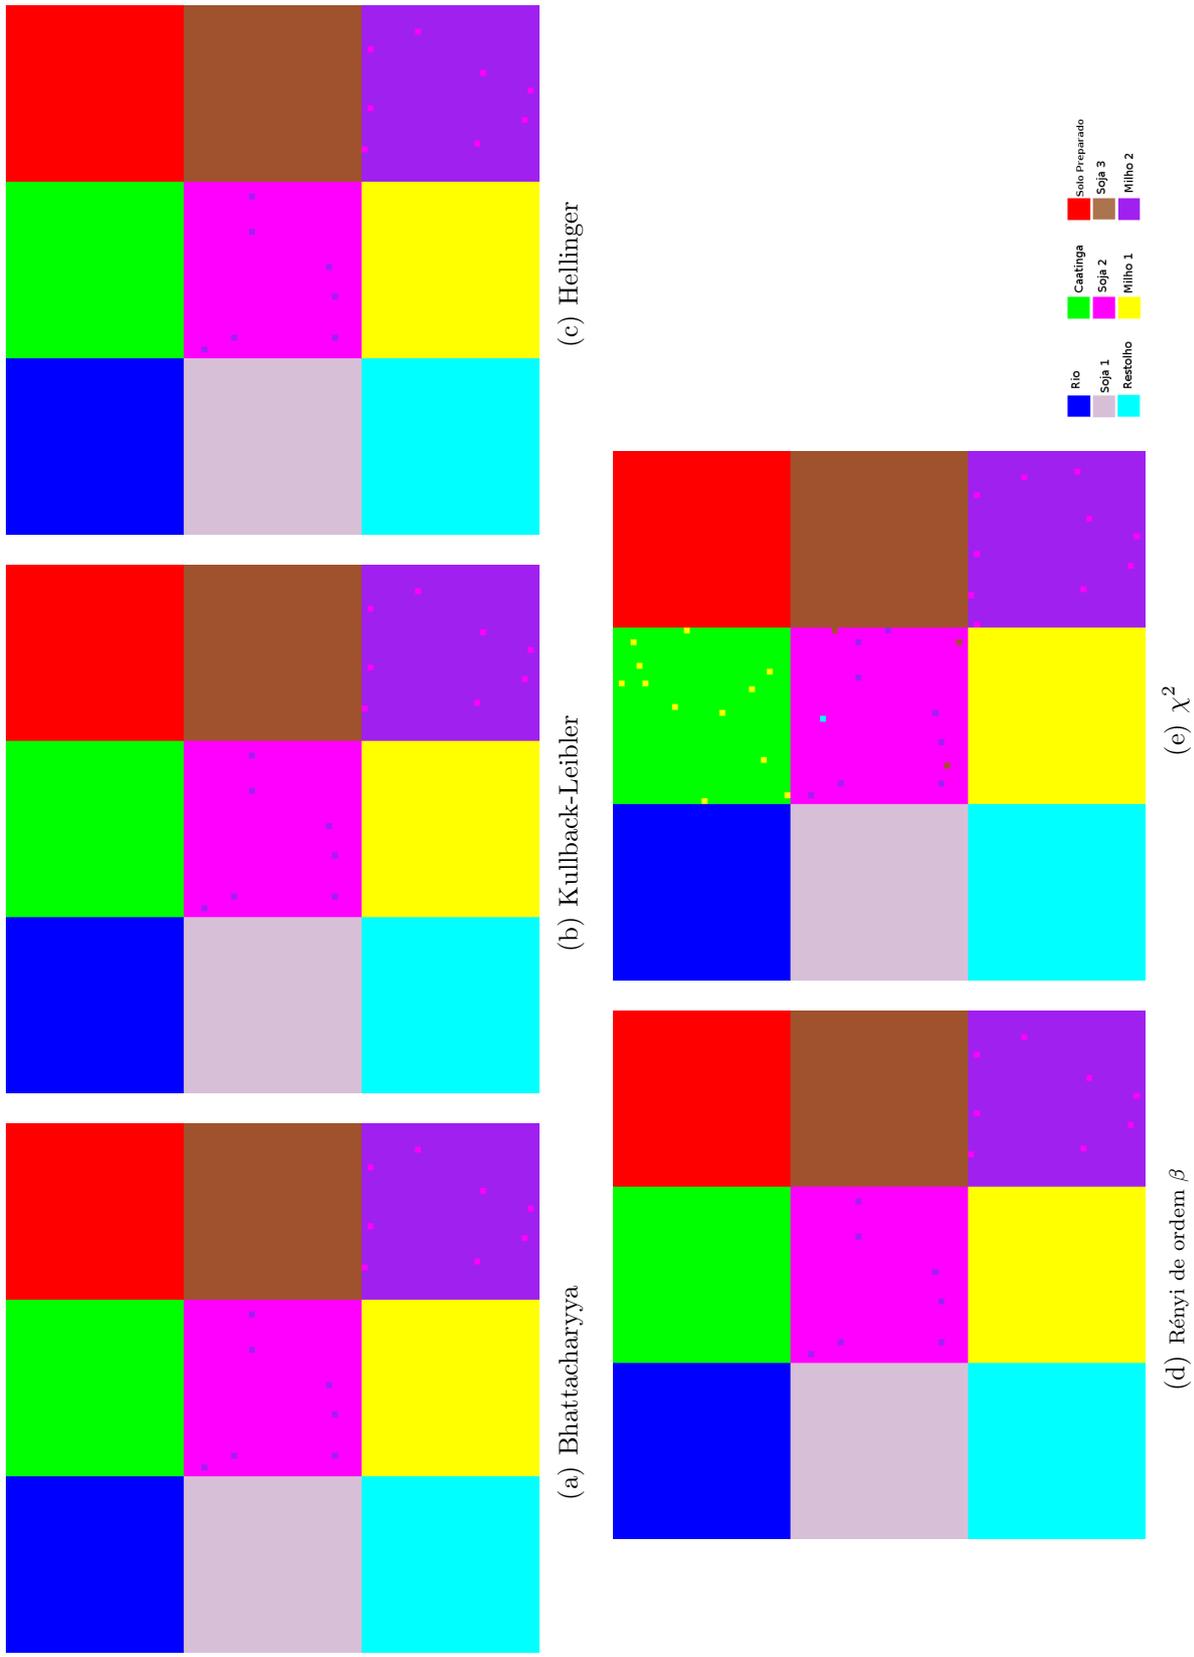


Figura 4.7 - Resultados de classificação - Modelo Wishart (PolSAR) com segmentos de tamanho 5×5 pixels.

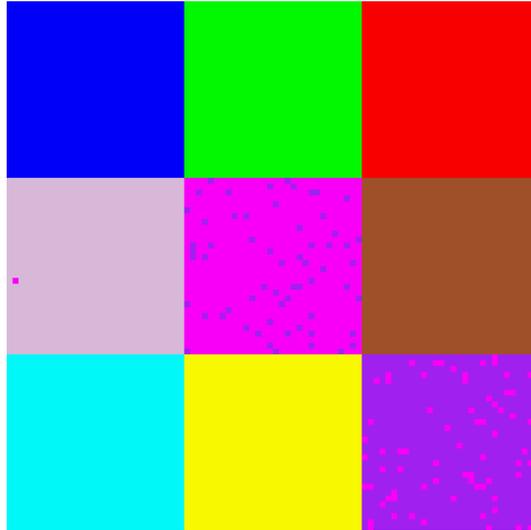


Figura 4.8 - Resultados de classificação - Modelo Gaussianao com segmentos de tamanho 5×5 pixels.

Tabela 4.12 - Porcentagem de segmentos cuja hipótese H_0 não foi rejeitada ao nível de significância de 5 %, para o caso dos dados simulados (PolSAR e amplitude).

Distâncias	Porcentagem (%)			
	5×5 pixels 8100 segmentos	10×10 pixels 2025 segmentos	15×15 pixels 900 segmentos	30×30 pixels 225 segmentos
Bhattacharyya	94,0	95,2	94,3	93,8
Kullback-Leibler	93,7	95,1	94,3	93,3
Hellinger	95,2	95,3	94,8	93,8
Rényi (ordem $\beta = 0,9$)	93,8	95,1	94,3	93,8
χ^2	75,5	91,2	92,8	92,4
Bhattacharyya (Gaussiana)	90,6	94,1	95,1	98,2

caso de segmentos menores (5×5 pixels). O fraco desempenho da distância χ^2 foi também observado por Frery et al. (2011b), em que foram apresentados resultados que associam grandes tamanhos de teste a essa distância.

Adicionalmente, foram feitas classificações de pares de imagens SAR em intensidade, utilizando-se o módulo do classificador apropriado. Os pares de intensidade foram extraídos da imagem PolSAR no formato matriz de covariância, pela seleção dos elementos da diagonal principal da matriz de covariância, agrupando-os dois a dois. Os resultados dessa extração foram então três pares de imagens SAR em intensidade: HH,HV, HH,VV e HV,VV. Classificações por regiões foram feitas com esses três

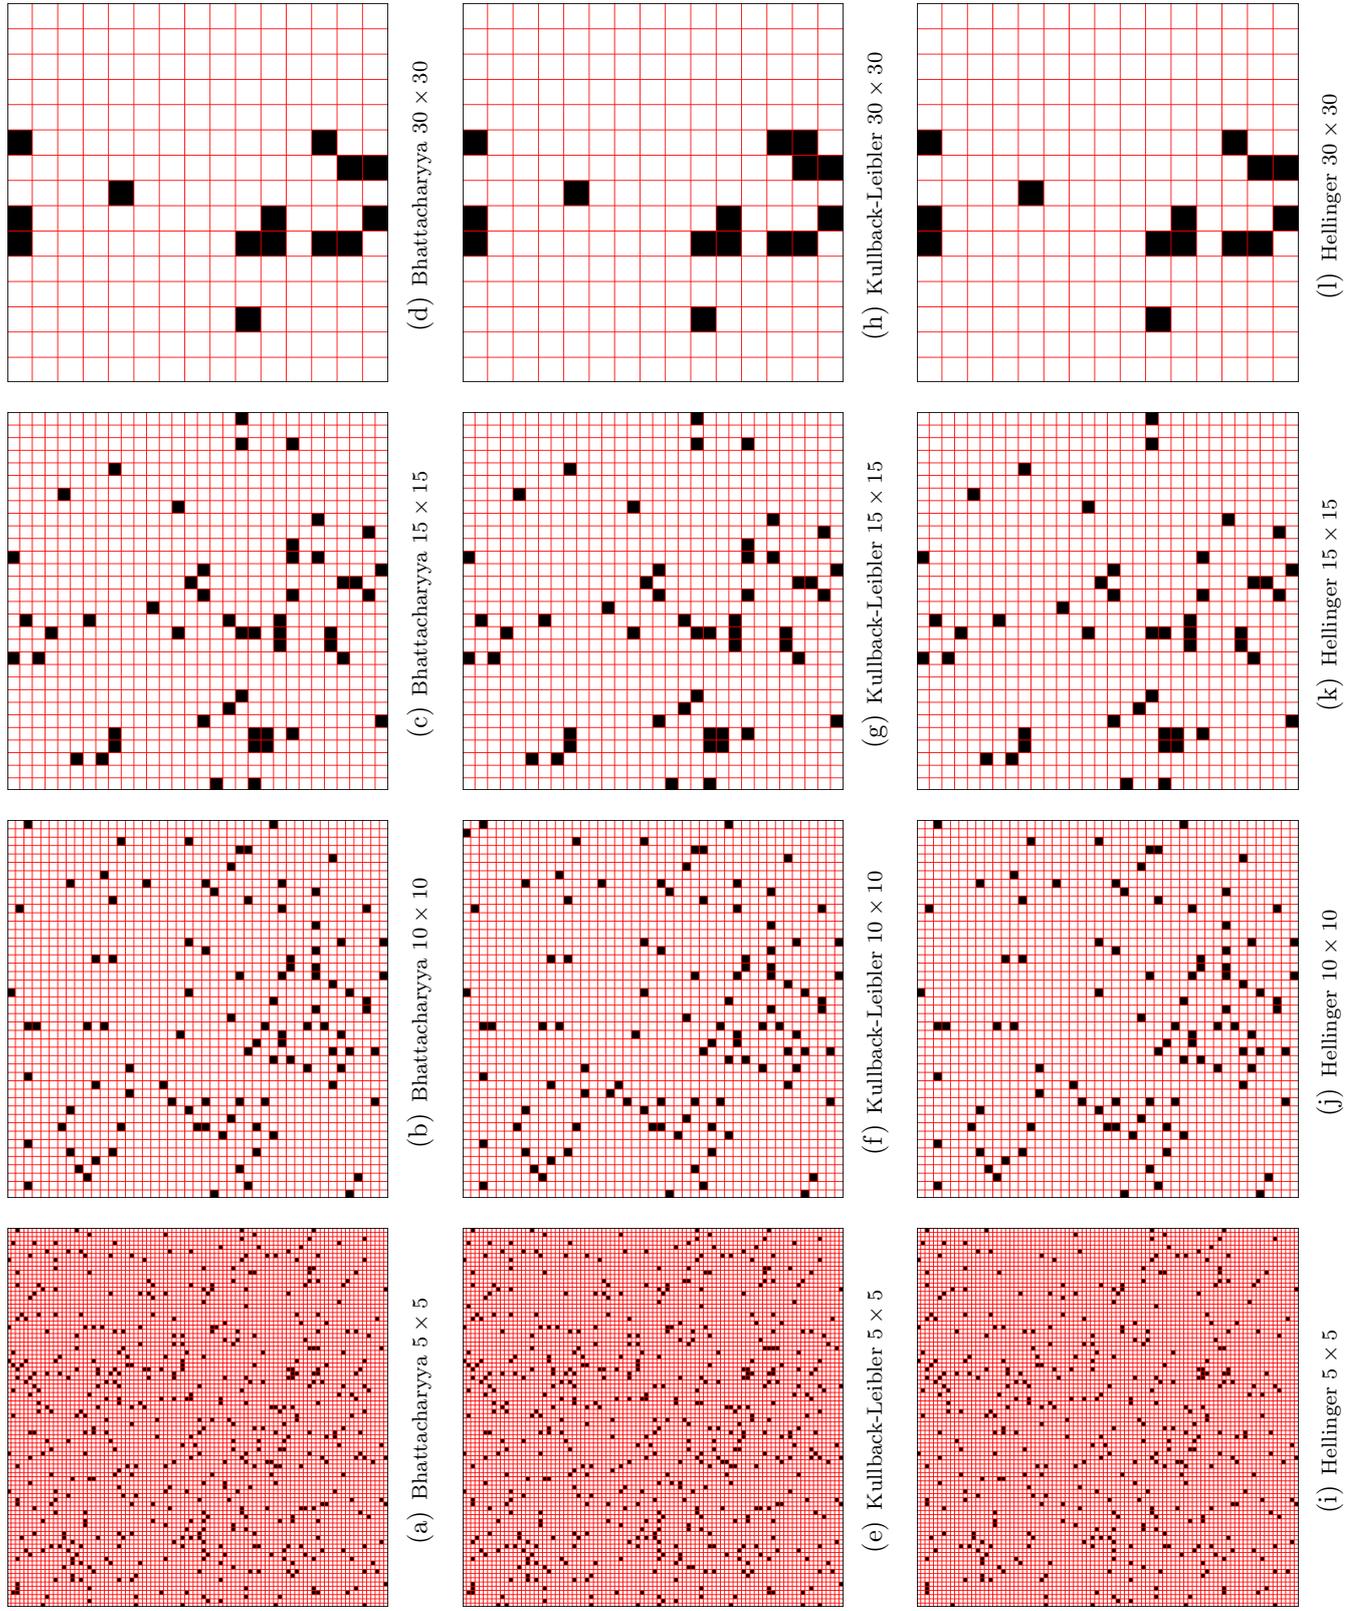


Figura 4.9 - Mapas binários de estimativas de p -valor para classificações das imagens simuladas, distâncias de Bhattacharyya, Kullback-Leibler e Hellinger - segmentos em branco tem hipótese nula não rejeitada ($p \geq 0,05$).

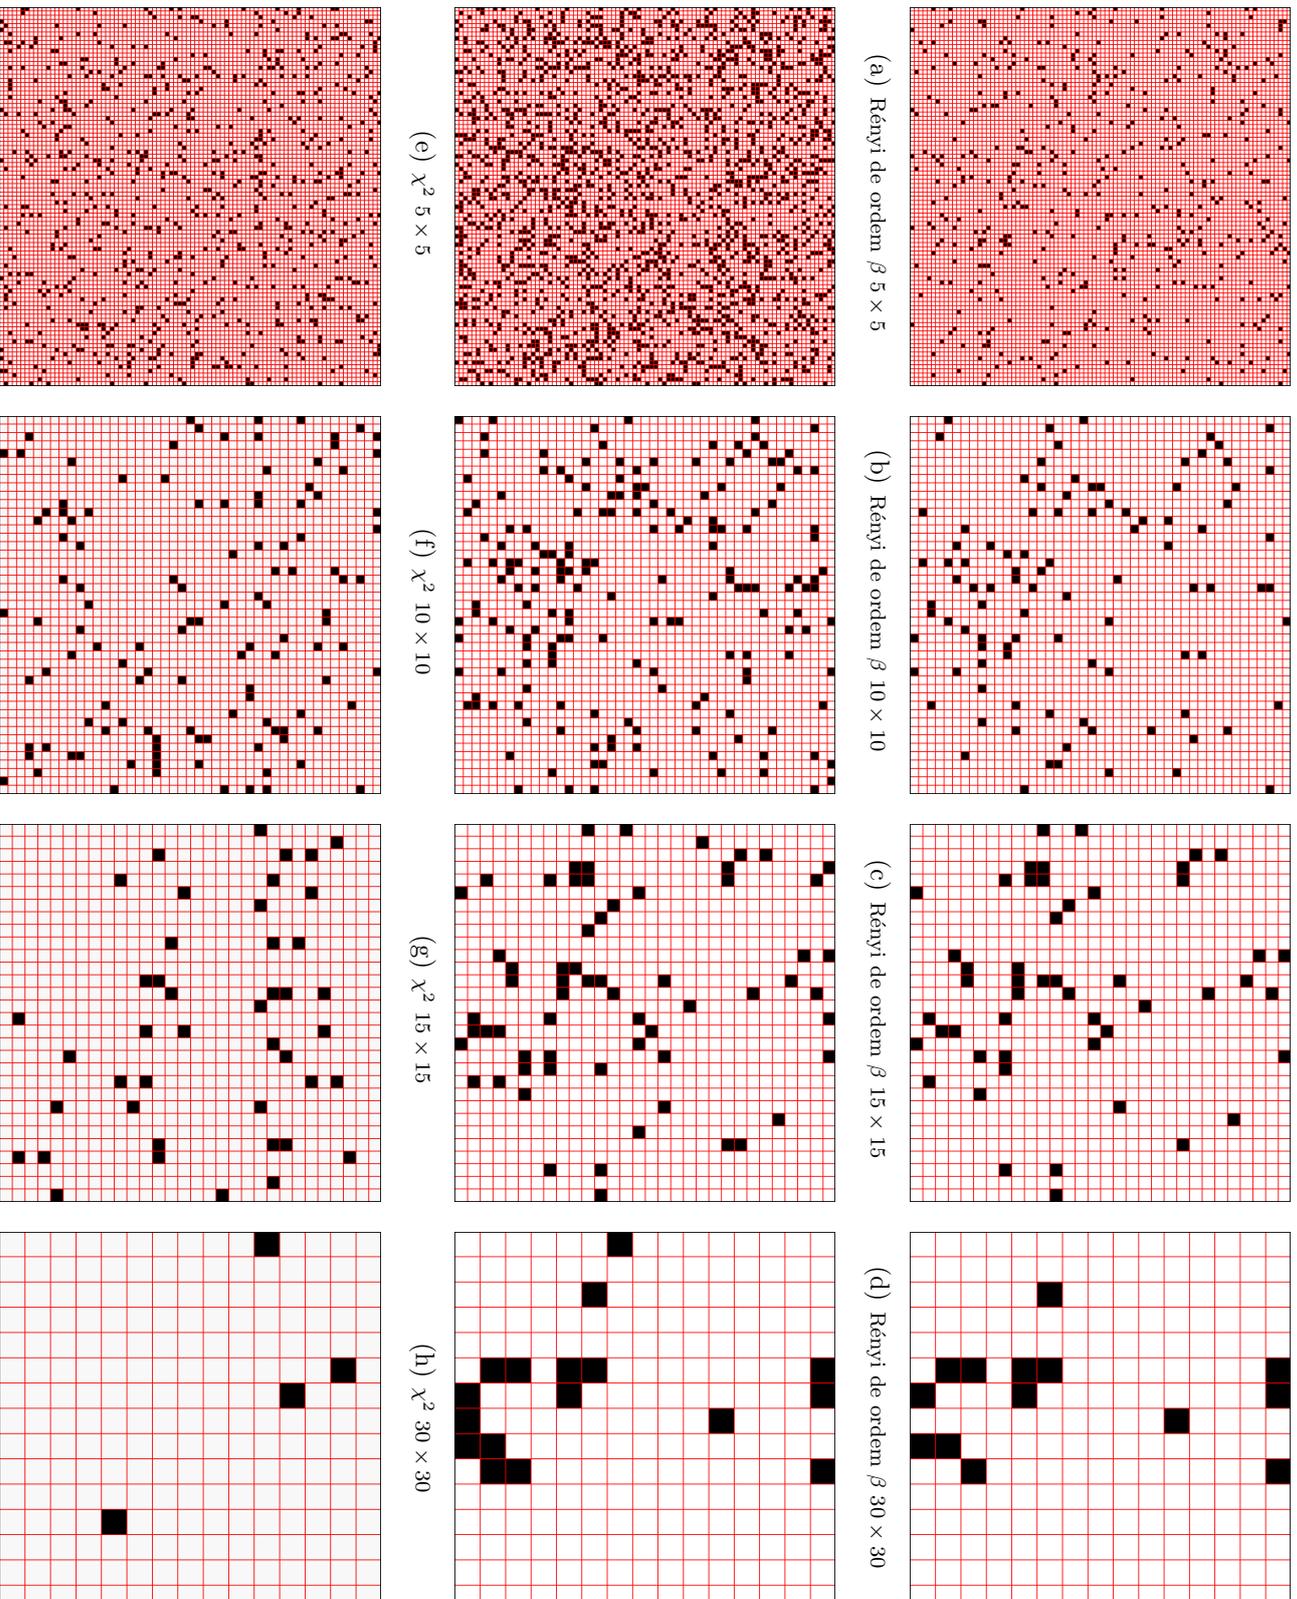


Figura 4.10 - Mapas binários de estimativas de p -valor para classificações das imagens simuladas, distâncias de Rényi de ordem β , χ^2 e Bhattacharyya gaussiana - segmentos em branco tem hipótese nula não rejeitada ($p \geq 0,05$).

pares de imagens com vistas a verificar o desempenho do módulo do classificador por regiões. As três imagens SAR simuladas em intensidade são apresentadas na Figura 4.11.

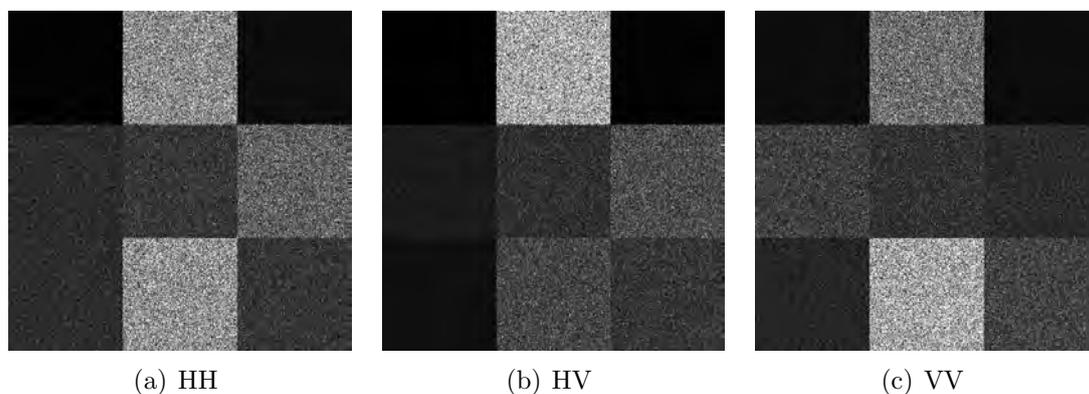


Figura 4.11 - Imagens SAR simuladas em intensidade.

As classificações com os pares de imagens em intensidade obtiveram resultados ligeiramente diferentes das classificações com os demais dados. Os valores de acurácia global para estas classificações são apresentadas na Tabela 4.13. Enquanto nas classificações com dados PolSAR e dados SAR em amplitude obtiveram resultados de acurácia global de 100% para as classificações com todos os tamanhos de segmento, exceto o de 5×5 pixels, com relação aos pares de intensidade, a única configuração que obteve resultado similar foi a HV,VV. Para o caso do par HH,HV, somente a classificação com segmentos de 30×30 pixels alcançou acurácia global de 100%. As classificações com segmentos de 5×5 , 10×10 e 15×15 pixels obtiveram acurácias globais menores do que 100%. Para o caso do par HH,VV, a acurácia global de 100% foi alcançada apenas com as segmentações de tamanhos de segmentos iguais a 15×15 e 30×30 pixels.

As classificações dos três pares de intensidade, para todas as segmentações disponíveis, com utilização da distância de Bhattacharyya por solução numérica são apresentadas na Figura 4.12. Pode-se verificar, tanto quantitativamente (Tabela 4.13) quanto visualmente, que o par HV,VV obteve melhor resultado de classificação, sendo possivelmente a configuração que apresenta a melhor separabilidade entre as classes definidas. O resultado de acurácia global utilizando o par de intensidades HV,VV é estatisticamente inferior ao resultado utilizando as distâncias entre distri-

Tabela 4.13 - Valores de acurácia global para classificações dos pares de intensidade utilizando distância de Bhattacharyya.

Par de Intensidades	Acurácia global (%)			
	5 × 5 pixels 8100 segmentos	10 × 10 pixels 2025 segmentos	15 × 15 pixels 900 segmentos	30 × 30 pixels 225 segmentos
HH,HV	93,25	96,74	98,44	100
HH,VV	92,64	99,36	100	100
HV,VV	98,28	100	100	100

buições Wishart. Os resultados de acurácia global obtidos pela classificação do par de intensidades HV,VV e pela classificação com dados em amplitude multivariada são estatisticamente iguais. Os mapas de segmentos para os quais a hipótese nula não foi rejeitada ao nível de significância de 5% são apresentados na Figura 4.13.

As porcentagens de segmentos cuja hipótese H_0 não foi rejeitada ao nível de significância de 5%, levando-se em conta cada tamanho de segmento e par de intensidades utilizados, com classificação feita pela distância estocástica de Bhattacharyya (solução numérica) são apresentadas na Tabela 4.14.

Tabela 4.14 - Porcentagem de segmentos cuja hipótese H_0 não foi rejeitada ao nível de significância de 5%, para o caso dos dados simulados (pares de intensidade).

Par de intensidades	Porcentagem (%)			
	5 × 5 pixels 8100 segmentos	10 × 10 pixels 2025 segmentos	15 × 15 pixels 900 segmentos	30 × 30 pixels 225 segmentos
HH,HV	94,46	92,20	93,89	91,11
HH,VV	93,74	91,21	91,22	92,00
HV,VV	94,26	94,17	94,44	94,67

Os resultados de classificação obtidos com a utilização dos pares de imagens em intensidade mostram-se, na maioria dos casos, de qualidade inferior àqueles obtidos quando da utilização dos dados PolSAR ou em amplitude multivariada, haja vista os indicadores de qualidade apresentados. As classes que apresentaram maior confusão foram Soja 2 e Milho 2, a exemplo do que aconteceu com os resultados do classificador de dados PolSAR e gaussiano para pequenos segmentos, mas em grau

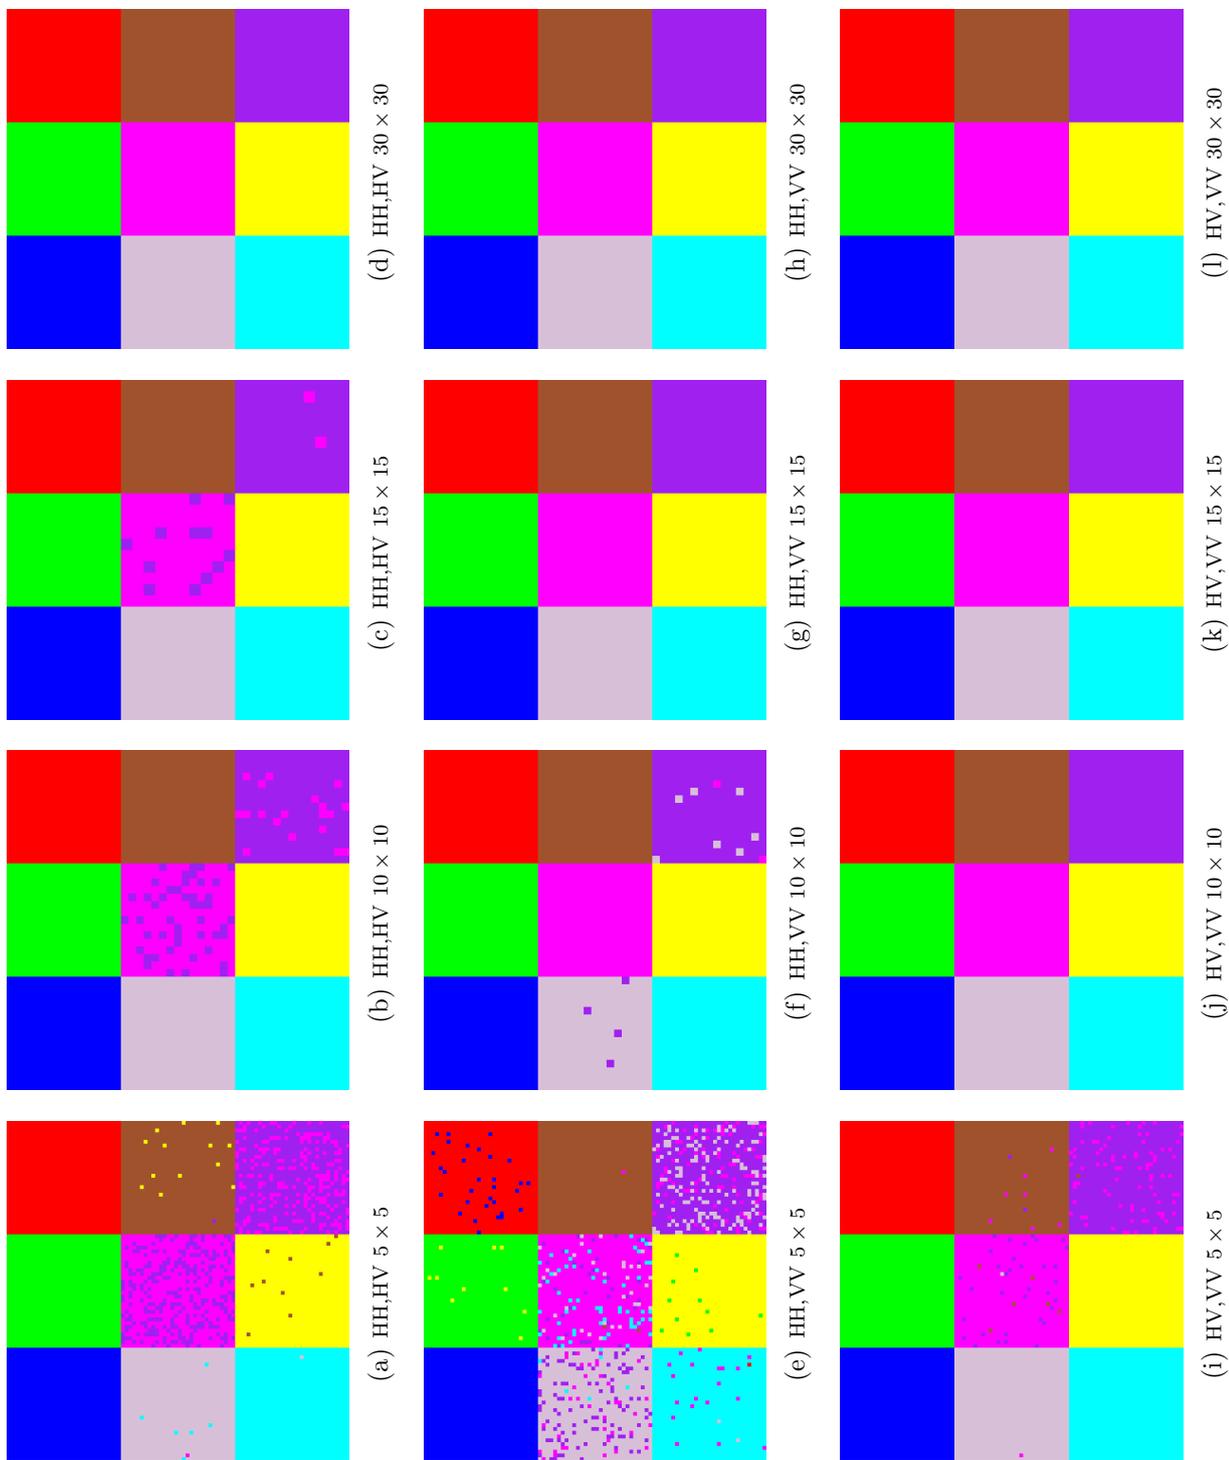


Figura 4.12 - Classificações dos pares de imagem SAR em intensidade com distância de Bhattacharyya (solução numérica), por tamanho de segmento.

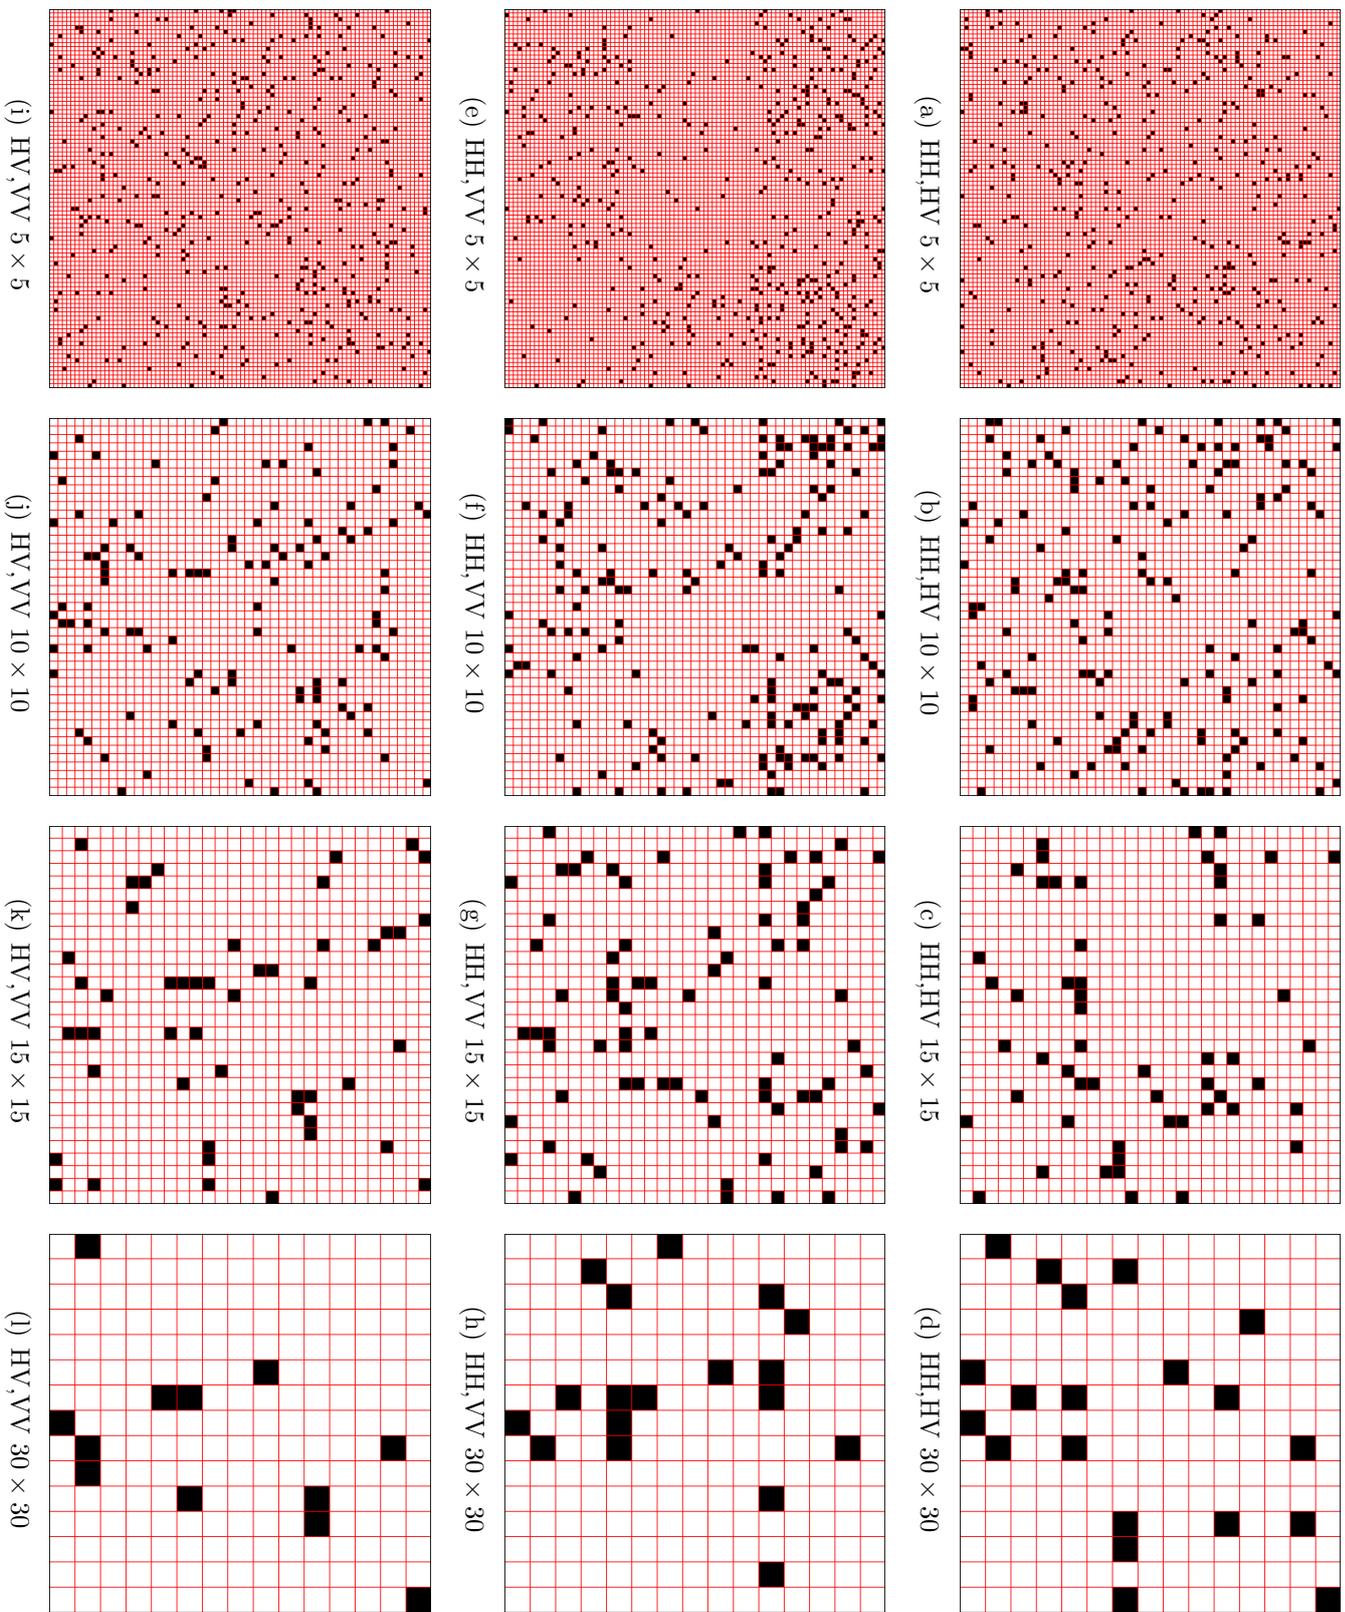


Figura 4.13 - Mapas binários de p -valores para classificações dos pares de imagens SAR em intensidade, HH, HV; HH, VV; HV, VV - segmentos em branco tem hipótese nula aceita ($p \geq 0.05$).

mais elevado. No caso do par HH,VV, a classificação com utilização da segmentação com 5×5 pixels obteve significativa confusão entre outros pares de classes, como por exemplo Rio e Solo Exposto, Soja 1 e Soja 2 e também Caatinga e Milho 1. Entretanto, mesmo obtendo resultados sensivelmente piores, o módulo em questão alcançou valores excelentes de acurácia global, permanecendo sempre maiores do que 93%, pelo menos. Levando-se em conta a menor dimensionalidade dos dados (apenas dois atributos) e a solução numérica utilizada pela ferramenta como possíveis fatores de influência no desempenho do classificador, os resultados podem ser ainda considerados coerentes com o esperado teoricamente, assegurando a potencialidade de utilização do classificador que utiliza pares de imagens SAR em intensidade.

De modo geral, as taxas de rejeição dos testes de hipótese obtidas pelas classificações envolvendo os pares de imagem em intensidade ficaram um pouco maiores do que as obtidas pelos casos PolSAR e amplitude multivariada. Entretanto, ainda assim ficaram bastante próximas ao esperado (5%), conforme pode ser observado na Tabela 4.14. Com a utilização de dados gerados sob condições rigorosamente conhecidas os resultados obtidos contribuem para confirmar a potencialidade do módulo de classificação por regiões de pares de imagens SAR em intensidade, assim como foi verificado nos outros dois classificadores.

4.2.3 Aplicação em dados PolSAR SIR-C reais

Conforme comentado na Seção 2.4, a classificação por regiões requer a segmentação da imagem a ser classificada. Com o objetivo de classificar as imagem PolSAR SIR-C nas banda L e C, foi utilizada uma segmentação obtida pelo software SegSAR (SOUSA-JÚNIOR, 2005), que utiliza um algoritmo hierárquico multi-níveis fundamentado no crescimento de regiões, projetado para imagens SAR e que utiliza testes estatísticos com base nas distribuições gama e gaussiana. Foram utilizadas para a segmentação as três componentes de intensidade (HH, HV e VV) extraídas da imagem PolSAR SIR-C da banda L. A banda L foi selecionada para a segmentação por ser melhor em termos de identificação das bordas entre as diferentes regiões. Os valores dos parâmetros relativos ao crescimento de regiões foram 100 pixels de área mínima e 1 dB de similaridade. O parâmetro área mínima foi definido visando ao estabelecimento de um valor que representasse um equilíbrio entre a necessidade de uma quantidade mínima de amostras por segmento a serem utilizadas no teste de hipótese $h-\phi$ e a formação de segmentos de tamanho adequado, representando com fidelidade a disposição das regiões da cena.

O número equivalente de visadas (*looks*) foi estimado por Correia (1998), levando-se em conta todos os canais de polarização com uso do método denominado por Anfinson et al. (2009) como estimativa por momentos fracionários. O valor estimado por Correia (1998) foi de 2,97. A imagem segmentada é apresentada na Figura 4.14, em que cada segmento é apresentado em uma cor definida pela associação dos canais RGB às médias de cada componente de polarização em intensidade (HH, HV e VV). O procedimento de classificação descrito pela equação (3.1) foi aplicado então à imagem PolSAR SIR-C, nas bandas L e C, utilizando este resultado de segmentação.

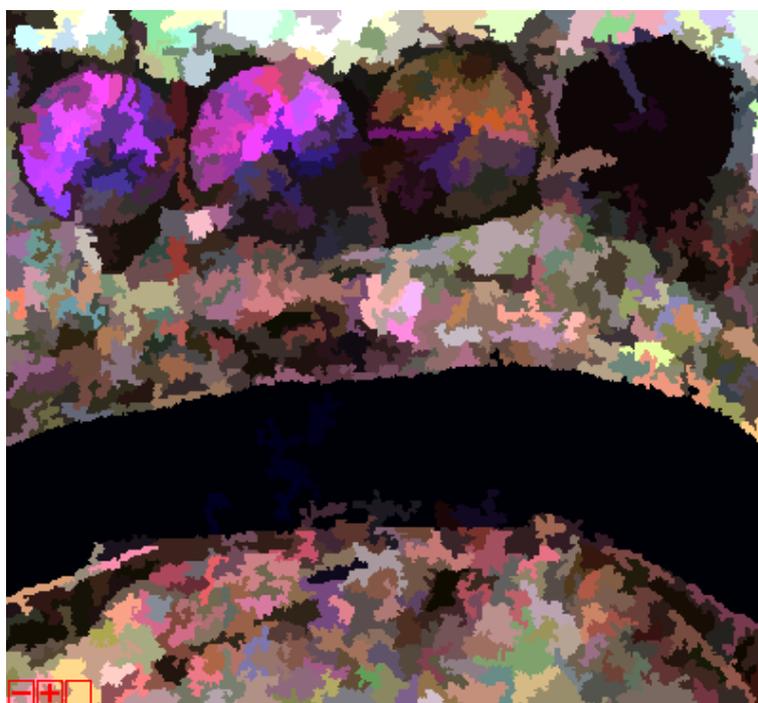


Figura 4.14 - Segmentação da imagem PolSAR SIR-C, banda L.

Com a segmentação, foram obtidas 553 regiões, cujos tamanhos (quantidade de pixels) variam de 101 a 31343. O segmento que possui 31343 pixels é um exemplo de *outlier*, pois apresenta um número muito maior de pixels do que os demais. Este segmento corresponde à maior parte da área do Rio que, por sua homogeneidade, acaba contida quase totalmente em uma mesma região no processo de segmentação. Um outro segmento, que corresponde ao pivô de irrigação onde domina a área da classe Solo Preparado, possui 6369 pixels. Com exceção desses dois segmentos, todos possuem menos de 1000 pixels, sendo que a média do número de pixels por segmento

é de aproximadamente 230.

Com a utilização de imagens reais, pode ser observado que, em relação às imagens simuladas, o número de *looks* é menor, os dados possuem autocorrelação e o número de pixels de boa parte dos segmentos não é muito grande. Portanto, espera-se que os resultados para imagens reais sejam piores do que os obtidos para imagens simuladas.

As imagens PolSAR foram então classificadas utilizando-se o classificador por regiões baseado na modelagem Wishart complexa. Neste caso foram utilizadas as estatísticas de teste dadas pelas equações (2.45)–(2.49). A exemplo do que foi feito com as imagens simuladas, foram extraídas das imagens PolSAR, uma imagem multivariada SAR em amplitude e três pares de imagens SAR em intensidade, para cada banda de frequência (L e C). A classificação utilizando as três imagens em amplitude foi efetuada através do classificador baseado na modelagem gaussiana multivariada, com cálculo da estatística de teste derivada da distância de Bhattacharyya, conforme equação (2.51). Para os pares de intensidade, foi empregado o classificador apropriado, com cálculo da estatística derivada da distância de Bhattacharyya por método numérico. O p -valor, definido na equação (3.2), foi calculado para cada segmento em cada classificação utilizada.

Esses resultados de classificação por regiões foram comparados com a classificação polarimétrica pontual/contextual, que emprega o método de máxima verossimilhança (MaxVer)/ICM (Iterated Conditional Modes) implementado por Correia (1998). O classificador desenvolvido por Correia (1998) apresenta a funcionalidade de seleção entre três modelagens para os dados PolSAR para a utilização do algoritmo de classificação pontual MaxVer: Wishart, \mathcal{K}_P e \mathcal{G}_P^0 . Neste trabalho, foi utilizada somente a modelagem com base na distribuição Wishart, para comparação com os resultados do classificador por regiões. Foram obtidas então nove classificações por regiões e uma classificação pontual/contextual–MaxVer/ICM.

Os desempenhos de classificação foram comparados utilizando-se a estimativa do coeficiente de concordância *kappa* ($\hat{\kappa}$) e a acurácia global, conforme descritos na Seção 2.5.

4.2.3.1 Resultados obtidos com os dados PolSAR da banda L

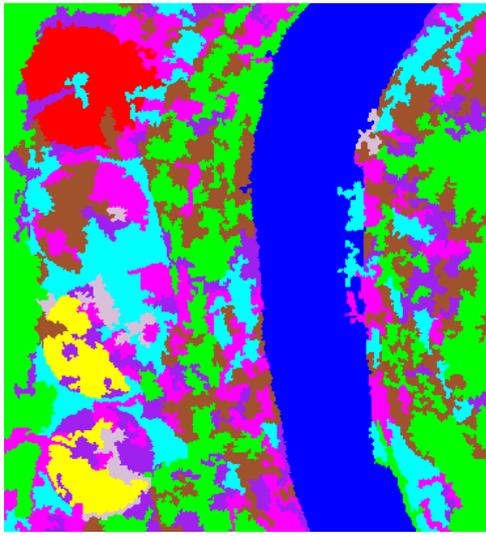
As imagens classificadas a partir da imagem polarimétrica da banda L estão apresentadas em duas figuras. Na Figura 4.15, são apresentados os resultados utilizando-se

as distâncias de Bhattacharyya, Kullback-Leibler, Hellinger, Rényi de ordem β e χ^2 entre distribuições Wishart complexas escalonadas, além do resultado de classificação contextual ICM, para comparação. Na Figura 4.16, são apresentados os resultados utilizando-se as distâncias Bhattacharyya entre distribuições gaussianas multivariadas e Par de Intensidades *multi-look*, além do resultado de classificação contextual ICM, para comparação. Foram obtidas matrizes de confusão com utilização das imagens classificadas e das amostras de teste para as nove classificações realizadas. A acurácia global, a estimativa do coeficiente de concordância *kappa* ($\hat{\kappa}$) e sua variância foram obtidas a partir das matrizes de confusão e são apresentados na Tabela 4.15.

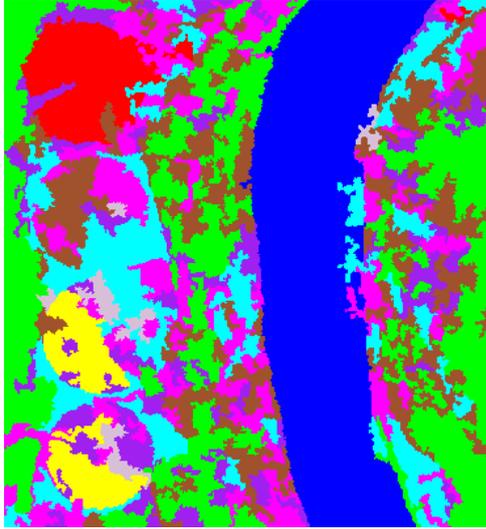
Tabela 4.15 - Resultados de classificação por regiões para a imagem PolSAR SIR-C banda L, imagem amplitude multivariada, pares de intensidade e classificação pontual MaxVer/ICM.

Método de classificação	Distância (modelo)	Imagem SIR-C banda L		
		Acurácia Global (%)	$\hat{\kappa}$	$s_{\hat{\kappa}}^2 (\times 10^{-5})$
Por Regiões	Bhattacharyya (Wishart)	86,60	0,835	1,25
	Kullback-Leibler (Wishart)	86,60	0,835	1,25
	Hellinger (Wishart)	85,97	0,827	1,30
	Rényi (ordem $\beta = 0,9$) (Wishart)	86,60	0,835	1,25
	χ^2 (Wishart)	71,36	0,654	2,08
	Bhattacharyya (Gauss. mult.)	85,35	0,819	1,33
	Bhattacharyya (Par Int.-HH,HV)	79,95	0,755	1,66
	Bhattacharyya (Par Int.-HH,VV)	71,60	0,653	2,02
	Bhattacharyya (Par Int.-HV,VV)	82,71	0,788	1,49
Contextual	MaxVer/ICM - Wishart	83,97	0,803	1,43

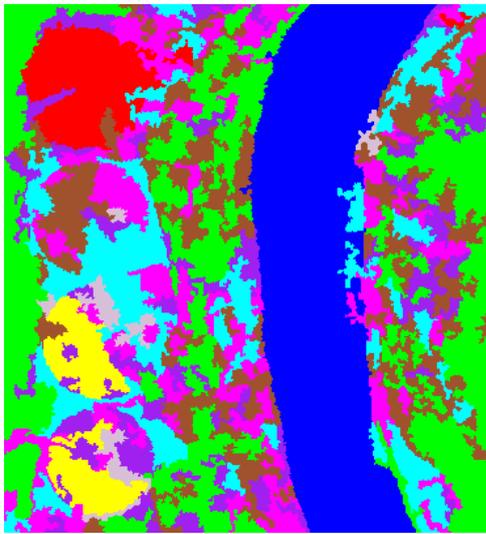
Foram feitos testes de hipótese com vistas a verificar a igualdade entre as matrizes de confusão resultantes das avaliações de todas as classificações, conforme procedimento descrito pela equação (2.54). Os resultados desses testes são apresentados na Tabela 4.16. A Tabela 4.16 é organizada do seguinte modo: na primeira linha e primeira coluna estão os nomes das dez classificações realizadas, nove por regiões e uma por classificação pontual/contextual (ICM). Compreendendo a tabela como uma matriz quadrada de ordem 10×10 , os elementos acima da diagonal principal (triang. superior) são os p -valores obtidos nos testes de hipótese para verificação de igualdade e os elementos abaixo da diagonal principal (triang. inferior) são os valores



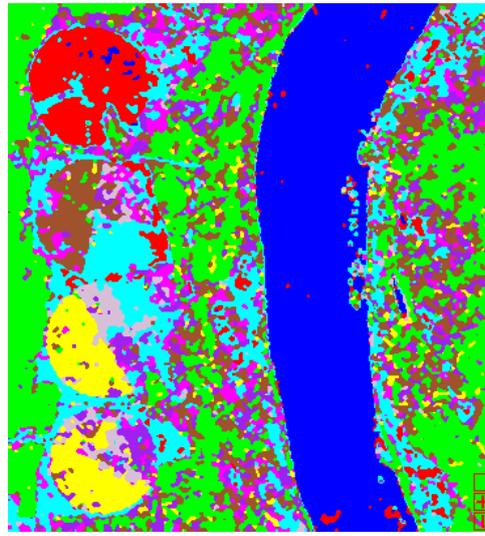
(a) Bhattacharyya



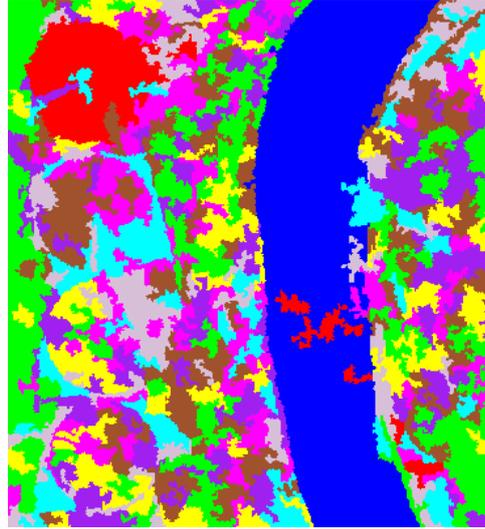
(b) Kullback-Leibler



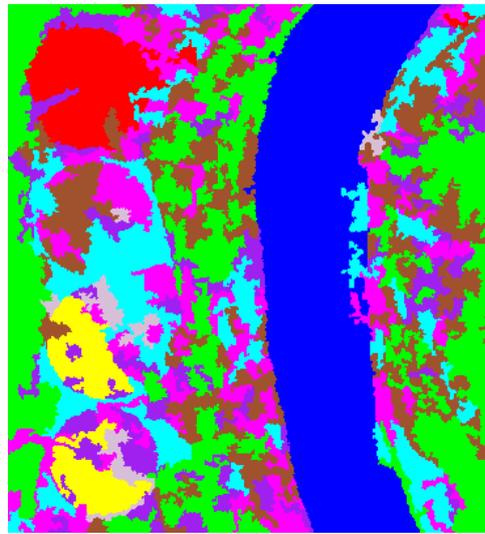
(c) Helinger



(f) MaxVer/ICM

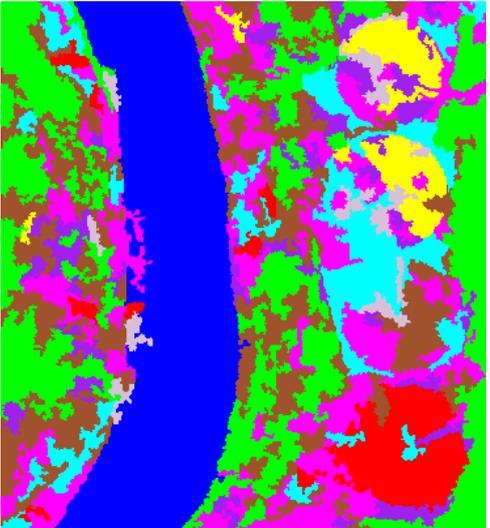


(e) χ^2

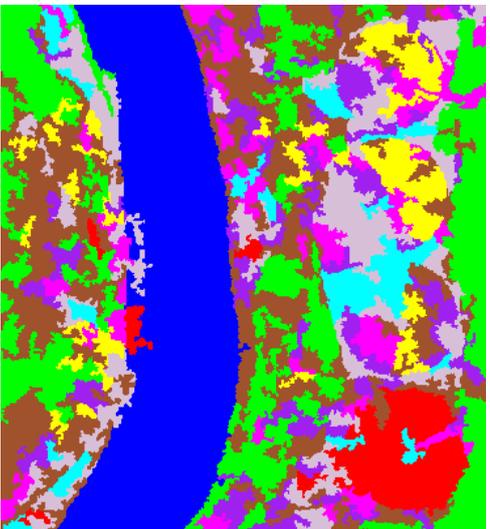


(d) Rényi de ordem 0,9

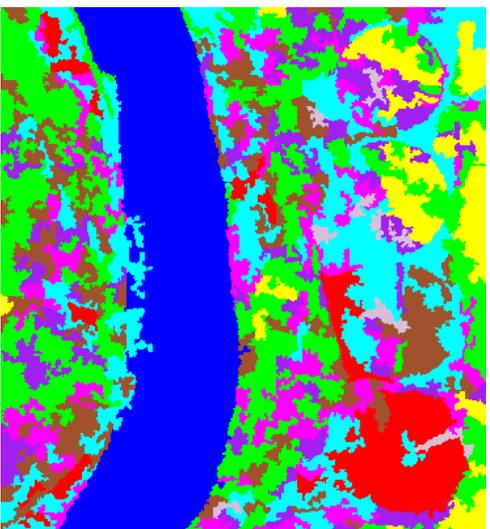
Figura 4.15 - Resultados de classificação utilizando distâncias entre distribuições Wishart



(a) Bhattacharyya Gauss. Mult.



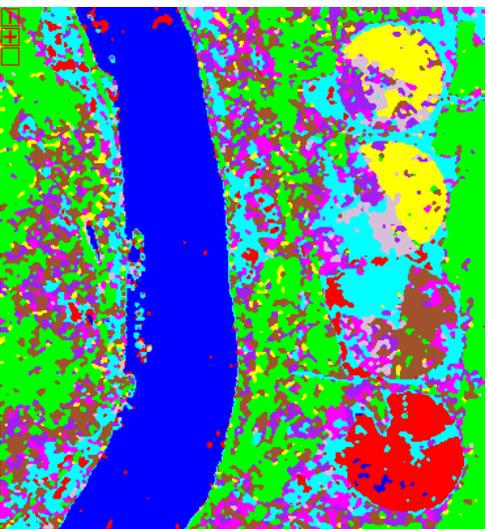
(b) Bhattacharyya (Par Int.-HH, HV)



(c) Bhattacharyya (Par Int.-HH, VV)



(d) Bhattacharyya (Par Int.-HV, VV)



(e) MaxVer/ICM

Figura 4.16 - Resultados de classificação utilizando distâncias entre distribuições gaussianas multivariadas e entre distribuições Par de intensidades *multi-look*

de estatística de teste obtidos. Verificam-se que alguns dos p -valores encontrados foram maiores do que 5%, nível de significância utilizado, e correspondem a valores de estatística Z menores do que 1,96, valor crítico. Esses valores, que estão assinalados em negrito, indicam igualdade estatística entre as matrizes de confusão obtidas e, portanto, entre as classificações. Na Tabelas 4.16 os nomes dados as classificações são organizados como se segue:

BAT - Classificação por regiões utilizando a distância de Bhattacharyya entre duas distribuições Wishart.

KL - Classificação por regiões utilizando a distância de Kullback-Leibler entre duas distribuições Wishart.

HEL - Classificação por regiões utilizando a distância de Hellinger entre duas distribuições Wishart.

REN - Classificação por regiões utilizando a distância de Rényi de ordem $\beta = 0,9$ entre duas distribuições Wishart.

CHI - Classificação por regiões utilizando a distância χ^2 entre duas distribuições Wishart.

BAT_G - Classificação por regiões utilizando a distância de Bhattacharyya entre duas distribuições Gaussianas multivariadas.

BAT_{HHHV} - Classificação por regiões utilizando a distância de Bhattacharyya entre duas distribuições Par de Intensidades *Multi-look* (Par HHHV).

BAT_{HHVV} - Classificação por regiões utilizando a distância de Bhattacharyya entre duas distribuições Par de Intensidades *Multi-look* (Par HHHV).

BAT_{HVVV} - Classificação por regiões utilizando a distância de Bhattacharyya entre duas distribuições Par de Intensidades *Multi-look* (Par HHHV).

ICM - Classificação pontual/contextual MaxVer/ICM utilizando a distribuição Wishart complexa escalonada.

Os testes mostraram que as classificações com base nas distâncias de Bhattacharyya, Hellinger, Kullback-Leibler e Rényi de ordem $\beta = 0,9$ entre distribuições de Wishart

Tabela 4.16 - Resultados de teste de igualdade entre matrizes de confusão - Banda L. Parte triangular superior: p -valores - Parte triangular inferior: estatísticas Z .

	BAT	KL	HEL	REN	CHI	BAT _G	BAT _{HHV}	BAT _{HVV}	BAT _{HVVV}	ICM
BAT	-	1	0,13	1	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
KL	0	-	0,13	1	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
HEL	1,53	1,53	-	0,13	<0,01	0,13	<0,01	<0,01	<0,01	<0,01
REN	0	0	1,53	-	<0,01	<0,01	<0,01	<0,01	<0,01	<0,01
CHI	31,22	31,22	29,68	31,22	-	<0,01	<0,01	0,78	<0,01	<0,01
BAT _G	3,05	3,05	1,52	3,05	28,19	-	<0,01	<0,01	<0,01	<0,01
BAT _{HHV}	14,78	14,78	13,25	14,78	16,44	11,74	-	<0,01	<0,01	<0,01
BAT _{HVV}	31,82	31,82	30,26	31,82	0,28	28,75	16,86	-	<0,01	<0,01
BAT _{HVVV}	8,92	8,92	7,38	8,92	22,33	5,87	5,88	22,82	-	<0,01
ICM	6,20	6,20	4,67	6,20	25,00	3,15	8,57	25,52	2,71	-

produziram resultados estatisticamente iguais. Observa-se ainda, tanto quantitativamente, quanto por análise visual, que os resultados referentes às distâncias Bhattacharyya, Kullback-Leibler e Rényi de ordem $\beta = 0,9$ são idênticos e correspondem aos melhores resultados encontrados dentre todas as classificações realizadas.

Com respeito à comparação entre as classificações que utilizam dados PolSAR completos na banda L e modelagem Wishart complexa escalonada, pode-se verificar, sob ponto de vista quantitativo, que há uma melhora significativa de classificação quando se utiliza a abordagem por regiões e distâncias estocásticas em relação à abordagem contextual. O melhor desempenho, sob o viés quantitativo, pode ser comprovado pelos valores de coeficiente de concordância *kappa* estimados ($\hat{\kappa}$), que foram de 0,835 para as melhores classificações por regiões que utilizam distâncias estocásticas entre distribuições Wishart complexas escalonadas e de 0,803 para a classificação contextual ICM, como pode ser verificado na Tabela 4.15.

Considerando as classificações que utilizam dados PolSAR, a classificação contextual ICM supera a classificação por distância estocástica χ^2 , que se mostra novamente como o pior resultado dentre as classificações por regiões analisadas, estando portanto em conformidade com os resultados encontrados com os dados simulados.

A classificação com base na distância de Bhattacharyya entre modelos gaussianos multivariados é superior à classificação pontual/contextual ICM e à que utiliza a distância χ^2 entre modelos Wishart. Entretanto, é estatisticamente igual à classificação que utiliza a distância de Hellinger entre modelos Wishart.

Dentre as classificações por regiões dos pares de imagens SAR em intensidade na banda L, obtidas com distância de Bhattacharyya, as que utilizam os pares HH,HV e HV,VV apresentaram desempenho superior à classificação com a distância χ^2 , enquanto a que utiliza o par HH,VV mostrou-se estatisticamente igual a que utiliza a distância χ^2 . O par de intensidades HV,VV obteve o melhor resultado, que é significativamente superior às duas outras classificações de pares de intensidade. Convém também observar que o valor de κ obtido pelo par HV,VV (0,788) é estatisticamente superior ao obtido por Correia (1998) utilizando o classificador pontual ICM com distribuições gama bivariadas (0,682).

Na Tabela 4.17 é apresentada, para cada distância estocástica, a porcentagem de segmentos para os quais o p -valor foi maior do que 5%, ou seja, porcentagem de

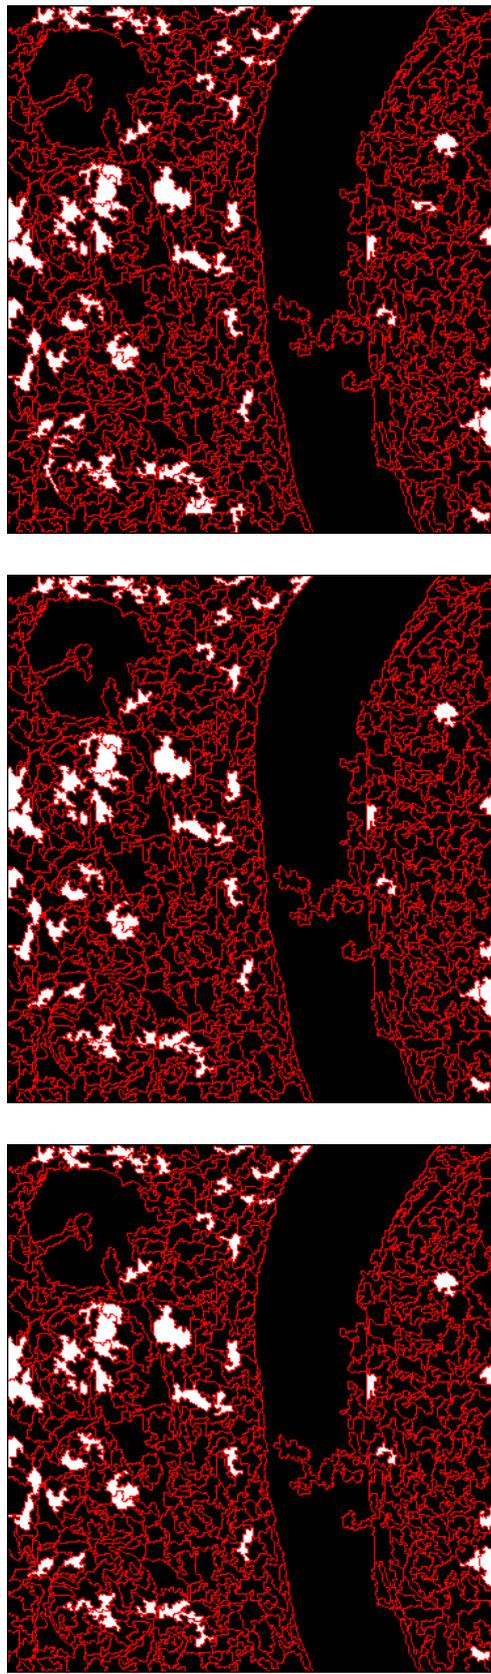
segmentos que não tiveram a hipótese nula (H_0) rejeitada ao nível de significância 5%. Tais segmentos são ilustrados em branco nas Figuras 4.17 e 4.18.

Tabela 4.17 - Porcentagem de segmentos da imagem SIR-C banda L que não tiveram a hipótese H_0 rejeitada ao nível de significância 5%.

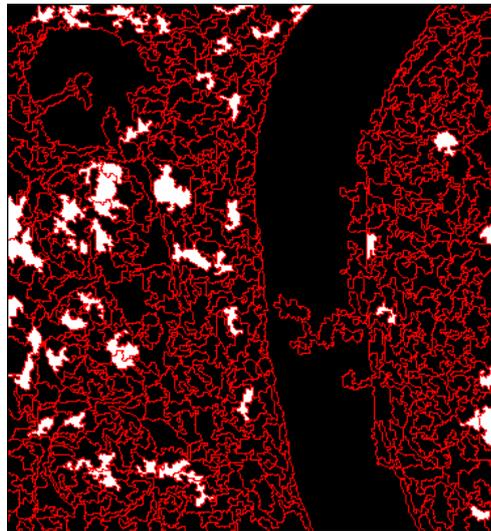
Distâncias	Porcentagem (%)
Bhattacharyya	9,76
Kullback-Leibler	9,58
Hellinger	10,49
Rényi de ordem β)	9,58
χ^2	6,33
Bhattacharyya (Gauss. mult.)	6,33
Bhattacharyya (Par Int.-HH,HV)	27,85
Bhattacharyya (Par Int.-HH,VV)	27,85
Bhattacharyya (Par Int.-HV,VV)	18,99

Muito embora os valores da Tabela 4.15 tenham se mostrado bastante promissores para a classificação por mínima distância estocástica utilizando a modelagem Wishart, as porcentagens apresentadas na Tabela 4.17 estão bastante distantes da porcentagem teoricamente esperada (95%), ao contrário dos resultados obtidos com dados simulados, conforme análise da subseção 4.2.2. Levando-se em conta que as amostras selecionadas da banda L não seguem, na sua maioria, a distribuição de Wishart complexa escalonada (FRERY et al., 2007), a baixa quantidade de segmentos cuja hipótese nula não foi rejeitada em relação ao esperado poderia ser explicada em parte pela modelagem inapropriada dos dados e também pela autocorrelação entre os pixels. Esta afirmação pode ser corroborada pelos resultados obtidos com dados simulados que, seguindo rigorosamente a modelagem teórica, obtiveram resultados muito próximos aos esperados.

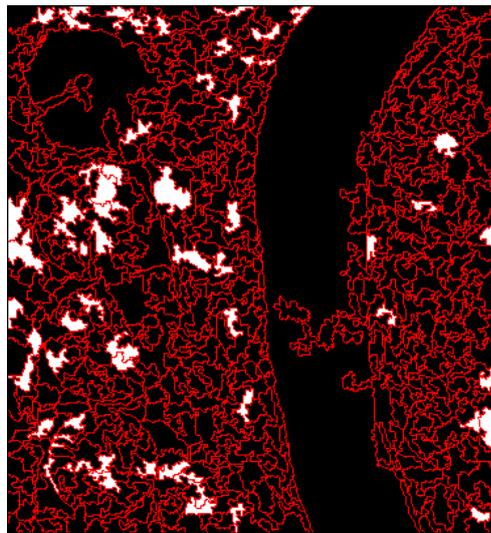
O resultado de número de segmentos cuja H_0 não foi rejeitada com a distância Hellinger mostrou-se levemente superior aos demais resultados PolSAR. Isto pode se dever ao fato de que a distância de Hellinger é, analiticamente, definida entre 0 e 1, o que gera resultados numéricos de distância menores do que as demais para um mesmo conjunto de parâmetros. Este efeito conseqüentemente passa para o cálculo da estatística de teste, apresentando valores também menores, podendo ter a hipótese nula aceita com maior frequência.



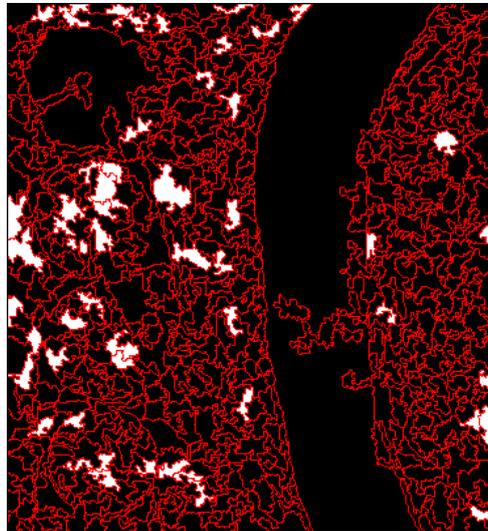
(a) Bhattacharyya



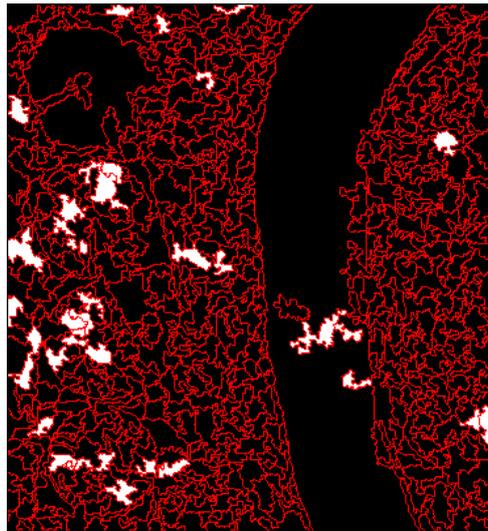
(b) Kullback-Leibler



(c) Hellinger

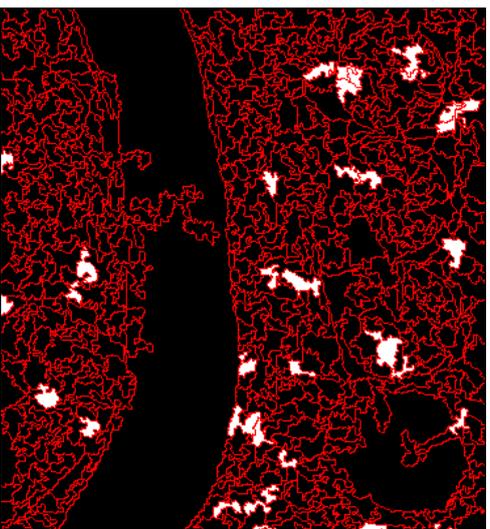


(d) Rényi de ordem 0,9

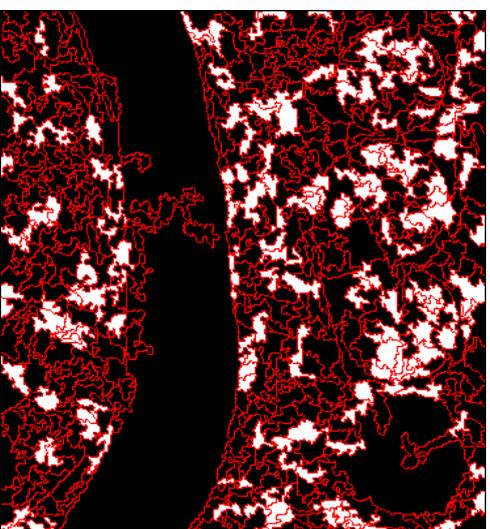


(e) χ^2

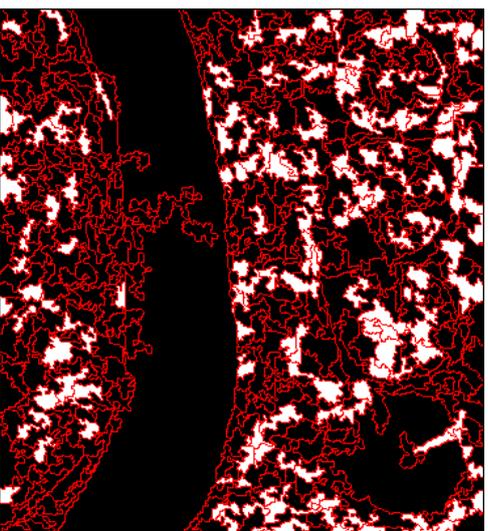
Figura 4.17 - Mapas binários de p -valores para classificações da imagem SIR-C banda L - distâncias entre distribuições Wishart - segmentos em branco tem hipótese nula não rejeitada ($p \geq 0,05$).



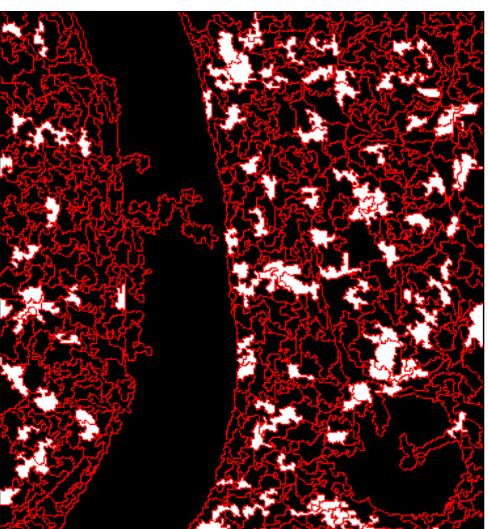
(a) Bhattacharyya Gauss. Mult.



(b) Bhattacharyya (Par Int.-HH,HV)



(c) Bhattacharyya (Par Int.-HH,VV)



(d) Bhattacharyya (Par Int.-HV,VV)

Figura 4.18 - Mapas binários de p -valores para classificações da imagem SIR-C banda L - distâncias entre distribuições gaussianas multivariadas e entre distribuições Par de intensidades *multi-look* - segmentos em branco tem hipótese nula não rejeitada ($p \geq 0,05$).

Para as classificações de pares de intensidade, a quantidade de segmentos que passaram no teste de hipótese foram significativamente mais próximos da porcentagem teoricamente esperada (95%). A menor dimensionalidade desses dados poderia explicar esses melhores valores em relação aos alcançados pelos dados PolSAR. Os dados PolSAR, além de conterem as intensidades, também englobam produtos entre amplitudes dos canais polarimétricos e diferenças de fase, nos elementos fora da diagonal principal, o que poderia contribuir para acentuar o afastamento em relação ao modelo teórico quando comparados aos pares de imagens SAR em intensidade.

Foram selecionadas quatro classificações para comparação de resultados por classe de cobertura. As classificações selecionadas e a motivação para sua escolha estão relacionadas a seguir:

Bhattacharyya entre distribuições Wishart: representante das melhores classificações por região com dados PolSAR;

Bhattacharyya entre distribuições gaussianas multivariadas: classificação utilizando imagem multivariada em amplitude;

Bhattacharyya entre distribuições Par de intensidades multilook - HVVV: melhor resultado de classificação utilizando pares de intensidade;

MaxVer/ICM: classificação pontual/contextual utilizando distribuição de Wishart.

Quatro gráficos ilustrativos com os valores constantes nas matrizes de confusão foram criados, correspondendo às quatro classificações selecionadas. Esses gráficos apresentam círculos cujos valores de área são proporcionais aos valores em porcentagem das matrizes de confusão. Os gráficos são apresentados nas Figuras 4.19–4.22.

A partir de uma análise mais detalhada, verifica-se que, em relação à abordagem pontual/contextual, a classificação por regiões obteve melhores classificações para as classes Rio, Caatinga, Solo Preparado, Soja 2, Soja 3 e Milho 2 e foi superada nas classes Soja 1, Restolho e Milho 2. A melhora de qualidade da classificação por regiões em relação à contextual pode ser observada também qualitativamente. Ao se observar o resultado da classificação MaxVer/ICM, identificam-se ainda uma grande quantidade de pequenas áreas indesejadas. Este efeito, inerente à classificação de

Referência



Classificação

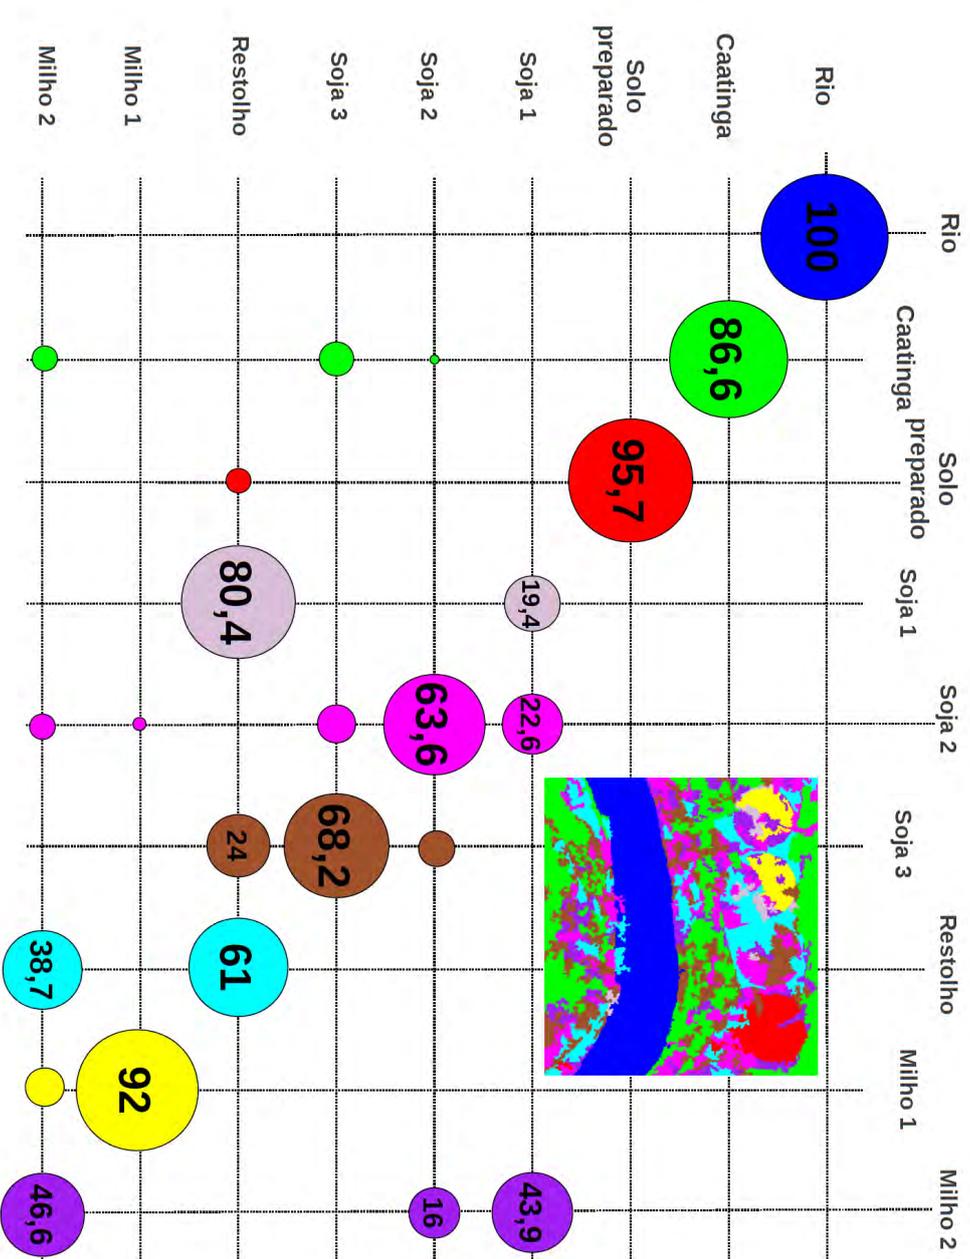


Figura 4.19 - Matriz de confusão - Distância de Bhattacharyya - Wishart.

Referência

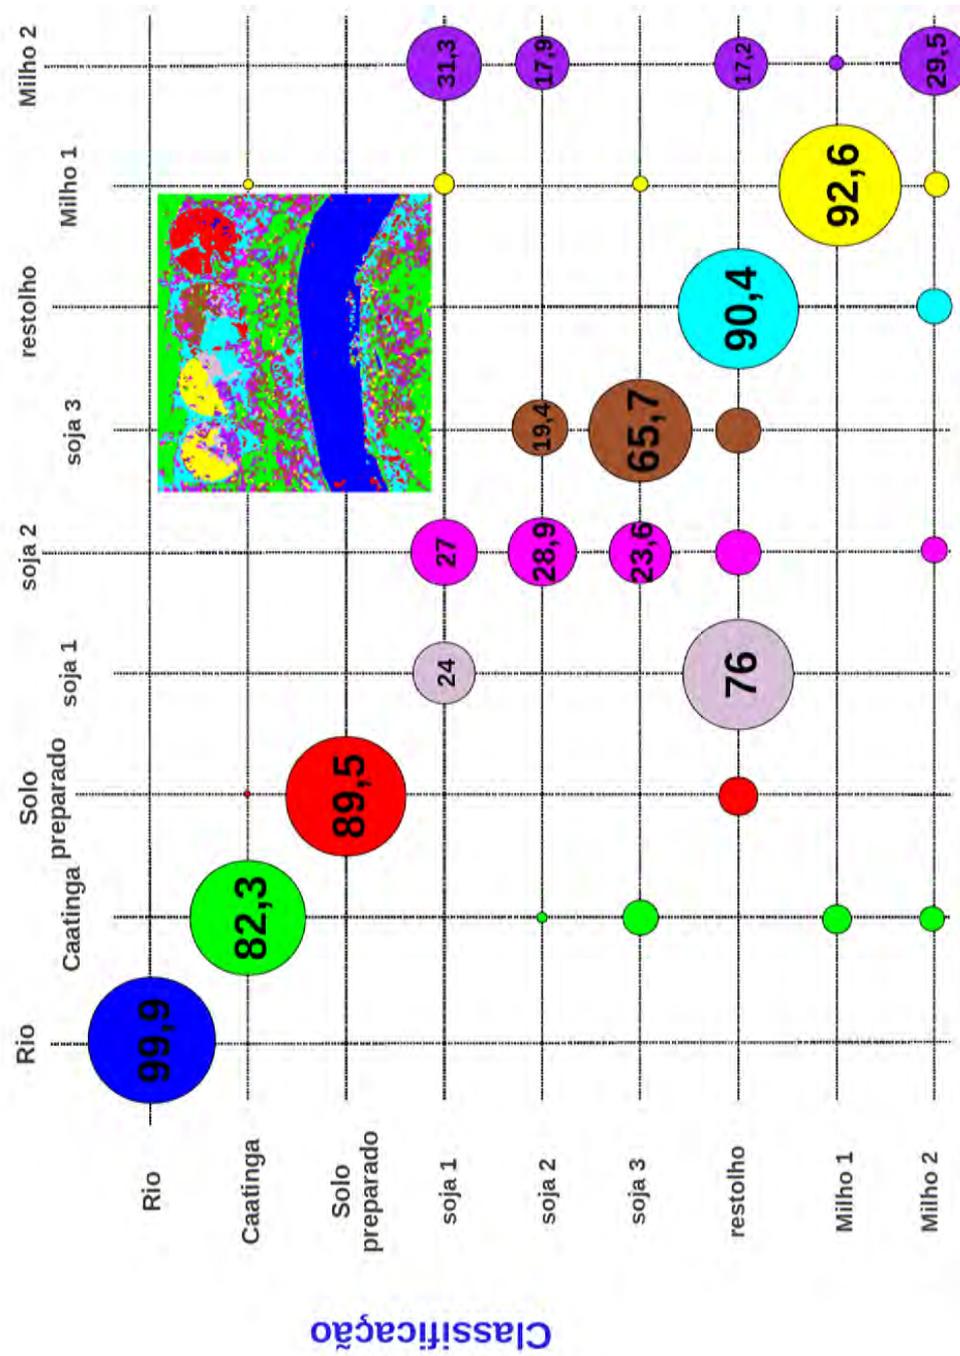


Figura 4.20 - Matriz de confusão - Classificador ICM - Modelagem Wishart.

Referência

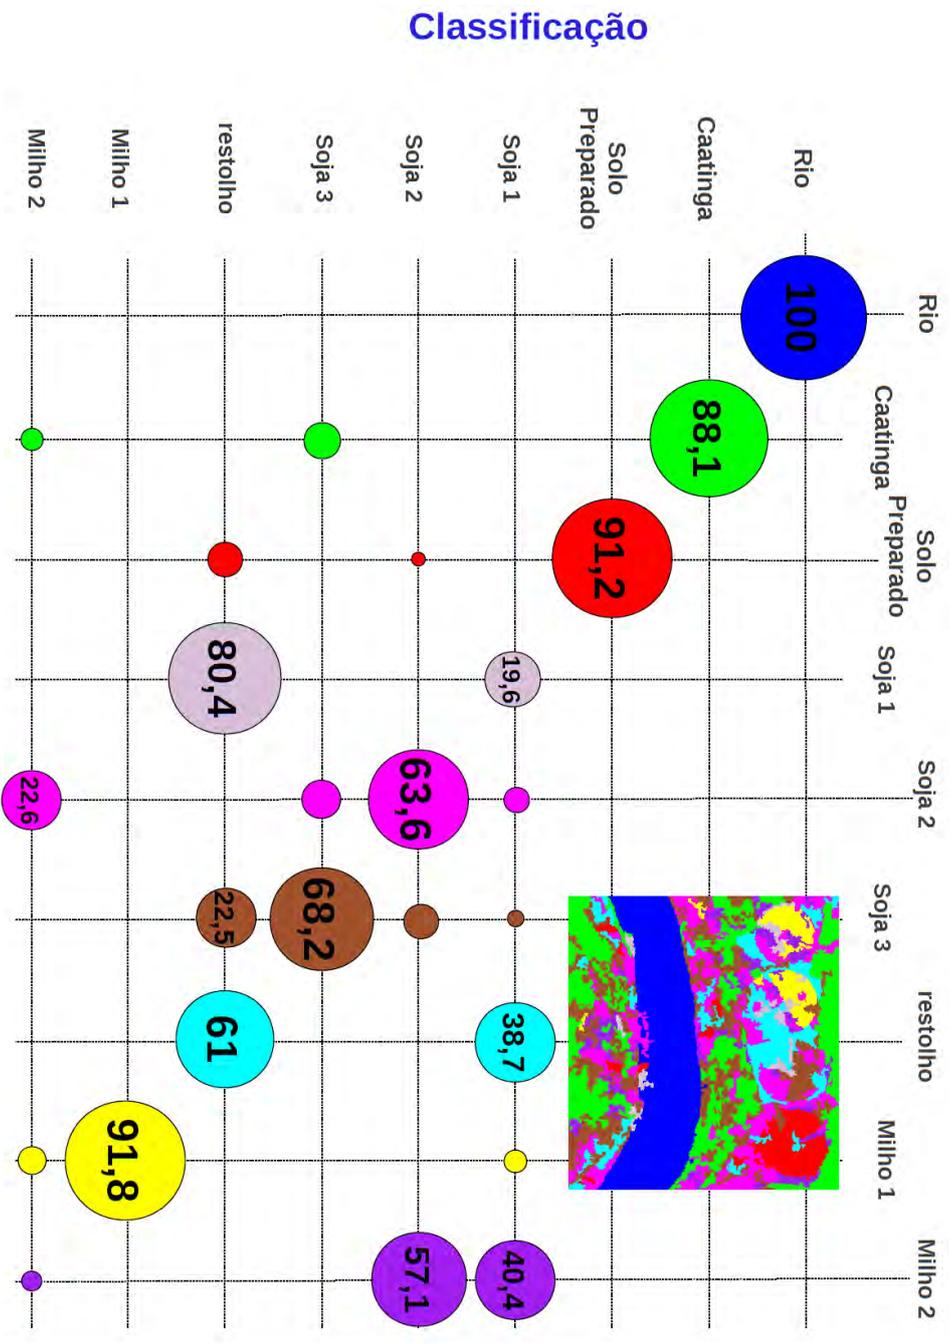


Figura 4.21 - Matriz de confusão - Distância de Bhattacharyya - Gaussiana.

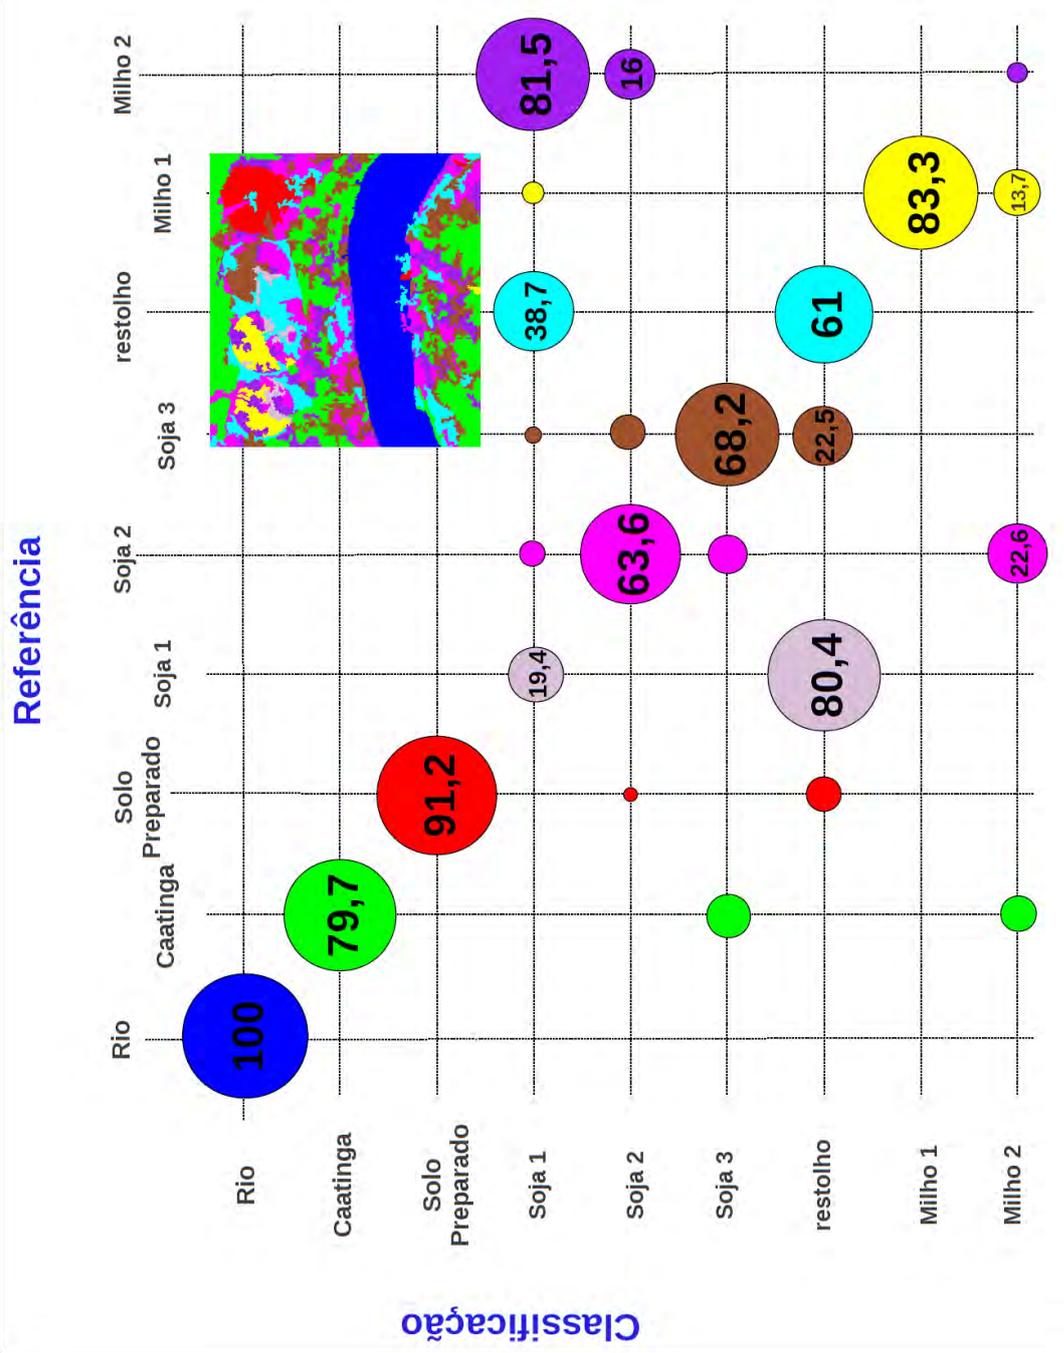


Figura 4.22 - Matriz de confusão - Distância de Bhattacharyya - Par de intensidades HVVV.

imagens SAR por abordagem pontual, deve-se principalmente à ocorrência do ruído “speckle”. A classificação por regiões minimiza ou quase elimina este problema.

4.2.3.2 Resultados obtidos com os dados PolSAR da banda C

Assim como no caso da Banda L, as imagens classificadas a partir da imagem polarimétrica da banda C estão apresentadas em duas figuras. Na Figura 4.23, são apresentados os resultados utilizando-se as distâncias de Bhattacharyya, Kullback-Leibler, Hellinger, Rényi de ordem β e χ^2 entre distribuições Wishart complexas escalonadas, além do resultado de classificação contextual ICM, para comparação. Na Figura 4.24, são apresentados os resultados utilizando-se as distâncias Bhattacharyya entre distribuições gaussianas multivariadas e Par de Intensidades *multi-look*, além do resultado de classificação contextual ICM, para comparação. Foram obtidas matrizes de confusão com utilização das imagens classificadas e das amostras de teste para as nove classificações realizadas. A acurácia global, a estimativa do coeficiente de concordância *kappa* ($\hat{\kappa}$) e sua variância foram obtidas a partir das matrizes de confusão e são apresentados na Tabela 4.18.

Tabela 4.18 - Resultados de classificação por regiões para a imagem PolSAR SIR-C banda C, imagem amplitude multivariada, pares de intensidade e classificação pontual MaxVer/ICM.

Método de classificação	Distância (modelo)	Imagem SIR-C banda C		
		Acurácia Global (%)	$\hat{\kappa}$	$s_{\hat{\kappa}}^2 (\times 10^{-5})$
Por Regiões	Bhattacharyya (Wishart)	76,71	0,719	1,74
	Kullback-Leibler (Wishart)	76,71	0,719	1,74
	Hellinger (Wishart)	76,71	0,719	1,74
	Rényi (ordem $\beta = 0,9$) (Wishart)	76,71	0,719	1,74
	χ^2 (Wishart)	77,18	0,724	1,73
	Bhattacharyya (Gauss. mult.)	74,22	0,691	1,82
	Bhattacharyya (Par Int.-HH,HV)	70,51	0,647	1,90
	Bhattacharyya (Par Int.-HH,VV)	66,00	0,597	1,92
	Bhattacharyya (Par Int.-HV,VV)	68,13	0,616	1,99
Contextual	MaxVer/ICM - Wishart	67,24	0,604	2,02

A exemplo do que foi apresentado para os dados da banda L na Tabela 4.16, os resultados dos testes de hipótese para verificar igualdade estatística entre as matrizes de confusão obtidas a partir das classificações com os dados da banda C são

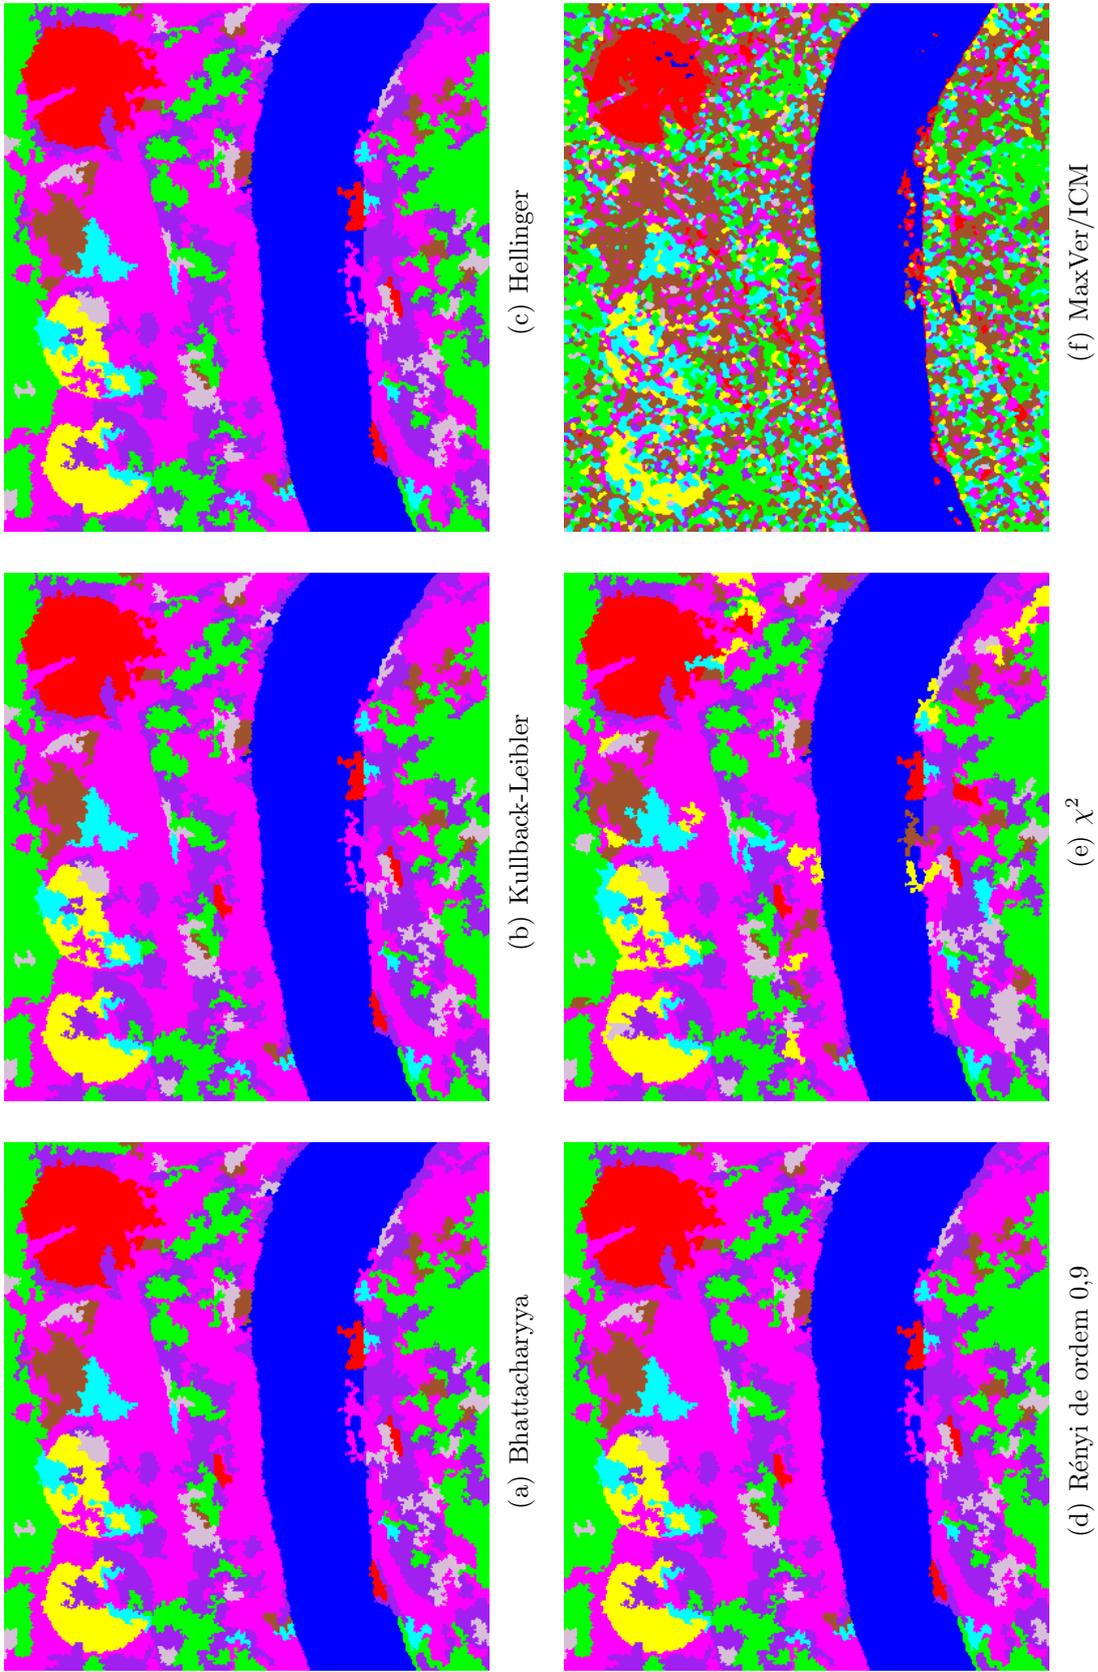
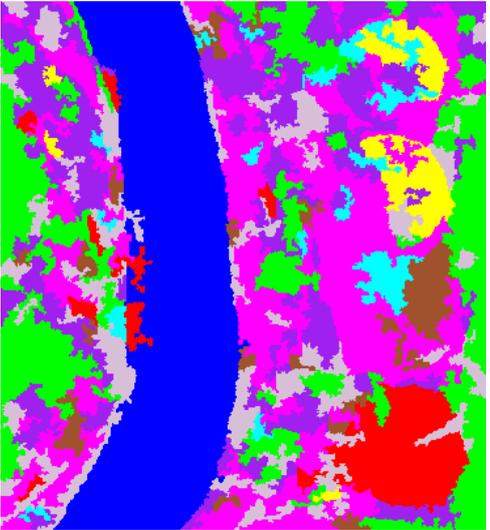


Figura 4.23 - Resultados de classificação utilizando distâncias entre distribuições Wishart



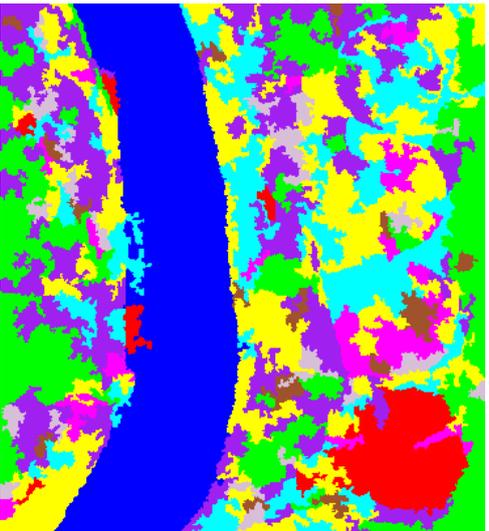
(a) Bhattacharyya Gaus. Mult.



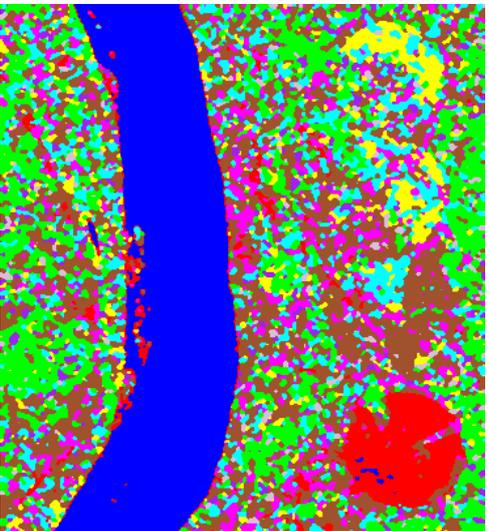
(b) Bhattacharyya (Par Int.-HH, HV)



(c) Bhattacharyya (Par Int.-HH, VV)



(d) Bhattacharyya (Par Int.-HV, VV)



(e) MaxVer/ICM

Figura 4.24 - Resultados de classificação utilizando distâncias entre distribuições gaussianas multivariadas e entre distribuições Par de intensidades *multi-look*

apresentados na Tabela 4.19. A nomenclatura para as classificações e organização dos resultados constantes da Tabela 4.19 é idêntica à definida para a banda L. Os p -valores superiores a 5% e os valores de estatística Z realçados em negrito representam igualdade estatística entre as classificações.

A classificação das imagens PolSAR na banda C com base na distância χ^2 obteve o melhor resultado em termos de valores de acurácia, conforme pode ser verificado na Tabela 4.18. Quando comparado aos resultados obtidos com as demais distâncias entre distribuições Wishart, verifica-se o resultado de classificação com a distância χ^2 é estatisticamente igual aos das demais classificações. Este resultado difere significativamente daqueles encontrado com os dados da banda L e com os dados simulados, em que a classificação com a distância χ^2 obteve o pior resultado dentre as classificações que utilizam distâncias entre distribuições Wishart.

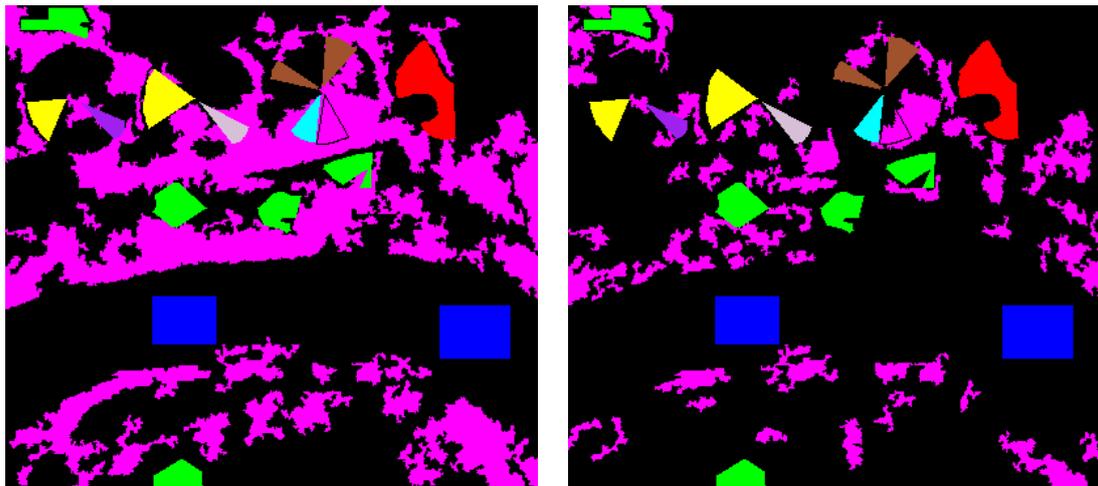
Em quase todas os resultados de classificação por regiões obtidos com dados da banda C, observou-se a grande ocorrência de regiões classificadas como Soja 2. Para ilustrar essa evidência, comum a quase todos os resultados, a Figura 4.25 apresenta as áreas de Soja 2 obtidas nas classificações por regiões com o classificador para dados PolSAR utilizando a distância de Bhattacharyya, com a imagem da banda C (4.25(a)) e banda L (4.25(b)), juntamente com as amostras de teste. Essa tendência em atribuir a classe Soja 2 a um elevado número de regiões acarreta prejuízo tanto nos resultados de acurácia quanto no resultado visual.

No resultado apresentado na figura 4.25(a), considerando amostras de teste, quase a totalidade (98,99%) das amostras da classes restolho e 84,69% das amostras de Soja 1 foram classificadas como Soja 2. O único caso, dentre as classificações por regiões, em que esse “domínio” da classe Soja 2 não ocorreu com as imagens da banda C foi com o par de imagens SAR em intensidade (HV,VV).

Pode-se verificar ainda, com os resultados expressos pela Tabela 4.19, que a classificação pontual/contextual MaxVer/ICM com os dados da banda C e modelagem Wishart ($\hat{\kappa} = 0,604$) é estatisticamente igual às classificações por regiões utilizando distância de Bhattacharyya entre pares de imagens SAR em intensidade HH,VV ($\hat{\kappa} = 0,597$) e HV,VV ($\hat{\kappa} = 0,616$), respectivamente as segunda e terceira melhores classificações com pares de intensidade. Entretanto, é estatisticamente inferior à classificação do par HH,HV ($\hat{\kappa} = 0,647$).

Tabela 4.19 - Resultados de teste de igualdade entre matrizes de confusão - Banda C. Parte triangular superior: p -valores - Parte triangular inferior: estatísticas Z .

	BAT	KL	HEL	REN	CHI	BAT _G	BAT _{HHHV}	BAT _{HHVV}	BAT _{HVVV}	ICM
BAT	-	1	1	1	0,40	<0,01	<0,01	<0,01	<0,01	<0,01
KL	0	-	1	1	0,40	<0,01	<0,01	<0,01	<0,01	<0,01
HEL	0	0	-	1	0,40	<0,01	<0,01	<0,01	<0,01	<0,01
REN	0	0	0	-	0,40	<0,01	<0,01	<0,01	<0,01	<0,01
CHI	0,85	0,85	0,85	0,85	-	<0,01	<0,01	<0,01	<0,01	<0,01
BAT _G	4,69	4,69	4,69	4,69	5,53	-	<0,01	<0,01	<0,01	<0,01
BAT _{HHHV}	11,94	11,94	11,94	11,94	12,78	7,22	-	<0,01	<0,01	<0,01
BAT _{HHVV}	20,01	20,01	20,01	20,01	20,87	15,23	7,96	-	<0,01	0,30
BAT _{HVVV}	16,80	16,80	16,80	16,80	17,64	12,09	4,91	2,97	-	0,06
ICM	18,70	18,70	18,70	18,70	19,54	13,99	6,83	1,04	1,91	-



(a) Classe Soja 2 - classificação por regiões (Bhattacharyya - Wishart) da banda C (b) Classe Soja 2 - classificação por regiões (Bhattacharyya - Wishart) da banda L



(c) Legenda das classes

Figura 4.25 - Classe Soja 2 nas classificações por regiões dos dados PolSAR utilizando distância de Bhattacharyya entre distribuições Wishart. Amostras de teste são superpostas: (a) banda C e (b) banda L

Assim como observado nos resultados obtidos com os dados da banda L, pode-se verificar uma melhora significativa de classificação quando se utiliza a abordagem por regiões e distâncias estocásticas em relação à abordagem pontual/contextual. Isto pode ser concluído por meio da observação dos valores de coeficiente de concordância $kappa$ estimados ($\hat{\kappa}$) na Tabela 4.18. Para o melhor resultado de classificação por regiões, com a distância χ^2 , tem-se o valor de 0,724, enquanto que para a abordagem pontual/contextual MaxVer/ICM, o valor foi de 0,606.

No caso da banda C, a classificação pontual/contextual com modelagem Wishart ficou bem mais aquém, em termos de medidas de acurácia, dos resultados obtidos por classificadores por regiões com dados PolSAR, quando comparados ao caso da banda L. Enquanto na banda L o resultado da melhor classificação por regiões com os dados PolSAR superou em cerca de 4% a classificação MaxVer/ICM, na banda C essa superação ficou em aproximadamente 20%.

De modo geral os resultados de classificação com os dados da banda C são inferiores aos da banda L, conforme pode ser verificado observando-se as tabelas 4.15 e 4.18. Entretanto, a classificação por regiões dos dados na banda C obtém resultados bem melhores em relação a abordagem pontual quando comparados aos da banda L. Além disso, para a maioria das classes, os dados PolSAR na banda C são mais adequadamente modelados pela distribuição de Wishart complexa escalonada do que os dados na banda L, conforme verificado por Frery et al. (2007).

Especificamente com relação às classificações dos pares de imagens SAR em intensidade da banda C, verificou-se que o par HH,HV obteve o melhor resultado, alcançando a melhor estimativa do coeficiente *kappa* ($\hat{\kappa}$), com o valor de 0,647. Os outros dois pares, HH,VV e HV,VV, obtiveram $\hat{\kappa}$ de 0,597 e 0,616. No caso do melhor resultado, houve um incremento de aproximadamente 7% em relação ao resultado obtido pela abordagem pontual/contextual MaxVer/ICM utilizando dados PolSAR. Desta forma, é reforçada a importância da utilização dos pares de intensidade para classificação desse tipo de dado com a abordagem por regiões, sobretudo se não estiverem disponíveis os dados PolSAR completos.

Se comparados com os resultados de classificação obtidos por Correia (1998), com classificador pontal/contextual de pares de imagens SAR em intensidade, verifica-se que essa melhora foi bem mais proeminente. Correia (1998) obteve, para os pares de intensidade da banda C HH,HV; HHVV; HVVV, respectivamente, valores de $\hat{\kappa}$ iguais a 0,450, 0,540 e 0,582.

Na Tabela 4.20 é apresentada, para cada distância estocástica, a porcentagem de segmentos para os quais o *p*-valor foi maior do que 5%, ou seja, porcentagem de segmentos que não tiveram a hipótese nula (H_0) rejeitada ao nível de significância 5%. Tais segmentos são ilustrados em branco nas Figuras 4.26 e 4.27.

Em comparação com os resultados de porcentagem de segmentos cuja hipótese H_0 não foi rejeitada ao nível de significância especificado obtidos pela banda L, as porcentagens obtidas pelos dados da banda C foram muito mais próximos da porcentagem teoricamente esperada (95%), ficando em torno dos 70% para as seguintes distâncias entre distribuições Wishart complexas escalonadas: Bhattacharyya, Kullback-Leibler, Rényi de ordem β e Hellinger. Para a distância χ^2 , a porcentagem foi de 55,70%, valor próximo da porcentagem obtida para o caso da distância de Bhattacharyya entre distribuições gaussianas multivariadas (54,61%). A modelagem

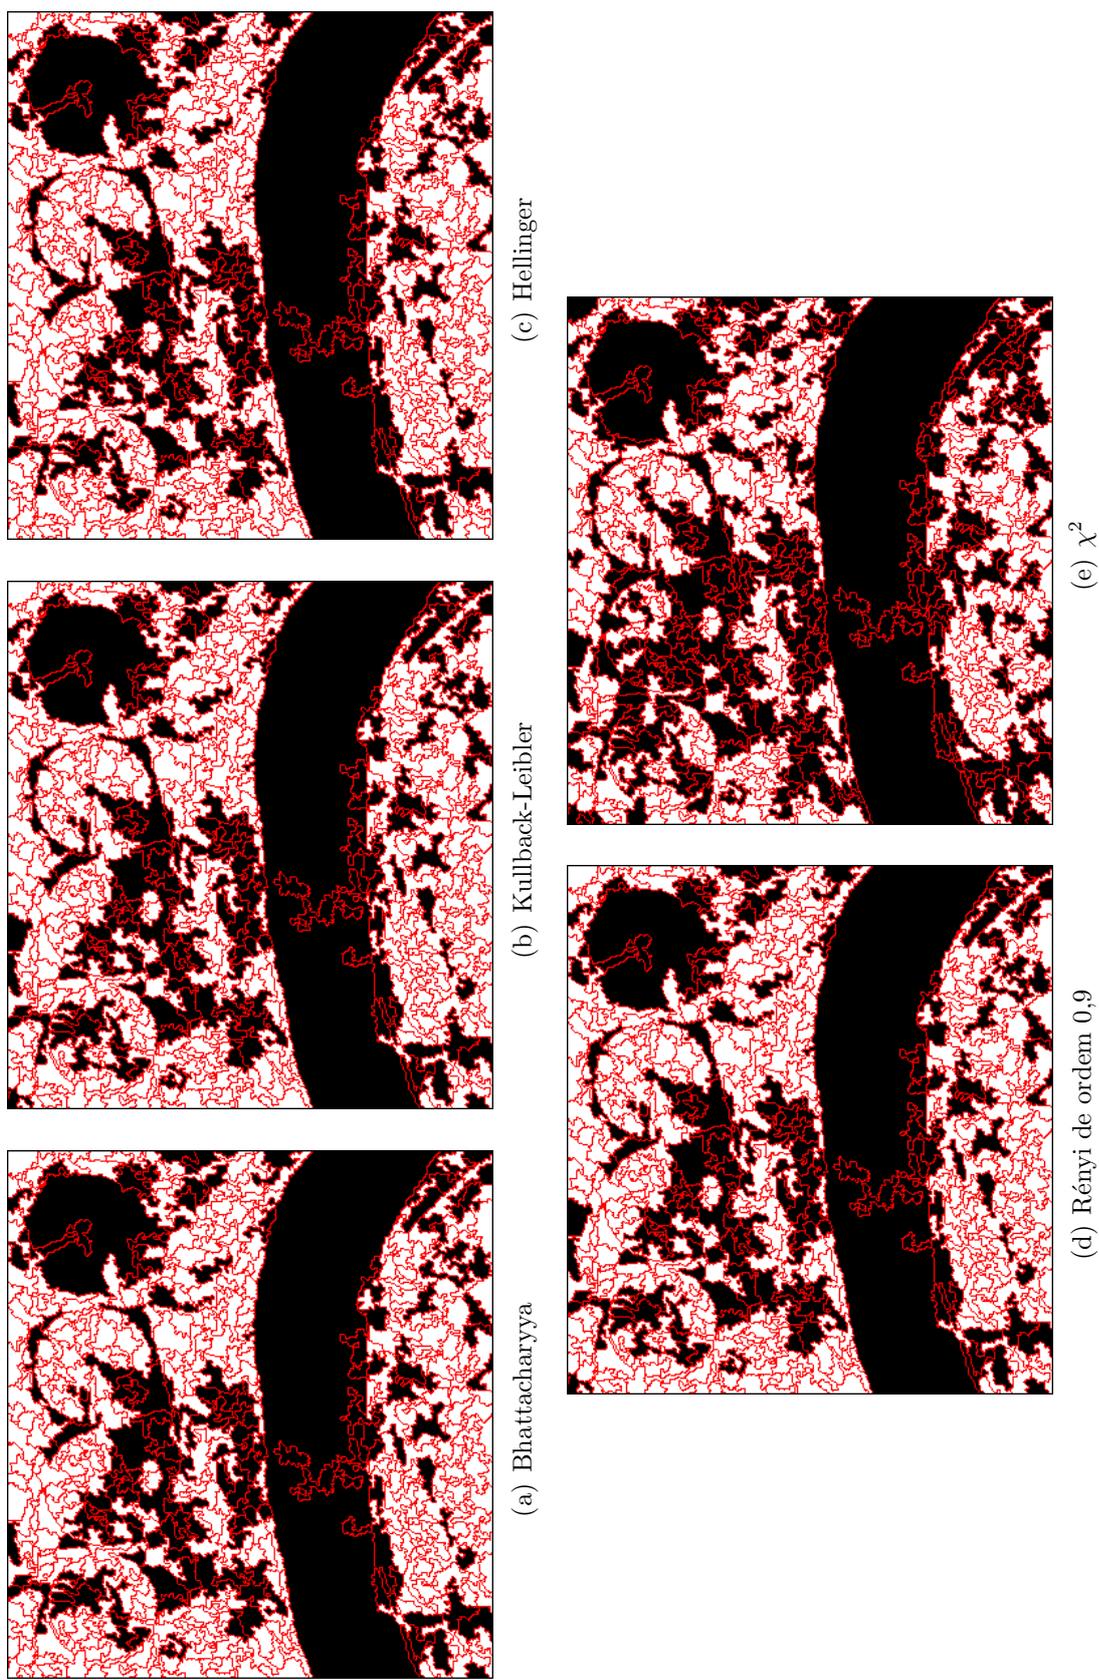
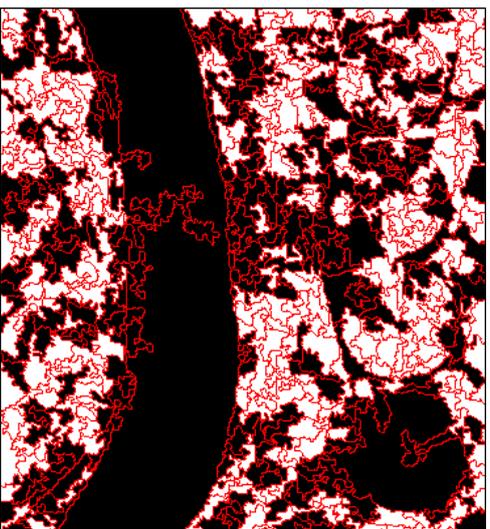
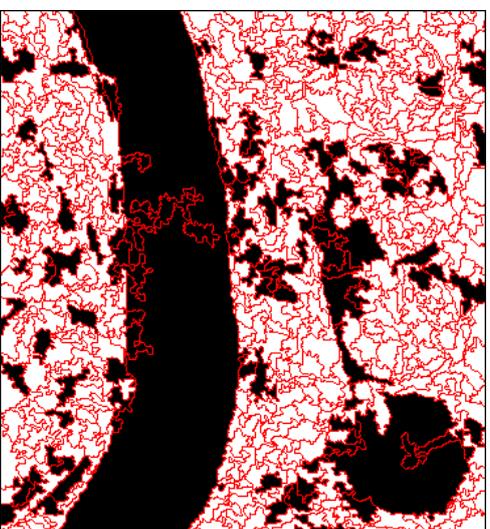


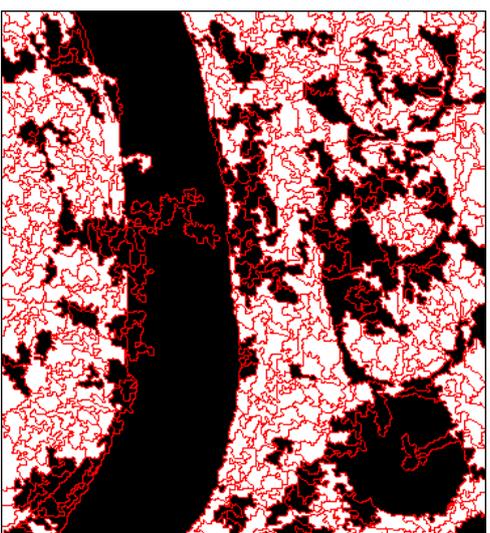
Figura 4.26 - Mapas binários de p -valores para classificações da imagem SIR-C banda C - distâncias entre distribuições Wishart - segmentos em branco tem hipótese nula não rejeitada ($p \geq 0,05$).



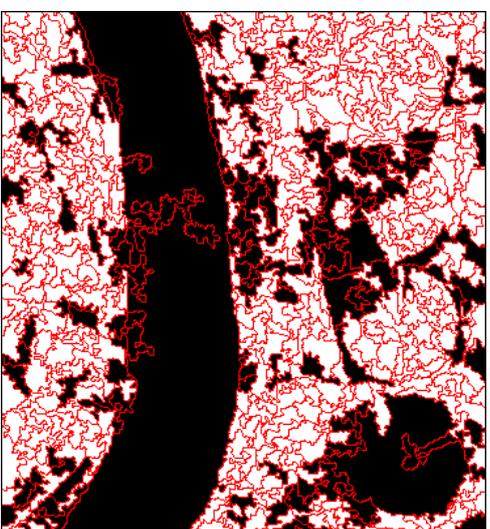
(a) Bhattacharyya Gaus. Mult.



(b) Bhattacharyya (Par Int.-HH,HV)



(c) Bhattacharyya (Par Int.-HH,VV)



(d) Bhattacharyya (Par Int.-HV,VV)

Figura 4.27 - Mapas binários de p -valores para classificações da imagem SIR-C banda C - distâncias entre distribuições gaussianas multivariadas e entre distribuições Par de intensidades *multi-look* - segmentos em branco tem hipótese nula não rejeitada ($p \geq 0,05$).

Tabela 4.20 - Porcentagem de segmentos da imagem SIR-C banda C que não tiveram a hipótese H_0 rejeitada ao nível de significância 5 %.

Distâncias	Porcentagem (%)
Bhattacharyya	71,61
Kullback-Leibler	70,71
Hellinger	72,88
Rényi de ordem β	70,89
χ^2	55,70
Bhattacharyya (Gauss. mult.)	54,61
Bhattacharyya (Par Int.-HH,HV)	80,65
Bhattacharyya (Par Int.-HH,VV)	71,25
Bhattacharyya (Par Int.-HV,VV)	75,77

dos dados da banda C pela distribuição de Wishart, considerando a maioria das amostras utilizadas, provavelmente contribui para explicar esses resultados.

A exemplo do que ocorreu com os resultados de porcentagem de segmentos cuja hipótese H_0 não foi rejeitada, entre as classificações de dados PolSAR, a distância de Hellinger foi levemente superior às demais. Este melhor comportamento desta distância na geração dos mapas de segmentos aceitos no teste de hipótese $h-\phi$ pode ser um bom indicador para sua utilização em trabalhos futuros tendo em vista que, invariavelmente, os resultados de classificação com a distância de Hellinger são estatisticamente iguais aos das outras distâncias entre distribuições de Wishart.

Assim como ocorreu com os dados da banda L, para as classificações de pares de intensidade, a quantidade de segmentos que passaram no teste de hipótese foram significativamente mais próximos da porcentagem teoricamente esperada (95%).

5 CONCLUSÕES E SUGESTÕES

Este trabalho teve por objetivo geral a proposição, desenvolvimento e teste de um classificador de segmentos de imagens SAR polarimétricas utilizando as distâncias estocásticas disponíveis e os testes de hipóteses derivados das mesmas.

A proposição do classificador foi feita com base na teoria dos testes de hipótese derivados de distâncias estocásticas da família $h-\phi$. Foram utilizadas distâncias entre distribuições de Wishart complexas escalonadas, distâncias entre distribuições gaussianas multivariadas e uma solução numérica para cálculo de distâncias entre distribuições Par de Imagens SAR em Intensidade *multi-look*. Nessa fase, identificam-se significativas contribuições na utilização de expressões para distâncias entre diversos modelos disponíveis na literatura e na concepção de uma solução numérica para o importante caso dos pares de intensidade SAR.

Na fase de implementação, utilizou-se a linguagem de programação *Interactive Data Language* (IDL), versão 7.1 para o desenvolvimento do classificador em três diferentes módulos, orientados aos modelos estatísticos utilizados e às distâncias disponíveis e implementadas. Com isso, obteve-se uma ferramenta com relativo grau de flexibilidade e abrangência diversificada com relação aos dados. O trabalho vem a ser então importante contribuição com respeito à utilização prática pelos usuários de sensoriamento remoto. O classificador implementado tem ainda a importante funcionalidade de geração de mapas indicativos de qualidade com base nos p -valores dos testes de hipótese realizados nas classificações. Esta é uma contribuição até então não disponível nas ferramentas de classificação por regiões.

Na fase de aplicação e avaliação do classificador gerado, foram obtidos importantes resultados quanto ao desempenho dos testes de hipótese utilizados para a classificação quando da contaminação dos dados por autocorrelação espacial. Este estudo pode servir de base ao entendimento das potencialidades e limitações da ferramenta desenvolvida quando utilizado com dados reais de sensoriamento remoto. Na avaliação do classificador com dados simulados segundo a modelagem Wishart e com dados reais, uma significativa quantidade de resultados foram analisados no Capítulo 4. Com base nos resultados obtidos, são apresentadas a seguir as conclusões sobre o trabalho desenvolvido.

5.1 Conclusões

De acordo com o trabalho desenvolvido, os objetivos propostos e os resultados obtidos, pode-se concluir que:

Quanto à funcionalidade, o classificador por regiões desenvolvido:

- 1) permite a seleção entre três modelagens estatísticas diferentes, Wishart complexa escalonada, gaussiana multivariada e par de imagens SAR *multi-look*, proporcionando maior adequação aos dados disponíveis;
- 2) apresenta uma interface gráfica de fácil entendimento e manipulação, permitindo a escolha dos dados de entrada e parâmetros a serem utilizados na classificação;
- 3) possui opções de subamostragem com vistas a minimização do efeito causado pela autocorrelação espacial;
- 4) fornece, além do resultado de classificação esperado (imagem temática), um mapa que indica os segmentos para os quais a hipótese nula do teste não foi rejeitada, a um nível de significância de 5%.

Quanto ao desempenho do teste de hipótese com dados gaussianos simulados sob contaminação por autocorrelação espacial:

- 1) O teste é influenciado pela autocorrelação espacial dos dados. Quanto maior o índice de correlação, maior é a taxa de rejeição observada. Taxas de rejeição próximas a 60% foram obtidas quando da utilização de dados com alta correlação (parâmetro $\alpha = 1$), enquanto taxas de rejeição similares à esperada teoricamente foram obtidas quando utilizados dados com baixas correlações.
- 2) Para um mesmo parâmetro de correlação espacial (α), são obtidas maiores taxas de rejeição a medida que se aumenta o número de variáveis dos dados simulados. Nos maiores índices de correlação espacial, este comportamento é observado de forma mais aparente.
- 3) Quanto maior o número de variáveis, maior a quantidade de amostras envolvidas no experimento para se verificar o comportamento assintótico.

- 4) O teste de hipótese $h-\phi$ apresenta bom desempenho com dados não correlacionados espacialmente, haja vista que as taxas de rejeição são similares aos valores de nível de significância do teste quando da utilização de dados pouco correlacionados.
- 5) Os resultados obtidos indicam que a correlação entre variáveis não influencia no desempenho do teste, haja vista a investigação desenvolvida com dados simulados e três variáveis, em que esta conclusão foi verificada.

Quanto aos resultados da aplicação do classificador em dados PolSAR simulados sob a distribuição de Wishart e simetria circular:

- 1) Os resultados de classificação obtidos com uso dos dados PolSAR simulados obtiveram acurácia global de 100%, com excessão de alguns pequenos erros de classificação observados quando utilizados pequenos segmentos (5×5 pixels). Esta evidência pode estar relacionada com a menor quantidade de amostras utilizadas (segmentos pequenos) e o comportamento assintótico do teste de hipótese.
- 2) As taxas de aceitação da hipótese nula, que mede a confiabilidade da classificação, foram muito próximas dos valores teoricamente esperados para quase todas as distâncias e tamanhos de segmentos utilizados. Os piores resultados ocorreram quando utilizada a distância do χ^2 , especialmente em classificações de pequenos segmentos. Com excessão deste último caso, as evidências permitem concluir que o método de classificação apresenta desempenho e confiabilidade muito bons quando os dados seguem rigorosamente a modelagem Wishart e não apresentam autocorrelação.
- 3) A utilização da estatística com base na distância de Hellinger entre distribuições Wishart mostra-se usualmente melhor do que as estatísticas derivadas de outras distâncias na obtenção dos mapas de p -valores, especialmente para imagens segmentadas com regiões pequenas. Essa evidência pode representar uma maior robustez para essa distância, tendo em vista que mesmo sob condições mais adversas (pequena quantidade de amostras), o número de segmentos cuja hipótese nula foi aceita assemelha-se ao esperado.
- 4) A utilização do classificador por regiões com modelagem gaussiana em

dados em amplitude multivariada encontraram resultados de classificação semelhantes aos do caso PolSAR, mas ligeiramente piores. Em imagens com segmentos pequenos, um grau maior de incorreção foi obtido neste caso, quando se observou acurácia global de 98,35%, em relação às classificações PolSAR, com acurácia global de 99,81%. A confusão para o caso dos segmentos pequenos se deu entre as mesmas classes (Soja 2 e Milho 2).

- 5) Os resultados obtidos com os pares de imagens em intensidade extraídos da imagem PolSAR simulada asseguram a potencialidade de utilização do módulo correspondente quando não se dispõem dos dados polarimétricos completos, tendo em vista que os resultados de indicadores de qualidade de classificação e que as taxas de números de segmentos para os quais hipótese nula foi aceita aproxima-se do teoricamente esperado, conforme pode ser verificado na análise feita na seção 4.2.2.

Quanto aos resultados da aplicação do classificador em dados PolSAR reais, na banda L,

- 1) O classificador por regiões proposto, quando aplicado aos dados da missão SIR-C, na banda L, obteve resultados excelentes em termos de medidas de acurácia, segundo a classificação proposta por Landis e Koch (1977). Os melhores resultados foram obtidos com as distâncias de Bhattacharyya, Kullback-Leibler, Rényi e Hellinger entre distribuições Wishart.
- 2) A relevância de utilização de uma modelagem mais adequada aos dados pode ser comprovada pelo melhor resultado alcançado pelas classificações envolvendo distâncias entre modelos Wishart do que com a modelagem gaussiana e dados em amplitude multivariada.
- 3) A abordagem por regiões, para os dados utilizados, mostrou-se superior com relação à classificação pontual/contextual sobre a qual se fundamenta o classificador MaxVer/ICM, haja vista a análise quantitativa desenvolvida em função dos valores de coeficiente de concordância *kappa* obtidos pelas duas abordagens. Indica-se então a possibilidade de melhoria nos resultados de classificação PolSAR por modelagem estatística, em relação ao estado da arte. Esse avanço nos resulta-

dos de classificação pode também ser ilustrado pela minimização da geração de pequenas áreas na classificação por regiões, e que ainda permanecem no resultado contextual.

- 4) As taxas de rejeição da hipótese nula obtidas pelas classificações de dados PolSAR reais foram bastante distantes em relação ao valor teórico esperado, com obtenção de valores maiores do que 90%. Considerando que os dados simulados rigorosamente sob a suposição Wishart obtiveram valores muito próximos aos esperados teoricamente, identifica-se, com base nos resultados de taxas rejeição, que os maus resultados devem-se a incorreta modelagem estatística dos dados reais. Tal afirmação se comprova pela consideração feita na Seção 4.2.1, em que a maioria das amostras das classes consideradas são melhor modeladas pelas distribuições \mathcal{K}_P e \mathcal{G}_P^0 . Os resultados indicam que o método proposto apresenta boa robustez com respeito a classificação, entretanto o mesmo não se repete com relação à geração de mapas de p -valores.
- 5) Outras possíveis fontes de prejuízo ao desempenho dos testes de hipótese com os dados reais podem ser enumerados: a autocorrelação espacial, a qual se buscou minimizar com a subamostragem, que altera sensivelmente o tamanho das amostras; a existência de classes diferentes em relação às definidas pelo especialista; a existência de segmentos muito grandes, como os existentes nas classes Rio e Solo Preparado; e a possível influência de uma segmentação inadequada, tendo em vista que o programa SegSAR tem seu desenvolvimento fundamentado na modelagem de imagens em intensidade. Essas conclusões são reforçadas pelo fato de que essas condições foram rigorosamente controladas quando da utilização de dados simulados, em que os resultados podem ser considerados perfeitamente compatíveis com a teoria considerada.
- 6) Os resultados de classificação utilizando-se os pares de imagens em intensidade permitem concluir a respeito da potencialidade da utilização deste módulo do classificador quando não se dispõem dos dados polarimétricos completos. A maioria das classes foi classificada de modo similar às classificações PolSAR, sobretudo para o par HV/VV, considerando os dados utilizados.

Quanto aos resultados da aplicação do classificador em dados PolSAR reais, na banda C,

- 1) O classificador por regiões proposto, quando aplicado aos dados da missão SIR-C, na banda C, obteve resultados muito bons em termos de medidas de acurácia, segundo a classificação proposta por [Landis e Koch \(1977\)](#). O melhor resultado foi obtido com a distância χ^2 entre distribuições Wishart. Porém esse resultado foi igualado estatisticamente pelas classificações obtidas com as distâncias de Bhattacharyya, Kullback-Leibler, Rényi e Hellinger entre distribuições Wishart.
- 2) As classificações com a abordagem por regiões dos dados da banda C apresentaram uma tendência em classificar um grande número de segmentos na classe Soja 2.
- 3) A relevância de utilização de uma modelagem mais adequada aos dados pode ser comprovada pelo melhor resultado alcançado pelas classificações envolvendo distâncias entre modelos Wishart do que com a modelagem gaussiana e dados em amplitude multivariada. Neste caso (banda C), a classificação com a modelagem Wishart foi ainda melhor do que a com modelagem gaussiana, quando comparada aos resultados da banda L. Considerando este resultado, pode-se reforçar a justificativa para o desenvolvimento de ferramentas que utilizem modelagem estatística especificamente adequadas aos dados PolSAR.
- 4) A abordagem por regiões, para os dados utilizados, assim como no caso da banda L, mostrou-se superior com relação à classificação pontual/contextual sobre a qual se fundamenta o classificador Max-Ver/ICM. Entretanto neste caso, a melhora foi bem mais acentuada. Enquanto com os dados da banda L, houve uma melhora de aproximadamente 4%, com os da banda C foi obtido aproximadamente 20% de incremento na acurácia.
- 5) As taxas de rejeição da hipótese nula obtidas pelas classificações de dados PolSAR reais foram bem mais próximas do valor teórico esperado (5%) em relação às obtidas pelos dados da banda L. Os valores para as classificações com os dados PolSAR foram inferiores a 30% de taxa de rejeição, exceto para a distância χ^2 , que foi aproximadamente 45%. A modelagem mais adequada dos dados PolSAR da banda C pela distribuição Wishart complexa escalonada provavelmente é responsável, em grande medida, pela explicação desse resultado.
- 6) Os resultados de classificação utilizando-se os pares de imagens em in-

tensidade da banda C permitem concluir a respeito da potencialidade da utilização deste módulo do classificador quando não se dispõem dos dados polarimétricos completos. A classificação do par HH,HV superou inclusive a classificação PolSAR pontual/contextual Maxver/ICM, que utiliza os dados polarimétricos completos, que foi igualada estatisticamente pelas classificações por regiões dos pares HH,VV e HV,VV. A classificação do par de intensidades HV,VV, apesar de obter $\hat{\kappa}$ inferior ao do par HH,HV, evitou o efeito de classificação de muitos segmentos na classe Soja 2, comum a todas os outros resultados de classificação por regiões com dados da banda C.

Em resumo, pode-se concluir, de acordo com a análise dos resultados obtidos, que o classificador por regiões proposto tem grande potencial de utilização na análise de imagens PolSAR, pares de imagens em intensidade e imagens SAR multivariadas em amplitude.

5.2 Sugestões

Com a finalidade de dar continuidade à pesquisa conduzida neste trabalho, sugerem-se os seguintes temas para o desenvolvimento de trabalhos futuros:

- Uma investigação da influência da autocorrelação espacial no desempenho do teste de hipótese $h-\phi$ com dados simulados sob a suposição de modelagem Wishart, em complemento à análise feita neste trabalho com dados gaussianos multivariados.
- Aprofundamento nas análises do classificador com observações que não sigam rigorosamente a distribuição de Wishart complexa.
- Utilização das estatísticas de melhor desempenho para aplicação em uma pós classificação, determinada pelo voto da maioria, o que poderia trazer melhores resultados em relação à utilização de uma única medida.
- Utilização dos p -valores calculados para classificação por lógica nebulosa. Cada segmento poderia ser classificado em diferentes classes, com graus de pertinência diferenciados, desde que os p -valores das classes escolhidas superassem determinado limiar mínimo.

- Comparações entre classificações por região e distâncias estocásticas com outros métodos como os fundamentados na decomposição polarimétrica de alvos.
- Utilização da teoria de testes de hipótese $h-\phi$ em classificação não-supervisionada.
- Desenvolvimento de um estimador por máxima verossimilhança para o parâmetro módulo do coeficiente de correlação complexa, com vistas a utilização nas aplicações do teste de hipótese $h-\phi$ entre distribuições Par de Intensidades *multi-look*.
- Incorporação ao classificador de uma ferramenta de estimação de máxima verossimilhança não supervisionada para o parâmetro número equivalente de *looks* para imagens PolSAR, com base no trabalho de [Anfinsen et al. \(2009\)](#).
- Implementação de uma ferramenta não supervisionada de cálculo da autocorrelação espacial, com vistas a definição automática do grau de subamostragem requerido.
- Geração de dados PolSAR simulados sob suposição de distribuições estatísticas de maior complexidade em relação à Wishart, como as distribuições \mathcal{K}_P e \mathcal{G}_P^0 . Classificação por regiões desses dados e avaliação dos resultados.
- Classificação por regiões e avaliação dos resultados utilizando dados de diversas frequências, polarizações ou diferentes sensores. Uma possível solução seria o desenvolvimento das distâncias e dos testes de hipóteses associados supondo a independência entre os dados.
- Investigação de soluções de classificação por regiões que utilizem estatísticas associadas a medidas de entropia, desenvolvidas por [Nascimento \(2012\)](#), e a estatística da razão de verossimilhança, desenvolvida por [Conradsen et al. \(2003\)](#)

REFERÊNCIAS BIBLIOGRÁFICAS

ABRAMOWITZ, M.; STEGUN, I. A. **Handbook of mathematical functions: with formulas, graphs, and mathematical tables.** 10. ed. New York: Dover, 1972. 19

ALI, S. M.; SILVEY, S. D. A general class of coefficients of divergence of one distribution from another. **Journal of the Royal Statistical Society. Series B (Methodological)**, Blackwell Publishing for the Royal Statistical Society, v. 28, n. 1, p. 131–142, 1966. 22

ANFENSEN, S. N. **Statistical Analysis of Multilook Polarimetric Radar Images with the Mellin Transform.** 196 p. Tese (Doutorado) — University of Tromsø, 2010. 15

ANFENSEN, S. N.; DOULGERIS, A. P.; ELTOFT, T. Estimation of the equivalent number of looks in polarimetric synthetic aperture radar imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 11, p. 3795–3809, nov 2009. ISSN 0196-2892. 17, 25, 90, 124

_____. Goodness-of-fit tests for multilook polarimetric radar data based on the Mellin transform. **IEEE Transactions on Geoscience and Remote Sensing**, v. 49, n. 7, p. 2764–2781, july 2011. ISSN 0196-2892. 16

BINS, L. S.; ERTHAL, G. J.; FONSECA, L. M. G. Um método de classificação não supervisionada por regiões. In: FIGUEIREDO, L. H. d.; GOMES, J. d. M. (Ed.). **Anais...** Porto Alegre: Sociedade Brasileira de Computação, 1993. v. 2, p. 65–68. ISBN 978-85-7669-271-3. Disponível em: <<http://urlib.net/sid.inpe.br/sibgrapi/2012/12.20.16.43>>. Acesso em: 20 de outubro de 2013. 33

BOMBRUN, L.; VASILE, G.; GAY, M.; TOTIR, F. Hierarchical segmentation of polarimetric SAR images using heterogeneous clutter models. **IEEE Transactions on Geoscience and Remote Sensing**, v. 49, n. 2, p. 726–737, feb. 2011. ISSN 0196-2892. 16

CAMARA, G.; SOUZA, R. C. M.; FREITAS, U.; GARRIDO, J.; LI, F. M. Spring: Integrating remote sensing and GIS by object-oriented data modelling. **Computers & Graphics**, v. 20, p. 3, 1996. 26, 33

CINTRA, R. J. S.; FRERY, A. C.; NASCIMENTO, A. D. C. Parametric and nonparametric tests for speckled imagery. **Pattern Analysis & Applications**, London, p. 1–21, 2011. ISSN 1433-7541. 10.1007/s10044-011-0249-3. 3, 5

CLOUDE, S. R.; POTTIER, E. A review of target decomposition theorems in radar polarimetry. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 34, n. 2, p. 498–518, 1996. 12

_____. An entropy based classification scheme for land applications of polarimetric SAR. **IEEE Transactions on Geoscience and Remote Sensing**, v. 35, n. 1, p. 68–78, jan 1997. ISSN 0196-2892. 1, 12

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. 2nd. ed. Boca Raton, Florida USA: CRC Press, 2009. 1–200 p. ISBN 9781420055122. 34, 35, 36, 37

CONRADSEN, K.; NIELSEN, A. A.; SCHOU, J.; SKRIVER, H. A test statistic in the complex Wishart distribution and its application to change detection in polarimetric SAR data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 1, p. 4–19, january 2003. 32, 124

CORREIA, A. H. **Projeto, desenvolvimento e avaliação de classificadores estatísticos pontuais e contextuais para imagens SAR polarimétricas**. 271 p. Dissertação (Mestrado) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 1998. xi, xiii, 2, 19, 69, 90, 91, 97, 112

CORREIA, A. H.; FREITAS, C. C.; FRERY, A. C.; SANT’ANNA, S. J. S. A user friendly statistical system for polarimetric SAR image classification. **Revista de Teledetección**, v. 10, p. 79–93, 1998. 2

COVER, T.; THOMAS, J. **Elements of Information Theory**. New York, NY, USA: Wiley-Interscience, 1991. 542 p. 3, 21

CSISZÁR, I. Information-type measures of difference of probability distributions and indirect observations. **Studia Sci. Math. Hungar.**, v. 2, p. 299–318, 1967. 3, 21, 22

DEZA, M. M.; DEZA, E. **Dictionary of Distances**. Amsterdam, The Netherlands: Elsevier Science, 2006. Hardcover. ISBN 0444520872. 22

DOULGERIS, A. P.; ANFINSEN, S. N.; ELTOFT, T. Classification with a non-Gaussian model for PolSAR data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 46, n. 10, p. 2999–3009, oct. 2008. ISSN 0196-2892. 16

DOULGERIS, A. P.; ELTOFT, T. Scale mixture of gaussian modelling of polarimetric SAR data. **EURASIP Journal on Advances in Signal Processing**, v. 2010, p. 874592, 2010. 16

DRUMMOND, I.; SANDRI, S. Parameterized imprecise classification: Elicitation and assessment. In: SICHMAN, J.; COELHO, H.; REZENDE, S. (Ed.). **Advances in Artificial Intelligence - IBERAMIA-SBIA 2006**. Berlin, Heidelberg: Springer-Verlag, 2006, (Lecture Notes in Computer Science, v. 4140). p. 319–328. ISBN 978-3-540-45462-5. 54

EVERITT, B.; SKRONDAL, A. **The Cambridge Dictionary of Statistics**. Cambridge: Cambridge University Press, 2010. ISBN 9780521766999. 55

EXELIS. **IDL Reference Guide: Interactive Data Language Version 7.1**. Exelis, 2009. Disponível em: <http://www.exelisvis.com/portals/0/pdfs/idl>. Acesso em: 9 de setembro de 2009. 39

FREITAS, C. C. **Statistical analysis of synthetic aperture radar images and its applications to System Analysis and Change Detection**. 346 p. Tese (Doutorado) — University of Sheffield, 1991. 56

FREITAS, C. C.; FRERY, A. C.; CORREIA, A. H. The polarimetric \mathcal{G} distribution for SAR data analysis. **Environmetrics**, John Wiley & Sons, Ltd., v. 16, n. 1, p. 13–31, 2005. ISSN 1099-095X. 1, 13, 14, 16

FRERY, A. C.; CORREIA, A. H.; FREITAS, C. C. Classifying multifrequency fully polarimetric imagery with multiple sources of statistical evidence and contextual information. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, n. 10, p. 3098–3109, 2007. ISSN 0196-2892. 1, 2, 16, 17, 19, 47, 70, 98, 112

FRERY, A. C.; MÜLLER, H.-J.; FREITAS, C. C.; SANT'ANNA, S. J. S. A model for extremely heterogeneous clutter. **IEEE Transactions on Geoscience and Remote Sensing**, v. 35, n. 3, p. 648–659, 1997. 1, 13, 14

FRERY, A. C.; NASCIMENTO, A. D. C.; CINTRA, R. J. Hypothesis test in complex Wishart distributions. In: INTERNATIONAL WORKSHOP ON SCIENCE AND APPLICATIONS OF SAR POLARIMETRY AND POLARIMETRIC INTERFEROMETRY. **Proceedings...** Frascati, Italy, 2011. 3, 5

_____. Information theory and image understanding: An application to polarimetric SAR imagery. **Chilean Journal of Statistics**, v. 2, n. 2, p. 81–100, 2011. 28, 39, 82

_____. Analytic expressions for stochastic distances between relaxed complex Wishart distributions. **IEEE Transactions on Geoscience and Remote Sensing**, in press. 3, 5

GAO, G. Statistical modeling of SAR images: A survey. **Sensors**, v. 10, n. 1, p. 775–795, january 2010. 1, 14

GONZALEZ, R.; WOODS, R. E. **Processamento digital de imagens**. 3. ed. São Paulo, Brasil: Pearson Prentice Hall, 2010. ISBN 9788576054016. 31

GOODMAN, J. W. Statistical analysis based on a certain multivariate complex gaussian distribution (an introduction). **Annals of Mathematical Statistics**, v. 34, n. 1, p. 152–177, 1963. Disponível em: http://projecteuclid.org/DPubS/Repository/1.0/Disseminate?view=body&id=pdf_1&handle=euclid.aoms/1177704250. Acesso em: 11 de maio de 2009. 14, 15, 71

GRADSHTEYN, I. S.; RYZHIK, I. M. **Table of Integrals, Series, and Products**. 7. ed. New York: Academic Press, 2007. ISBN 0-12-373637-4. 19

HAGEDORN, M.; SMITH, P. J.; BONES, P. J.; MILLANE, R. P.; PAIRMAN, D. A trivariate chi-squared distribution derived from the complex Wishart distribution. **Journal of Multivariate Analysis**, Academic Press, Inc., Orlando, FL, USA, v. 97, n. 3, p. 655–674, mar 2006. ISSN 0047-259X. 25

JORDAN, R.; HUNEYCUTT, B.; WERNER, M. The SIR-C/X-SAR synthetic aperture radar system. **IEEE Transactions on Geoscience and Remote Sensing**, v. 33, n. 4, p. 829 –839, jul 1995. ISSN 0196-2892. 68

KENDALL, M. G.; STUART, A. **The advanced theory of statistics**. London, U.K.: Griffin, 1963. 20

- KHAN, S.; GUIDA, R. On single-look multivariate \mathcal{G} distribution for PolSAR data. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 5, n. 4, p. 1149–1163, aug. 2012. ISSN 1939-1404. 16
- KULLBACK, S.; LEIBLER, R. A. On information and sufficiency. **The Annals of Mathematical Statistics**, Institute of Mathematical Statistics, v. 22, n. 1, p. pp. 79–86, 1951. ISSN 00034851. 21
- LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159–174, 1977. 36, 120, 122
- LEE, J. S.; DU, L.; SCHULER, D. L.; GRUNES, M. R. Statistical analysis and segmentation of multi-look SAR imagery using partial polarimetric data. In: **International Geoscience and Remote Sensing Symposium, 1995. IGARSS '95. 'Quantitative Remote Sensing for Science and Applications'**. Firenze, Italy: IEEE, 1995. v. 2, p. 1422–1424. 47
- LEE, J. S.; GRUNES, M. R. Classification of multi-look polarimetric SAR data based on complex Wishart distribution. In: **Telesystems Conference, 1992. NTC-92., National**. Washington, DC: IEEE, 1992. p. 7/21–7/24. 1, 15, 16
- LEE, J. S.; GRUNES, M. R.; AINSWORTH, T. L.; DU, L. J.; SCHULER, D. L.; CLOUDE, S. R. Unsupervised classification using polarimetric decomposition and the complex Wishart classifier. **IEEE Transactions on Geoscience and Remote Sensing**, v. 37, n. 5, p. 2249–2258, Sep 1999. ISSN 0196-2892. 1, 12, 15, 16
- LEE, J. S.; GRUNES, M. R.; POTTIER, E. Quantitative comparison of classification capability: fully polarimetric versus dual and single-polarization SAR. **IEEE Transactions on Geoscience and Remote Sensing**, v. 39, n. 11, p. 2343–2351, nov 2001. ISSN 0196-2892. 15, 16, 47
- LEE, J. S.; HOPPEL, K. W.; MANGO, S. A.; MILLER, A. R. Intensity and phase statistics of multilook polarimetric and interferometric SAR imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v. 32, n. 5, p. 1017–1028, Sep 1994. ISSN 0196-2892. xi, xiii, 5, 14, 15, 16, 17, 18, 25, 46, 47
- LEE, J. S.; MILLER, A. R.; HOPPEL, K. W. Statistics of phase difference and product magnitude of multi-look processed gaussian signals. **Waves in Random Media**, v. 4, n. 3, p. 307–319, 1994. 14, 17, 19

LEE, J. S.; POTTIER, E. **Polarimetric Radar Imaging: From Basics to Applications**. Boca Raton, FL: CRC Press, Taylor and Francis, 2009. (Optical Science and Engineering). ISBN 9781420054989. 1, 9, 10, 11, 12, 17

LEE, J. S.; SCHULER, D. L.; LANG, R. H.; RANSON, K. J. K distribution for multi-look processed polarimetric SAR imagery. In: **International Geoscience and Remote Sensing Symposium, 1994. IGARSS '94. Surface and Atmospheric Remote Sensing: Technologies, Data Analysis and Interpretation**. Pasadena: IEEE, 1994. v. 4, p. 2179–2181. 1

LI, H. T.; GU, H. Y.; HAN, Y. S.; YANG, J. H. Object-oriented classification of polarimetric SAR imagery based on statistical region merging and support vector machine. In: **International Workshop on Earth Observation and Remote Sensing Applications, 2008**. Benjing, China: IEEE, 2008. p. 1–6. 33

MASSONNET, D.; SOUYRIS, J. **Imaging With Synthetic Aperture Radar**. 1. ed. Boca Raton, FL: CRC Press, 2008. 13

MEJAIL, M. E.; JACOBO-BERLLES, J. C.; FRERY, A. C.; BUSTOS, O. H. Classification of SAR images using a general and tractable multiplicative model. **International Journal of Remote Sensing**, Taylor & Francis, v. 24, n. 18, p. 3565–3582, 2003. 1, 13, 14

NASCIMENTO, A. D. C. **Teoria Estatística da InformaÃ§Ã£o para Dados de Radar de Abertura Sintética Univariados e Polarimétricos**. 280 p. Tese (Doutorado) — Universidade federal de Pernambuco, 2012. xix, 5, 23, 24, 27, 29, 34, 124

NASCIMENTO, A. D. C.; CINTRA, R. J.; FRERY, A. Hypothesis testing in speckled data with stochastic distances. **IEEE Transactions on Geoscience and Remote Sensing**, v. 48, n. 1, p. 373–385, 2010. xix, 3, 5, 22, 23, 24, 27, 28, 34, 48, 51

NEGRI, R. G. **Avaliação de dados polarimétricos do sensor ALOS PALSAR para classificação da cobertura da terra da Amazônia**. Dissertação (Mestrado) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, maio 2009. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m18@80/2009/05.14.12.59>>. Acesso em: 22 de julho de 2009. 18, 47

OLIVER, C.; QUEGAN, S. **Understanding synthetic aperture radar images**. 1. ed. Raleigh, NC: SciTech Publ., 2004. ISBN 1-891121-31-6. 13, 14

OLKIN, I.; PRATT, J. W. Unbiased estimation of certain correlation coefficients. **The Annals of Mathematical Statistics**, Institute of Mathematical Statistics, v. 29, n. 1, p. pp. 201–211, 1958. ISSN 00034851. 20

PICINBONO, B. Second-order complex random vectors and normal distributions. **IEEE Transactions on Signal Processing**, v. 44, n. 10, p. 2637–2640, oct 1996. ISSN 1053-587X. 71

PRIESTLEY, B. **Spectral analysis and time series**. SanDiego: Academic Press, 1982. (Probability and mathematical statistics, v. 1-2). ISBN 9780125649223. 55

QI, Z.; YEH, A. G.; LI, X.; LIN, Z. A novel algorithm for land use and land cover classification using RADARSAT-2 polarimetric SAR data. **Remote Sensing of Environment**, v. 118, p. 21 – 39, 2012. ISSN 0034-4257. 33

ROSENQVIST, A.; SHIMADA, M.; ITO, N.; WATANABE, M. ALOS PALSAR: A pathfinder mission for global-scale monitoring of the environment. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, n. 11, p. 3307–3316, 2007. ISSN 0196-2892. 18

SALICRU, M.; MORALES, D.; MENENDEZ, M. L.; PARDO, L. On the applications of divergence type measures in testing statistical hypotheses. **Journal of Multivariate Analysis**, v. 51, n. 2, p. 372–391, November 1994. Disponível em: <<http://ideas.repec.org/a/eee/jmvana/v51y1994i2p372-391.html>>. Acesso em: 22 de julho de 2009. xi, xiii, 3, 22, 28, 47

SANT'ANNA, S. J. S.; FREITAS, C. C. Um estudo monte carlo na avaliação de erro em modelos digitais de elevação. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12. (SBSR), 16-21 abr. 2005, Goiânia. **Anais...** São José dos Campos: INPE, 2005. p. 3579–3586. ISBN 85-17-00018-8. Disponível em: <<http://urlib.net/ltid.inpe.br/sbsr/2004/11.21.15.52>>. Acesso em: 23 de outubro de 2010. 58

SHANNON, C. A mathematical theory of communication. **Bell System Tech.**, v. 27, p. 379–423, 1948. 3, 21

SOUSA-JÚNIOR, M. A. **Segmentação multi-níveis e multi-modelos para imagens de radar e ópticas**. 131 p. Tese (Doutorado) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005-03-31 2005. Disponível em: <<http://urlib.net/sid.inpe.br/jeferson/2005/06.01.18.47>>. Acesso em: 18 de outubro de 2012. 31, 89

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. 4th. ed. San Diego, CA: Academic Press, 2008. ISBN 1597492728, 9781597492720. 26, 39

ULABY, F. T.; ELACHI, C. **Radar polarimetry for geoscience applications**. Norwood: Artech House, 1990. 364 p. 10

VASILE, G.; PASCAL, F.; OVARLEZ, J.-P.; FORMONT, P.; GAY, M. Optimal parameter estimation in heterogeneous clutter for high-resolution polarimetric SAR data. **IEEE Geoscience and Remote Sensing Letters**, v. 8, n. 6, p. 1046–1050, nov. 2011. ISSN 1545-598X. 16

WAY, J.; EVANS, D.; ELACHI, C. The SIR-C/X-SAR mission. In: **International Geoscience and Remote Sensing Symposium, 1993. IGARSS '93. Better Understanding of Earth Environment**. New York, NJ: IEEE. 68

WOODHOUSE, I. H. **Introduction to Microwave Remote Sensing**. 1. ed. Boca Raton, FL USA: Taylor & Francis, 2006. ISBN 0415271231. 9, 11

APÊNDICE A - CLASSIFICADOR POR REGIÕES COM BASE EM DISTÂNCIAS ESTOCÁSTICAS E TESTES DE HIPÓTESE - GUIA DE UTILIZAÇÃO

A.1 Classificador por Regiões - Instalação

Define-se, para este trabalho, instalação como o processo de criação do projeto que conterá os arquivos que compõem o classificador por regiões e a importação desses arquivos para o projeto criado, com a operação final de construção do projeto. Ao final dessas operações, será criada, no sistema de arquivos do sistema operacional, uma pasta relativa ao projeto criado, que estará ligada ao projeto, quando da execução do mesmo pelo IDL. Após a criação do projeto, o mesmo sempre será apresentado ao se abrir o IDL, desde que não haja mudança do espaço de trabalho (*Workspace*) do IDL, e estará pronto para utilização.

A.1.1 Criação do projeto

Abrir o IDL;

Criar um novo projeto IDL: Acionar: Arquivo → novo → Projeto IDL

Será aberta uma janela como a Fig. A.1

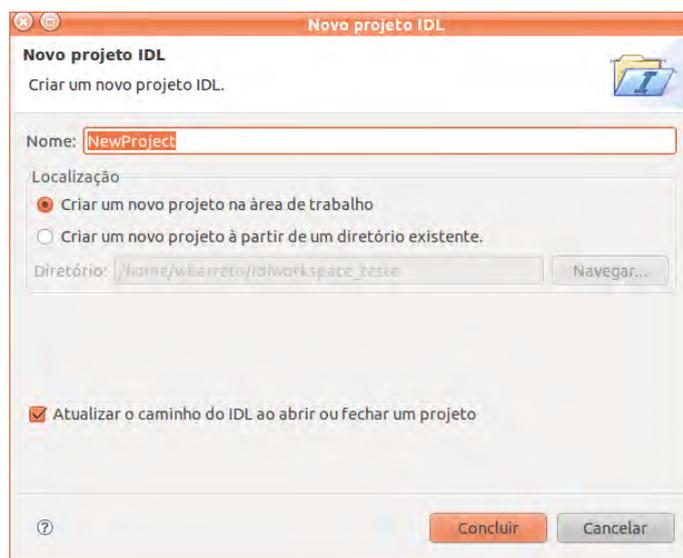


Figura A.1 - Criação do projeto IDL.

Escolher para o nome do projeto o mesmo nome do arquivo do programa principal do classificador. No caso, o nome é: REGION_BASED_CLASSIFIER_0.

O novo projeto será apresentado na janela de projetos do IDL, juntamente com o projeto default, já existente (Fig. A.2).

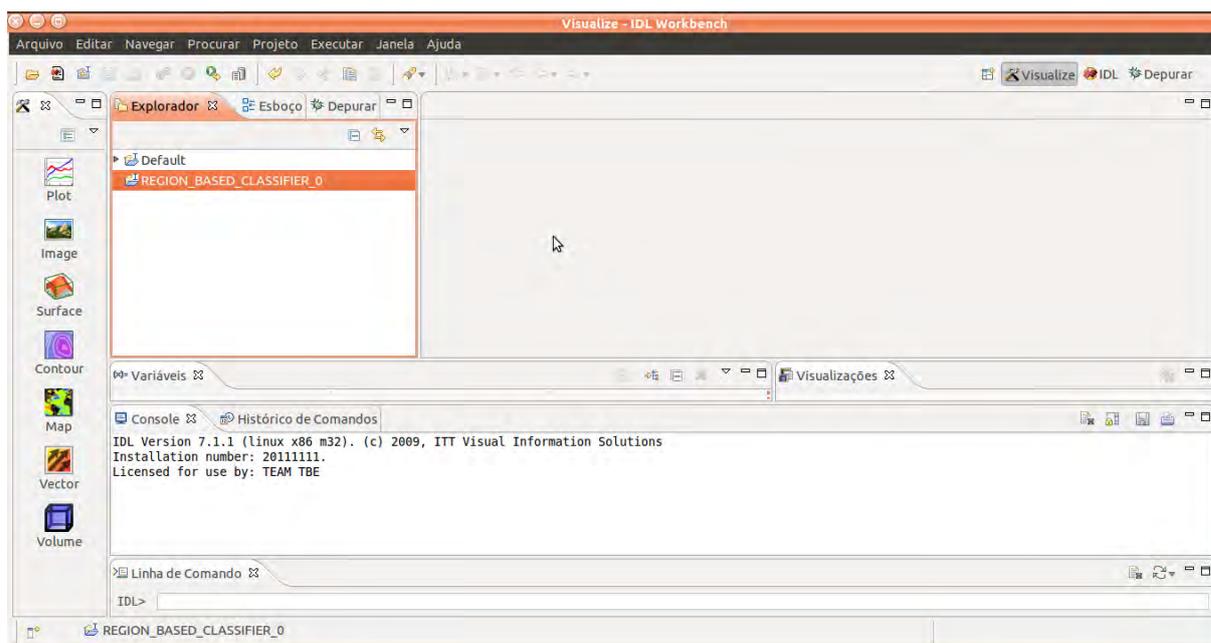


Figura A.2 - Lista de projetos IDL.

A.1.2 Importação dos arquivos do projeto

Serão importados os arquivos (programas do IDL) para o projeto do classificador.

Inicialmente, deve-se descomprimir o arquivo fornecido para uma pasta com o mesmo nome do arquivo do programa principal do classificador (REGION_BASED_CLASSIFIER_0). Para isso, utiliza-se o ambiente de organização de arquivos conveniente a cada sistema operacional. Como exemplos, podem ser citados o Windows Explorer, no Windows e o Nautilus, em alguma distribuição Linux/Ubuntu.

Novamente no IDL, sobre o projeto listado na janela de projetos, deve-se clicar com o botão direito do mouse, dentre as opções que aparecerão na aba, deve-se escolher

a **importar**. A janela apresentada na figura A.3 será então aberta.

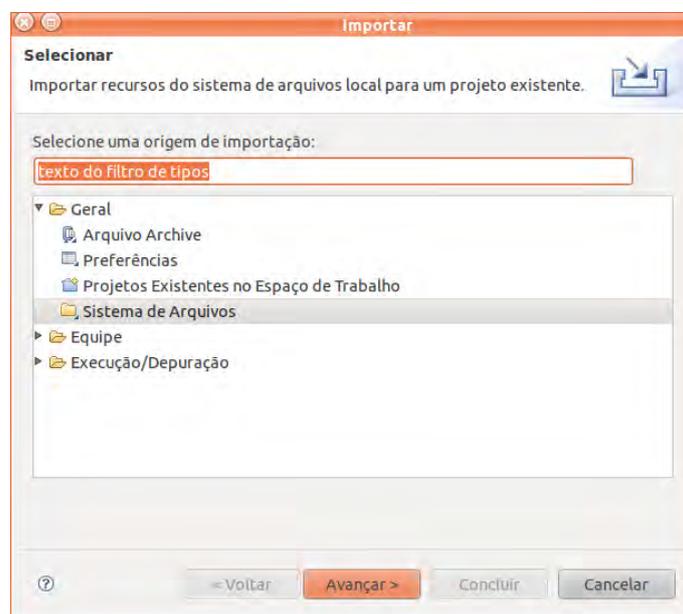


Figura A.3 - Janela de importação do projeto.

Ao se escolher a opção **sistema de arquivos** e acionar o botão **avançar**, deve-se escolher a pasta que contém os arquivos do classificador através do botão **procurar**, conforme apresentado na figura A.4. Depois de selecionada a pasta dos arquivos do classificador, os mesmos serão carregados no espaço do lado direito da janela de importação. Deve-se então selecionar todos os arquivos listados através do acionamento do botão **marcar todos**. Pode-se reparar que todas as caixas de checagem relativas aos arquivos ficam então marcadas. Deve-se então finalizar a importação, acionando o botão **concluir** da janela de importação. Após essas operações, uma pasta com o nome do projeto e conseqüentemente com o nome do arquivo do programa principal do classificador é criada em uma pasta do sistema de arquivos (pasta IDLworkspace), que é a pasta de trabalho do IDL, criada quando da instalação da linguagem.

O projeto deve ser finalmente construído. Com a construção, é gerado um arquivo .SAV do projeto. Para isso, na janela principal do IDL, deve-se clicar com o botão direito do mouse sobre o nome do projeto e escolher a opção construir projeto. Os arquivos serão então compilados e o projeto construído, ficando pronto para ser utilizado.

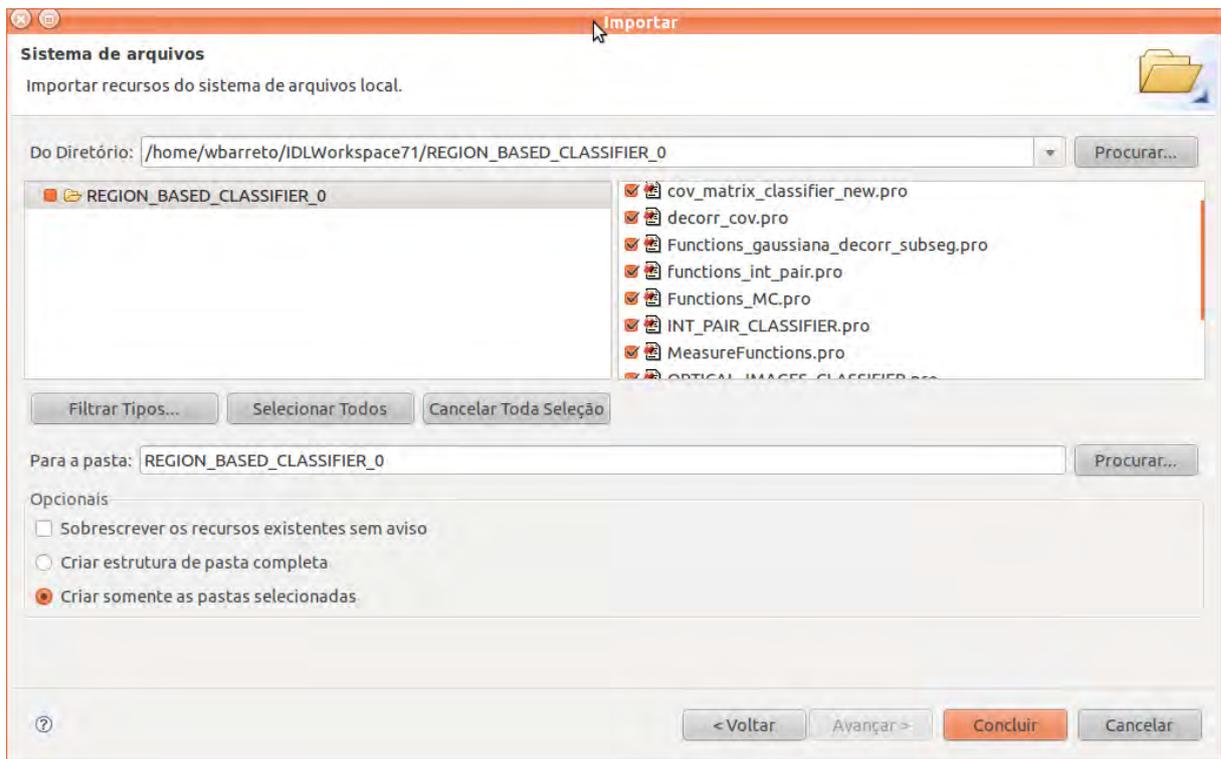


Figura A.4 - janela de importação dos arquivos a partir do sistema de arquivos.

A.2 Classificador por Regiões - Utilização

A.2.1 Descrição do classificador

O classificador por regiões desenvolvido permite classificar imagens polarimétricas, no formato matriz de covariância; pares de imagens em intensidade e imagens que podem ser modeladas pela distribuição gaussiana multivariada (como as imagens óticas e SAR multivariadas em amplitude). Além de fazer a classificação das imagens, o programa desenvolvido utiliza testes de hipótese para cada segmento a partir das distâncias calculadas. Esses testes verificam se os dados relativos a cada segmento das imagens e cada amostra podem ser modelados estatisticamente pela mesma distribuição estatística, de acordo com cada tipo de dado utilizado. A partir desses testes, são gerados produtos complementares que agregam à imagem classificada informações sobre a qualidade da mesma. Esses produtos são imagens indicativas dos p -valores do teste e dos segmentos para os quais a hipótese nula não foi rejeitada (igualdade entre parâmetros das distribuições). Também são relatórios de quantidades de segmentos que passaram no teste. É produzido também um relató-

rio de qualidade da classificação com os cálculos de acurácia global e coeficiente de concordância *kappa* a partir de amostras de teste ou avaliação que sempre deverão ser utilizadas pelo classificador. É importante ressaltar que é imprescindível a existência de uma imagem previamente segmentada para utilização no classificador. O classificador não segmenta as imagens. Para as imagens SAR, pode ser utilizado o sistema SEGSAR e para as ópticas o segmentador do “software” SPRING. A imagem segmentada a ser utilizada no classificador deve estar no formato .TIF.

Três tipos de imagens podem ser utilizadas pelo classificador, conforme foi mencionado no item 2.1. Para cada uma delas, os pré-requisitos são os seguintes:

Imagens polarimétricas Devem estar no formato de matriz de covariância, sem repetição dos componentes complexos conjugados, todas as bandas encapsuladas em um mesmo arquivo .TIF. Foi criado um programa para geração de imagens no formato de matriz de covariância no formato adequado à utilização do classificador. O programa não faz parte do conjunto de programas do classificador, por enquanto, e deve ser utilizado anteriormente à utilização do mesmo. O programa utiliza como dado de entrada arquivos no formato do ENVI com todas as bandas polarimétricas. As bandas polarimétricas devem estar encapsuladas num mesmo arquivo do ENVI. Se o usuário inicialmente dispuser das imagens polarimétricas em arquivos separados, é imperativo que as mesmas sejam carregadas no ENVI e salvas unidas em um novo arquivo do formato do ENVI, com todas as imagens polarimétricas. Uma rápida instrução para geração do arquivo no formato de matriz de covariância é fornecida no item 2.3.

Pares de imagens em intensidade As duas imagens em intensidade devem estar encapsuladas em mesmo um arquivo .TIF.

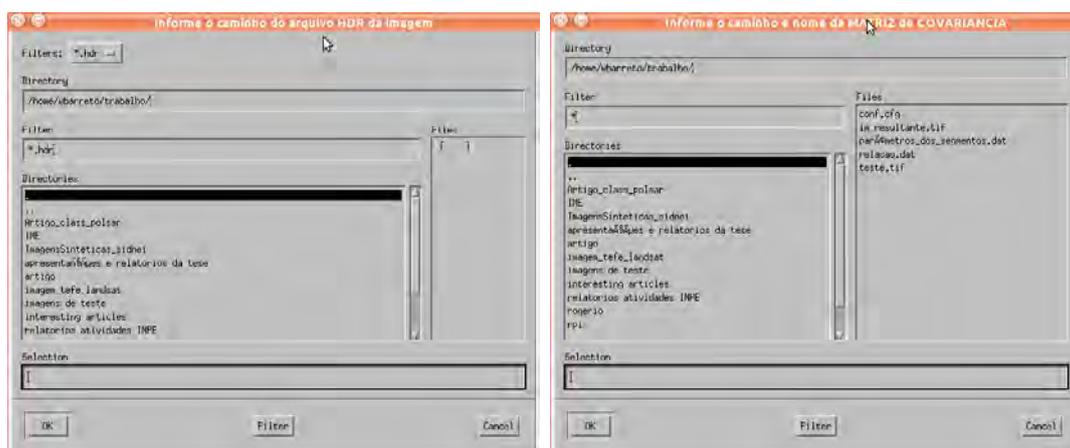
Imagens ópticas multi-espectrais ou SAR em amplitude multivaridas

As diversas imagens ópticas multiespectrais (bandas) devem estar encapsuladas em um mesmo arquivo .TIF

A.2.2 Geração do arquivo de imagem polarimétrica no formato de matriz de covariância

Para a geração da imagem no formato matriz de covariância, pode ser utilizado um programa em IDL que é fornecido juntamente com o classificador por regiões,

chamado GERA_MATRIZ_COVARIANCIA_TIFF.pro. O programa deve ser aberto no IDL com o comando abrir arquivo (Ctrl+O). Deve então ser compilado (Ctrl+F8) e executado (F8). O programa pedirá para ser informado qual o arquivo auxiliar .HDR do arquivo no formato do ENVI que contém todas as bandas polarimétricas e pedirá para informar o local e nome do novo arquivo de matriz de covariância (Fig. A.5(a) e A.5(b)).



(a) escolha da imagem formato do ENVI (b) escolha da imagem matriz de covariância

Figura A.5 - Escolha das imagens de entrada e saída na geração da matriz de covariância.

Após a geração do arquivo de matriz de covariância, o programa perguntará qual a reamostragem que será aplicada ao mesmo. Caso haja interesse em aplicar reamostragem, que corresponde a um processamento *multi-look*, o usuário deverá informar qual o fator em linhas e colunas, conforme pedirá o programa, conforme apresentado pela Fig. A.6.

O arquivo de matriz de covariância a ser utilizado no módulo para imagens polarimétricas do classificador será então finalmente gerado e armazenado no local especificado pelo usuário.

A.2.3 Utilização do classificador

Para iniciar o classificador, com o projeto carregado na lista de projetos do IDL, aciona-se: Projeto → Executar Projeto **nome do projeto** ou aciona-se o ícone apresentado na Fig. A.7 ou aciona-se: Ctrl+Shift+F8. A Interface gráfica do Clas-

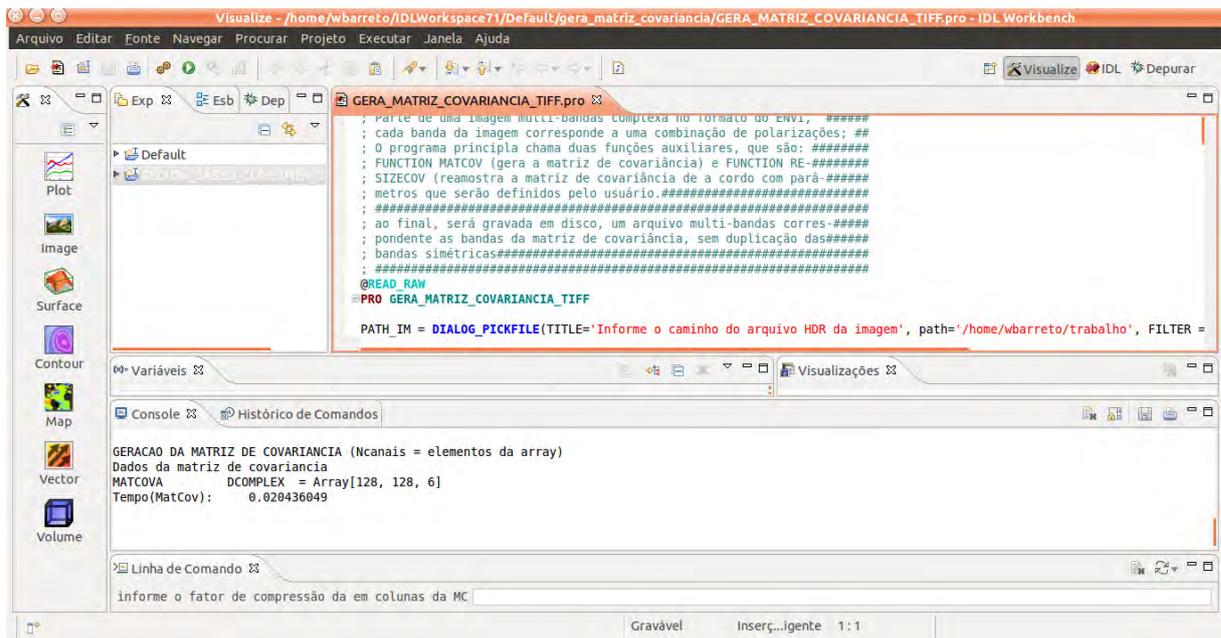


Figura A.6 - Reamostragem em linha e coluna (processamento *multi-look*).

sificador será então apresentada na tela.

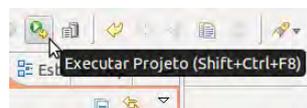


Figura A.7 -

A.2.3.1 Módulo polarimétrico (imagens no formato matriz de covariância)

O módulo polarimétrico é apresentado na interface gráfica do classificador na primeira das abas (Fig. A.8)

Na Figura A.9, são descritos todas as informações que devem ser fornecidas para classificação com os dados polarimétricos.



Figura A.8 - Classificador por regiões: módulo para imagens PolSAR.

A.2.3.2 Módulo par de imagens em intensidade

A aba de classificação dos pares de imagens SAR em intensidade pode ser visualizada na figura A.10.

As únicas diferenças entre a aba do par de intensidades e a das imagens polarimétricas, descrita na subseção A.2.3.1 são a imagem a ser carregada, que agora é o arquivo de imagem .TIF, com as duas intensidades encapsuladas e a relação de distâncias disponíveis, onde são encontradas a Bhattacharyya e a Triangular, ambas resolvidas por solução numérica.

O restante do procedimento operacional é idêntico ao já apresentado no modo polarimétrico.

A.2.3.3 Módulo imagens óticas

No módulo para imagens óticas (Fig.A.11), não estão presentes os campos da banda SAR correspondentes a imagem e ao valor do número equivalente de *looks*, já que este não é um parâmetro da distribuição gaussiana multivariada, utilizada por este módulo do classificador. As distâncias disponíveis também são diferentes das anteriores, essas são a Bhattacharyya e a Kullback-Leibler, todas calculadas por fórmulas fechadas, assim como as do módulo polarimétrico. A imagem multivariada refere-

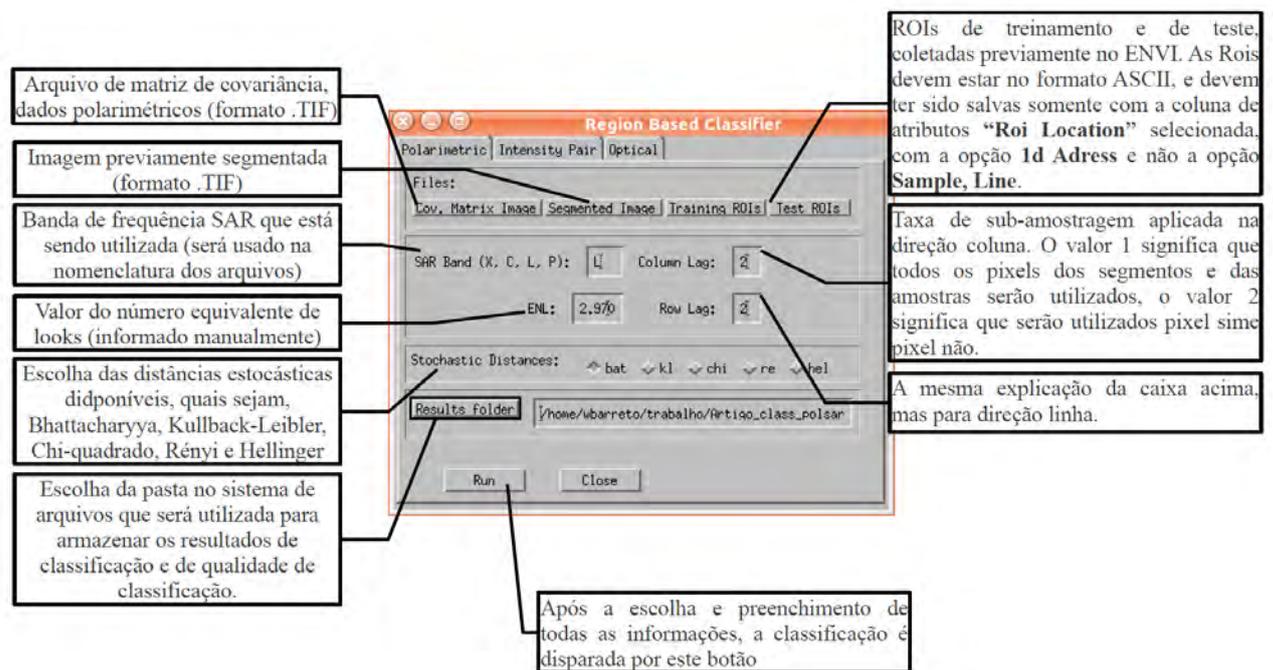


Figura A.9 - Descrição das informações para classificação.

se a um arquivo com diversas bandas, normalmente de imagens ópticas, mas com a possibilidade de utilização de imagens SAR multivariadas em amplitude, preferencialmente com grande número de visadas. Este arquivo deve estar no formato .TIF.

No que diz respeito às outras informações, o procedimento é mesmo.

A.2.3.4 Produtos gerados pelo classificador

Este item tem por objetivo descrever os produtos gerados pelo classificador, que serão armazenados na pasta de resultados, escolhida antes de iniciado o processo de classificação.

Resultados em imagem:

Imagem classificada: imagem classificada no formato ENVI. Uma imagem indexada que, quando aberta no ENVI, apresenta as cores escolhidas para as classes quando da seleção das amostras. No ENVI, ao movimento cursor sobre a imagem, a classe de cada segmento é informada;

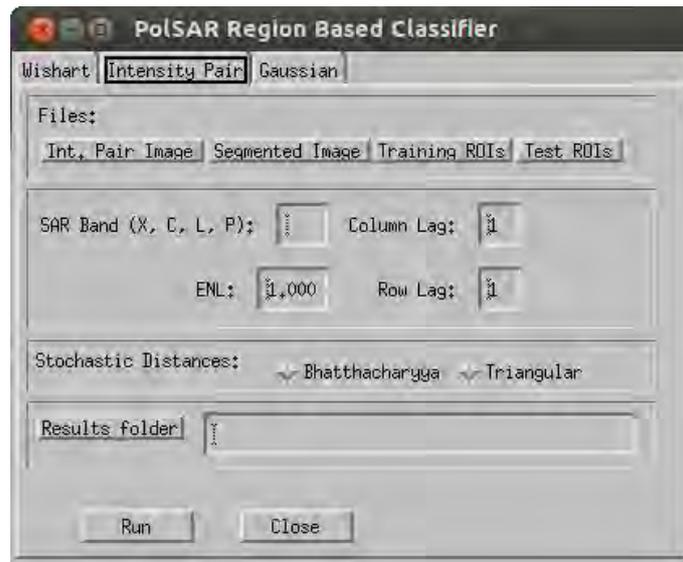


Figura A.10 - Classificador por regiões: módulo para pares de imagens em intensidade.

mapa_p: imagem multibandas com cada banda correspondendo a uma classe, com a informação do p -valor obtido nos testes de hipótese, para cada banda;

mapa_p_máximo: Imagem com a informação do maior p -valor entre todas as bandas para cada segmento;

Border_segpass: imagem com as bordas dos segmentos e com os segmentos que passaram no teste de hipótese ao nível de significância de 5% preenchidos na cor branca;

Resultados em relatório:

report_test: relatório de qualidade da classificação com acurácia global, coeficientes τ e κ e matriz de confusão;

relatório: relatório dos valores de distância, estatística s e p -valor entre cada segmento e todas as classes, ao final, quantidade e percentagem de segmentos que passaram no teste de hipótese;

relação estatística de segmentos: relação com todos os segmentos e as classes escolhidas para cada um e o valor da estatística s calculada entre cada

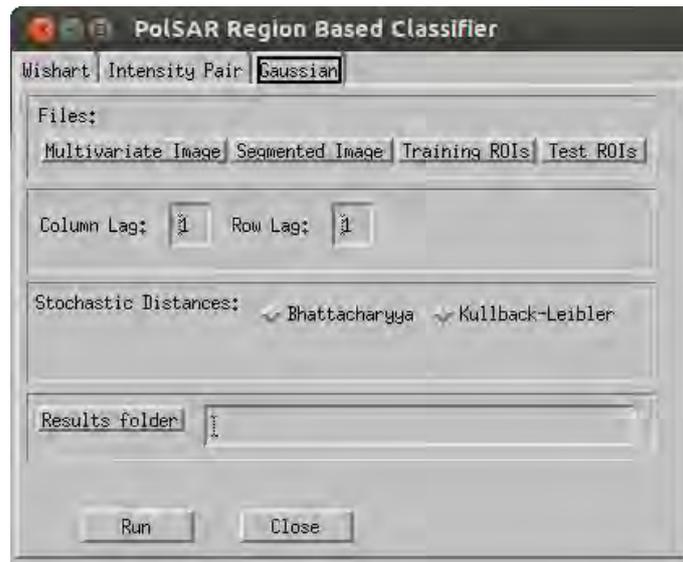


Figura A.11 - Classificador por regiões: módulo para imagens óticas e imagens SAR multivariadas em amplitude.

par segmento-classe. Ao final, a média aritmética entre todos os valores que teoricamente deveriam aproximar-se do valor esperado para uma distribuição do Qui-quadrado com tantos graus de liberdade quanto forem o número de parâmetros estimados por máxima verossimilhança da distribuição que modela os dados da imagem a ser classificada.

relação estatística de segmentos aceitos: relação dos valores de estatística similar a anterior, porém somente com os pares segmento-classe para os quais a hipótese nula foi aceita.

PUBLICAÇÕES TÉCNICO-CIENTÍFICAS EDITADAS PELO INPE

Teses e Dissertações (TDI)

Teses e Dissertações apresentadas nos Cursos de Pós-Graduação do INPE.

Manuais Técnicos (MAN)

São publicações de caráter técnico que incluem normas, procedimentos, instruções e orientações.

Notas Técnico-Científicas (NTC)

Incluem resultados preliminares de pesquisa, descrição de equipamentos, descrição e ou documentação de programas de computador, descrição de sistemas e experimentos, apresentação de testes, dados, atlas, e documentação de projetos de engenharia.

Relatórios de Pesquisa (RPQ)

Reportam resultados ou progressos de pesquisas tanto de natureza técnica quanto científica, cujo nível seja compatível com o de uma publicação em periódico nacional ou internacional.

Propostas e Relatórios de Projetos (PRP)

São propostas de projetos técnico-científicos e relatórios de acompanhamento de projetos, atividades e convênios.

Publicações Didáticas (PUD)

Incluem apostilas, notas de aula e manuais didáticos.

Publicações Seriadas

São os seriados técnico-científicos: boletins, periódicos, anuários e anais de eventos (simpósios e congressos). Constam destas publicações o Internacional Standard Serial Number (ISSN), que é um código único e definitivo para identificação de títulos de seriados.

Programas de Computador (PDC)

São a seqüência de instruções ou códigos, expressos em uma linguagem de programação compilada ou interpretada, a ser executada por um computador para alcançar um determinado objetivo. Aceitam-se tanto programas fonte quanto os executáveis.

Pré-publicações (PRE)

Todos os artigos publicados em periódicos, anais e como capítulos de livros.