



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

sid.inpe.br/mtc-m21c/2018/05.02.23.02-TDI

**SISTEMA DE CLASSIFICAÇÃO DE IMAGENS MONO E  
MULTIFONTES BASEADO EM DISTÂNCIAS  
ESTOCÁSTICAS E TESTES DE HIPÓTESES  
ASSOCIADOS**

Michael Douglas Lemes dos Santos

Dissertação de Mestrado do Curso  
de Pós-Graduação em Computação  
Aplicada, orientada pelo Dr. Sidnei  
João Siqueira Sant'Anna, aprovada  
em 03 de maio de 2018.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3R36HK5>>

INPE  
São José dos Campos  
2018

**PUBLICADO POR:**

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GBDIR)

Serviço de Informação e Documentação (SESID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

E-mail: pubtc@inpe.br

**COMISSÃO DO CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO  
DA PRODUÇÃO INTELECTUAL DO INPE (DE/DIR-544):****Presidente:**

Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação (CPG)

**Membros:**

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

Dr. André de Castro Milone - Coordenação-Geral de Ciências Espaciais e Atmosféricas (CGCEA)

Dra. Carina de Barros Melo - Coordenação de Laboratórios Associados (COCTE)

Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia e Tecnologia Espacial (CGETE)

Dr. Hermann Johann Heinrich Kux - Coordenação-Geral de Observação da Terra (CGOBT)

Dr. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos Climáticos (CGCPT)

Silvia Castro Marcelino - Serviço de Informação e Documentação (SESID)

**BIBLIOTECA DIGITAL:**

Dr. Gerald Jean Francis Banon

Clayton Martins Pereira - Serviço de Informação e Documentação (SESID)

**REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

Simone Angélica Del Duca Barbedo - Serviço de Informação e Documentação (SESID)

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

**EDITORAÇÃO ELETRÔNICA:**

Marcelo de Castro Pazos - Serviço de Informação e Documentação (SESID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SESID)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

sid.inpe.br/mtc-m21c/2018/05.02.23.02-TDI

**SISTEMA DE CLASSIFICAÇÃO DE IMAGENS MONO E  
MULTIFONTES BASEADO EM DISTÂNCIAS  
ESTOCÁSTICAS E TESTES DE HIPÓTESES  
ASSOCIADOS**

Michael Douglas Lemes dos Santos

Dissertação de Mestrado do Curso  
de Pós-Graduação em Computação  
Aplicada, orientada pelo Dr. Sidnei  
João Siqueira Sant'Anna, aprovada  
em 03 de maio de 2018.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3R36HK5>>

INPE  
São José dos Campos  
2018

Dados Internacionais de Catalogação na Publicação (CIP)

---

Santos, Michael Douglas Lemes dos.

Sa59s Sistema de classificação de imagens mono e multifontes baseado em distâncias estocásticas e testes de hipóteses associados / Michael Douglas Lemes dos Santos. – São José dos Campos : INPE, 2018.

xxiv + 182 p. ; (sid.inpe.br/mtc-m21c/2018/05.02.23.02-TDI)

Dissertação (Mestrado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018.

Orientador : Dr. Sidnei João Siqueira Sant’Anna.

1. Classificação de imagens. 2. Classificação multifontes. 3. Divergência. 4. Distâncias estocásticas. 5. Testes de hipótese. I.Título.

CDU 528.854

---



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).



Aluno (a): **Michael Douglas Lemes dos Santos**  
Título: "SISTEMA DE CLASSIFICAÇÃO DE IMAGENS MONO E MULTIFONTES BASEADO EM DISTÂNCIAS ESTOCÁSTICAS E TESTES DE HIPÓTESES ASSOCIADOS".

Aprovado (a) pela Banca Examinadora  
em cumprimento ao requisito exigido para  
obtenção do Título de **Mestre** em  
**Computação Aplicada**

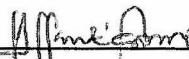
Dr. Thales Sehn Körting



Presidente / INPE / São José dos Campos - SP

( ) Participação por Vídeo - Conferência

Dr. Sidnei João Siqueira Sant'Anna



Orientador(a) / INPE / São José dos Campos - SP

( ) Participação por Vídeo - Conferência

Dr. Leonardo Sant'Anna Bins



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

( ) Participação por Vídeo - Conferência

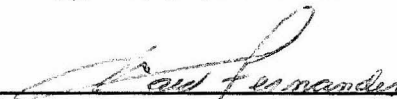
Dr. Elcio Hideiti Shiguemori



Convidado(a) / IEAv / São José dos Campos - SP

( ) Participação por Vídeo - Conferência

Dr. David Fernandes



Convidado(a) / ITA / SJCampos - SP

( ) Participação por Vídeo - Conferência

Este trabalho foi aprovado por:

( ) maioria simples

(x) unanimidade



*“... eu não fui, apenas, aviador, mas que me foi necessário estudar,  
pensar, inventar, construir e só depois, voar...”*

ALBERTO SANTOS DUMONT



*A meus pais **Reginaldo e Cristiane***



## AGRADECIMENTOS

Primeiramente a Deus, por toda Graça nos dada através de seu filho Jesus.

Aos meus pais, Reginaldo e Cristiane, que me apoiaram, ajudaram e incentivaram toda a minha vida. Todo o meu amor e respeito a eles.

Ao meu orientador Dr. Sidnei que sempre esteve disponível e pronto a ajudar. E também ao Dr. Elcio que também atuou como orientador. Agradeço aos dois pela confiança, paciência, incentivo, ensinamentos, "puxões de orelha", dicas e amizade. Tenho profunda admiração pelos dois e são grandes exemplos de profissionais e seres humanos para mim.

À Bruna que, desde o início da pesquisa, incansavelmente me ajudou, explicou repetidas vezes, tirou dúvidas e ensinou.

Aos professores e pesquisadores Dr. Thales, Emiliano e Dr. Haroldo que se disponibilizaram em ajudar e foram fundamentais em momentos críticos para tirar dúvidas e contribuir para o andamento do trabalho.

Ao Eto e ao Vanderson por toda a contribuição no início da pesquisa, pois sempre estiveram disponíveis e me ajudaram muito com a TerraLib.

Aos amigos da turma 2015, Luan, Luicho, Raian, Naiallen, Neelakshi e Luciano, por todos os momentos juntos, pela companhia nos melhores momentos e nos difíceis também.

Aos meus irmãos Giuliano e Evelyn por sempre estarem ao meu lado.

Aos meus amigos, que considero como parte da minha família, que me apoiaram, incentivaram e torceram por mim em todo o tempo.

A todos os professores e pessoal da CAP e do SERE, pelo apoio durante o período do meu mestrado. Agradecimento especial à (agora mamãe) Jéssica, por toda a ajuda na secretaria da CAP.

A todos do Inpe, pessoal da biblioteca, SPG, segurança e serviços gerais que deram apoio durante esses anos.

E agradeço à CAPES pelo apoio financeiro durante o mestrado.





## RESUMO

A classificação de imagens oriundas de sensores orbitais, utilizadas em áreas do conhecimento como o sensoriamento remoto, é uma tarefa fundamental para o estudo do uso e ocupação do solo. A quantidade de sensores que atuam em diferentes faixas do espectro eletromagnético e a disponibilização dos dados para a comunidade científica tem tido um acréscimo considerável. Inevitavelmente, diferentes técnicas têm sido estudadas e utilizadas para a classificação de imagens. Encontram-se na literatura algumas técnicas que são baseadas em conceitos da Teoria da Informação, como divergências e distâncias estocásticas, e que são adequadas para imagens ópticas e de radar. Tem-se considerado também a natureza muitas vezes complementar entre sensores distintos, pois diante das diferenças significativas entre imagens provenientes destes sensores, técnicas que integrem estas informações podem trazer contribuições significativas para o processamento e análise destas imagens. Neste sentido, objetiva-se neste trabalho o desenvolvimento de um sistema computacional que permite a classificação de dados mono e multifontes provenientes de distintos sensores (ópticos e de micro-ondas). O classificador implementado é estatístico, supervisionado, de regiões e baseado em distâncias estocásticas e testes de hipótese associados. Distâncias estas calculadas para as funções densidades de probabilidade Wishart, Par de Intensidade, Gama e Gaussiana Multivariada que são utilizadas, respectivamente, para modelar dados SAR Polarimétrico completo, SAR Par de intensidade e SAR monocanal em intensidade e ópticos. O sistema computacional também é desenvolvido em uma plataforma computacional amigável, flexível e gratuita na linguagem C++ e o suporte para o processamento dos dados geoespaciais é dado pela biblioteca TerraLib. Foram feitos dois casos de testes que evidenciaram a corretude, confiabilidade e completude do sistema e a validação dos resultados. Dados SAR monocanais em intensidade foram aplicados e analisados pela primeira vez nas classificações mono e multifontes baseadas em distâncias estocásticas e testes de hipóteses. Para os dados em estudo, os canais HV e VV foram tão eficazes quanto os dados bivariados e polarimétricos completos para a classificação monofonte. Nas classificações multifontes com as combinações da soma e dos mínimos, os índices de avaliação das classificações envolvendo a imagem monocanal foram equivalentes aos índices das classificações que envolveram os outros dados. Na combinação do produto, a classificação envolvendo o dado modelado por meio da distribuição Gama teve resultados inferiores. Além de permitir a classificação de dados monocanais SAR em intensidade, o desenvolvimento da plataforma computacional significou a concretização da metodologia de classificação multifontes baseada em distâncias estocásticas e testes de hipóteses associados.

Palavras-chave: Classificação de imagens. Classificação multifontes. Divergência. Distâncias estocásticas. Testes de hipótese.



# MONO AND MULTI-SOURCE IMAGE CLASSIFICATION SYSTEM BASED ON STOCHASTIC DISTANCES AND ASSOCIATED HYPOTHESIS TESTS

## ABSTRACT

Image classification from remote sensing imagery is an important task for use and land cover studies. The number of different sensors and the availability of data for the scientific community have had a considerable increase. Inevitably, various techniques have been studied and used for image classification, like techniques based on Information Theory. The complementary nature of different sensors has also been considered due to the important differences among the images obtained from them. Different techniques that integrate this information can bring significant contributions to the processing and analysis of these images. Then, the aim of this work is the development of a computational system for mono and multi-source data (optical and microwave) classification. The classifier methodology is based on stochastic distances and associated hypothesis tests among probability density function of the random variables that represent the information from the different sensors. The probability density functions Wishart, Intensity Pair, Gamma and Gaussian have been considered in order to model polarimetric SAR, bivariate SAR, single-channel SAR e optical data. The classifier is coded using C++ language and the support for geospatial data processing will be given by TerraLib. Two test sets have been applied to verify the correctness, reliability, and completeness of the system and validate the results. Single-channel intensity SAR data have been classified for the first time in this type of methodology, i.e., classification based on stochastic distances and hypothesis tests. HV and VV channels classification results have had as effective as the bivariate and complete polarimetric data for mono-source classifications, for the data set applied in this work. In the multi-source case, single-channel classification results have had effectiveness for sum and minimum combination types. In the product combination, the classification that involved the data modeled through the Gamma distribution has had inferior results. In addition to allowing the classification of single-channel intensity SAR data, the development of the computational platform is the concretion of multi-source classification methodology based on stochastic distances and associated hypothesis tests.

Keywords: Image classification. Multi-source classification. Divergence. Stochastic distances. Hypothesis test.



## LISTA DE FIGURAS

	<u>Pág.</u>
2.1 Metodologia do classificador por regiões baseado em distâncias estocásticas.	28
2.2 Metodologia do classificador multifontes baseado em distâncias estocásticas. . . . .	31
3.1 Diagrama de blocos da metodologia. . . . .	36
4.1 Diagrama das classes implementadas. . . . .	50
4.2 Janela principal da interface gráfica. . . . .	51
4.3 Segunda janela da interface gráfica. . . . .	52
4.4 Posições e classes das regiões das imagens do Caso de Teste 1. . . . .	55
4.5 Imagem SAR em amplitude multivariada simulada em composição colorida R(HH), G(HV) e B(VV). . . . .	55
4.6 Imagens SAR monocanais (a) HH e (b) HV em intensidade simuladas. . . . .	56
4.7 Segmentação e amostras de treinamento e de teste dos dados simulados. . . . .	56
4.8 Resultados para a classificação da imagem simulada PolSAR com a distância de <i>Bhattacharyya</i> . . . . .	59
4.9 Resultados para a classificação do par de imagens SAR simuladas HH,HV com a distância de <i>Bhattacharyya</i> . . . . .	59
4.10 Resultados para a classificação da imagem SAR simulada em amplitude multivarida com a distância de <i>Bhattacharyya</i> . . . . .	60
4.11 Resultados para a classificação da imagem SAR simulada monocanal em intensidade HH com a distância de <i>Bhattacharyya</i> . . . . .	60
4.12 Resultados para a classificação multifonte com a combinação da soma. . . . .	61
4.13 Resultados para a classificação multifonte com a combinação do produto. . . . .	61
4.14 Resultados para a classificação multifonte com a combinação dos mínimos. . . . .	62
4.15 Resultados para a classificação multifonte com a combinação <i>Fuzzy</i> . . . . .	63
4.16 Imagem TM na composição 5(R)4(G)3(B). . . . .	65
4.17 Imagem Palsar na composição HH(R)HV(G)HH(B). . . . .	66
4.18 Localização das amostras de treinamento sobre a imagem TM na composição colorida 3(R)4(G)5(B). . . . .	68
4.19 Localização das amostras de teste sobre a imagem TM na composição colorida 3(R)4(G)5(B). . . . .	69
4.20 Segmentação sobreposta à imagem TM na composição colorida 5(R)4(G)3(B). . . . .	70

4.21	Classificação por meio da distribuição Gaussiana multivariada com a distância de <i>Bhattacharyya</i> . . . . .	73
4.22	Classificação por meio da distribuição Gaussiana multivariada com a distância de <i>Kullback-Leibler</i> . . . . .	74
4.23	Classificação por meio da distribuição Wishart complexa escalonada com a distância de <i>Kullback-Leibler</i> . . . . .	75
4.24	Classificação por meio da distribuição Wishart complexa escalonada com a distância de <i>Rényi</i> . . . . .	76
4.25	Classificação por meio da distribuição Wishart complexa escalonada com a distância de <i>Bhattacharyya</i> . . . . .	77
4.26	Classificação por meio da distribuição Wishart complexa escalonada com a distância de <i>Hellinger</i> . . . . .	78
4.27	Classificação por meio da distribuição Par de Intensidades <i>multilook</i> com a distância Triangular. . . . .	79
4.28	Imagem Landsat/TM em composição colorida 5(R)4(G)3(B). . . . .	81
4.29	Imagem Radarsat2 em composição colorida HH(R)HV(G)VV(B). . . . .	82
4.30	Canal em intensidade HH da imagem Radarsat. . . . .	84
4.31	Canal em intensidade HV da imagem Radarsat. . . . .	85
4.32	Canal em intensidade VV da imagem Radarsat. . . . .	86
4.33	Segmentação única construída por meio da união das segmentações individuais das imagens TM e Radarsat. . . . .	87
4.34	Localização das amostras de treinamento e de teste sobre a imagem TM em composição colorida 1(R)2(G)3(B). . . . .	88
4.35	Comparação dos <i>Kappas</i> obtidos nas classificações monofontes. . . . .	91
4.36	Comparação das acurácias globais obtidas nas classificações monofontes. . . . .	91
4.37	Classificação da imagem TM com a distância de <i>Bhattacharyya</i> . . . . .	94
4.38	Classificação da imagem TM com a distância de <i>Kullback-Leibler</i> . . . . .	95
4.39	Classificação do par de imagens HH,VV com a distância de <i>Bhattacharyya</i> . . . . .	96
4.40	Classificação do par de imagens HH,VV com a distância de Triangular. . . . .	97
4.41	Classificação da imagem monocanal HH com a distância de <i>Bhattacharyya</i> . . . . .	98
4.42	Classificação da imagem monocanal HH com a distância de <i>Kullback-Leibler</i> . . . . .	99
4.43	Classificação da imagem monocanal HH com a distância de <i>Rényi</i> . . . . .	100
4.44	Classificação da imagem monocanal HH com a distância de <i>Helinger</i> . . . . .	101
4.45	Classificação da imagem monocanal HV com a distância de <i>Bhattacharyya</i> . . . . .	102
4.46	Classificação da imagem monocanal HV com a distância de <i>Kullback-Leibler</i> . . . . .	103
4.47	Classificação da imagem monocanal HV com a distância de <i>Rényi</i> . . . . .	104
4.48	Classificação da imagem monocanal HV com a distância de <i>Hellinger</i> . . . . .	105

4.49	Classificação da imagem monocanal VV com a distância de <i>Bhattacharyya</i> .	106
4.50	Classificação da imagem monocanal VV com a distância de <i>Kullback-Leibler</i> .	107
4.51	Classificação da imagem monocanal VV com a distância de <i>Hellinger</i> .	108
4.52	Classificação da imagem monocanal VV com a distância de <i>Rényi</i> ( $\beta = 0,5$ ).	109
4.53	Classificação da imagem PolSAR com a distância de <i>Bhattacharyya</i> .	110
4.54	Classificação da imagem PolSAR com a distância de <i>Kullback-Leibler</i> .	111
4.55	Classificação da imagem PolSAR com a distância de <i>Rényi</i> .	112
4.56	Classificação da imagem PolSAR com a distância Qui-quadrado.	113
4.57	Classificação do par de imagens HH,HV com a distância de <i>Bhattacharyya</i> .	114
4.58	Classificação do par de imagens HH,HV com a distância Triangular.	115
4.59	Classificação do par de imagens VV,HV com a distância de <i>Bhattacharyya</i> .	116
4.60	Classificação do par de imagens VV,HV com a distância de Triangular.	117
4.61	Comparação das acurácias globais obtidas na combinação da soma.	120
4.62	Comparação das acurácias globais obtidas na combinação dos mínimos.	120
4.63	Comparação das acurácias globais obtidas na combinação do produto.	121
4.64	Melhora quantitativa das classificações multifontes em relação às classificações monofontes da TM.	124
4.65	Melhora quantitativa das classificações multifontes em relação às classificações monofontes da Radarsat.	124
4.66	Classificação multifontes I com a combinação da soma.	127
4.67	Classificação multifontes II com a combinação da soma.	128
4.68	Classificação multifontes III com a combinação da soma.	129
4.69	Classificação multifontes IV com a combinação da soma.	130
4.70	Classificação multifontes V com a combinação da soma.	131
4.71	Classificação multifontes I com a combinação dos mínimos.	132
4.72	Classificação multifontes II com a combinação dos mínimos.	133
4.73	Classificação multifontes III com a combinação dos mínimos.	134
4.74	Classificação multifontes IV com a combinação dos mínimos.	135
4.75	Classificação multifontes V com a combinação dos mínimos.	136
4.76	Classificação multifontes I com a combinação do produto.	137
4.77	Classificação multifontes II com a combinação do produto.	138
4.78	Classificação multifontes III com a combinação do produto.	139
4.79	Classificação multifontes IV com a combinação do produto.	140
4.80	Classificação multifontes V com a combinação do produto.	141
A.1	Janela 1 da interface gráfica.	156
A.2	Fluxograma da interface gráfica.	159
A.3	Janela 2 da interface gráfica.	160

A.4	Exemplo da ordem das bandas das imagens polarimétricas de matriz de covariância de ordem 3. . . . .	161
B.1	Posições e classes das regiões das imagens do Caso de Teste 1. . . . .	163
B.2	Resultados para a classificação do par de imagens SAR simuladas HH,HV com a distância Triangular. . . . .	164
B.3	Resultados para a classificação da imagem SAR simulada em amplitude multivarida com a distância de <i>Kullback-Leibler</i> . . . . .	165
B.4	Resultados para a classificação da imagem SAR simulada monocanal em intensidade HH com a distância de <i>Kullback-Leibler</i> . . . . .	165
B.5	Resultados para a classificação da imagem SAR simulada monocanal em intensidade HH com a distância de <i>Rényi</i> . . . . .	166



## LISTA DE TABELAS

	<u>Pág.</u>
2.1 Distâncias tipo $h - \phi$ e funções $h$ e $\phi$ relacionadas. . . . .	19
2.2 Distâncias e constantes $\nu$ . . . . .	24
3.1 Módulos do Classificador. . . . .	38
3.2 Matriz de confusão. . . . .	48
4.1 Classificações monofontes com dados reais. . . . .	71
4.2 Características da imagem TM. . . . .	83
4.3 Características da imagem Radarsat. . . . .	83
4.4 Configurações do computador utilizado para os experimentos. . . . .	89
4.5 Classificações monofontes. . . . .	90
4.6 Classificações multifontes com a combinação da soma. . . . .	118
4.7 Classificações multifontes com a combinação dos mínimos. . . . .	119
4.8 Classificações multifontes com a combinação do produto. . . . .	119
4.9 Melhora quantitativa das classificações multifontes em relação às classificações monofontes. . . . .	123
A.1 Arquivos dos códigos do classificador e seus diretórios na TerraLib. . . . .	155
B.1 Classificações monofontes com os dados simulados. . . . .	164
B.2 Resultados correspondentes à classificação monofonte I. . . . .	167
B.3 Resultados correspondentes à classificação monofonte II. . . . .	168
B.4 Resultados correspondentes à classificação monofonte III. . . . .	169
B.5 Resultados correspondentes à classificação monofonte IV. . . . .	170
B.6 Resultados correspondentes à classificação monofonte V. . . . .	171
B.7 Resultados correspondentes à classificação monofonte VI. . . . .	172
B.8 Resultados correspondentes à classificação monofonte VII. . . . .	173
B.9 Resultados correspondentes à classificação monofonte VIII. . . . .	174
B.10 Resultados correspondentes à classificação monofonte IX. . . . .	175
B.11 Resultados correspondentes à classificação monofonte X. . . . .	176
B.12 Resultados correspondentes à classificação monofonte XI. . . . .	177
B.13 Resultados correspondentes à classificação monofonte XII. . . . .	178
B.14 Resultados correspondentes à classificação monofonte XIII. . . . .	179
C.1 Comparação dos valores dos parâmetros de matriz de covariância $\Sigma$ da distribuição Wishart complexa escalonada. . . . .	182



## LISTA DE ABREVIATURAS E SIGLAS

INPE	– Instituto Nacional de Pesquisas Espaciais
CAPES	– Coordenação de aperfeiçoamento de pessoal de nível superior
SAR	– <i>Synthetic Aperture Radar</i>
MAXVER	– Máxima Verossimilhança
ICM	– <i>Iterated Conditional Modes</i>
NASA	– <i>National Aeronautics and Space Administration</i>
$f.d.p$	– Função Densidade de Probabilidade
$f.d.p$ 's	– Funções Densidade de Probabilidade
PolClass	– Classificador polarimétrico
IDL	– <i>Interactive Data Language</i>
IHS	– <i>Intensity Hue Saturation</i>
PCA	– <i>Principal Component Analysis</i>
SVM	– <i>Support Vector Machine</i>
$\mathbb{Z}_+$	– Conjunto dos números inteiros não negativos
ENL	– <i>Equivalent Number of Looks</i>
PolSAR	– <i>Polarimetric SAR</i>
$Z_{\Re}$	– Parte real do número complexo $Z$
$Z_{\Im}$	– Parte imaginária do número complexo $Z$
$\mathcal{N}$	– Distribuição Gaussiana multivariada
$\mathcal{W}$	– Distribuição Wishart escalonada
$\mathbb{R}$	– Conjunto dos números reais
$\mathcal{G}$	– Distribuição Gama
HR	– <i>High Resolution</i>
VRH	– <i>Very High Resolution</i>
DPI	– Divisão de Processamento de Imagem
FUNCATE	– Fundação de Ciência, Aplicações e Tecnologia Espaciais
$cdf$	– <i>Cumulative Distribution Function</i>
TIFF	– <i>Tagged Image File Format</i>
SIG	– Sistema de Informações Geográficas



## SUMÁRIO

	<u>Pág.</u>
<b>1 INTRODUÇÃO</b> . . . . .	<b>1</b>
1.1 Objetivo . . . . .	5
1.2 Organização da Dissertação . . . . .	5
<b>2 REVISÃO BIBLIOGRÁFICA E FUNDAMENTAÇÃO TEÓRICA</b> . . . . .	<b>7</b>
2.1 Integração de informações de imagens . . . . .	7
2.2 Tipos de imagens . . . . .	10
2.2.1 Imagens ópticas . . . . .	10
2.2.2 Imagens SAR . . . . .	11
2.3 Modelagem estatística de dados . . . . .	13
2.3.1 Distribuição Gaussiana multivariada . . . . .	14
2.3.2 Distribuição Wishart complexa escalonada . . . . .	15
2.3.3 Distribuição Par de Intensidades <i>multi-look</i> . . . . .	15
2.3.4 Distribuição Gama . . . . .	17
2.4 Medidas da Teoria da Informação . . . . .	17
2.4.1 Métricas de divergência . . . . .	18
2.4.2 Distâncias estocásticas . . . . .	19
2.4.3 Estatísticas de testes de hipótese . . . . .	23
2.5 Classificação de imagens por regiões . . . . .	26
2.6 Teoria da informação e a classificação de imagens . . . . .	27
2.6.1 Classificador monofonte por regiões baseado em distâncias estocásticas e estatísticas de teste de hipóteses . . . . .	27
2.6.2 Classificador multifontes por regiões baseado em distâncias estocásticas e testes de hipóteses associados . . . . .	30
<b>3 METODOLOGIA</b> . . . . .	<b>35</b>
3.1 Dados de Entrada . . . . .	35
3.2 Cálculo de atributos . . . . .	37
3.2.1 Módulo Par de Intensidades . . . . .	38
3.2.2 Módulo Gaussiana . . . . .	39
3.2.3 Módulo Wishart . . . . .	40
3.2.4 Módulo Gama . . . . .	40
3.3 Classificação Monofonte . . . . .	41

3.4	Classificação Multifonte . . . . .	42
3.4.1	Combinação da soma . . . . .	43
3.4.2	Combinação do produto . . . . .	44
3.4.3	Combinação dos mínimos . . . . .	45
3.5	Classificação <i>Fuzzy</i> . . . . .	46
3.6	Dados de Saída . . . . .	47
<b>4</b>	<b>RESULTADOS . . . . .</b>	<b>49</b>
4.1	Ferramenta computacional desenvolvida . . . . .	49
4.2	Validações da ferramenta computacional . . . . .	53
4.2.1	Aplicação a dados simulados . . . . .	53
4.2.2	Aplicação a dados reais . . . . .	64
4.3	Avaliação entre dados polarimétricos, dados bivariados e dados monocanais	80
4.3.1	Descrição dos dados utilizados . . . . .	80
4.3.2	Resultados obtidos . . . . .	89
<b>5</b>	<b>CONCLUSÕES . . . . .</b>	<b>143</b>
	<b>REFERÊNCIAS BIBLIOGRÁFICAS . . . . .</b>	<b>147</b>
	<b>APÊNDICE A - MANUAL DO USUÁRIO . . . . .</b>	<b>155</b>
	<b>APÊNDICE B - CASO DE TESTE I . . . . .</b>	<b>163</b>
	<b>APÊNDICE C - CASO DE TESTE II . . . . .</b>	<b>181</b>

# 1 INTRODUÇÃO

A necessidade de recuperar informação de uma grande variedade e quantidade de dados impulsionou o crescimento de pesquisas e aplicações na área de reconhecimento de padrões. O reconhecimento de padrões objetiva a descoberta automática de regularidades nos dados através do uso de técnicas e a utilização dessas regularidades para a classificação dos dados em diferentes categorias ou classes (BISHOP, 2006). No início, existiam basicamente pesquisas teóricas na área de estatística, mas o advento da computação aumentou a demanda por aplicações práticas e mais desenvolvimentos teóricos (THEODORIDIS; KOUTROUMBAS, 2008).

Alguns tópicos de reconhecimento de padrões têm sido profundamente estudados por diversas disciplinas científicas, como é o caso da classificação de imagens. Entre os campos de pesquisa que cooperaram para a difusão desse tópico está a classificação de imagens oriundas de sensores orbitais. Esse tipo de imagem, utilizado em áreas do conhecimento como o sensoriamento remoto, é fundamental para o estudo do uso e ocupação do solo, dentre outras aplicações. Os satélites de observação da Terra, as plataformas aéreas (tripuladas e não tripuladas) e outros tipos de sensores terrestres têm coletado uma quantidade cada vez maior de dados. A quantidade de sensores orbitais que atuam em diferentes faixas do espectro eletromagnético e a disponibilização dos dados para a comunidade científica têm tido um acréscimo considerável (POHL; GENDEREN, 2017). Cada sensor tem seus próprios limites no imageamento no sentido de suas resoluções temporal, espacial, espectral e outras características inerentes e, conseqüentemente, são obtidas diferentes informações das áreas imageadas.

Inevitavelmente, diferentes técnicas têm sido estudadas e utilizadas para a classificação de imagens. Dentre essas técnicas, destacam-se as heurísticas, estatísticas, redes neurais artificiais e agrupamento. Os métodos podem ser divididos em pontuais, contextuais ou por regiões. Na classificação pontual é utilizada a informação de cada pixel isolado. No caso contextual, utiliza-se a informação dos pixels vizinhos de determinado pixel para classificá-lo. Em um classificador por regiões, um conjunto de pixels é usado como unidade de classificação. Outra divisão das técnicas comumente utilizada é em relação ao tipo de treinamento do classificador, que pode ser supervisionado ou não supervisionado. Na classificação supervisionada dispõe-se previamente de dados com informações que permitem a identificação de uma classe de interesse, ou seja, faz-se o uso de dados previamente rotulados. Quando não há dados previamente rotulados e o algoritmo tem que reconhecer as classes presentes

na imagem, a classificação é dita não supervisionada (SCHOWENGERDT, 2007).

Geralmente, técnicas de classificação de imagens são utilizadas para classificar uma única imagem de um único sensor, o que é chamado neste trabalho pelo termo de classificação monofonte. Por exemplo, a técnica desenvolvida em Wu et al. (2008) é apropriada para classificar imagens SAR (*Synthetic Aperture Radar*) polarimétricas, pois, é baseada em regiões e utiliza a função de distribuição de probabilidade Wishart. Uma matriz de covariância hermitiana dos dados polarimétricos segue este tipo de distribuição. Outro exemplo, MAXVER-ICM (máxima verossimilhança - *Iterated Conditional Modes*) desenvolvida no *software* SPRING (CÂMARA et al., 1996) que é apropriada para imagens que podem ser modeladas com a distribuição Gaussiana.

Paralelamente ao estudo de técnicas monofontes, métodos de integração de imagens de diferentes sensores têm sido propostos na literatura em busca de obter melhores resultados de classificação. Este não é um tema exclusivo para imagens. Diante dos desafios e necessidades crescentes de estudar a Terra e o meio ambiente, a integração de dados provenientes de múltiplas fontes é uma tecnologia essencial. Por exemplo, muitas aplicações da NASA (*National Aeronautics and Space Administration*) utilizam e integram uma variedade de dados de múltiplas fontes, seja para observação da Terra ou do espaço (MOIGNE et al., 2006). Para Xie e Li (2016), a integração de dados multisensores, especificamente de observação da Terra, ainda é um desafio e requer um grande esforço da comunidade científica.

A integração de dados é muito importante para a análise e exploração da grande quantidade de imagens orbitais que existe atualmente (ZHANG; PRASAD, 2014). Combinar as imagens com características diferentes pode fornecer uma visão mais completa dos objetos de interesse e aumentar a capacidade de interpretação e de tomada de decisão (MAKARAU et al., 2011). Cabe ressaltar que o termo multifontes, usado neste trabalho, se refere a essa integração de informações de imagens provenientes de diferentes sensores.

Pohl e Genderen (2017) exemplificam uma combinação de imagens considerando inicialmente uma imagem óptica pancromática de alta resolução que fornece um alto detalhe do padrão, forma e tamanho de um objeto. Ao combinar informações de uma imagem multiespectral do mesmo objeto, são adicionados detalhes espectrais de vários comprimentos de onda. Ao adicionar uma imagem termal, informações da temperatura e emissividade do objeto podem ser adicionadas, facilitando sua identificação e compreensão. Adicionando uma imagem de radar, outras propriedades



únicas do objeto de interesse poderão ser fornecidas.

Existem na literatura diferentes abordagens visando refinar, aplicar, desenvolver e comparar novas técnicas de integração de dados extraídos de imagens de diferentes sensores orbitais. Segundo Mura et al. (2015), a técnica de fusão de dados, em especial, tem sido amplamente aplicada em tarefas do Sensoriamento Remoto, tais como mapeamento urbano, estudos de florestas, detecção e caracterização de manchas de óleo, gestão de desastres e geração de modelos de superfície e elevação digital. Ainda de acordo com Mura et al. (2015), as potencialidades e o êxito do processamento e análise de imagens multifontes têm crescido. O mesmo estudo mostrou o interesse da comunidade científica pelo tema, exemplificando a presença de grupos ativos em sociedades profissionais dedicadas ao assunto (IEEE *Data Fusion Technical Committee* e o *Working Group VII/6: Remote Sensing Data Fusion* do *International Society of Photogrammetry and Remote Sensing*) e a presença constante em sessões especiais de quase todas as conferências, *workshops* e revistas de Sensoriamento Remoto (como o *International Symposium Remote Sensing and Data Fusion over Urban Areas* e *Special Issue on Data Fusion* do *IEEE Transaction and Geoscience Remote Sensing*).

Em classificação de imagens, estudos têm buscado obter classificações com índices de acurácia cada vez melhores (PEREIRA, 2012; SHEORAN; HAACK, 2014). Muitos algoritmos de fusão de imagens são usados para esse fim, tornando essa técnica a mais comum encontrada na literatura (SCHMITT; ZHU, 2016). Contudo, a integração de imagens para classificação também pode ser realizada através dos métodos de empilhamento (GHANBARI; SAHEBI, 2014) e através da utilização dos planos de informação intermediários de uma classificação monofonte específica (BRAGA, 2016; SANTOS et al., 2017). Os índices de acurácia na classificação de imagens de múltiplas fontes geralmente são melhores em relação às classificações individuais (POHL; GENDEREN, 2017).

Alguns autores têm desenvolvido ferramentas computacionais que permitem a utilização de imagens multifontes. Moigne et al. (2006) desenvolveram uma ferramenta baseada em ambiente *Web* que permite fazer registro de imagens de sensores distintos. Chen et al. (2016) implementaram um arcabouço (*framework*) para detecção de mudanças em imagens multifontes utilizando a fusão. Chen et al. (2017) desenvolveram uma ferramenta para a fusão de imagens para realizar a classificação. Durante a última década, a fusão de imagens se tornou um procedimento operacional para várias aplicações em sensoriamento remoto e os algoritmos de fusão têm sido im-

plementados e fornecidos em pacotes de *softwares* comerciais de processamento de imagens (POHL; GENDEREN, 2017).

Independentemente de classificação de imagens monofonte ou multifontes, observa-se que o desenvolvimento e a evolução da Tecnologia e da Ciência criaram desafios e oportunidades para usar a grande quantidade de imagens disponíveis. A necessidade de classificar as imagens apresenta a dificuldade de extração automática de informações dos dados e a falta de ferramentas amigáveis para o uso das diferentes técnicas que são desenvolvidas. Na literatura são encontrados exemplos de metodologias que permitem a utilização tanto de imagens ópticas, quanto de imagens de radar, como as desenvolvidas por Silva (2013) e Braga (2016). Ambos os métodos utilizam medidas da Teoria da Informação, tais como, divergências e distâncias estocásticas, porém, uma técnica é monofonte e a outra é multifontes.

A metodologia monofonte citada foi desenvolvida por Silva (2013), onde o classificador foi nomeado *PolClass*. Neste método, a classificação é obtida a partir dos cálculos das distâncias e suas respectivas estatísticas de teste entre segmentos de uma imagem e classes de interesse. Admite-se que são conhecidas as funções densidades de probabilidade (*f.d.p*'s) que modelam os dados. Neste classificador é possível utilizar imagens ópticas, SAR multivariadas em amplitude, pares de imagens SAR em intensidade e SAR polarimétricas, e as funções de distribuição de probabilidade usadas para modelar os dados são: Gaussiana Multivariada, Par de Intensidades *multi-look* e Wishart complexa escalonada. Silva (2013) também desenvolveu uma plataforma computacional para o *PolClass* utilizando a linguagem de programação *Interactive Data Language* (IDL) (EXELIS, 2010).

A segunda técnica citada, que é multifonte, foi proposta por Braga (2016) e trata-se de uma metodologia baseada em distâncias estocásticas e testes de hipóteses para integração de dados classificados. A integração é feita a partir dos dados classificados de cada um dos sensores distintos (classificações individuais ou monofontes) com uso da metodologia desenvolvida em Silva (2013). É possível classificar imagens ópticas, SAR multivariadas em amplitude, pares SAR em intensidade e SAR polarimétricas, pois, as funções de distribuição de probabilidade adotadas para modelar os dados são a Gaussiana Multivariada, Par de Intensidades *multi-look* e Wishart complexa escalonada. Esta metodologia foi desenvolvida em um plano abstrato e não foi implementada uma plataforma computacional. Para a geração de resultados foram utilizados o *PolClass* e outros algoritmos implementados em IDL e, portanto, geraram-se implementações não intuitivas e de alta complexidade.

Ambas as técnicas têm a vantagem, como já mencionado, de permitir a utilização de imagens ópticas e de radar. Os dois métodos também se diferem de outros encontrados na literatura pelo fato de que, além de uma classificação, imagens de confiabilidade da classificação são geradas através das estatísticas de teste e dos valores- $p$  associados a estas estatísticas.

## 1.1 Objetivo

Este trabalho tem como principal objetivo a construção de uma plataforma computacional amigável (intuitiva) e flexível (para diferentes técnicas e sistemas operacionais) para um classificador de imagens de múltiplos e distintos sensores. Objetiva-se disponibilizar o *software* como uma ferramenta gratuita para a utilização de informações adquiridas por fontes distintas e independentes para obter melhores desempenhos na classificação. Contribuições e discussões para o classificador também fazem parte do objetivo deste trabalho. A seguir, os objetivos específicos desta Dissertação são apresentados.

- Adicionar e avaliar a aplicação da modelagem estatística através da distribuição Gama, permitindo a utilização de imagens de radar monocanal no formato intensidade. A distribuição Par de Intensidades *multi-look* é utilizada na classificação de dados SAR em intensidade. Porém, como não há expressões analíticas fechadas para o cálculo de distâncias entre distribuições Par de Intensidades, um método numérico pode ser utilizado. Para a distribuição Gama existem expressões fechadas e, dessa maneira, torna-se viável a avaliação da aplicação de dados SAR polarimétricos incompletos nesta modelagem estatística.
- Desenvolver um *framework* para as técnicas mono e multifontes de classificação de imagens na linguagem C++ como um módulo integrado à TerraLib (CÂMARA et al., 2010), que é uma biblioteca aberta de classes e métodos escrita em C++ e que dá suporte para o processamento dos dados geoespaciais.

## 1.2 Organização da Dissertação

Este trabalho está organizado em cinco capítulos. No Capítulo 2 são descritos os fundamentos teóricos necessários para o entendimento dos demais capítulos, além da revisão dos métodos de classificação de imagens derivados da Teoria da Informação. A metodologia de desenvolvimento da plataforma computacional proposta é exposta no Capítulo 3, com descrição das etapas implementadas. No Capítulo 4 são apresentados alguns resultados experimentais e a avaliação destes resultados e

no Capítulo 5 são apresentadas as conclusões e trabalhos futuros.

## 2 REVISÃO BIBLIOGRÁFICA E FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, primeiramente, é apresentada uma revisão da literatura sobre a integração de imagens de sensores orbitais distintos. Em seguida, são apresentados alguns tópicos importantes como os tipos de dados, a modelagem estatística dos dados e os conceitos usados no desenvolvimento do sistema de classificação. Por fim, descrevem-se as metodologias das técnicas de classificação de imagens monofonte e multifontes que são utilizadas no desenvolvimento do classificador neste trabalho.

### 2.1 Integração de informações de imagens

Considerar as informações presentes em dados provenientes de sensores orbitais distintos em conjunto pode levar a uma descrição mais abrangente de uma cena em estudo. Dessa forma, a integração de dados tem o potencial de fornecer informações complementares e aumentar a qualidade da interpretação da cena estudada e de tomada de decisão (MURA et al., 2015). Na literatura são encontrados exemplos do emprego de imagens multifontes em estudos de desastres naturais (fusão de imagens com diferentes resoluções espaciais e temporais) (HEDHLI et al., 2014), exploração mineral (imagens SAR e ópticas) (TEIXEIRA et al., ), florestas (imagens LiDAR e ópticas) (MA et al., 2012), monitoramento da qualidade da água (imagens ópticas) (CHANG; VANNAH, 2013), detecção de mudanças (LI et al., 2016), e outros tópicos.

Entre as técnicas utilizadas para a integração de dados, a fusão de imagens é a mais comum. Segundo Pohl e Genderen (2017), a fusão de imagens pode ser definida como a combinação de duas ou mais imagens diferentes para formar uma nova imagem com a utilização de um algoritmo. Seu uso mais comum é para aumentar a resolução espacial de uma imagem, porém, é realizada também com o intuito de tornar a detecção, identificação e classificação de certos objetos mais fáceis.

A quantidade de diferentes algoritmos de fusão tem aumentado. Pohl e Genderen (2017) consideraram seis categorias para estes algoritmos e são exemplificadas a seguir:

- substituição de componentes: transformação Intensidade Matiz Saturação (IHS - *Intensity Hue Saturation*), substituição de Principais Componentes e transformação *Gram-Schmidt*;
- métodos numéricos: soma, multiplicação, diferença de imagens e técnicas baseadas em modulação;

- técnicas estatísticas: Análise de Componentes Principais (PCA - *Principal Component Analysis*), abordagem do erro mínimo médio quadrático (*Minimum Mean-Square Error*) e regressão;
- abordagens de multiresolução: transformação *Wavelet*, transformação discreta *Wavelet* e transformação *Wavelet* aditiva;
- técnicas híbridas: *Wavelet-IHS*, *Wavelet-PCA* e filtro Laplaciano com regressão múltipla;
- outras técnicas: fusão de dados Bayesiana e modelo de fusão de reflectância adaptativa espacial e temporal.

Muitos estudos têm sido realizados com o objetivo de verificar as vantagens e desvantagens dos diferentes tipos de algoritmos. Akoguz et al. (2013) compararam quatorze técnicas diferentes de fusão e Merentitis e Debes (2015) estudaram três tipos de fusão com técnicas de *ensemble learning* (*Random Forest*, *Extra Trees* e *Gradient Boosted Regression Trees*). Para entender mais sobre algoritmos de fusão, uma revisão do estado da arte da pesquisa de fusão de dados de sensoriamento remoto foi feita por Schmitt e Zhu (2016).

A fusão de imagens tem algumas limitações, como por exemplo quando os dados adquiridos de diferentes sensores possuem formatos completamente diferentes. Os sensores que adquirem dados 3-D, como LiDAR, têm uma resolução espacial complexa para alinhar com outros sensores. Além disso, pixels em imagens ópticas e dados em LiDAR são valores reais multivariados, enquanto que imagens de radar têm valores complexos. A conversão dos dados em formatos comuns para processá-los em conjunto pode gerar incertezas adicionais, como por exemplo, erros devido a operações como quantificação e interpolação (MURA et al., 2015). Segundo Brell et al. (2016), uma simples integração não ajustada da informação de elevação do LiDAR e da reflectância hiperespectral de um dado óptico causa uma perda substancial de informações e o potencial total de ambos os sensores não é aproveitado.

Pohl e Genderen (2017) enumeraram uma série de desafios para a fusão de imagens: imagens de alta resolução requerem medidas mais precisas na acurácia geométrica na fusão de imagens; os ângulos no imageamento causam características de sombra diferentes em cada imagem em dados de alta resolução criando informações incorretas após a fusão; e maiores resoluções espectrais e espaciais trazem um desafio maior para a qualidade das imagens geradas pela fusão e, portanto, um desafio para

as técnicas de fusão.

Para a classificação de imagens, diversos autores têm empregado técnicas para integração de dados, a maioria por fusão, visando obter classificações com índices de acurácia mais satisfatórios e melhores interpretações visuais (BRAGA, 2016). Entre as diferentes técnicas, alguns exemplos de classificações multifontes com imagens de sensores ópticos distintos são Wu e Gao () (utilizaram redes neurais Bayesianas), Wang et al. (2013) (*Support Vector Machine* - SVM) e Huang et al. (2016) (redes neurais de desconvolução profunda). As diferenças no comportamento dos dados de imagens ópticas e SAR também têm sido exploradas, por exemplo em Baek et al. (2013) (utilizaram PCA e *root-mean-square*), Voisin et al. (2012) (modelo de Markov) e Sato (2012) (árvore de decisão). A integração de informações de imagens LiDAR e ópticas também vem sendo utilizada para a classificação, como em Dupuy et al. (2012) (classificação baseada em objeto), Makarau et al. (2011) (redes neurais artificiais), Khodadadzadeh et al. (2015) (*multiple feature learning*), Zhang e Prasad (2014) (SVM) e Chen et al. (2017) (redes neurais convolucionais). Em geral, os métodos de integração analisados apresentaram resultados melhores do que aqueles obtidos individualmente. A acurácia na classificação de imagens de múltiplas fontes geralmente é significativamente melhorada em relação às classificações individuais (SILVA, 2013; BRAGA, 2016; POHL; GENDEREN, 2017).

Embora a fusão seja a maneira mais difundida na literatura devido as suas diferentes categorias de métodos, essa não é a única prática usada na classificação de imagens multifontes. O empilhamento também pode ser usado para essa tarefa. Ghanbari e Sahebi (2014) compararam a fusão usando PCA e o empilhamento com imagens SAR e ópticas. Para a área em estudo naquele trabalho, a acurácia da classificação para a fusão foi de 73,3% e para o empilhamento foi de 89,1%.

Outro método de classificação multifontes é a utilização dos planos de informação intermediários de uma classificação monofonte específica. Seguindo essa metodologia, Braga (2016) desenvolveu uma técnica que utiliza distâncias estocásticas e testes de hipótese associados. Esta técnica é utilizada neste trabalho e seus detalhes são apresentados na Subseção 2.6.2. Este método, assim como o empilhamento, não gera uma nova imagem, como acontece na fusão (SANTOS et al., 2017).

Cada técnica tem vantagens e benefícios, assim como desvantagens e limitações. Para escolher um método é preciso considerar o objetivo e a aplicação do usuário, o problema em questão, os passos necessários de pré-processamento e os tipos de dados que serão usados na integração (POHL; GENDEREN, 2017). A seguir, são descritos

os tipos de imagens e as modelagens estatísticas dos dados admitidas nos métodos mono e multifontes implementados neste trabalho.

## 2.2 Tipos de imagens

Nos últimos anos houve um aumento exponencial no número de sensores remotos disponíveis e isso tem facilitado a obtenção de conjuntos de dados de múltiplas fontes de uma mesma região (CHEN et al., 2017). Diferentes satélites e plataformas aéreas tripuladas e não tripuladas têm sido utilizados, aumentando significativamente a capacidade de imageamento. E o imageamento tem sido feito com uso de sensores que operam em faixas distintas do espectro eletromagnético e com diferentes resoluções espaciais e temporais. Essa grande variedade de imagens disponíveis apresenta um potencial para aplicações em integração de imagens multifontes (HEDHLI et al., 2014).

As diferenças relevantes entre os tipos de imagens, principalmente relacionadas ao comportamento dos dados, vêm sendo observadas nos últimos anos (BRAGA, 2016). Para aplicações em que a modelagem estatística é considerada, diferentes modelos são usados para cada tipo de dado. As técnicas de classificação implementadas neste trabalho são estatísticas e, portanto, modelos estatísticos devem ser adotados para os dados. As funções densidade de probabilidade usadas para a modelagem são apresentadas na Seção 2.3 e são usualmente indicadas para imagens ópticas e imagens SAR, que são descritas nas subseções a seguir (2.2.1 e 2.2.2). Dessa maneira, o classificador desenvolvido neste estudo permite trabalhar com esses tipos de imagens. Imagens ópticas são amplamente estudadas e utilizadas em diversas aplicações e imagens SAR de vários sensores já estão disponíveis para a comunidade científica (POHL; GENDEREN, 2017).

### 2.2.1 Imagens ópticas

Os sensores ópticos operam na faixa óptica do espectro eletromagnético ( $0,30$  a  $15,0\mu m$ ) e são tipos de sensores passivos. Isso significa que captam a energia refletida dos alvos imageados que recebem radiação eletromagnética de uma fonte externa, que geralmente é o Sol. Após a aquisição e processamento dos dados, cada pixel da imagem representa a média da energia captada em uma determinada área da superfície da Terra e esses valores são representados pelos números inteiros não negativos ( $\mathbb{Z}_+$ ) (FREITAS et al., ).

Imagens obtidas por sensores ópticos são muito estudadas e algoritmos de processamento e análise são desenvolvidos com maior frequência para esse tipo de dado. Por



outro lado, o processo de aquisição desse tipo de imagem tem grande dependência das condições climáticas, pois nuvens, chuva e neblina são exemplos de possíveis problemas para o imageamento através de sensores ópticos.

### 2.2.2 Imagens SAR

Os radares de abertura sintética (SAR - *Synthetic Aperture Radar*) operam, em geral, na faixa de micro-ondas do espectro eletromagnético (0,3 a 100cm) e são tipos de sensores ativos, ou seja, possuem uma fonte própria para a emissão de pulsos de radiação eletromagnética. O radar emite o sinal eletromagnético para a superfície da Terra e parte do sinal retorna ao ser refletido após a interação com um conjunto de alvos da área imageada. O dado associado a um pixel é resultado das contribuições desses alvos difusores e das reflexões múltiplas entre eles dentro de uma unidade especificada do terreno (célula de resolução). Esses alvos ficam distribuídos aleatoriamente e as distâncias entre as suas posições e a antena do radar variam aleatoriamente. Dessa forma, esses elementos difusores podem interferir uns aos outros construtivamente (quando os sinais refletidos são somados) ou destrutivamente (quando os sinais são cancelados). Isso causa uma variação de intensidade pixel a pixel, deixando a imagem com um efeito visual granular. Essas variações súbitas na intensidade da imagem são denominadas de ruído *speckle* e é um ruído multiplicativo que está associado a sistemas de imageamento coerente, tais como os sensores SAR. O ruído *speckle* dificulta a interpretação das imagens e reduz a separabilidade entre os objetos da cena (NASCIMENTO, 2012). Para diminuir o ruído existem dois principais métodos: filtros e o processamento *multi-look* (SOUSA-JÚNIOR, 2005). Em imagens SAR *multi-look*, o parâmetro número equivalente de *looks* (*Equivalent Number of Looks* - ENL) indica o nível de ruído *speckle* (REN et al., 2015).

Sistemas SAR, normalmente, transmitem e recebem os pulsos de energia pela antena nas polarizações lineares horizontal (H) e vertical (V). Assim, considerando-se as possíveis combinações de transmissão e recepção os sinais podem ser HH, HV, VH e VV (NASCIMENTO, 2012). Nos sistemas SAR polarimétricos (PolSAR - *Polarimetric SAR*) os dados resultantes contém a amplitude e a fase dos sinais retornados nessas combinações e podem ser representados pela matriz de espalhamento complexa  $\mathbf{S}$ , dada por:

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

onde cada elemento  $S_{t,r}$  é um número complexo e os índices subscritos referem-se a cada par de polarizações possíveis. A letra  $t$  corresponde à polarização de transmissão e a letra  $r$  à polarização de recepção da antena SAR (SOUSA-JÚNIOR, 2005).

Com o desenvolvimento de uma expansão lexicográfica da matriz  $\mathbf{S}$  e considerando a hipótese da condição de reciprocidade ( $S_{HV} = S_{VH}$ ), obtém-se o vetor de espalhamento  $\mathbf{k}_B$ :

$$\mathbf{k}_B = \begin{bmatrix} S_{HH} & \sqrt{2}S_{HV} & S_{VV} \end{bmatrix}^\top. \quad (2.2)$$

A partir do vetor  $\mathbf{k}_B$  pode ser definido outro tipo de representação, onde os pixels da imagem PolSAR contém matrizes de covariância  $\mathbf{C}$ . A matriz  $\mathbf{C}$  em cada pixel é calculada pela esperança do produto entre o vetor de espalhamento  $\mathbf{k}_B$  e o seu complexo conjugado transposto  $\mathbf{k}_B^H$ , como mostra a Equação 2.3, e registra o inter-relacionamento estatístico entre os diferentes canais de polarização transmitidos e recebidos pela antena SAR, ao invés da informação de cada canal separadamente (SILVA, 2013).

$$\mathbf{C} = \mathbb{E} \left[ \mathbf{k}_B \mathbf{k}_B^H \right] = \mathbb{E} \left[ \begin{pmatrix} |S_{HH}|^2 & S_{HH}S_{HV}^* & S_{HH}S_{VV}^* \\ S_{HV}S_{HH}^* & |S_{HV}|^2 & S_{HV}S_{VV}^* \\ S_{VV}S_{HH}^* & S_{VV}S_{HV}^* & |S_{VV}|^2 \end{pmatrix} \right], \quad (2.3)$$

em que  $(\cdot)^H$  indica o transposto conjugado de um vetor,  $(\cdot)^*$  representa o conjugado de um número complexo e  $\mathbb{E}[\cdot]$  é o operador esperança.

A representação digital das imagens polarimétricas é feita por números complexos ( $S_{t,r} = Z_{\Re} + iZ_{\Im}$ ), mas os dados SAR também podem ser representados nos formatos amplitude ( $A = \sqrt{Z_{\Re}^2 + Z_{\Im}^2}$ ) e intensidade ( $I = A^2 = Z_{\Re}^2 + Z_{\Im}^2$ ) (SOUSA-JÚNIOR, 2005).

Imagens geradas pelos sensores de micro-ondas são pouco influenciadas por condições atmosféricas (por exemplo, chuva e neblina), podendo ser usadas em regiões com grande ocorrência de nuvens e serem obtidas em período noturno. Porém, geralmente, essas imagens são de interpretação visual mais difícil quando comparadas às imagens ópticas.

### 2.3 Modelagem estatística de dados

Os pixels de uma imagem podem ser descritos por uma variável aleatória que segue uma determinada distribuição (NASCIMENTO, 2012). Os métodos de classificação supervisionada que adotam técnicas estatísticas requerem modelos para os pixels (ou regiões da imagem) e para as classes. Consequentemente, diferentes funções densidade de probabilidade (*f.d.p.*) têm sido propostas para modelar os dados oriundos de sensores orbitais e que dependem do sensor utilizado (óptico, micro-ondas, etc), do tipo de dado (intensidade, amplitude, polarimétrico, etc) e do tipo de alvo imageado (FRERY et al., 1997; KRILOV et al., 2012).

Tendo em vista as distâncias estocásticas utilizadas no desenvolvimento deste trabalho, a descrição da modelagem estatística desta Seção tem seu enfoque nos dados ópticos e SAR. Em relação às imagens ópticas, a hipótese da Gaussianidade desse tipo de dado é comumente utilizada no desenvolvimento e implementação de classificadores que adotam técnicas estatísticas. Desta forma, na literatura a distribuição Gaussiana multivariada é geralmente usada para modelar os dados de imagens ópticas que contenham mais de uma banda espectral (FREITAS et al., ).

Neste trabalho, a modelagem estatística dos dados PolSAR é feita através da distribuição Wishart complexa escalonada. As vantagens da utilização da distribuição Wishart em comparação com outros modelos presentes na literatura (NASCIMENTO et al., 2010) são a sua menor complexidade analítica, o desenvolvimento de distâncias estocásticas baseadas nesta distribuição e a indisponibilidade de expressões fechadas para distâncias entre modelos mais complexos.

Para imagens de radar no formato intensidade, a distribuição Gama é utilizada neste trabalho no caso de imagem monocanal (dados em uma única banda e polarização) e a distribuição Par de Intensidades *multi-look* quando se trabalha com os dados de duas polarizações distintas. Essas duas distribuições são casos particulares da distribuição Wishart (LEE et al., 1994) e na literatura são utilizadas na modelagem estatística dos tipos de dados mencionados (NASCIMENTO et al., 2010; SALDANHA et al., 2013; BRAGA, 2016; SANTOS et al., 2017).

A utilização da distribuição Gama para a modelagem de imagem monocanal no formato intensidade é inédita na metodologia da classificação de imagens baseada em distâncias estocásticas e testes de hipótese. Em relação à modelagem por intermédio da distribuição Par de Intensidades *multi-look*, em Braga (2016) os resultados de classificação das imagens SAR modeladas por essa distribuição exibiram as melhores

imagens de probabilidade em relação às outras classificações estudadas. Além disso, para determinado número de classes de uso e cobertura da Terra, a classificação utilizando essa distribuição na modelagem estatística pode apresentar resultados similares aos obtidos pelos dados polarimétricos completos (NEGRI, 2009).

Por fim, para a modelagem de imagens SAR multivariadas em amplitude com grande número de visadas, na literatura, é comum o uso da distribuição Gaussiana multivariada (NASCIMENTO et al., 2010; BRAGA, 2016; SANTOS et al., 2017). As descrições destas distribuições utilizadas neste trabalho são dadas nas subseções a seguir.

### 2.3.1 Distribuição Gaussiana multivariada

A distribuição Gaussiana multivariada é usada para modelar estatisticamente dados de imagens ópticas (FREITAS et al., ) e de imagens SAR multivariadas em amplitude com grande número de visadas (SILVA, 2013). Seja um vetor aleatório normal multivariado  $\mathbf{Y} = (Y_1, Y_2, \dots, Y_q)^\top$ ,  $q \in \mathbb{N}^*$ , cujos componentes são variáveis aleatórias Gaussianas com médias  $\mu_1, \dots, \mu_q$  e variâncias  $\sigma_1^2, \dots, \sigma_q^2$ .  $\mathbf{Y}$  tem uma distribuição Normal  $q$ -variada com  $\mathbb{E}(\mathbf{Y}) = \boldsymbol{\mu}$  e  $\text{Cov}(\mathbf{Y}) = \boldsymbol{\Sigma}$ ,  $\mathbf{Y} \sim \mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ , se sua função densidade de probabilidade é representada por:

$$f_{\mathbf{Y}}(\mathbf{y}; \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{(\sqrt{2\pi})^q} |\boldsymbol{\Sigma}|^{-\frac{1}{2}} \exp \left\{ -\frac{1}{2} (\mathbf{y} - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \boldsymbol{\mu}) \right\}, \quad (2.4)$$

em que  $|\cdot|$  denota o determinante da matriz,  $(\cdot)^{-1}$  denota a matriz inversa,  $(\cdot)^\top$  indica a transposição do vetor ou matriz,  $\boldsymbol{\mu}$  é um vetor  $q \times 1$ ,  $\boldsymbol{\Sigma}$  é uma matriz  $q \times q$ , e  $q$  é a ordem do vetor  $\boldsymbol{\mu}$  e da matriz  $\boldsymbol{\Sigma}$  e corresponde ao número de variáveis em  $\mathbf{Y}$ .

Os estimadores de máxima verossimilhança para os parâmetros  $\boldsymbol{\mu}$  e  $\boldsymbol{\Sigma}$  são dados por:

$$\hat{\boldsymbol{\mu}} = \frac{1}{N} \sum_{i=1}^N \mathbf{y}_i, \quad (2.5)$$

$$\hat{\boldsymbol{\Sigma}} = \frac{1}{N} \sum_{i=1}^N (\mathbf{y}_i - \hat{\boldsymbol{\mu}})^\top (\mathbf{y}_i - \hat{\boldsymbol{\mu}}), \quad (2.6)$$

onde  $N$  é o tamanho de uma amostra aleatória.

### 2.3.2 Distribuição Wishart complexa escalonada

A distribuição Wishart complexa escalonada (GOODMAN, 1963) é utilizada para modelar estatisticamente dados PolSAR, principalmente para áreas homogêneas (SILVA, 2013). Seja uma variável aleatória  $Y$  que tem uma distribuição Wishart complexa escalonada com parâmetros  $L$  e  $\Sigma$ , denotada por  $Y \sim \mathcal{W}(\Sigma, L)$ . Sua função densidade de probabilidade é dada por:

$$f_Y(y; \Sigma, L) = \frac{L^q |y|^{L-q}}{|\Sigma|^L \Gamma_q(L)} \exp\{-L \text{Tr}(\Sigma^{-1}y)\}, \quad (2.7)$$

onde  $\Sigma$  é a matriz de covariância,  $q$  representa a ordem da matriz  $\Sigma$ ,  $\text{Tr}(\cdot)$  representa o traço da matriz,  $|\cdot|$  denota o determinante da matriz,  $(\cdot)^{-1}$  indica a matriz inversa e  $\Gamma_q(L)$  é a função gama multivariada para o caso complexo e é dada por:

$$\Gamma_q(L) = \pi^{q(q-1)/2} \prod_{i=0}^{q-1} \Gamma(L - i). \quad (2.8)$$

O parâmetro  $L$  é o número equivalente de *looks* que está relacionado à qualidade na modelagem de dados SAR e  $\Sigma$  é a matriz de covariância *multi-look*, que é uma matriz positiva definida hermitiana (NASCIMENTO, 2012).

Considerando que  $N$  é o número de observações independentes, o estimador de máxima verossimilhança para o parâmetro  $\Sigma$  é dado por:

$$\hat{\Sigma} = \frac{1}{N} \sum_{i=1}^N \mathbf{k}_{Bi} \mathbf{k}_{Bi}^H, \quad (2.9)$$

onde  $(\cdot)^H$  representa o transposto conjugado de um vetor. O parâmetro  $L$  não é estimado pelo método da máxima verossimilhança e neste trabalho o parâmetro é considerado conhecido.

### 2.3.3 Distribuição Par de Intensidades *multi-look*

A distribuição Par de Intensidades *multi-look*, derivada por Lee et al. (1994), é utilizada para modelar dados SAR no formato intensidade com duas polarizações distintas (SILVA, 2013). Sejam duas variáveis aleatórias  $Y_1$  e  $Y_2$  e os parâmetros  $L$ ,  $h_{11}$ ,  $h_{22}$  e  $\rho_c$ , a função densidade de probabilidade da Par de Intensidades pode ser

definida por:

$$f_{Y_1 Y_2}(y_1, y_2; L, h_{11}, h_{22}, \rho_c) = \frac{L^{L+1} (y_1 y_2)^{\frac{L-1}{2}} \exp\left\{-\frac{L(y_1/h_{11} + y_2/h_{22})}{1-|\rho_c|^2}\right\}}{(h_{11} h_{22})^{\frac{L+1}{2}} \Gamma(L) (1-|\rho_c|^2) |\rho_c|^{L-1}} I_{L-1} \left( \frac{2L|\rho_c|}{1-|\rho_c|^2} \sqrt{\frac{y_1 y_2}{h_{11} h_{22}}} \right) \quad (2.10)$$

em que  $L$  é o número equivalente de *looks*,  $h_{11} = \mathbb{E}(Y_1)$ ,  $h_{22} = \mathbb{E}(Y_2)$ ,  $\rho_c$  é o coeficiente de correlação complexo entre  $Y_1$  e  $Y_2$ , e  $I_{L-1}$  é a função modificada de Bessel de ordem  $L - 1$ . Dado  $v \in \mathbb{R}$ , uma função modificada de Bessel de ordem  $v$  é definida por:

$$I_v(y) = \frac{y^v/2}{\Gamma(v + \frac{1}{2})\Gamma(\frac{1}{2})} \int_0^\pi \cosh(y \cos \theta) \text{sen}^{2v} \theta d\theta \quad (2.11)$$

onde  $\cosh(\cdot)$ ,  $\cos(\cdot)$  e  $\text{sen}(\cdot)$  representam respectivamente as funções cosseno hiperbólico, cosseno e seno.

Neste trabalho, o parâmetro  $L$  é considerado conhecido, pois não é estimado pelo método da máxima verossimilhança. Os estimadores de máxima verossimilhança para os parâmetros  $h_{11}$  e  $h_{22}$ , considerando  $N$  o número de observações de uma amostra, são dados por:

$$\hat{h}_{11} = \frac{1}{N} \sum_{i=1}^N y_{1i}, \quad (2.12)$$

$$\hat{h}_{22} = \frac{1}{N} \sum_{i=1}^N y_{2i}. \quad (2.13)$$

O módulo do coeficiente de correlação complexo ( $|\rho_c|$ ) pode ser estimado a partir de:

$$|\rho_c|^2 = \frac{\mathbb{E}((Y_1 - h_{11})(Y_2 - h_{22}))}{\sqrt{\mathbb{E}((Y_1 - h_{11})^2)\mathbb{E}((Y_2 - h_{22})^2)}}, \quad (2.14)$$

onde  $\mathbb{E}(\cdot)$  é o operador esperança.

### 2.3.4 Distribuição Gama

A distribuição Gama é usada para modelar dados SAR monocanal no formato intensidade (TORRES, 2012). Seja uma variável aleatória  $Y$  que segue uma distribuição Gama com parâmetros  $L$  e  $\lambda$ , denotada por  $Y \sim \mathcal{G}(L, \lambda)$ . Sua função densidade de probabilidade é dada por:

$$f_Y(y; L, \lambda) = \frac{L^L}{\lambda^L \Gamma(L)} y^{L-1} \exp\left\{-\frac{Ly}{\lambda}\right\}, \quad (2.15)$$

em que  $L$  é o número equivalente de *looks*,  $\lambda = E(Y)$  e  $\Gamma$  é a função Gama de *Euler* e é dada por:

$$\Gamma(\nu + 1) = \int_{\mathbb{R}_+} t^\nu \exp\{-t\} dt, \quad (2.16)$$

$\forall \nu > -1$ .

Como  $L$  não é estimado pelo método da máxima verossimilhança, neste trabalho, o parâmetro é considerado conhecido. O estimador de máxima verossimilhança para o parâmetro  $\lambda$ , considerando  $N$  amostras independentes, é dado por:

$$\hat{\lambda} = \frac{1}{N} \sum_{i=1}^N y_i. \quad (2.17)$$

## 2.4 Medidas da Teoria da Informação

A Teoria da Informação, também conhecida como Teoria Matemática da Comunicação, é um ramo da matemática que data do final dos anos de 1940 e é responsável pelo estudo da quantificação de informação (KULLBACK, 1959). Em 1948, Claude Shannon publicou um importante artigo formalizando conceitos com aplicações na teoria da comunicação e estatística, onde as medidas de informação e entropia são os conceitos chave de sua teoria (SHANNON, 1948). A partir destes conceitos se estabeleceu a medida de entropia relativa (uma divergência) com o objetivo de mensurar o erro de se escolher uma variável quando outra seria mais ajustável às informações (KULLBACK, 1959). Posteriormente aos primeiros conceitos de entropias e divergências, iniciaram-se os estudos de classes destas medidas.

A Teoria da Informação foi desenvolvida originalmente para a codificação e com-

pressão de dados (DONOHO et al., 1998), mas tem sido utilizada em várias áreas, tais como Telecomunicações, Inferência Estatística (BLATT; HERO, 2007) e processamento de imagens (FRERY et al., 2011; NASCIMENTO et al., 2014). Para problemas de visão computacional e reconhecimento de padrões, Escolano et al. (2009) fazem uma revisão de várias aplicações de métricas de informação e divergência estatística. Nas próximas subseções serão apresentadas as principais medidas provenientes da teoria da informação, utilizadas no desenvolvimento desta Dissertação.

### 2.4.1 Métricas de divergência

As definições de divergência e distância estocástica estão diretamente relacionadas com o desenvolvimento da Teoria da Informação. Divergências estatísticas são métricas utilizadas para indicar a separabilidade entre distribuições de probabilidade e são utilizadas para a comparação de distribuições e determinar se são similares (BINDILATTI, 2014). Na literatura existe uma variedade de medidas de divergência. Csiszar (1967) desenvolveu a família de divergências  $\phi$ , que se caracteriza por um procedimento analítico formalizado que visa obter medidas de divergência a partir da escolha adequada de uma função convexa  $\phi$  satisfazendo determinadas condições. Salicru et al. (1994) propuseram uma extensão do procedimento formal desenvolvido por Csiszar (1967), ou seja, propuseram uma classe mais generalizada de divergências para unificar o estudo de diversas medidas de divergência (BINDILATTI, 2014). A inserção de uma nova função  $h$  no procedimento permitiu gerar expressões para um número muito maior de divergências conhecidas e essa família ficou conhecida como família  $h - \phi$  (SALICRU et al., 1994).

Para a definição de classe de divergência  $h - \phi$ , sejam  $\mathbf{X}$  e  $\mathbf{Y}$  matrizes aleatórias definidas sobre um mesmo domínio  $\Omega$  correspondente ao conjunto das matrizes hermetianas positivas definidas. Considere que as matrizes aleatórias possuem distribuições de probabilidade caracterizadas pelas densidades  $f_{\mathbf{X}}(y, \boldsymbol{\theta}_1)$  e  $f_{\mathbf{Y}}(y, \boldsymbol{\theta}_2)$  em que  $\boldsymbol{\theta}_1$  e  $\boldsymbol{\theta}_2$  são vetores de parâmetros. De acordo com Salicru et al. (1994) a divergência  $h - \phi$  entre  $\mathbf{X}$  e  $\mathbf{Y}$  é espessa por

$$D_{\phi}^h(\mathbf{X}, \mathbf{Y}) = h \left( \int_{y \in \Omega} \phi \left( \frac{f_{\mathbf{X}}(y, \boldsymbol{\theta}_1)}{f_{\mathbf{Y}}(y, \boldsymbol{\theta}_2)} \right) f_{\mathbf{Y}}(y, \boldsymbol{\theta}_2) dy \right), \quad (2.18)$$

em que  $\phi : (0, \infty) \rightarrow [0, \infty)$  é uma função convexa e  $h : (0, \infty) \rightarrow [0, \infty)$  é uma função estritamente crescente com  $h(0) = 0$  e  $h'(x) > 0$  para  $\forall x \in \Omega$ , em que  $h'$  representa a derivada de primeira ordem da função  $h$ . Na Tabela 2.1 são apresentadas



as funções  $h$  e  $\phi$  que geram as distâncias utilizadas neste trabalho e que são listadas na próxima Subseção.

Tabela 2.1 - Distâncias tipo  $h - \phi$  e funções  $h$  e  $\phi$  relacionadas.

Distância	$h(y)$	$\phi(x)$
<i>Bhattacharyya</i>	$-\log(-y + 1), 0 \leq y < 1$	$-\sqrt{x} + \frac{x+1}{2}$
<i>Kullback-Leibler</i>	$y/2$	$(x - 1)\log x$
<i>Hellinger</i>	$y/2, 0 \leq y < 2$	$(\sqrt{x} - 1)^2$
<i>Rényi</i> (ordem $\beta$ )	$\frac{1}{\beta-1}\log((\beta - 1)y + 1), 0 \leq y < \frac{1}{1-\beta}$	$\frac{x^{1-\beta} + x^\beta - \beta(x-1) - 2}{2(\beta-1)}, 0 < \beta < 1$
Qui-quadrado	$y/4$	$(x - 1)^2(x + 1)/x$
Triangular	$y, 0 \leq y < 2$	$(x - 1)^2/(x + 1)$

Fonte: Adaptado de Nascimento (2012).

#### 2.4.2 Distâncias estocásticas

As métricas de divergência não são necessariamente métricas de distância devido à propriedade de simetria e a desigualdade triangular não serem sempre satisfeitas (BINDILATTI, 2014). Segundo Lima (2011), uma métrica em um conjunto  $\Lambda$  é uma função  $d_\phi^h : \Lambda \times \Lambda \rightarrow \mathbb{R}$ , que associa a cada par ordenado de elementos  $\mathbf{X}, \mathbf{Y} \in \Lambda$  um número real  $d_\phi^h(\mathbf{X}, \mathbf{Y})$ , chamado de distância de  $\mathbf{X}$  a  $\mathbf{Y}$ , de modo que sejam satisfeitas as seguintes condições para quaisquer  $\mathbf{X}, \mathbf{Y}$  e  $\mathbf{Z} \in \Lambda$ :

- 1)  $d_\phi^h(\mathbf{X}, \mathbf{Y}) = 0 \Leftrightarrow \mathbf{X} = \mathbf{Y}$ ; (Definitividade)
- 2) Se  $\mathbf{X} \neq \mathbf{Y}$  então  $d_\phi^h(\mathbf{X}, \mathbf{Y}) > 0$ ; (Não-Negatividade)
- 3)  $d_\phi^h(\mathbf{X}, \mathbf{Y}) = d_\phi^h(\mathbf{Y}, \mathbf{X})$ ; (Simetria)
- 4)  $d_\phi^h(\mathbf{X}, \mathbf{Z}) \leq d_\phi^h(\mathbf{X}, \mathbf{Y}) + d_\phi^h(\mathbf{Y}, \mathbf{Z})$ . (Desigualdade triangular)

Quando a propriedade de simetria é acrescida às métricas de divergência estatística elas são consideradas distâncias estocásticas (NASCIMENTO et al., 2010). Uma solução para obtenção de distâncias a partir de divergências não simétricas é o cálculo da simetrização dado por

$$d_\phi^h(\mathbf{X}, \mathbf{Y}) = \frac{D_\phi^h(\mathbf{X}, \mathbf{Y}) + D_\phi^h(\mathbf{Y}, \mathbf{X})}{2}. \quad (2.19)$$

Distâncias estocásticas são métricas utilizadas para medir a distância entre distribuições de probabilidade, isto é, quanto maior a discrepância entre duas distribuições

de probabilidade, maior será a distância entre elas (BINDILATTI, 2014). Note que, as distâncias estocásticas entre duas distribuições de mesmo tipo passam a ser distâncias entre os parâmetros das distribuições (NASCIMENTO, 2012).

As distâncias estocásticas utilizadas neste trabalho são apresentadas nas Equações 2.20 a 2.25 (SILVA, 2013; TORRES, 2012) e, para fins de simplificação, foram omitidos o domínio de integração e a dependência da variável.

#### Distância de *Bhattacharyya*

$$d_B(X, Y) = -\log \int \sqrt{f_X f_Y} \quad (2.20)$$

#### Distância de *Kullback-Leibler*

$$d_{KL}(X, Y) = \frac{1}{2} \int (f_X - f_Y) \log \frac{f_X}{f_Y} \quad (2.21)$$

#### Distância de *Hellinger*

$$d_H(X, Y) = 1 - \int \sqrt{f_X f_Y} \quad (2.22)$$

#### Distância de *Rényi* de ordem $\beta$

$$d_R^\beta(X, Y) = \frac{1}{\beta - 1} \log \left( \frac{\int f_X^\beta f_Y^{1-\beta} + \int f_X^{1-\beta} f_Y^\beta}{2} \right) \quad (2.23)$$

com  $0 < \beta < 1$ .

#### Distância Qui-quadrado

$$d_{\chi^2}(X, Y) = \frac{1}{2} \left[ \int \frac{(f_X - f_Y)^2}{2f_X} + \frac{(f_X - f_Y)^2}{2f_Y} \right] \quad (2.24)$$

#### Distância Triangular

$$d_T(X, Y) = \int \frac{(f_X - f_Y)^2}{f_X + f_Y} \quad (2.25)$$

Theodoridis e Koutroumbas (2008) derivaram analiticamente as distâncias de *Bhattacharyya* e *Kullback-Leibler* entre distribuições Gaussianas multivariadas. Da mesma forma, Nascimento (2012) desenvolveu cinco expressões fechadas para distâncias entre distribuições Wishart complexas escalonadas: *Bhattacharyya*, *Kullback-Leibler*, *Hellinger*, *Rényi* de ordem  $\beta$  e Qui-quadrado. Torres (2012) derivou para a distribuição Gama as distâncias *Bhattacharyya*, *Kullback-Leibler*, *Rényi* de ordem  $\beta$  e *Hellinger*. As expressões obtidas para as distâncias estocásticas correspondentes são apresentadas nas Equações 2.26 a 2.36. Para a distância Triangular entre distribuições Par de Intensidades *multi-look*, não foi encontrado na literatura pelo autor uma expressão analítica fechada.

As expressões para o cálculo das distâncias de *Bhattacharyya* e *Kullback-Leibler* entre distribuições Gaussianas multivariadas  $\mathcal{N}(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_1)$  e  $\mathcal{N}(\boldsymbol{\mu}_2, \boldsymbol{\Sigma}_2)$ , desenvolvidas por Theodoridis e Koutroumbas (2008), são apresentadas nas Equações 2.26 e 2.27.

$$d_{GB}(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_1, \boldsymbol{\mu}_2, \boldsymbol{\Sigma}_2) = \frac{1}{8} \left[ (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^T \left( \frac{(\boldsymbol{\Sigma}_1 + \boldsymbol{\Sigma}_2)^{-1}}{2} \right) (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2) \right] + \frac{1}{2} \log \frac{|\frac{\boldsymbol{\Sigma}_1 + \boldsymbol{\Sigma}_2}{2}|}{\sqrt{|\boldsymbol{\Sigma}_1| |\boldsymbol{\Sigma}_2|}} \quad (2.26)$$

$$d_{GKL}(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_1, \boldsymbol{\mu}_2, \boldsymbol{\Sigma}_2) = \frac{1}{2} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^T (\boldsymbol{\Sigma}_1^{-1} + \boldsymbol{\Sigma}_2^{-1}) (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2) + \frac{1}{2} \text{Tr}(\boldsymbol{\Sigma}_1^{-1} \boldsymbol{\Sigma}_2 + \boldsymbol{\Sigma}_2^{-1} \boldsymbol{\Sigma}_1 - 2\mathbb{I}_q) \quad (2.27)$$

em que  $\mathbb{I}_q$  é a matriz identidade de ordem  $q$ ,  $\text{Tr}(\cdot)$  é o traço da matriz,  $(\cdot)^{-1}$  representa a inversa da matriz,  $|\cdot|$  indica o determinante da matriz e  $(\cdot)^T$  representa a transposta da matriz.

As expressões para o cálculo das distâncias de *Bhattacharyya*, *Kullback-Leibler*, *Hellinger*, *Rényi* de ordem  $\beta$  e Qui-quadrado entre distribuições Wishart complexas escalonadas  $\mathcal{W}(\boldsymbol{\Sigma}_1)$  e  $\mathcal{W}(\boldsymbol{\Sigma}_2)$ , desenvolvidas por Nascimento (2012), são apresentadas nas Equações 2.28 a 2.32.

$$d_{WB}(\boldsymbol{\Sigma}_1, \boldsymbol{\Sigma}_2) = L \left[ \frac{\log|\boldsymbol{\Sigma}_1| + \log|\boldsymbol{\Sigma}_2|}{2} - \log \left| \left( \frac{\boldsymbol{\Sigma}_1^{-1} + \boldsymbol{\Sigma}_2^{-1}}{2} \right)^{-1} \right| \right] \quad (2.28)$$

$$d_{WKL}(\Sigma_1, \Sigma_2) = L \left[ \frac{\text{Tr}(\Sigma_1^{-1}\Sigma_2 + \Sigma_2^{-1}\Sigma_1)}{2} - q \right] \quad (2.29)$$

$$d_{WH}(\Sigma_1, \Sigma_2) = 1 - \left[ \frac{|(2^{-1}(\Sigma_1^{-1} + \Sigma_2^{-1}))^{-1}|}{\sqrt{|\Sigma_1||\Sigma_2|}} \right]^L \quad (2.30)$$

$$\begin{aligned} d_{WR}^\beta(\Sigma_1, \Sigma_2) = \frac{\log 2}{1-\beta} + \frac{1}{\beta-1} \log \{ & [|\Sigma_1|^{-\beta} |\Sigma_2|^{\beta-1} |(\beta \Sigma_1^{-1} + (1-\beta)\Sigma_2^{-1})^{-1}|]^L \\ & + [|\Sigma_1|^{\beta-1} |\Sigma_2|^{-\beta} |(\beta \Sigma_2^{-1} + (1-\beta)\Sigma_1^{-1})^{-1}|]^L \} \end{aligned} \quad (2.31)$$

$$\begin{aligned} d_{W\chi^2} = \frac{1}{4} \left[ \left( \frac{|\Sigma_1|}{|\Sigma_2|^2} \text{abs}(|(2\Sigma_2^{-1} - \Sigma_1^{-1})^{-1}|) \right)^L \right. \\ \left. + \left( \frac{|\Sigma_2|}{|\Sigma_1|^2} \text{abs}(|(2\Sigma_1^{-1} - \Sigma_2^{-1})^{-1}|) \right)^L - 2 \right] \end{aligned} \quad (2.32)$$

em que  $\text{abs}(\cdot)$  denota o valor absoluto e  $q$  é a ordem das matrizes  $\Sigma_1$  e  $\Sigma_2$ .

As expressões para o cálculo das distâncias de *Bhattacharyya*, *Kullback-Leibler*, *Heltinger* e *Rényi* de ordem  $\beta$  entre distribuições Gama  $\mathcal{G}(\lambda_1)$  e  $\mathcal{G}(\lambda_2)$ , desenvolvidas por Torres (2012), são apresentadas nas Equações 2.33 a 2.36.

$$d_{GB}(\lambda_1, \lambda_2) = \log \left( \frac{(\lambda_1 + \lambda_2)^L}{2^L (\lambda_1 \lambda_2)^{(L/2)}} \right) \quad (2.33)$$

$$d_{GKL}(\lambda_1, \lambda_2) = L \left( \frac{\lambda_1^2 + \lambda_2^2}{2\lambda_1\lambda_2} - 1 \right) \quad (2.34)$$

$$d_{GH}(\lambda_1, \lambda_2) = 1 - \left( \frac{(2^L (\lambda_1 \lambda_2)^{L/2}}{(\lambda_1 + \lambda_2)^L} \right) \quad (2.35)$$

$$d_{GR}^\beta(\lambda_1, \lambda_2) = \frac{L}{2(\beta-1)} \log \frac{\lambda_1 \lambda_2}{(\beta \lambda_2 + (1-\beta)\lambda_1)(\beta \lambda_1 + (1-\beta)\lambda_2)} \quad (2.36)$$

Note que  $L_1 = L_2$ , pois em uma classificação supervisionada por regiões são comparados os segmentos da imagem e amostras das classes extraídas da mesma imagem. As expressões até aqui citadas para o cálculo das distâncias entre distribuições Gaussianas multivariadas, distribuições Wishart complexas escalonadas e distribuições Gama foram obtidas por meio de soluções analíticas. Para o cálculo de dissimilaridade entre distribuições Par de Intensidades *multi-look* (Equação 2.10) não há na literatura, até onde o autor tenha conhecimento, expressão analítica fechada. Dessa forma, os cálculos das distâncias entre distribuições Par de Intensidades devem ser realizados por meio de soluções numéricas.

### 2.4.3 Estatísticas de testes de hipótese

Segundo Torres (2012), distâncias estocásticas podem ser convenientemente dimensionadas para apresentar boas propriedades estatísticas, que as tornam estatísticas de testes. Sejam, então,  $\boldsymbol{\theta}_1$  e  $\boldsymbol{\theta}_2$  vetores de parâmetros e suponha que se deseja testar a hipótese de igualdade entre estes vetores. Com base no desenvolvimento proposto por Salicru et al. (1994), a estatística de teste é dada pela formulação descrita a seguir.

Sejam  $\hat{\boldsymbol{\theta}}_1 = (\hat{\theta}_{11}, \dots, \hat{\theta}_{1M})$  e  $\hat{\boldsymbol{\theta}}_2 = (\hat{\theta}_{21}, \dots, \hat{\theta}_{2M})$  estimadores de máxima verossimilhança de  $\boldsymbol{\theta}_1$  e  $\boldsymbol{\theta}_2$ , baseados em amostras independentes  $m$  e  $n$ , respectivamente, e  $M$  o número de parâmetros. Sob a hipótese nula  $H_0 : \boldsymbol{\theta}_1 = \boldsymbol{\theta}_2$  e a hipótese alternativa  $H_1 : \boldsymbol{\theta}_1 \neq \boldsymbol{\theta}_2$ , a estatística de teste de hipótese  $S_\phi^h$  é dada por:

$$S_\phi^h(\hat{\boldsymbol{\theta}}_1, \hat{\boldsymbol{\theta}}_2) = \frac{2mn\nu}{m+n} d_\phi^h(\hat{\boldsymbol{\theta}}_1, \hat{\boldsymbol{\theta}}_2). \quad (2.37)$$

onde  $\nu$  é uma constante que depende das funções  $h$  e  $\phi$ , específicas para a distância estocástica utilizada, e é dada por:

$$\nu = \frac{1}{h'(0)\phi''(1)} \quad (2.38)$$

em que  $h'$  é a derivada de primeira ordem de  $h$  e  $\phi''$  é a derivada de segunda ordem de  $\phi$ . Na Tabela 2.2 são apresentados os valores da constante  $\nu$  (calculadas utilizando a Equação 2.38 e as funções da Tabela 2.1) referentes às distâncias utilizadas neste trabalho.

Tabela 2.2 - Distâncias e constantes  $\nu$ .

Distâncias	$\nu$
<i>Bhattacharyya</i>	4
<i>Kullback-Leibler</i>	1
<i>Hellinger</i>	4
<i>Rényi</i> (ordem $\beta$ )	$1/\beta$
Qui-quadrado	1
Triangular	1

Fonte: Produção do autor.

A estatística de teste distribui-se assintoticamente como uma lei Qui-quadrado com grau de liberdade  $M$ , então

$$\frac{2mn\nu}{m+n} d_{\phi}^h(\hat{\boldsymbol{\theta}}_1, \hat{\boldsymbol{\theta}}_2) \xrightarrow{D} \mathcal{X}_M^2, \quad (2.39)$$

em que  $\xrightarrow{D}$  denota convergência em distribuição,  $\mathcal{X}_M^2$  é a distribuição Qui-quadrado e  $M$  a dimensão de  $\boldsymbol{\theta}_i$  ( $i = 1, 2$ ).

Para valores suficientemente grandes de  $m$  e  $n$  e  $S_{\phi}^h(\hat{\boldsymbol{\theta}}_1, \hat{\boldsymbol{\theta}}_2) = s$ , a hipótese nula  $H_0 : \boldsymbol{\theta}_1 = \boldsymbol{\theta}_2$  pode ser rejeitada ao nível de significância  $\eta$  se  $\Pr(\mathcal{X}_M^2 > s) \leq \eta$  (SILVA, 2013). Mais detalhes podem ser encontrados em Salicru et al. (1994).

As estatísticas de teste correspondentes às distâncias de *Bhattacharyya* (2.26) e *Kullback-Leibler* (2.27) entre distribuições Gaussianas multivariadas, desenvolvidas em Nascimento (2012), são apresentadas nas Equações 2.40 e 2.41.

$$S_{GB} = \frac{mn}{m+n} \left[ (\hat{\boldsymbol{\mu}}_1 - \hat{\boldsymbol{\mu}}_2)^T \left( \frac{\hat{\boldsymbol{\Sigma}}_1 + \hat{\boldsymbol{\Sigma}}_2}{2} \right)^{-1} (\hat{\boldsymbol{\mu}}_1 - \hat{\boldsymbol{\mu}}_2) + 4 \log \frac{\left| \frac{\hat{\boldsymbol{\Sigma}}_1 + \hat{\boldsymbol{\Sigma}}_2}{2} \right|}{\sqrt{|\hat{\boldsymbol{\Sigma}}_1| |\hat{\boldsymbol{\Sigma}}_2|}} \right] \quad (2.40)$$

$$S_{GKL} = \frac{mn}{m+n} [(\hat{\boldsymbol{\mu}}_1 - \hat{\boldsymbol{\mu}}_2)^T (\hat{\boldsymbol{\Sigma}}_1^{-1} + \hat{\boldsymbol{\Sigma}}_2^{-1}) (\hat{\boldsymbol{\mu}}_1 - \hat{\boldsymbol{\mu}}_2) + \text{Tr}(\hat{\boldsymbol{\Sigma}}_1^{-1} \hat{\boldsymbol{\Sigma}}_2 + \hat{\boldsymbol{\Sigma}}_2^{-1} \hat{\boldsymbol{\Sigma}}_1 - 2\mathbb{I}_q)] \quad (2.41)$$

As estatísticas de teste correspondentes às distâncias de *Bhattacharyya* (2.28),

*Kullback-Leibler* (2.29), *Hellinger* (2.30), *Rényi* de ordem  $\beta$  (2.31) e Qui-quadrado (2.32) entre distribuições Wishart complexa escalonada, desenvolvidas em Nascimento (2012), são apresentadas nas Equações 2.42 a 2.46.

$$S_{WB} = \frac{8mn}{m+n} L \left[ \frac{\log|\widehat{\Sigma}_1| + |\widehat{\Sigma}_2|}{2} - \log \left| \left( \frac{\widehat{\Sigma}_1^{-1} + \widehat{\Sigma}_2^{-1}}{2} \right)^{-1} \right| \right] \quad (2.42)$$

$$S_{WKL} = \frac{2mn}{m+n} L \left[ \frac{\text{Tr}(\widehat{\Sigma}_1^{-1} \widehat{\Sigma}_2 + \widehat{\Sigma}_2^{-1} \widehat{\Sigma}_1)}{2} - q \right] \quad (2.43)$$

$$S_{WH} = \frac{8mn}{m+n} \left\{ 1 - \left[ \frac{|2^{-1}(\widehat{\Sigma}_1^{-1} + \widehat{\Sigma}_2^{-1})^{-1}|}{\sqrt{|\widehat{\Sigma}_1| |\widehat{\Sigma}_2|}} \right]^L \right\} \quad (2.44)$$

$$S_{WR}^\beta = \frac{2mn}{\beta(m+n)} \left\{ \frac{\log 2}{1-\beta} + \frac{1}{\beta-1} \log \left\{ [|\widehat{\Sigma}_1|^{-\beta} |\widehat{\Sigma}_2|^{\beta-1} |(\beta \widehat{\Sigma}_1^{-1} + (1-\beta) \widehat{\Sigma}_2^{-1})^{-1}|]^{-1} + [|\widehat{\Sigma}_1|^{\beta-1} |\widehat{\Sigma}_2|^\beta |(\beta \widehat{\Sigma}_2^{-1} + (1-\beta) \widehat{\Sigma}_1^{-1})^{-1}|]^{-1} \right\} \right\} \quad (2.45)$$

$$S_{W\chi^2} = \frac{mn}{2(m+n)} \left[ \left( \frac{|\widehat{\Sigma}_1|}{|\widehat{\Sigma}_2|^2} \text{abs}(|(2\widehat{\Sigma}_2^{-1} - \widehat{\Sigma}_1^{-1})^{-1}|) \right)^L + \left( \frac{|\widehat{\Sigma}_2|}{|\widehat{\Sigma}_1|^2} \text{abs}(|(2\widehat{\Sigma}_1^{-1} - \widehat{\Sigma}_2^{-1})^{-1}|) \right)^L - 2 \right] \quad (2.46)$$

As estatísticas de teste correspondentes às distâncias de *Bhattacharyya* (2.33), *Kullback-Leibler* (2.34), *Hellinger* (2.35) e *Rényi* de ordem  $\beta$  (2.36) entre distribuições Gama, desenvolvidas em TORRES (2012), são apresentadas nas Equações 2.47 a 2.50.

$$S_{GB} = \frac{4mn}{m+n} 2L \log \frac{\widehat{\lambda}_1 + \widehat{\lambda}_2}{2\sqrt{\widehat{\lambda}_1 \widehat{\lambda}_2}} \quad (2.47)$$

$$S_{\mathcal{G}KL} = \frac{2mnL}{m+n} \left( \frac{\hat{\lambda}_1^2 + \hat{\lambda}_2^2}{2\hat{\lambda}_1\hat{\lambda}_2} - 1 \right) \quad (2.48)$$

$$S_{\mathcal{G}H} = \frac{8mn}{m+n} \left( 1 - \frac{2^L(\hat{\lambda}_1\hat{\lambda}_2)^{L/2}}{(\hat{\lambda}_1 + \hat{\lambda}_2)^L} \right) \quad (2.49)$$

$$S_{\mathcal{G}R}^\beta = \frac{4mnL\beta(\beta-1)}{m+n} \log \frac{\hat{\lambda}_1\hat{\lambda}_2}{(\beta\hat{\lambda}_2 + (1-\beta)\hat{\lambda}_1)(\beta\hat{\lambda}_1 + (1-\beta)\hat{\lambda}_2)} \quad (2.50)$$

Nas últimas seções foram apresentados os conceitos para entendimento da metodologia implementada nesta Dissertação. Nas próximas seções são descritas as técnicas de classificação de imagens que utilizam esses conceitos.

## 2.5 Classificação de imagens por regiões

Embora métodos distintos de classificação de imagens tenham surgido, geralmente as técnicas podem ser divididas em dois grupos: pontual e por região. O classificador é pontual quando a classificação é feita pixel a pixel, portanto, utiliza-se a informação de cada pixel isolado. A classificação pontual também pode ser contextual, que classifica cada pixel, no entanto, utiliza também a informação de um contexto ao redor do pixel. O classificador por região realiza a classificação em um conjunto de pixels (região), ou seja, um agrupamento de pixels é selecionado e usado como unidade de classificação, ao invés de pixels isolados.

Tradicionalmente, a classificação pontual é utilizada devido à sua eficiência. Contudo, métodos baseados em região têm sido utilizados para a classificação de imagens de sensores de alta resolução (*high-resolution* - HR) e de altíssima resolução (*very high resolution* - VHR) e também de imagens provenientes de radares de abertura sintética. A classificação por região tem sido usada nas imagens obtidas pelos sensores HR e VHR devido ao alto grau de detalhe dessas imagens que evidencia as variações espectrais entre os objetos e tornam visíveis os contornos dos objetos (BERNARDI, 2007). Para as imagens SAR, a técnica tem sido utilizada porque o ruído *speckle* (aspecto de granulação característico nesse tipo de imagem) afeta na classificação pixel a pixel (WU et al., 2008). Além disso, a classificação por regiões pode alcançar melhores resultados se comparada aos classificadores pontuais (SILVA et al., ).

Uma das abordagens de classificação por regiões adota distâncias estocásticas entre



as distribuições que modelam regiões nas imagens e as distribuições que modelam as amostras que representam as classes de interesse. Para o caso da classificação por regiões supervisionada, a atribuição de uma classe aos segmentos ocorre pela menor distância entre os modelos estatísticos que representam os segmentos e aqueles que representam as amostras das classes (SILVA, 2013). Na próxima Seção são descritas as técnicas de classificação por regiões, supervisionadas e derivadas da Teoria da Informação utilizadas neste trabalho.

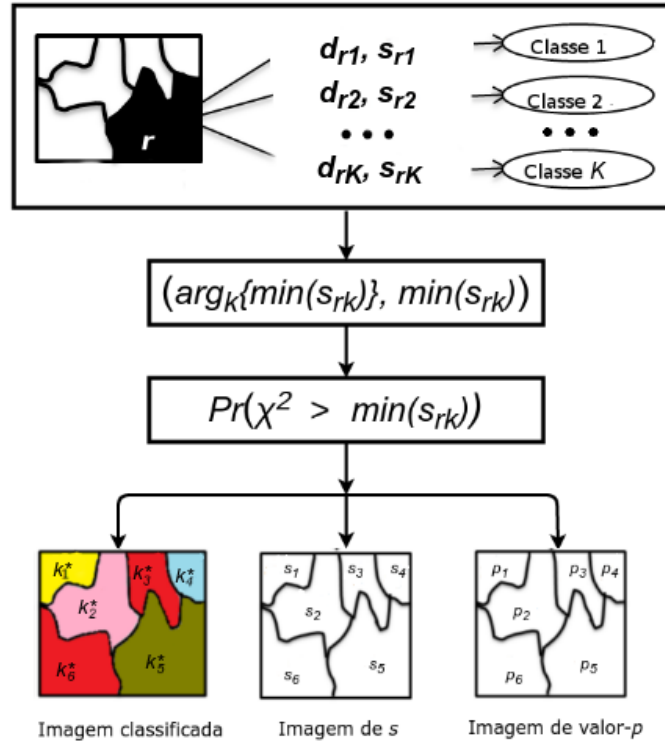
## 2.6 Teoria da informação e a classificação de imagens

O interesse em se utilizar ferramentas da Teoria da Informação no processamento de imagens tem crescido (NASCIMENTO, 2012). Na literatura existem diferentes contextos de aplicação de medidas de divergência e distâncias estocásticas, como em análise de contraste em imagens PolSAR (FRERY et al., 2011), filtros para imagens SAR (TORRES et al., 2014), detecção de borda (NASCIMENTO et al., 2014) e segmentação (SALDANHA et al., 2013). Para a classificação de imagens, na literatura são encontrados dois exemplos de técnicas desenvolvidas por Silva (2013) e Braga (2016) derivadas de conceitos da Teoria da Informação baseadas em distâncias estocásticas. A primeira é denominada, neste trabalho, como classificação monofonte e a segunda como classificação multifontes e nas próximas subseções, 2.6.1 e 2.6.2, são apresentadas as metodologias dessas técnicas.

### 2.6.1 Classificador monofonte por regiões baseado em distâncias estocásticas e estatísticas de teste de hipóteses

Diante dos últimos avanços no processamento e análise de imagens decorrentes da Teoria da Informação, Silva (2013) desenvolveu um classificador por regiões supervisionado baseado em distâncias estocásticas e testes de hipótese, denominado *PolClass*. Nesse classificador a atribuição dos segmentos a uma dada classe é feita pela estatística de teste e não pela distância. Além de uma classificação, mapas de confiabilidade da classificação são gerados através das estatísticas de teste e dos valores- $p$  associados a estas estatísticas. O classificador foi desenvolvido para tratar imagens ópticas e de radar. Funções densidade de probabilidade Gaussiana multivariada, Wishart complexa escalonada e Par de Intensidades *multi-look* foram utilizadas, permitindo uma modelagem adequada aos tipos de dados. A metodologia do classificador é apresentada na Figura 2.1 e sua explicação é feita a seguir.

Figura 2.1 - Metodologia do classificador por regiões baseado em distâncias estocásticas.



Dadas  $K$  classes e uma imagem com  $R$  segmentos, calcula-se entre cada segmento  $r$  e classe  $k$  a distância estocástica  $d_{rk}$  e a estatística de teste  $s_{rk}$ . A partir das  $R \times K$  estatísticas de teste calculadas, define-se para cada região  $r$  a menor estatística  $s_r = \min_k \{s_{rk}\}$  e sua classe correspondente  $k_r^* = \arg_k \{ \min_k \{s_{rk}\} \}$ . Computa-se também para essa menor estatística o valor- $p$ , dado por  $p_r = \Pr(\chi^2_M > s_r)$ . Geram-se as imagens de classificação, possibilidade e probabilidade com as espacializações de  $k_r^*$ ,  $s_r$  e  $p_r$ , respectivamente.

Fonte: Adaptado de Braga (2016).

Suponha uma imagem com  $R$  segmentos disjuntos e que para cada segmento exista um vetor de parâmetros  $\theta_r$  estimado pelo método de máxima verossimilhança  $\hat{\theta}_r$ , em que  $1 \leq r \leq R$ . Suponha também  $K$  classes de interesse e que para cada classe exista um vetor de parâmetros  $\hat{\theta}_k$  estimado pelo mesmo método, em que  $1 \leq k \leq K$ .

Para verificação da hipótese nula  $H_0 : \hat{\theta}_r = \hat{\theta}_k$ , calcula-se a distância estocástica (representada por  $d_{rk}$ ) entre cada segmento  $r$  e cada classe  $k$ . Portanto, no total são calculadas  $R \times K$  distâncias estocásticas. Calcula-se também as estatísticas de teste  $S_\phi^h(\hat{\theta}_r, \hat{\theta}_k)$ . Para cada distância estocástica calcula-se uma estatística de teste (representada por  $s_{rk}$ ) pela equação 2.51.

$$s_{rk} = \frac{2m_r n_k \nu}{m_r + n_k} d_{rk}, \quad (2.51)$$

onde  $\nu$  é uma constante referente às funções  $h$  e  $\phi$  da distância estocástica utilizada e  $m_r$  e  $n_k$  representam o número de amostras independentes da região  $r$  e da classe  $k$ , respectivamente. Portanto, totalizam-se também  $R \times K$  estatísticas de teste calculadas.

A classificação é obtida por meio da menor estatística de teste, onde se rotula o segmento  $r$  com a  $j$ -ésima classe se

$$S_\phi^h(\hat{\theta}_r, \hat{\theta}_j) < S_\phi^h(\hat{\theta}_r, \hat{\theta}_k), \quad (2.52)$$

$\forall j \neq k$ . Uma vez que o segmento  $r$  foi classificado com a classe  $k$ , o valor- $p$  do teste de hipóteses é calculado por

$$p_{rk} = \Pr(\chi_M^2 > s_{rk}), \quad (2.53)$$

em que  $M$  corresponde ao número de parâmetros estimados na função densidade de probabilidade considerada.

Nesta metodologia de classificação, portanto, define-se para cada região  $r$  o vetor de classificação

$$C_r = (k_r^*, s_r, p_r), \quad (2.54)$$

onde  $s_r = \min_k \{s_{rk}\}$ ,  $p_r = \Pr(\chi_M^2 > s_r)$  e  $k_r^* = \arg_k \{ \min_k \{s_{rk}\} \}$ , ou seja,  $k_r^*$  é a classe que possui a menor estatística de teste  $s_r$  para o segmento  $r$ . A imagem de classificação é constituída pelos valores de  $k_r^*$  e as imagens de confiabilidade da classificação são compostas pelos valores de  $s_r$  e  $p_r$ . Estas duas últimas indicam a confiabilidade de uma determinada classe ser atribuída a uma região na imagem.

Como  $s_r$  e  $p_r$  são grandezas inversamente relacionadas, a imagem de confiabilidade pode ser formada tanto pela mínima estatística de teste de hipótese quanto pelo valor- $p$  correspondente à mínima estatística. Uma imagem de confiabilidade formada pelas mínimas estatísticas de teste refere-se a uma imagem de possibilidades e uma

imagem composta por valores- $p$  trata-se de uma imagem de probabilidades (BRAGA, 2016).

Esta metodologia de classificação leva em consideração a correlação espacial entre os dados, que é um efeito inerente à formação das imagens. Dessa maneira, dois valores devem ser definidos como os parâmetros de autocorrelação entre pixels da imagem que distam entre si de um certo valor de *lag* (espacial) nas direções vertical e horizontal (SILVA, 2013). Silva (2013) também desenvolveu uma plataforma computacional para este classificador e utilizou a linguagem de programação *Interactive Data Language* (IDL) (EXELIS, 2010), que não é código aberto.

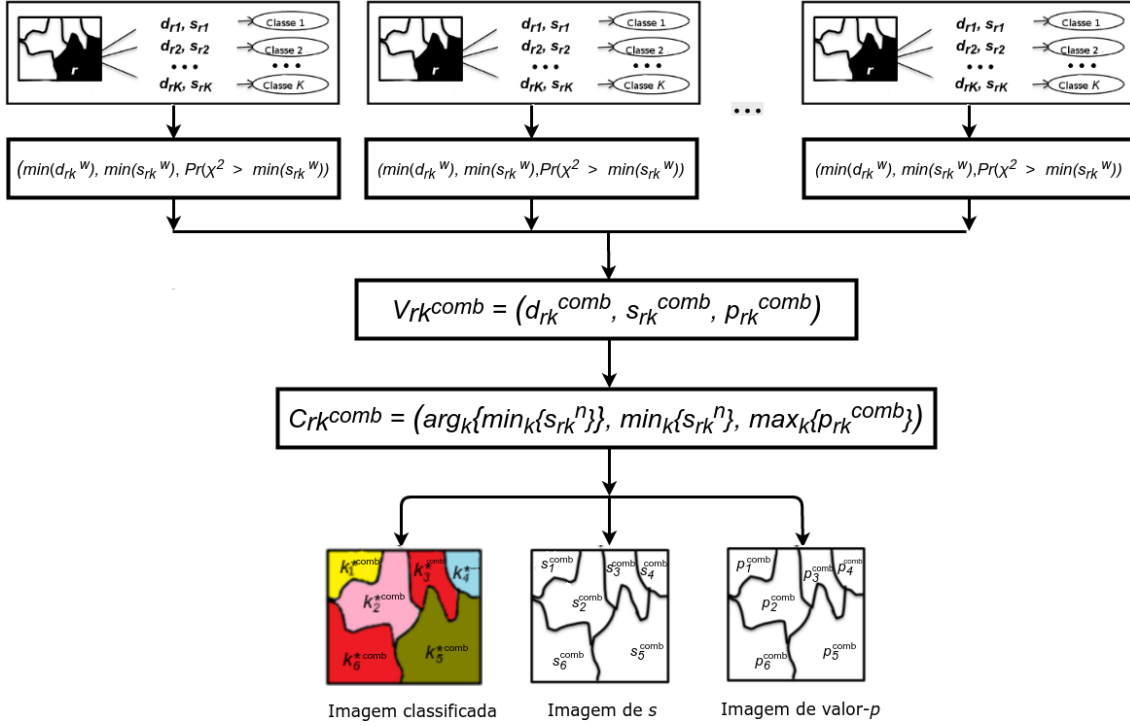
### 2.6.2 Classificador multifontes por regiões baseado em distâncias estocásticas e testes de hipóteses associados

As técnicas de classificação multifontes se diferem na maneira de realizar a integração dos dados (SHEORAN; HAACK, 2014; PEREIRA, 2012). Diferentes métodos de fusão e empilhamento, por exemplo, foram discutidos na Seção 2.1. Em Braga (2016) foi proposta uma metodologia de classificação multifontes inédita na literatura no sentido que se propõe o cálculo das distâncias (e respectivas estatísticas de teste) entre funções densidades de probabilidade (*f.d.p.*'s) multivariadas (distância conjunta), em função das distâncias entre as *f.d.p.*'s relativas a cada um dos modelos adotados para os dados de cada sensor (distâncias marginais). A metodologia multifonte de classificação por regiões supervisionada baseada em distâncias estocásticas e testes de hipóteses é apresentada na Figura 2.2.

Suponha  $W$  imagens diferentes provenientes de  $W$  sensores distintos e supostamente independentes com  $R$  segmentos disjuntos. Considera-se que as  $W$  imagens correspondem a uma mesma região da superfície terrestre e estão corregradas entre si. Suponha também que há  $K$  classes de interesse.

A partir de cada imagem  $w$ , onde  $1 \leq w \leq W$ , gera-se os planos de informação que contêm os atributos necessários para construção da classificação multifonte. A origem dos planos segue a mesma metodologia adotada para obtenção das distâncias estocásticas, estatísticas de teste e probabilidades, descrita na Seção 2.6.1. Isso quer dizer que, para cada imagem  $w$ , são gerados  $3 \times K$  planos de informação. Fixada a imagem  $w$ , para cada região  $r$  ( $1 \leq r \leq R$ ) são gerados em relação a cada classe  $k$  ( $1 \leq k \leq K$ ) três planos de informação relativos aos valores calculados de distância estocástica ( $d_{rk}^w$ ), estatística de teste ( $s_{rk}^w$ ) e probabilidade ( $p_{rk}^w$ ).

Figura 2.2 - Metodologia do classificador multifontes baseado em distâncias estocásticas.



Dadas  $K$  classes e  $W$  imagens de sensores distintos, para cada imagem  $w$  calcula-se os atributos conforme mostrado na metodologia descrita em 2.6.1. A combinação dos planos de informação gerados para cada imagem é feita através de alguma função matemática. Geram-se os vetores de combinação  $V_{rk}^{comb} = (d_{rk}^{comb}, s_{rk}^{comb}, p_{rk}^{comb})$ , onde  $d_{rk}^{comb}$ ,  $s_{rk}^{comb}$  e  $p_{rk}^{comb}$  são, respectivamente, a distância estocástica, estatística de teste e  $p$ -valor calculado entre o segmento  $r$  e classe  $k$ . A partir destes vetores, define-se o vetor de classificação  $C_r^{comb} = (k_r^{comb}, s_r^{comb}, p_r^{comb})$ , em que  $s_r^{comb} = \min_k\{s_{rk}^n\}$ ,  $p_r^{comb} = \max_k\{p_{rk}^{comb}\}$  e  $k_r^{comb} = \arg_k\{\min_k\{s_{rk}^n\}\}$ . As imagens de classificação, possibilidades e probabilidades são geradas pelas espacializações de  $k_r^{comb}$ ,  $s_r^{comb}$  e  $p_r^{comb}$ , nesta ordem.

Fonte: Adaptado de Braga (2016).

A classificação consiste na combinação entre os valores contidos nos planos de informação gerados para cada imagem. A combinação das informações provenientes dos diferentes sensores se dá com uso de operações matemáticas, tais como a soma entre as estatísticas de teste, o mínimo do produto entre as estatísticas de teste, o produto dos mínimos entre as estatísticas de teste ou outra combinação de funções matemáticas das estatísticas que seja diferente das apresentadas. Uma combinação pode envolver a lógica *Fuzzy*, onde todos os resultados individuais de classificação podem ser considerados.

Inicialmente são formados os vetores de atributos para cada segmento  $r$  e classe  $k$  dados por

$$V_{rk}^{comb} = (d_{rk}^{comb}, s_{rk}^{comb}, p_{rk}^{comb}), \quad (2.55)$$

onde  $d_{rk}^{comb}$  representa as distâncias;  $s_{rk}^{comb}$  e  $p_{rk}^{comb}$  são, respectivamente, os valores das estatísticas e probabilidades gerados pela operação matemática usada na combinação dos planos de informação. Por intermédio dos vetores de atributos, definem-se os vetores de classificação do segmento  $r$  como

$$C_r^{comb} = (k_r^{comb}, s_r^{comb}, p_r^{comb}), \quad (2.56)$$

em que  $s_r^{comb} = \min_k \{s_{rk}^n\}$ ,  $s_{rk}^n$  representa o valor normalizado de  $s_{rk}^{comb}$  dado por uma função de normalização, o valor- $p$  é dado por  $p_r^{comb} = \max_k \{p_{rk}^{comb}\}$  e  $k_r^{comb} = \arg_k \{ \min_k \{s_{rk}^n\} \}$ .  $k_r^{comb}$  é a classe que possui a menor estatística de teste  $s_r^{comb}$  para o segmento  $r$ . A imagem de classificação é constituída pelos valores de  $k_r^{comb}$  e as imagens de confiabilidade da classificação são compostas pelos valores de  $s_r^{comb}$  e  $p_r^{comb}$ .

Em Braga (2016), as análises realizadas sobre os resultados de classificação obtidos mostraram que esta metodologia de classificação multifonte é viável e efetiva para a melhora de classificações. Com esta metodologia é possível obter resultados de classificação por regiões com melhores índices de acurácia do que os apresentados por classificações individuais.

Uma limitação desta metodologia de classificação multifontes se refere às resoluções espaciais das imagens de entrada. Não é necessário que as imagens de entrada possuam a mesma resolução, pois os pixels das imagens são reamostrados para um valor definido no processo de correção. Contudo, imagens com resoluções espaciais muito diferentes podem prejudicar os resultados de classificação (BRAGA, 2016).

Outro ponto importante, esta metodologia desenvolvida em Braga (2016), está em um plano abstrato, pois, não foi desenvolvida uma plataforma computacional. Para a geração de resultados foram utilizados o PolClass e outros algoritmos implementados em IDL, portanto, geraram-se implementações não intuitivas e de alta complexidade.

Neste capítulo, apresentaram-se os conceitos necessários para a compreensão desta

Dissertação. Descreveram-se trabalhos relevantes sobre a integração de imagens, bem como uma classificação de algoritmos que realizam esta tarefa. Descreveu-se brevemente os tipos de dados oriundos de sensores remotos ópticos e de micro-ondas, abordaram-se suas modelagens e foram descritas as quatro distribuições usadas para o tratamento destes dados, a saber: Gaussiana multivariada, Wishart complexa escalonada, Par de Intensidades *multi-look* e Gama. Definiram-se as expressões para os cálculos das distâncias estocásticas e para as expressões de suas respectivas estatísticas de teste de hipóteses. Por fim, descreveram-se duas técnicas de classificação derivadas de conceitos da Teoria da Informação. Os métodos são supervisionados e baseados por regiões. A primeira técnica trata-se de um classificador monofonte em que, de forma geral, uma única *f.d.p* é usada para modelar os dados das imagens e amostras das classes para que as distâncias estocásticas sejam calculadas entre as distribuições. O segundo método consiste em uma classificação multifontes que permite que sejam utilizados dados de vários sensores, com *f.d.p*'s diferentes. Nesta metodologia o cálculo de distâncias é realizado entre *f.d.p*'s multivariadas, em função das distâncias entre as *f.d.p*'s marginais. Nos próximos capítulos são apresentadas a metodologia de desenvolvimento do sistema de classificação, as etapas de implementação do sistema computacional e os resultados, juntamente com as análises de sua aplicação.





### 3 METODOLOGIA

Neste capítulo é descrito o sistema de classificação mono e multifontes desenvolvido para as metodologias que utilizam distâncias estocásticas e testes de hipótese propostas em Silva (2013) e Braga (2016). O classificador foi implementado na linguagem de programação C++ e o suporte no código para o processamento dos dados geoespaciais foi dado pela TerraLib (CÂMARA et al., 2010), uma biblioteca aberta de classes e métodos escrita em C++ e multi-plataforma (MacOS, Windows e Linux). A biblioteca TerraLib é projetada, implementada e mantida pela Divisão de Processamento de Imagem (DPI) do INPE e pela FUNCATE (Fundação de Ciência, Aplicações e Tecnologia Espaciais). A biblioteca fornece um conjunto de funcionalidades para manipulação de dados raster e vetoriais e uma variedade de algoritmos de processamento de imagens. A metodologia de desenvolvimento e implementação é apresentada conforme o diagrama de blocos da Figura 3.1 e a seguir os componentes do diagrama são explicados.

#### 3.1 Dados de Entrada

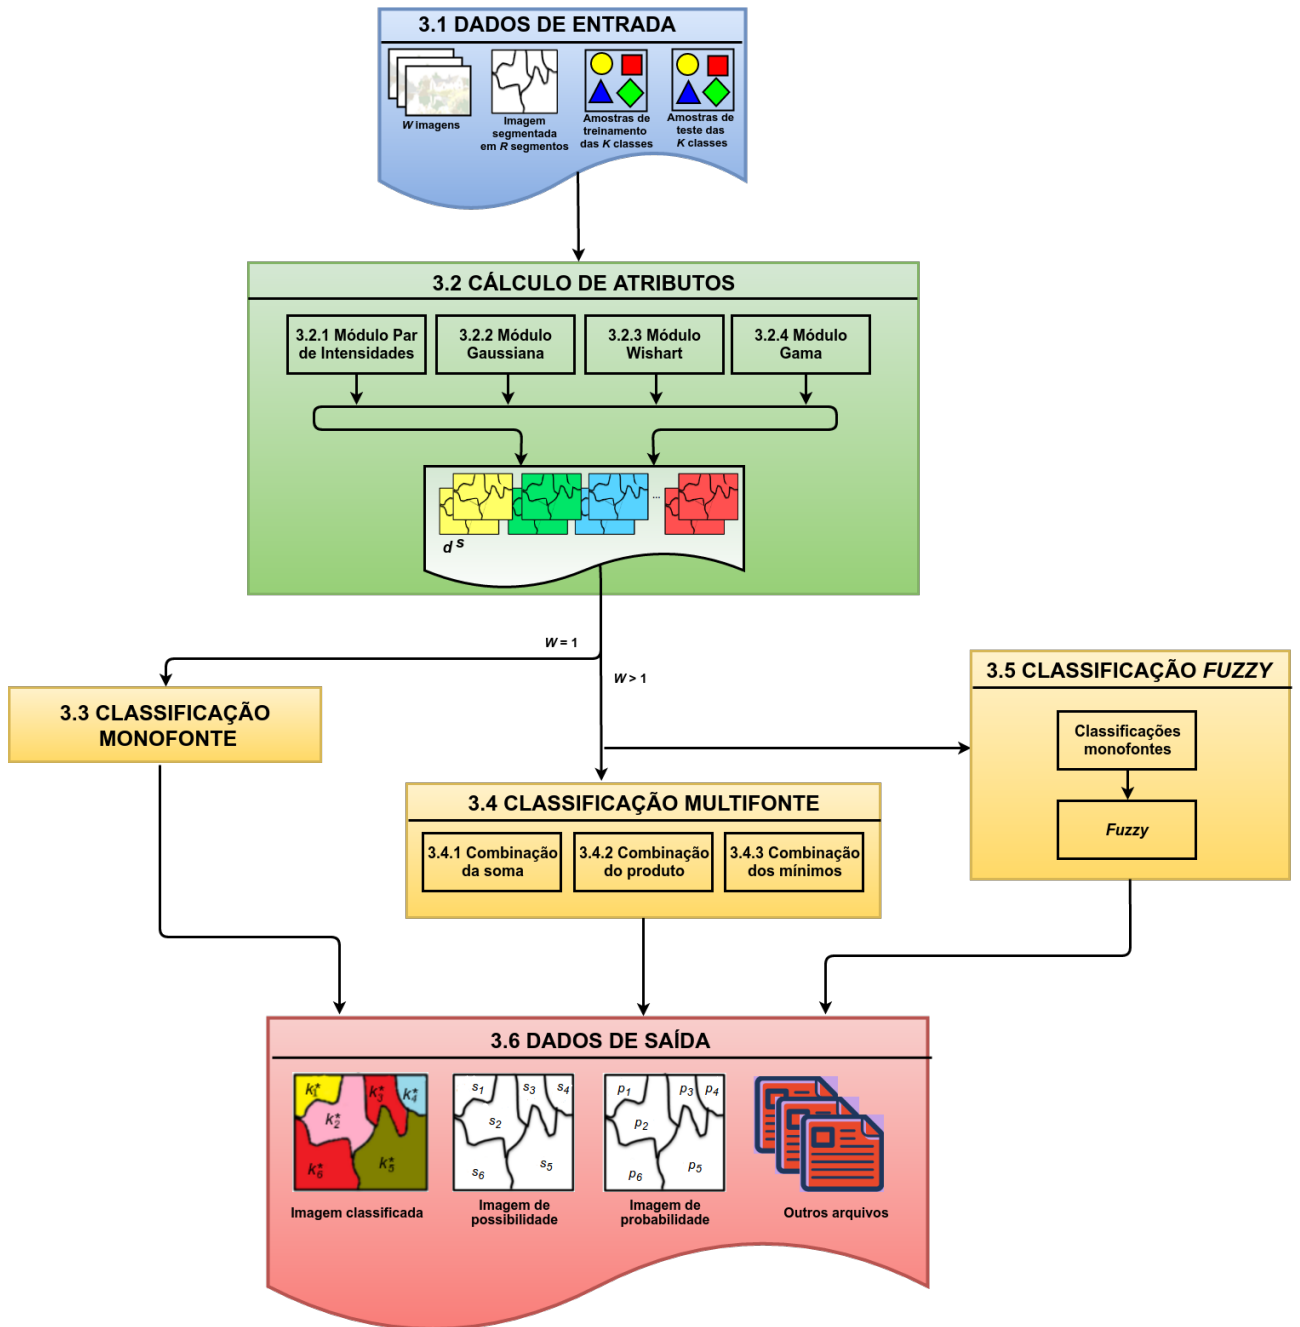
A entrada do sistema de classificação é composta por uma (monofonte) ou mais imagens (multifonte), uma imagem segmentada e amostras de treinamento e de teste das classes de interesse. Para aplicação da metodologia multifonte as imagens envolvidas devem pertencer a uma mesma região da superfície terrestre e devem estar corregistradas entre si. Em relação à segmentação utilizada é importante destacar que um bom resultado de classificação está diretamente relacionado à segmentação da imagem. As imagens de entrada e a imagem segmentada devem ser do tipo de dados geográficos matricial (*raster*). Como o suporte aos dados geográficos é feito pela biblioteca TerraLib, o formato do arquivo das imagens de entrada pode ser qualquer um suportado pela biblioteca GDAL<sup>1</sup>, como por exemplo, TIF, GeoTIFF e JPEG.

Por se tratar de classificação supervisionada, são necessárias amostras de treinamento das classes de interesse para treinar o classificador e amostras das mesmas classes para validar o resultado obtido de classificação. O tipo de dados geográficos das amostras das classes na entrada do sistema deve ser vetorial (representando os polígonos). Portanto, os arquivos das amostras devem estar no formato *shape file* (.shp) e devem estar separados por classe de interesse.

---

<sup>1</sup>Formatos disponíveis em [http://www.gdal.org/formats\\_list.html](http://www.gdal.org/formats_list.html)

Figura 3.1 - Diagrama de blocos da metodologia.



Fonte: Produção do autor.

É importante atentar para o fato de que todas as imagens envolvidas (de entrada e segmentada) devem ter o mesmo número de linhas e colunas. Além disso, todas as imagens e amostras (de treinamento e de teste) devem ter uma mesma projeção geográfica, inclusive os mesmos parâmetros de retângulo envolvente. Caso estes

parâmetros sejam diferentes, a execução do programa é interrompida.

É relevante enfatizar também que não faz parte da implementação do classificador neste trabalho os pré-processamentos necessários (registro, correções geométricas, etc.), segmentações e coletas de amostras. Por isso, essas tarefas devem ser realizadas em outros *softwares* de processamento de imagens previamente. Alguns *softwares* disponíveis para a segmentação de imagens de radar e ópticas são o SegSAR (SOUSA-JÚNIOR, 2005), PolSeg (SALDANHA et al., 2013), *Multiresolution Segmentation (E-Cognition)*, SPRING (BINS et al., ), TerraView (??), entre outros. A seleção de amostras pode ser realizada no TerraView (??) e no QGis (QGIS, 2017), por exemplo.

A entrada do sistema também é composta pelos seguintes parâmetros: modelo estatístico adotado para os dados, distância estocástica, parâmetros de autocorrelação vertical e horizontal (*lags*), nível de significância dos testes estatísticos, número equivalente de *looks* (para os modelos estatísticos Wishart, Par de Intensidades e Gama) e o parâmetro  $\beta$  (para a distância *Rényi*). Nesta etapa de desenvolvimento, interfaces gráficas são desenvolvidas para permitir que o usuário insira os dados de entrada necessários para o processo de classificação. O desenvolvimento das interfaces gráficas visa deixar a plataforma computacional simples e fácil de usar.

### 3.2 Cálculo de atributos

De acordo com as metodologias apresentadas nas subseções 2.6.1 e 2.6.2, seja uma imagem com  $R$  segmentos disjuntos e  $K$  classes de interesse. Para cada segmento são calculadas  $K$  distâncias estocásticas referentes a cada classe e suas respectivas estatísticas de teste de hipótese. A distância estocástica calculada depende do modelo estatístico adotado para esses segmentos e classes. O classificador dispõe de quatro tipos de modelos distintos, cada um apropriado à modelagem estatística mais adequada a um tipo de dado. Na Tabela 3.1 são apresentadas as modelagens estatísticas (os módulos do classificador) com as respectivas distâncias estocásticas implementadas disponíveis e o tipo de solução adotada para o cálculo destas distâncias (analítica ou numérica).

Considere uma região  $r$  e uma amostra  $c_1$  de uma dada classe de interesse, ambas selecionadas de uma imagem de entrada. A região  $r$  é modelada por uma distribuição e densidade  $f_{\mathbf{X}}$ . A amostra  $c_1$  é modelada pela mesma distribuição e densidade  $f_{\mathbf{Y}}$ . As distâncias e suas estatísticas de teste são calculadas entre os parâmetros das densidades  $f_{\mathbf{X}}$  e  $f_{\mathbf{Y}}$ . Portanto, independente do módulo apresentado na Tabela 3.1, a

saída desta etapa de cálculo de atributos consiste em, para cada imagem de entrada, dois planos de informação referentes às distâncias estocásticas e estatísticas de teste correspondentes a cada classe, ou seja,  $2 \times K$  planos.

Tabela 3.1 - Módulos do Classificador.

Módulo	Tipo de dado	Distância Estocástica	Solução
Par de Intensidades	Par de imagens SAR em intensidade	<i>Bhattacharyya</i> <i>Triangular</i>	Numérica
Gaussiana	Imagens ópticas e SAR multivariadas em amplitude	Bhattacharyya Kullback-Leibler	Analítica
Wishart	Imagens polarimétricas	<i>Bhattacharyya</i> <i>Kullback-Leibler</i> <i>Hellinger</i> <i>Rényi</i> (ordem $\beta$ ) Qui-quadrado ( $\mathcal{X}^2$ )	Analítica
Gama	Imagens SAR monocanais em intensidade	<i>Kullback-Leibler</i> <i>Rényi</i> (ordem $\beta$ ) <i>Bhattacharyya</i> <i>Hellinger</i>	Analítica

Fonte: Produção do autor.

### 3.2.1 Módulo Par de Intensidades

Neste módulo são tratados os cálculos relativos à distribuição Par de Intensidades *multi-look*, que é indicada para a modelagem de par de imagens SAR em intensidade. Conforme apresentado na Seção 2.3.3, a função densidade de probabilidade Par de Intensidades *multi-look* tem quatro parâmetros:  $L$ ,  $h_{11}$ ,  $h_{22}$  e  $|\rho_c|$ . Neste trabalho, o parâmetro  $L$  é considerado conhecido, portanto, ele deve ser informado pelo usuário na entrada, como foi citado na Seção 3.1. Os parâmetros  $h_{11}$ ,  $h_{22}$  e  $|\rho_c|$  são computados de acordo com as Equações 2.12, 2.13 e 2.14, respectivamente.

Atualmente, não existem (dentro do conhecimento do autor) expressões fechadas (soluções analíticas) para qualquer distância estocástica entre distribuições Par de Intensidades *multi-look*. Algumas abordagens já foram feitas para obter as expressões fechadas para as distâncias, porém, as resoluções das integrais duplas resultantes foram mal-sucedidas devido à dependência da função modificada de Bessel de ordem  $L - 1$  ( $I_{L-1}$ ) (SILVA, 2013).

Desta maneira, neste módulo as distâncias estocásticas entre duas distribuições Par de Intensidades são obtidas numericamente com as expressões em função das integrais 2.20 e 2.25. O método da Quadratura Gaussiana com 48 pontos foi implementado para a solução numérica de integrais duplas.

O cálculo das distâncias de *Bhattacharyya* e Triangular pelo método numérico Quadratura de Gauss se dá pela resolução das expressões disponíveis em *Silva (2013)* e apresentadas nas Equações 3.1 e 3.2.

$$d_{PIB}(f_{\mathbf{X}}, f_{\mathbf{Y}}) = -\log \left( \int \int \sqrt{f_{\mathbf{X}} f_{\mathbf{Y}}} \right) \quad (3.1)$$

$$d_{PIT}(f_{\mathbf{X}}, f_{\mathbf{Y}}) = \int \int \frac{(f_{\mathbf{X}} f_{\mathbf{Y}})^2}{f_{\mathbf{X}} + f_{\mathbf{Y}}} \quad (3.2)$$

Foi implementado um procedimento de obtenção dos limites de integração. Os limites variam de zero a infinito e o procedimento que muda os domínios infinitos para integração de domínios finitos é realizado para cada segmento e cada classe de interesse para fins práticos.

Para o cálculo das estatísticas  $S_{\phi}^h$  no módulo Par de Intensidades, a Equação 2.37 é aplicada ao valor de distância obtido pelo método numérico. Os valores da constante  $\nu$  referente às funções  $h$  e  $\phi$  das distâncias de *Bhattacharyya* e Triangular, são, respectivamente, 4 e 1.

### 3.2.2 Módulo Gaussiana

Este módulo foi implementado para dados que podem ser modelados pela distribuição Gaussiana multivariada. Este modelo é adequado a dados ópticos em geral e à imagens SAR em amplitude, principalmente quando decorrentes de processamento *multi-look* com elevado número de visadas. Os dois parâmetros da distribuição, conforme mostrado na Seção 2.3.1, são  $\boldsymbol{\mu}$  e  $\boldsymbol{\Sigma}$  e são estimados para as regiões da imagem e amostras das classes pelas Equações 2.5 e 2.6.

Para o cálculo das distâncias entre Gaussianas foram implementadas as expressões fechadas (solução analítica) apresentadas nas Equações 2.26-2.27. As estatísticas  $S_{\phi}^h$  são calculadas de acordo com as Equações 2.40-2.41.

### 3.2.3 Módulo Wishart

O módulo Wishart contém funções relativas à distribuição Wishart complexa escalonada, que é apropriada para a modelagem de imagens SAR polarimétricas. Conforme discutido na Seção 2.3.2, a matriz de covariância hermitiana segue a distribuição Wishart complexa escalonada e os parâmetros da distribuição são  $L$  e  $\Sigma$ . Neste trabalho, o parâmetro  $L$  é considerado conhecido e é informado pelo usuário na entrada. O parâmetro  $\Sigma$  é estimado para as regiões da imagem e para as amostras das classes conforme a Equação 2.9.

Para realizar os cálculos das distâncias entre distribuições Wishart foram utilizadas as expressões fechadas adaptadas para o caso particular em que o número equivalente de *looks* é considerado igual para as diversas regiões da imagem, como nas Equações 2.28-2.32. As estatísticas  $S_{\phi}^h$  deste módulo são calculadas de acordo com as formulações dadas em 2.42-2.46.

### 3.2.4 Módulo Gama

Em situações práticas, dados polarimétricos completos podem não estar disponíveis ao usuário. Esses dados são bem mais caros e são produtos muitas vezes específicos que levam em conta o modo operacional dos sistemas SAR. Alguns satélites/sensores SAR orbitais fornecem dados polarimétricos incompletos, como por exemplo, as imagens em intensidade. Nesses casos são disponibilizados somente os elementos da diagonal principal da matriz de covariância (SILVA, 2013).

Diante da disponibilidade desses dados polarimétricos incompletos e a existência de uma modelagem estatística apropriada a este tipo de dado (LEE et al., 1994), estudos de vários autores mostraram o potencial de classificação, para classes específicas, desses tipos de dados. Lee et al. (1995) e Lee et al. (2001) obtiveram resultados de classificação estatisticamente iguais entre imagens em intensidade (pares de imagens e monocanal) e dados polarimétricos completos, utilizando a classificação por máxima verossimilhança pontual. Negri (2009) também obteve resultados compatíveis com essa conclusão comparando as classificações de imagens polarimétricas e pares de imagens em intensidade utilizando-se da classificação pontual e contextual por máxima verossimilhança. Silva (2013) e Braga (2016) mostraram para os casos monofonte e multifonte, respectivamente, o potencial de classificação de pares de imagens em intensidade através das metodologias por regiões baseada em distâncias estocásticas e utilizando a modelagem Par de Intensidades *multi-look*.

Conforme discutido na Seção 3.2.1, para obter as distâncias entre distribuições Par de Intensidades *multi-look* é necessário resolver integrais duplas usando um método numérico. Os limites de integração variam de zero a infinito, e portanto, para fins práticos, um procedimento é feito para mudar os domínios infinitos para domínios finitos de integração. Além do custo computacional devido ao método numérico de solução de integrais duplas, este procedimento que é realizado para cada região e cada classe de interesse eleva o custo computacional para esta solução. Classificar imagens considerando esta modelagem demora mais do que outras modelagens (Gaussiana e Wishart), que utilizam expressões fechadas para calcular as distâncias.

Portanto, conforme apresentado na Seção 3.2.4, foi desenvolvido nesta metodologia um módulo que permite classificar imagens monocanal SAR em intensidade. Este módulo considera a distribuição Gama como modelagem estatística, que é apropriada para este tipo de dado. Além da vantagem de permitir modelar estes tipos de dados polarimétricos incompletos, esta modelagem utiliza expressões fechadas para o cálculo de distâncias, ou seja, não se utiliza de métodos numéricos como no caso da Par de Intensidades.

Os dois parâmetros da distribuição são  $L$  e  $\lambda$ . O parâmetro  $L$  é considerado conhecido e é informado pelo usuário na entrada. O parâmetro  $\lambda$  é estimado para as regiões da imagem e para as amostras da classe de acordo com a Equação 2.17. Para as distâncias entre distribuições Gama, foram implementadas as expressões fechadas disponíveis em Torres (2012), como nas Equações 2.33-2.36. As estatísticas são calculadas como nas formulações 2.47-2.50.

Pode-se observar nas formulações citadas nas últimas seções que, em vários casos, o cálculo de distâncias estocásticas e estatísticas de teste envolve operações com matrizes. Nos casos em que as matrizes precisam ser invertidas ou é preciso ser calculado o determinante, as matrizes em questão podem apresentar problemas de mal-condicionamento e serem conduzidas a singularidade. Para evitar esse problema foi implementado uma adaptação do método de *Levenberg-Marquardt* (LEVENBERG, 1944; MARQUARDT, 1963).

### 3.3 Classificação Monofonte

De posse dos planos de informação, considere apenas uma única imagem (monofonte), contendo  $R$  segmentos dessa imagem e  $K$  classes com as quais se deseja classificar a imagem. A classificação é obtida por meio da menor estatística de teste e, portanto, a obtenção do menor valor de estatística  $s_r$  para a região  $r$  é dado por

$$s_r = \min_k \{s_{rk}\}, \quad (3.3)$$

onde  $1 \leq r \leq R$  e  $1 \leq k \leq K$ .

A classe  $k_r^*$  que possui a menor estatística de teste  $s_r$  é atribuída à região  $r$ , ou seja,

$$k_r^* = \arg_k \left\{ \min_k \{s_{rk}\} \right\}. \quad (3.4)$$

A partir do valor da menor estatística de teste  $s_r$  encontrada para a região  $r$  é obtido o valor- $p$  por

$$p_r = \Pr(\chi_M^2 > s_r). \quad (3.5)$$

onde  $M$  é o grau de liberdade. Pela teoria do teste de hipótese  $h - \phi$ , o estimador dos parâmetros da *f.d.p.* que modela a imagem deve ser o de máxima verossimilhança. Para o caso da Par de Intensidades, o teste de hipótese utiliza uma distribuição Qui-quadrado com dois graus de liberdade ( $M = 2$ ). A estimativa do módulo do parâmetro de coeficiente de correlação complexa  $|\rho_c|$  não é contabilizada tendo em vista que é um parâmetro estimado pelo método dos momentos. O parâmetro do número equivalente de *looks* se considera conhecido neste trabalho. Para a distribuição Gaussiana multivariada com  $q$  variáveis tem-se que  $M = q(q + 3)/2$ . Para a distribuição Wishart representada por uma matriz de covariância  $q \times q$  tem-se  $M = q^2$ . Já para a distribuição Gama  $M = 1$ . Foram utilizadas as funções *chi-squared* e *cdf* (*Cumulative Distribution Function*) da biblioteca *Boost* (BOOST LIBRARIES, 2017) para o cálculo dos valores- $p$ .

### 3.4 Classificação Multifonte

Seja  $W$  o número de imagens independentes. Para o caso da classificação multifonte ( $W > 1$ ), a classificação final é obtida através de combinações dos valores contidos nos planos de informação gerados na etapa descrita na seção 3.2. A combinação dos planos de informação é realizada através de uma função matemática, como apresentado em Braga (2016). Para este trabalho foram consideradas as combinações da soma, produto e mínimos das estatísticas de teste.



### 3.4.1 Combinação da soma

Para o caso da soma, dadas as  $W$  imagens, as  $K$  classes de interesse e uma única segmentação dessas imagens em  $R$  regiões, é calculada a soma das estatísticas de teste ( $s_{rk}^{sum}$ ) para a região  $r$  e classe  $k$ , dada por:

$$s_{rk}^{sum} = \sum_{w=1}^W s_{rk}^w. \quad (3.6)$$

Após os cálculos da soma das estatísticas de todas as  $R$  regiões, os valores de estatística  $s_{rk}^{sum}$  são normalizados, cuja função é definida por:

$$\text{normalize}(s_{ik}^{sum} - s_c^{sum}) = \frac{(s_{ik}^{sum} - s_c^{sum}) - \min(s_{ik}^{sum} - s_c^{sum})}{\max(s_{ik}^{sum} - s_c^{sum}) - \min(s_{ik}^{sum} - s_c^{sum})}, \quad (3.7)$$

em que  $s_c^{sum}$  é o valor crítico para o teste da distribuição Qui-quadrado da soma e representa o limitante inferior para rejeição da hipótese nula do teste.

Por intermédio destes valores normalizados obtém-se o valor final de estatística de teste  $s_r^{sum}$  para a região  $r$  por

$$s_r^{sum} = \min_k \{ \text{normalize}(s_{rk}^{sum} - s_c^{sum}) \}. \quad (3.8)$$

Atribui-se à região  $r$  a classe  $k_r^{*sum}$ , que é a classe que possui esta menor estatística de teste  $s_r^{sum}$ , ou seja,

$$k_r^{*sum} = \arg_k \left\{ \min_k \{ \text{normalize}(s_{rk}^{sum} - s_c^{sum}) \} \right\}. \quad (3.9)$$

Define-se o valor- $p$  final para a região  $r$  por

$$p_r^{sum} = \Pr(\chi_M^2 > s_{rk_r^{*sum}}^{sum}). \quad (3.10)$$

onde  $M = \sum_{w=1}^W M_w$  e  $M_w$  é o grau de liberdade, ou seja, o número de parâmetros estimados pelo método da máxima verossimilhança da *f.d.p.* que modela a imagem  $w$ .

Dessa forma, as imagens temática (de classificação), de possibilidade e de probabilidade da combinação da soma são fornecidas, respectivamente, pelas espacializações de  $k_r^{*sum}$ ,  $s_r^{sum}$  e  $p_r^{sum}$ .

### 3.4.2 Combinação do produto

No caso da combinação do produto, inicialmente, o valor- $p$  é calculado para a região  $r$  e classe  $k$  por  $p_{rk}^w = \Pr(\chi_{M_w}^2 > s_{rk}^w)$ , onde  $M_w$  é o grau de liberdade referente à imagem  $w$ . Os valores das estatísticas de teste obtidos na etapa descrita na Seção 3.2 são normalizados. A função de normalização é definida por:

$$s_{rk}^{wnorm} = \text{normalize}(s_{rk}^w - s_c^w) = \frac{(s_{rk}^w - s_c^w) - \min(s_{rk}^w - s_c^w)}{\max(s_{rk}^w - s_c^w) - \min(s_{rk}^w - s_c^w)}, \quad (3.11)$$

em que  $s_c^w$  é o valor crítico para o teste da distribuição Qui-quadrado para as estatísticas de teste da imagem  $w$ . Assim como na combinação da soma, foram utilizadas as funções *chi-squared* e *quantile* da biblioteca *Boost*.

Dadas as  $W$  imagens, o produto das estatísticas de teste ( $s_{rk}^{prod}$ ) é calculado para a região  $r$  e classe  $k$  por:

$$s_{rk}^{prod} = \prod_{w=1}^W s_{rk}^{wnorm}. \quad (3.12)$$

A partir do resultado do produto define-se o valor final de estatística de teste  $s_r^{prod}$  para a região  $r$  através de

$$s_r^{prod} = \min_k \{s_{rk}^{prod}\}. \quad (3.13)$$

Atribui-se à região  $r$  a classe  $k_r^{*prod}$  que possui a menor estatística de teste  $s_{rk}^{prod}$ , portanto,

$$k_r^{*prod} = \arg_k \left\{ \min_k \{s_{rk}^{prod}\} \right\}. \quad (3.14)$$

Define-se, portanto, o valor- $p$  final  $p_r^{prod}$  por

$$p_r^{prod} = \prod_{w=1}^W p_{rk_r^{*prod}}^w. \quad (3.15)$$

As imagens de classificação, de possibilidade e de probabilidade da combinação do produto são geradas pelas espacializações de  $k_r^{*prod}$ ,  $s_r^{prod}$  e  $p_r^{prod}$ , respectivamente.

### 3.4.3 Combinação dos mínimos

Considerando as  $W$  imagens, o valor- $p$  é calculado para a região  $r$  e classe  $k$  por  $p_{rk}^w = \Pr(\chi_{M_w}^2 > s_{rk}^w)$ .

Os valores das estatísticas de teste são normalizados por

$$\text{normalize}(s_{rk}^w - s_c^w) = \frac{(s_{rk}^w - s_c^w) - \min(s_{rk}^w - s_c^w)}{\max(s_{rk}^w - s_c^w) - \min(s_{rk}^w - s_c^w)}, \quad (3.16)$$

onde  $s_c^w$  indica o valor crítico para o teste da distribuição Qui-quadrado para as estatísticas de teste da imagem  $w$ .

O valor final da estatística de teste  $s_r^{min}$  é definido por

$$s_r^{min} = \min_{k,w} \{\text{normalize}(s_{rk}^w - s_c^w)\}. \quad (3.17)$$

A classe  $k_r^{*min}$  que possui a menor estatística de teste  $s_r^{min}$  é atribuída à região  $r$

$$k_r^{*min} = \arg_k \left\{ \min_{k,w} \{\text{normalize}(s_{rk}^w - s_c^w)\} \right\}. \quad (3.18)$$

O valor- $p$  final é obtido por

$$p_r^{min} = p_{rk_r^{*min}}^w. \quad (3.19)$$

Nota-se que para todos os casos de combinação é necessária a normalização dos valores das estatísticas de teste. A normalização é importante porque diferentes tipos de dados estão envolvidos para a integração e a espacialização destes valores só passa a representar uma imagem de possibilidades quando se transferem as estatísticas do intervalo  $[0, \infty]$  para o intervalo  $[0, 1]$  (BRAGA, 2016).

Na implementação do cálculo dos valores- $p$ , em todas combinações, foram utilizadas as funções *chi-squared* e *cdf* (*Cumulative Distribution Function*) da biblioteca *Boost* (BOOST LIBRARIES, 2017). Para o cálculo do valor crítico foram utilizadas as funções *chi-squared* e *quantile*, também da biblioteca *Boost* e os parâmetros das funções foram o grau de liberdade  $M$  e o nível de significância adotado, respectivamente.

### 3.5 Classificação *Fuzzy*

A classificação *Fuzzy* é um caso particular de combinação de dados na classificação multifonte ( $W > 1$ ), em que  $W$  é o número de imagens de entrada. A lógica *Fuzzy* (incerta, difusa ou nebulosa) é uma modelagem para afirmações que não se pode ter muita certeza. Nesta lógica as propostas podem ser indicadas com um grau de certeza de 0 a 1, ou seja, podem possuir valores entre o absolutamente falso e o absolutamente verdadeiro (WEBER; KLEIN, 2003).

A classificação de imagens com este tipo de lógica mostra que uma tomada de decisão pela classificação mais representativa da realidade pode ser relativa. Uma região da imagem pode não possuir necessariamente uma classificação exata (BRAGA, 2016). Na classificação *Fuzzy*, cada região da imagem possui um valor associado a cada classe. Pode-se interpretar o valor 0 como a região não pertencer a uma determinada classe. O valor 1 pode ser interpretado como 100% de certeza da região pertencer apenas àquela classe (classe pura). Valores entre 0 e 1 indicam que a região pode ser classificada com uma classe que é a combinação de diferentes classes.

Para realizar a classificação *Fuzzy*, são gerados os resultados de classificações monofonte individuais das  $W$  imagens de entrada, como descrito na Seção 3.2. Dadas as  $W$  classificações individuais (imagens de  $k_r^*$ ) e as  $K$  classes de interesse, são gerados  $K$  planos de informação. Para o plano da classe  $k$  ( $1 \leq k \leq K$ ) o valor  $k_r^{*fuzzy}$  obtido para a região  $r$  é dado por

$$k_r^{*fuzzy} = \frac{1}{W} \sum_{w=1}^W k_r^w, \quad (3.20)$$

em que

$$k_r^w = \begin{cases} 0, & \text{região não rotulada com a classe } k \text{ na classificação monofonte da imagem } w \\ 1, & \text{região rotulada com a classe } k \text{ na classificação monofonte da imagem } w. \end{cases} \quad (3.21)$$

As estatísticas de teste e valores- $p$  são obtidos por:

$$s_r^{fuzzy} = \prod_{w=1}^W \text{normalize}(s_{r,k}^w - s_c^w). \quad (3.22)$$

$$p_r^{fuzzy} = \prod_{w=1}^W p_{r,k}^w. \quad (3.23)$$

### 3.6 Dados de Saída

Os resultados da classificação são as imagens temática (de classificação), de possibilidade e de probabilidade que são fornecidas, respectivamente, pelas espacializações de  $k_r^*$ ,  $s_r$  e  $p_r$ . É importante destacar que os dois últimos estão relacionados à confiabilidade da classificação. As três imagens consistem em três arquivos no formato *Tagged Image File Format* (TIF) e podem ser visualizados em qualquer Sistema de Informações Geográficas (SIG).

Nota-se em todos os casos multifonte e monofonte que a classificação final é fundamentada no cálculo da mínima estatística de teste  $h - \phi$  entre distribuições que modelam os segmentos da imagem e as classes de interesse. O cálculo do valor- $p$  para cada teste de hipótese é uma produção adicional que serve como um indicador de qualidade. Vale também ressaltar que no caso da classificação *Fuzzy*,  $K$  planos de informação são gerados, onde  $K$  é o número de classes.

Outro produto gerado é o relatório de classificação que contém a avaliação da exatidão dos resultados. Trata-se de um arquivo no formato de arquivo ASCII (extensão .txt) que contém a matriz de confusão, ou matriz de erros, e três medidas de informação de qualidade da classificação, os quais são: Coeficiente de Concordância *Kappa*, variância amostral do *Kappa* e acurácia global.

A matriz de confusão é construída a partir da utilização das amostras de teste das classes de interesse. Conforme exemplo mostrado na Tabela 3.2, para uma dada classe  $k_i$  ( $1 \leq i \leq K$ ), a quantidade  $n_{ij}$  indica o número de pixels classificados na classe  $i$ , sendo que são ocorrências da classe  $j$ . Esse valor é definido na comparação entre a imagem classificada e a amostra de teste. As quantidades  $n_{i+}$  e  $n_{+j}$  representam as proporções marginais em relação à linha  $i$  (referência) e coluna  $j$  (classificação) ( $1 \leq i \leq K$  e  $1 \leq j \leq K$ ).  $N$  é o número total de amostras e  $K$  o número de classes.

Tabela 3.2 - Matriz de confusão.

		Referência				
		$k_1$	$k_2$	$\dots$	$k_K$	
C	$k_1$	$n_{11}$	$n_{12}$	$\dots$	$n_{1K}$	$n_{1+}$
l	$k_2$	$n_{21}$	$n_{22}$	$\dots$	$n_{2K}$	$n_{2+}$
a	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
s	$k_K$	$n_{K1}$	$n_{K2}$	$\dots$	$n_{KK}$	$n_{K+}$
s		$n_{+1}$	$n_{+2}$	$\dots$	$n_{+K}$	$N$

Fonte: Adaptado de [Silva \(2013\)](#).

Neste capítulo foram descritas todas as etapas implementadas na metodologia de desenvolvimento do classificador monofonte e multifontes. A seguir, são apresentados os dados utilizados e os resultados da validação da ferramenta computacional desenvolvida e as etapas implementadas.

## 4 RESULTADOS

Neste capítulo são apresentados os dados utilizados e os resultados dos experimentos realizados para avaliar o sistema de classificação. As aplicações realizadas foram divididas em três partes: na primeira (Seção 4.1) apresenta-se o fluxo de funcionamento do sistema; na segunda (Seção 4.2) descrevem-se e analisam-se os testes de validação da ferramenta computacional em duas etapas, a saber, com dados simulados e com dados reais; por fim, na Seção 4.3 fez-se um breve estudo acerca da influência de dados SAR monocanais nos resultados de classificação, bem como a comparação com dados SAR bivariados e polarimétricos.

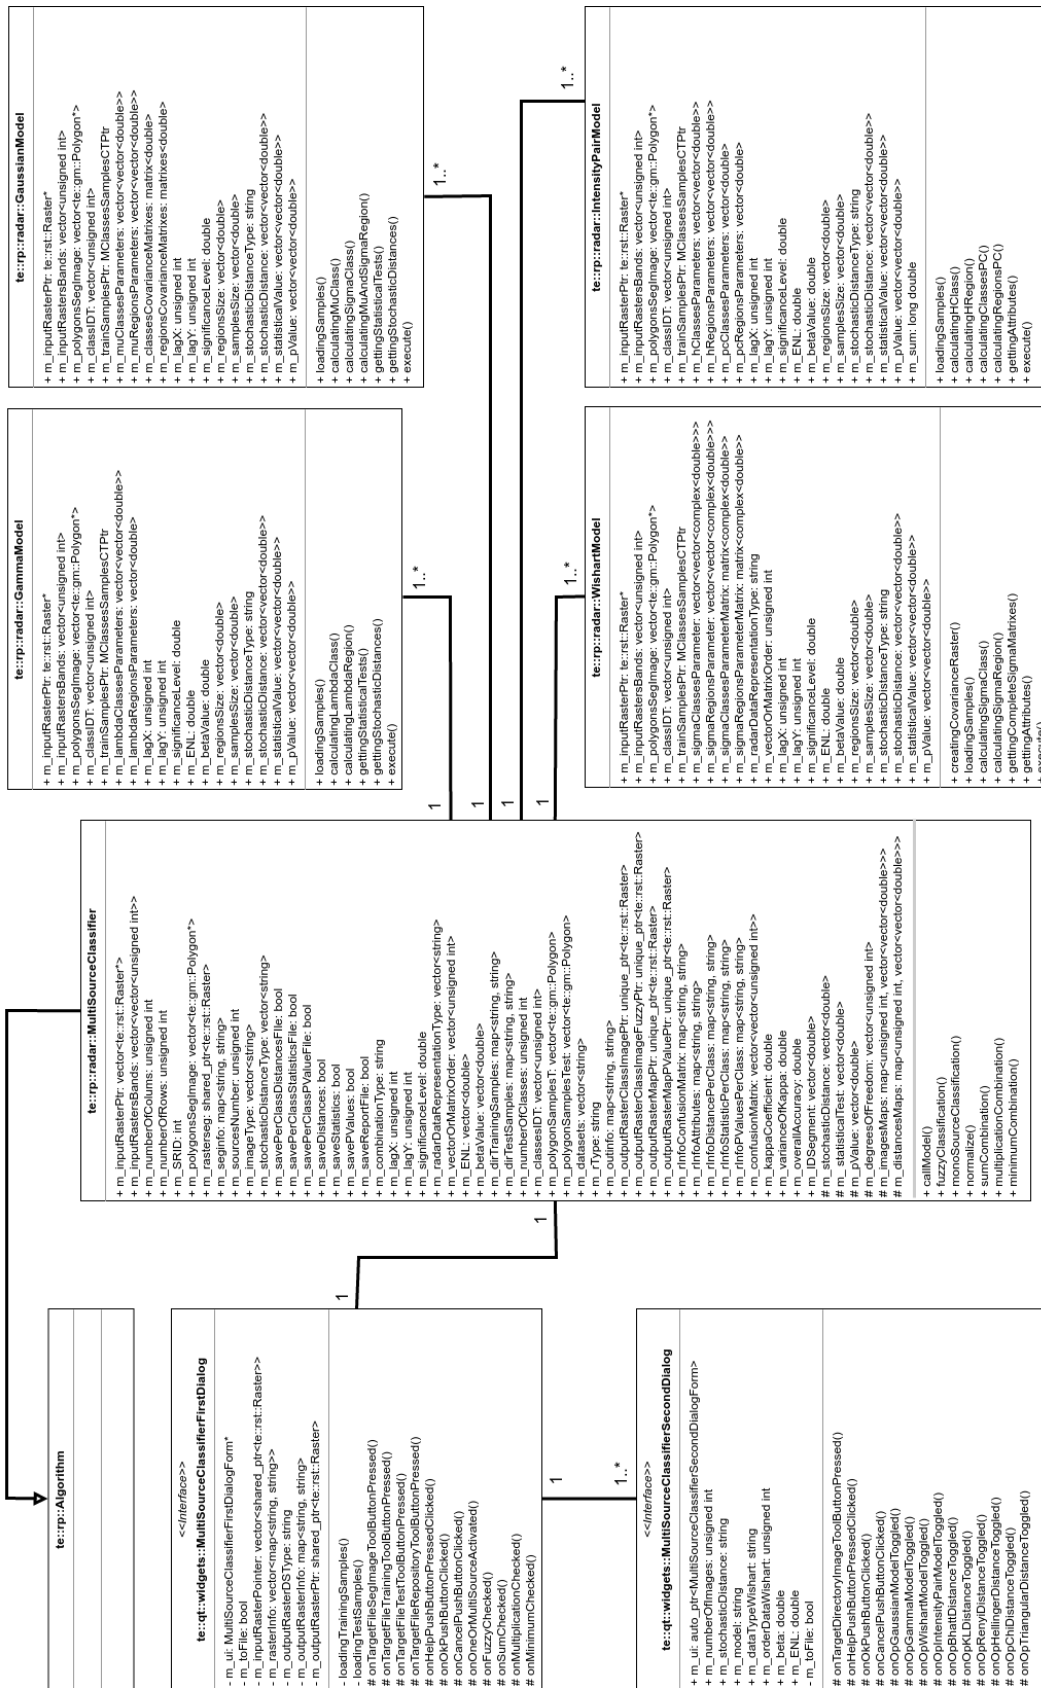
### 4.1 Ferramenta computacional desenvolvida

Nesta Seção apresentam-se o sistema de classificação desenvolvido, sua forma de uso e os resultados de alguns testes específicos. Inicialmente, são descritos os passos para a execução da plataforma computacional do classificador. É importante destacar que esses passos se referem à versão do sistema finalizada para esta Dissertação, uma vez que atingiram-se os objetivos de desenvolvimento listados no Capítulo 1. Após a descrição dos passos são discutidas possíveis continuações para a plataforma computacional.

Foi gerado um arquivo executável para a utilização do sistema de classificação. Contudo, a implementação na TerraLib permite que o classificador seja adicionado como um *plug-in* no SIG TerraView. A concretização dessa opção pode permitir que o usuário apenas instale a versão do *software* TerraView que tenha o *plug-in* do sistema de classificação para utilizá-lo.

Na implementação, sete classes foram definidas: MultiSourceClassifierFirstDialog, MultiSourceClassifierSecondDialog, MultiSourceClassifier, GammaModel, GaussianModel, WishartModel e IntensityPairModel, e implementam, respectivamente, a primeira janela da interface, segunda janela, classificador, módulo Gama, módulo Gaussiana, módulo Wishart e módulo Par de Intensidades. Todas as classes foram integradas à biblioteca TerraLib. O diagrama destas classes, contendo a interface e os conjuntos de atributos e métodos, é apresentado na Figura 4.1. As explicações de cada parte do sistema implementadas por estas classes são feitas nas próximas subseções.

Figura 4.1 - Diagrama das classes implementadas.



Fonte: Produção do autor.



Foram desenvolvidas interfaces gráficas que permitem que o usuário insira os dados de entrada necessários para o processo de classificação. As janelas que compõem a interface gráfica, mostradas nas Figuras 4.2 e 4.3, aparecem para o usuário quando o classificador é executado.

Figura 4.2 - Janela principal da interface gráfica.

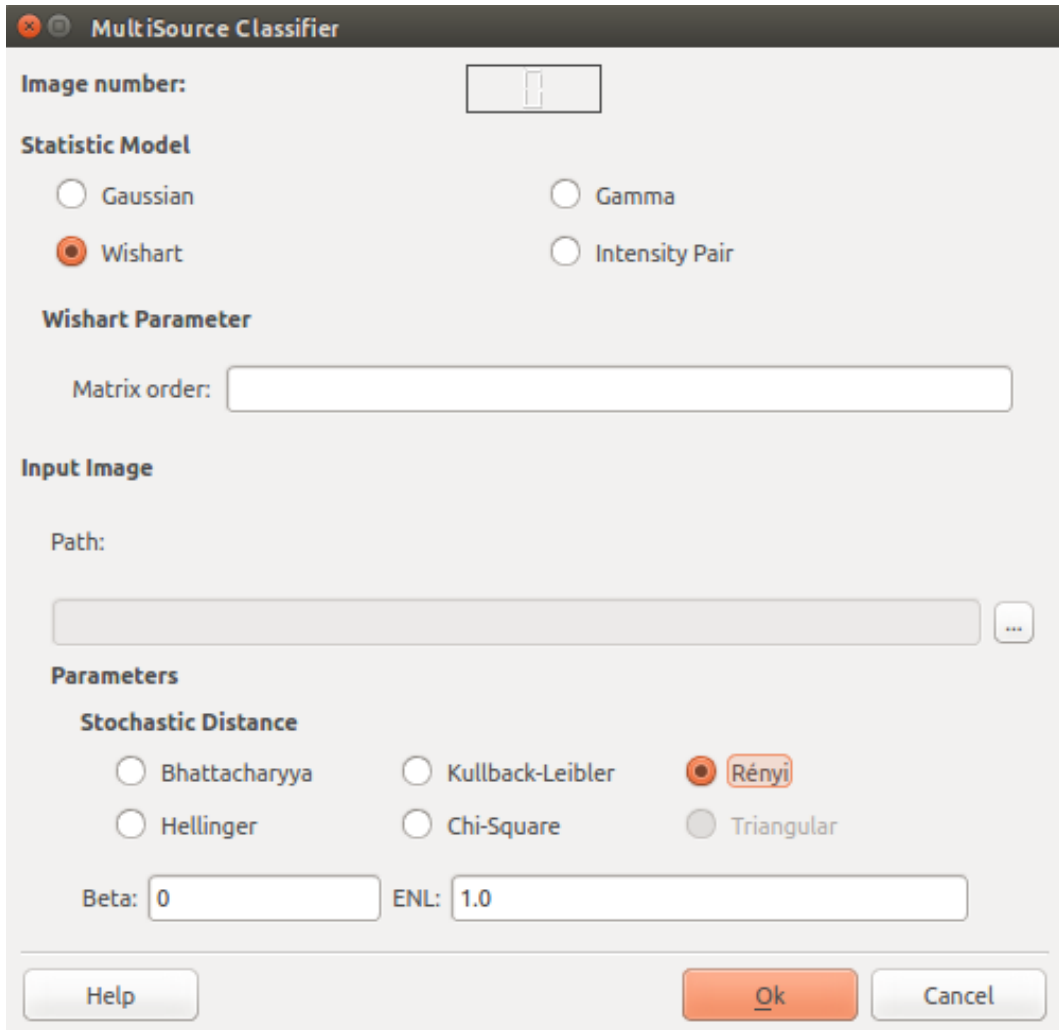
The image shows a software window titled "MultiSource Classifier" with a subtitle "MultiSource Classifier Based On Stochastic Distances". The window is divided into several sections:

- Input:** Contains four text input fields: "Number of Images:", "Segmented Image:", "Training Samples:", and "Test Samples:". Each field has a small "..." button to its right.
- Combination Type:** Features four radio buttons: "Sum" (selected), "Multiplication", "Minimum", and "Fuzzy".
- Confidence Level (%):** A text input field containing the value "95".
- Horizontal Lag:** A text input field containing the value "0".
- Vertical Lag:** A text input field containing the value "0".
- Output:** Contains two text input fields: "Repository:" and "Layer Name:", each with a "..." button to its right.
- Save on Disk:** A section with two rows of checkboxes. The first row has "Distances", "Statistics", "P-Values", and "Report", all checked. The second row, labeled "Per class:", has "Distances", "Statistics", and "P-Values", all checked.
- Buttons:** At the bottom, there are three buttons: "Help", "Ok", and "Cancel".

Janela principal do sistema de classificação que aparece quando o programa é executado.

Fonte: Produção do autor.

Figura 4.3 - Segunda janela da interface gráfica.



Segunda janela do sistema de classificação. Nesta Figura é mostrado um exemplo de quando é escolhida a modelagem Wishart com a distância Rényi de ordem  $\beta$ . Portanto, a distância Triangular é mostrada desabilitada por não ser uma distância disponível entre distribuições Wishart complexas escalonadas. Os detalhes do modo de usar as interfaces gráficas são apresentados no Apêndice A.

Fonte: Produção do autor.

Na janela principal (Figura 4.2) que aparece quando o programa é executado, o usuário deve inserir dados e opções de entrada, como por exemplo, a imagem segmentada e os diretórios dos arquivos das amostras das classes de treinamento e de teste. Na segunda janela (Figura 4.3), deve-se inserir a imagem de entrada e os seus parâmetros, como por exemplo, a modelagem estatística e a distância estocástica. No caso de classificação multifontes, a quantidade de vezes que a segunda janela aparece para o usuário é igual ao número de imagens de entrada. Mais detalhes

sobre os componentes das janelas da interface gráfica estão disponíveis no Apêndice A, juntamente com um manual do usuário.

Testes de interface foram realizados para verificar se a navegabilidade e os objetivos das janelas funcionam como especificados. Os testes consistiram em execuções empíricas do classificador com aplicações de diferentes tipos de dados em caminhos previstos no desenvolvimento. Por meio dos testes, observou-se que, as interfaces gráficas não apresentaram problemas durante o funcionamento da aplicação e devido a todos os componentes estarem nomeados foi simples e fácil utilizar o sistema de classificação. Na próxima Seção são apresentados os testes realizados para validar os resultados obtidos pelo sistema.

## 4.2 Validações da ferramenta computacional

Esta Seção tem como objetivo mostrar a corretitude, confiabilidade e completitude do *software* desenvolvido nesta Dissertação. Para isso, os testes de validação foram divididos em duas partes. A primeira parte (Subseção 4.2.1) consiste em um caso de teste feito a partir de dados simulados com o intuito de realizar experimentos controlados. Os resultados detalhados desse caso de teste são apresentados no Apêndice B. Na segunda parte (Subseção 4.2.2) são apresentados experimentos com dados que já foram aplicados à mesma metodologia de classificação em um trabalho publicado anteriormente por outro autor (BRAGA, 2016), visando a realização de testes com dados reais. Os resultados desses experimentos são comparados com os obtidos por Braga (2016), posteriormente, são analisados. Vale destacar que o Apêndice C apresenta um outro caso de teste detalhado que reforça a validação do *software* feita nesta Seção. A ferramenta computacional PolClass, desenvolvida por Silva (2013), também foi aplicada ao caso de teste do Apêndice C devido às diferenças nos resultados exibidos na Subseção 4.2.2 entre as duas ferramentas.

### 4.2.1 Aplicação a dados simulados

A utilização de imagens simuladas permite a condução de experimentos onde o comportamento dos alvos é conhecido a priori e a realização de avaliações é feita sem a influência das características de uma imagem em particular (SALDANHA et al., 2013). Esta parte do trabalho tem o objetivo de validar os resultados de classificações monofontes geradas por cada módulo do classificador descrito no Capítulo 3, com exceção do módulo Gama, sob condições de modelagem estatística rigorosamente controladas. Aplicações com o módulo Gama são discutidas na Seção 4.3.

Os dados simulados do caso de teste nesta Seção foram gerados e aplicados à metodologia de classificação de imagens por regiões baseada em distâncias estocásticas em [Silva \(2013\)](#) (Seção 2.6.1). No processo de simulação foram utilizados dados reais PolSAR na banda L e obtidas realizações de matrizes de covariância complexas aleatórias que seguem a distribuição Wishart complexa escalonada. Foram produzidas imagens correspondentes a classes diferentes e, após um processo de mosaico que as agrupou, resultou-se uma imagem PolSAR final com 4 visadas ( $L = 4$ ) e três polarizações (HH, HV e VV). Os detalhes do processo de simulação dos dados são encontrados em [Silva \(2013\)](#).

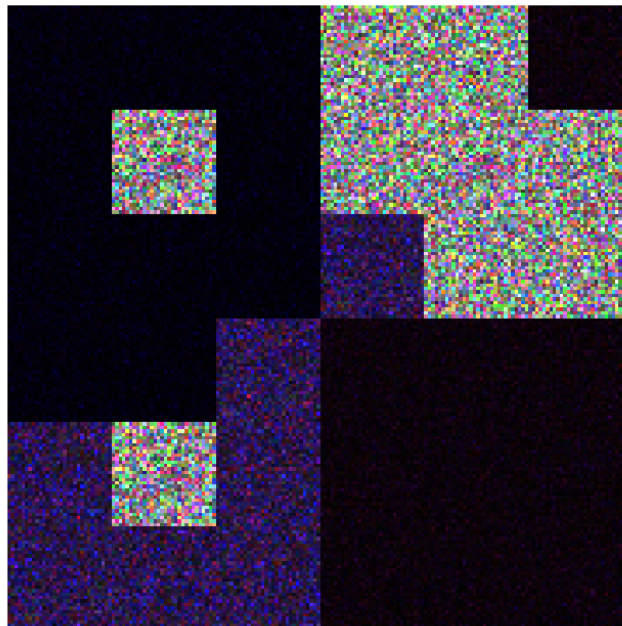
Para a realização dos experimentos apresentados nesta Seção, foram feitas algumas adaptações nos dados simulados obtidos em [Silva \(2013\)](#). O objetivo dessas adaptações foi obter quatro imagens diferentes para construir classificações multifontes com as seguintes características: dimensões menores para que o caso de teste não ficasse grande ou demorado e uma maior intercalação de regiões de classes diferentes. As classes definidas foram: Rio (RI), Caatinga (CA), Solo Preparado (SP) e Soja (SO). Como resultado dessas adaptações, as imagens simuladas adaptadas usadas para os testes possuem dimensões de  $180 \times 180$  pixels e na [Figura 4.4](#) são mostradas as posições das regiões e as classes a que pertencem. O resultado da simulação gerou uma imagem baseada em matriz de covariância complexa (imagem polarimétrica). A partir da imagem polarimétrica foram extraídas uma imagem amplitude multivariada (canais HH, HV e VV), além de duas imagens em intensidade (HH e HV), pela seleção dos elementos da diagonal principal da matriz de covariância. A [Figura 4.5](#) mostra uma composição colorida RGB dos canais de amplitude extraídos da imagem matriz de covariância. As duas imagens SAR simuladas em intensidade são apresentadas na [Figura 4.6](#).

Figura 4.4 - Posições e classes das regiões das imagens do Caso de Teste 1.

0 RI	1 RI	2 RI	3 CA	4 CA	5 SP
6 RI	7 CA	8 RI	9 CA	10 CA	11 CA
12 RI	13 RI	14 RI	15 SO	16 CA	17 CA
18 RI	19 RI	20 SO	21 SP	22 SP	23 SP
24 SO	25 CA	26 SO	27 SP	28 SP	29 SP
30 SO	31 SO	32 SO	33 SP	34 SP	35 SP


Fonte: Produção do autor.

Figura 4.5 - Imagem SAR em amplitude multivariada simulada em composição colorida R(HH), G(HV) e B(VV).



Fonte: Produção do autor.

Figura 4.6 - Imagens SAR monocanais (a) HH e (b) HV em intensidade simuladas.




(a) HH

(b) HV

Fonte: Produção do autor.

A segmentação utilizada possui 36 regiões quadradas de tamanhos  $30 \times 30$  pixels, como mostra a Figura 4.7 (a). As amostras de treinamento, uma região de  $30 \times 30$  pixels para cada classe de interesse, também são utilizadas como amostras de teste e foram posicionadas conforme mostra a Figura 4.7 (b).

Figura 4.7 - Segmentação e amostras de treinamento e de teste dos dados simulados.



(a) Segmentação

(b) Amostras das classes

Fonte: Produção do autor.

Treze classificações monofontes e quatro classificações multifontes diferentes foram construídas, totalizando dezessete classificações. No caso de classificações monofontes, produziram-se treze experimentos correspondentes a cinco distâncias entre distribuições Wishart complexa escalonada, duas distâncias entre Gaussianas multivariadas e entre distribuições Pares de Intensidade *multilook* e quatro distâncias entre distribuições Gamas. No caso das classificações multifontes, foram utilizados os quatro tipos de dados (imagens polarimétrica, multivariada em amplitude, par em intensidade HH,HV e monocanal em intensidade HH) em conjunto. Vale ressaltar que, de acordo com a metodologia desenvolvida em Braga (2016), as imagens devem ser provenientes de sensores distintos e independentes. Porém, como objetiva-se nesta Subseção verificar a corretitude do sistema, os testes foram realizados com esses dados que foram simulados a partir de uma mesma imagem de um sensor. As quatro classificações multifontes são referentes às combinações da soma, produto, mínimos e *Fuzzy* e em todos os casos foi utilizada a distância de *Bhattacharyya*, uma vez que todas as distâncias já foram testadas nos casos monofontes e deseja-se testar as combinações. Portanto, foram realizados testes utilizando todas as distâncias em todos os módulos e combinações multifontes disponíveis no *software*.

A imagem polarimétrica obtida no processo de simulação foi classificada por intermédio do módulo Wishart descrito na Subseção 3.2.3. A imagem em amplitude multivariada foi classificada com o módulo Gaussiana (Subseção 3.2.2). O par de imagens em intensidade HH,HV foi classificado por meio do módulo Par de Intensidades (Subseção 3.2.1). A imagem monocanal HH foi classificada com o módulo Gama (Subseção 3.2.4). Nos experimentos foram considerados os parâmetros nível de confiança igual a 95%,  $\beta$  igual a 0,5 para a distância de *Rényi* e na estimação dos parâmetros das distribuições que modelam os dados todas as amostras (segmentos e classes) foram subamostradas usando *lag* 0. Para a validação das classificações, se utilizaram os índices de acurácias globais, que são adquiridos por intermédio da matriz de confusão.


As classificações monofontes com a distância de *Bhattacharyya* correspondentes às imagens polarimétrica, em amplitude multivariada, HH,HV e monocanal HH são ilustradas nas Figuras 4.8 a 4.11, respectivamente. As classificações monofontes com as demais distâncias são apresentadas no Apêndice B. As classificações multifontes das combinações da soma, produto e mínimos são apresentadas, nesta ordem, nas Figuras 4.12 a 4.14. Nestas figuras a parte (a) ilustra a imagem classificada e a parte (b) representa o resultado da espacialização do valor-*p* (imagem de probabilidade ou imagem de certeza da classificação) da classificação.

A classificação multifonte *Fuzzy* é apresentada na Figura 4.15. Dadas  $K$  classes, neste tipo de classificação são gerados  $K$  planos de informação. Cada plano de informação é referente a uma classe. É possível obter uma classificação final utilizando uma regra simples, como por exemplo, realizando a soma ou o produto dos valores de cada plano.

Tendo como base de avaliação a imagem perfeitamente classificada, os resultados com os dados simulados nos experimentos controlados das dezessete classificações monofontes e multifontes alcançaram acurácia global de 100%. Não houve confusão entre os segmentos das classes em nenhuma das classificações que foram construídas com diferentes modelagens estatísticas, distâncias estocásticas e combinações. Dessa maneira, as imagens temáticas (imagens classificadas) em todas as classificações apresentadas na parte (a) nas Figuras 4.8 a 4.15 são iguais. Porém, as imagens probabilidades apresentadas na parte (b) dessas figuras são diferentes, pois os valores- $p$  finais são diferentes para cada distância e modelagem estatística. Analisando os resultados, conclui-se que, além de mostrarem a alta qualidade do classificador, uma vez que as suposições teóricas da metodologia foram perfeitamente satisfeitas, esses resultados mostram que o *software* desenvolvido gera resultados corretos e confiáveis para os dados simulados. No Apêndice B são apresentados os resultados detalhados das classificações construídas no caso de teste com dados simulados desta seção e que evidenciam a corretitude e a confiabilidade da ferramenta computacional desenvolvida neste trabalho.



Figura 4.8 - Resultados para a classificação da imagem simulada PolSAR com a distância de *Bhattacharyya*.




(a) Imagem classificada

(b) Imagem de probabilidade

Fonte: Produção do autor.

Figura 4.9 - Resultados para a classificação do par de imagens SAR simuladas HH,HV com a distância de *Bhattacharyya*.




(a) Imagem classificada

(b) Imagem de probabilidade

Fonte: Produção do autor.

Figura 4.10 - Resultados para a classificação da imagem SAR simulada em amplitude multivarida com a distância de *Bhattacharyya*.




(a) Imagem classificada

(b) Imagem de probabilidade

Fonte: Produção do autor.

Figura 4.11 - Resultados para a classificação da imagem SAR simulada monocanal em intensidade HH com a distância de *Bhattacharyya*.




(a) Imagem classificada

(b) ImagemMapa de probabilidade

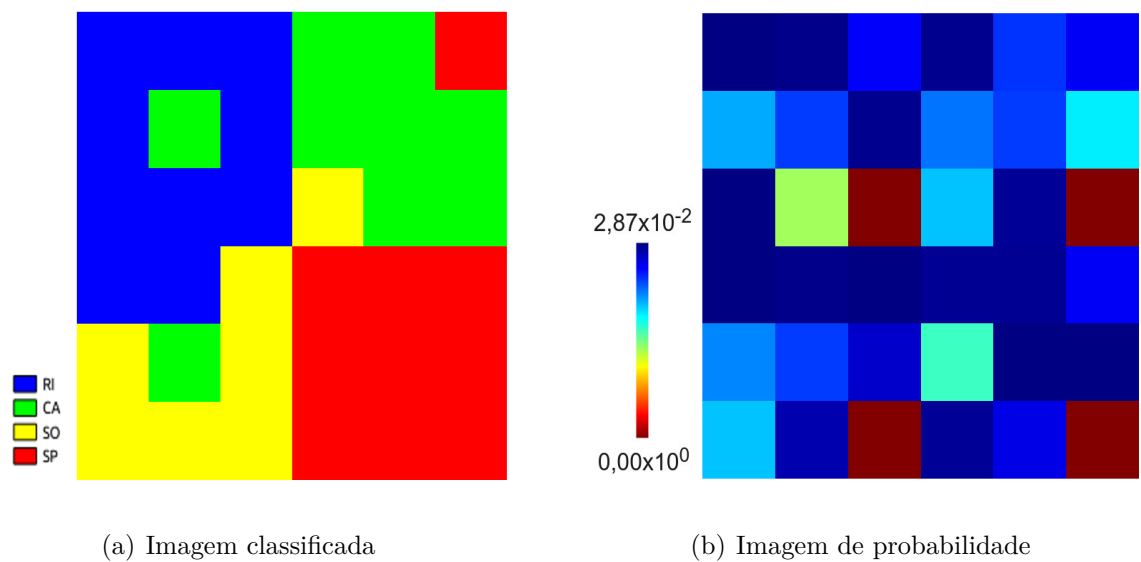
Fonte: Produção do autor.

Figura 4.12 - Resultados para a classificação multifonte com a combinação da soma.




Fonte: Produção do autor.

Figura 4.13 - Resultados para a classificação multifonte com a combinação do produto.



Fonte: Produção do autor.

Figura 4.14 - Resultados para a classificação multifonte com a combinação dos mínimos.

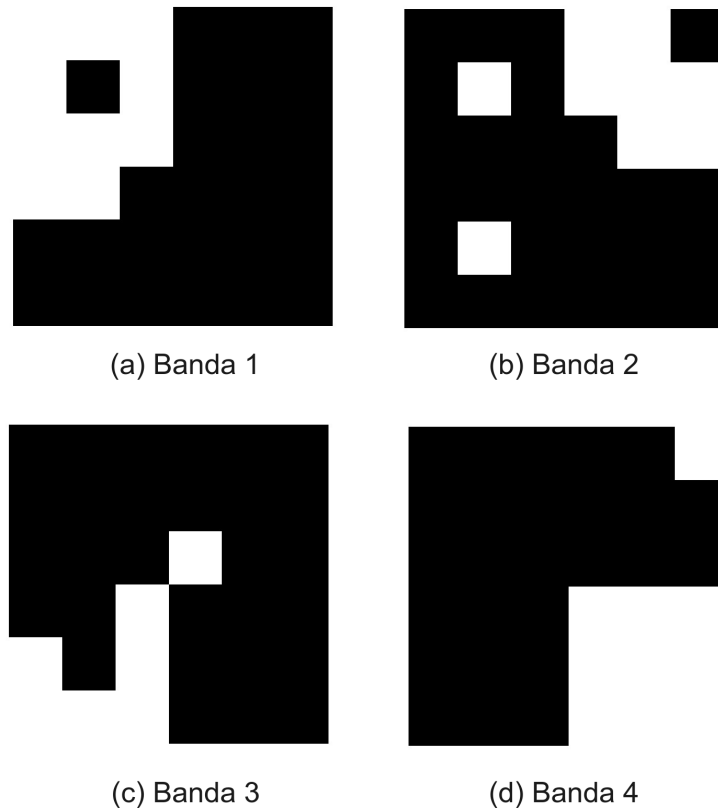


(a) Imagem classificada

(b) Imagem de probabilidade

Fonte: Produção do autor.

Figura 4.15 - Resultados para a classificação multifonte com a combinação *Fuzzy*.



As 4 bandas em escala de cinza da classificação *Fuzzy* correspondentes às classes RI, CA, SO, SP, respectivamente. A cor branca representa 1 (região rotulada com a classe  $k$  em todas as classificações monofontes) e a cor preta representa 0 (região não rotulada em nenhuma das classificações monofontes com a classe  $k$ ). Não houve valores entre 0 e 1, o que indicaria classificações diferentes entre os casos monofontes.

Fonte: Produção do autor.


### 4.2.2 Aplicação a dados reais

Nesta seção são usados dados reais para realizar experimentos de validação dos resultados do *software* nas classificações. Os dados reais consistem em imagens com dimensões maiores que os dados simulados e são provenientes de sensores distintos e independentes. A área de estudo e os dados são os mesmos utilizados em Braga (2016), uma vez que se trata da aplicação na mesma metodologia como descrito em 2.6.2. Dessa forma, obtêm-se parâmetros de comparação para fins de validação do sistema. É importante destacar que todos os procedimentos de pré-processamento dos dados, como registro, recortes e segmentação, estão descritos em Braga (2016).

Testes realizados no *software* PolClass mostraram que há um problema no cálculo dos parâmetros das classes no módulo responsável pelas classificações que adotam a modelagem pela distribuição Wishart complexa escalonada. Os experimentos desta Subseção se limitam às classificações monofontes, uma vez que, todas as classificações multifontes construídas em Braga (2016) utilizam, pelo menos, uma monofonte com a modelagem Wishart gerada pelo *software* PolClass. Devido ao problema encontrado no módulo responsável pelas classificações que adotam tal modelagem, preferiu-se não usar os resultados das multifontes como parâmetros de comparação para validações. Contudo, a aplicação de dados reais na validação de cada módulo apresentado no Capítulo 3 foi considerada importante e é apresentada a seguir.


Uma imagem óptica e uma de sensor micro-ondas foram utilizadas e ambas pertencem a uma região localizada próximo do Rio Tapajós, na região do estado do Pará, Brasil. As duas imagens utilizadas nos experimentos desta seção, ilustradas nas Figuras 4.16 e 4.17, têm dimensões  $1623 \times 1817$  pixels e estão na projeção UTM (*Universal Transverse Mercator*), zona 21 sul, datum WGS84 (*World Geodetic System* 1984). A imagem óptica, apresentada na Figura 4.16, é proveniente do sensor *Thematic Mapper* (TM) do satélite Landsat5 datada de 12 de julho de 2009. A imagem de micro-ondas, exibida na Figura 4.17, é proveniente do sensor *Phase Array L-Band Synthetic Aperture Radar 2* (Palsar 2) do satélite *Advanced Land Observing System 2* (Alos 2) datada de 28 de abril de 2009. A imagem SAR possui as quatro polarizações (HH, HV, VV e VH) e número equivalente de *looks* igual a 5 (BRAGA, 2016). Para fins de simplificação, no texto as imagens óptica e de micro-ondas são denominadas pelos termos TM e Palsar, respectivamente.

Figura 4.16 - Imagem TM na composição 5(R)4(G)3(B).



Fonte: Adaptado de Braga (2016).

Figura 4.17 - Imagem Palsar na composição HH(R)HV(G)HH(B).



Fonte: Adaptado de Braga (2016).




Sete classes de uso e cobertura da Terra foram adotadas, a saber: Floresta Primária (FP), Regeneração Antiga (RA), Regeneração Intermediária (RT), Regeneração Inicial (RI), Pasto Sujo (PS), Pasto Limpo (PL) e Solo Exposto (SE) (BRAGA, 2016). As amostras de treinamento e de teste foram obtidas por meio de dados de campos realizados em 2009 e 2015, com base na imagem TM e suas localizações são mostradas nas Figuras 4.18 e 4.19, respectivamente.

As segmentações das imagens foram obtidas por meio do *software* SegSAR (SOUSA-JÚNIOR, 2005). Para a segmentação da imagem Palsar, utilizaram-se as suas bandas em intensidades. Adotou-se o modelo de manchas em sete níveis, similaridade de 1,0 db, área mínima de 20 pixels e nível de confiabilidade de 95% aplicados às polarizações HH, HV, VH e VV. Para a segmentação da imagem TM, considerou-se todas as bandas e foi utilizado o modelo de manchas em sete níveis, similaridade 16,0 db, coeficiente de variação 0,6 e área mínima de 20 pixels.

As duas segmentações foram combinadas por meio do *software* ArcMap 10.2, gerando uma única segmentação contendo 2499 segmentos, na qual áreas menores que 50 pixels foram agrupadas com uso da ferramenta denominada rotulação de componentes conectados do SPRING 5.2.2. Uma representação da segmentação final sobre a imagem TM é apresentada na Figura 4.20. Ressalta-se que os passos da obtenção da imagem segmentada unificada foram feitos em Braga (2016).


Com o objetivo de verificar a corretitude dos resultados obtidos no *software*, foram construídas as mesmas classificações monofontes realizadas em Braga (2016) com as imagens TM e Palsar para que os resultados pudessem ser comparados, como é mostrado na Tabela 4.1. Os experimentos foram feitos considerando os mesmos parâmetros utilizados em Braga (2016), onde o nível de confiança é igual a 95%, na estimação dos parâmetros das distribuições que modelam os dados todas as amostras (segmentos e classes) foram subamostradas usando *lag* 0 e  $\beta$  igual a 0,9 para a distância de *Rényi*. A classificação de pares de imagens em intensidade foi realizada com as polarizações HV,VV como em Braga (2016), pois, comparada às outras combinações (HH,HV e HH,VV) foi a que obteve os melhores índices de acurácia para a imagem Palsar.

Figura 4.18 - Localização das amostras de treinamento sobre a imagem TM na composição colorida 3(R)4(G)5(B).




Fonte: Produção do autor.

Figura 4.19 - Localização das amostras de teste sobre a imagem TM na composição colorida 3(R)4(G)5(B).



Fonte: Produção do autor.

Figura 4.20 - Segmentação sobreposta à imagem TM na composição colorida 5(R)4(G)3(B).



Fonte: Adaptado de Braga (2016).

Após testes e análises, constatou-se que há um problema nas opções da interface gráfica das distâncias estocásticas no módulo que classifica pares de imagens SAR em intensidade do *software* PolClass. Como os resultados em Braga (2016) foram gerados por intermédio do PolClass, as classificações de pares de imagens em intensidade outrora publicadas com a distância de *Bhattacharyya*, foram feitas na realidade com a Triangular. Para a realização dos experimentos neste trabalho, a correção desta informação já está sendo considerada. Para a validação e comparação das classificações, se utilizaram os índices de acurácias adquiridos por intermédio da matriz de confusão coeficiente *Kappa* e acurácia global. Na Tabela 4.1 são exibidos os coeficientes *Kappas* e as acurácias globais correspondentes às classificações produzidas neste trabalho e em Braga (2016).

Tabela 4.1 - Classificações monofontes com dados reais.

Imagem	Modelagem estatística	Distância estocástica	<i>Kappa</i>	Acurácia global (%)	(BRAGA, 2016)	
					<i>Kappa</i>	Acurácia global (%)
TM	Gaussiana	<i>Bhattacharyya</i>	0,50	60,58	0,50	60,58
		<i>Kullback-Leibler</i>	0,49	58,88	0,49	58,88
Palsar	Wishart	<i>Kullback-Leibler</i>	0,11	20,88	0,11	20,52
		<i>Rényi</i>				
		<i>Bhattacharyya</i>			0,14	22,72
		<i>Hellinger</i>				
	Par de Intensidades	Triangular	0,14	23,09	0,14	23,09

Fonte: Produção do autor.


Observa-se que para a imagem TM, as classificações com o módulo Gaussiana obtiveram os mesmos resultados de *Kappa* e acurácia global que os obtidos em Braga (2016) nas duas distâncias estocásticas (*Bhattacharyya* e *Kullback-Leibler*). No caso da imagem Palsar, os resultados entre as duas plataformas computacionais foram diferentes para a modelagem Wishart e iguais para a classificação do par de imagens em intensidade. Por intermédio do módulo Wishart, foram obtidos os mesmos valores de *Kappa* e acurácia global em todas as distâncias estocásticas. Com o PolClass, os índices obtidos para as distâncias de *Kullback-Leibler* e *Rényi* foram diferentes das distâncias de *Bhattacharyya* e *Hellinger*. Além disso, para estas duas últimas distâncias os índices obtidos se diferem mais entre os dois *softwares* do que para as outras duas. Essas diferenças nos índices de avaliação são devido a um problema no cálculo das médias das matrizes de covariância no PolClass. Isso pode ser melhor

verificado no caso de teste do Apêndice C. Dessa forma, as classificações de imagens SAR polarimétricas obtidas por meio do PolClass não serão usadas como parâmetro de comparação, pois, não é possível ter um controle dos resultados dessas classificações. O caso de teste apresentado no Apêndice C evidencia ainda que os resultados gerados pela ferramenta computacional desenvolvida neste trabalho são iguais aos resultados esperados.


As classificações monofontes são ilustradas nas Figuras 4.21 a 4.27. Nestas figuras apresentam-se (a) as imagens classificadas e (b) as imagens de possibilidade ou imagens de incerteza das classificações.



Figura 4.21 - Classificação por meio da distribuição Gaussiana multivariada com a distância de *Bhattacharyya*.




(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.

Figura 4.22 - Classificação por meio da distribuição Gaussiana multivariada com a distância de *Kullback-Leibler*.




(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.



Figura 4.23 - Classificação por meio da distribuição Wishart complexa escalonada com a distância de *Kullback-Leibler*.




(a) Imagem classificada

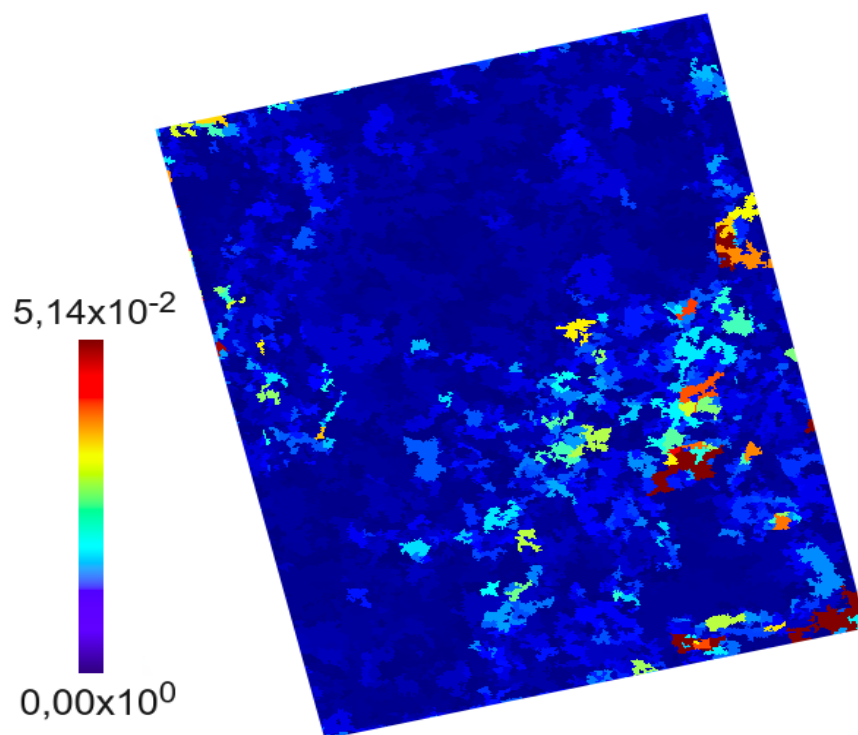


(b) Imagem de possibilidade  
Fonte: Produção do autor.

Figura 4.24 - Classificação por meio da distribuição Wishart complexa escalonada com a distância de Rényi.




(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.

Figura 4.25 - Classificação por meio da distribuição Wishart complexa escalonada com a distância de *Bhattacharyya*.




(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.

Figura 4.26 - Classificação por meio da distribuição Wishart complexa escalonada com a distância de *Hellinger*.




(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.

Figura 4.27 - Classificação por meio da distribuição Par de Intensidades *multilook* com a distância Triangular.



(a) Imagem classificada



(b) Imagem de possibilidade  
Fonte: Produção do autor.




### 4.3 Avaliação entre dados polarimétricos, dados bivariados e dados monocanais

O módulo Gama, apresentado na Subseção 3.2.4, foi aplicado às imagens SAR monocanais em intensidade, com vistas a avaliar a potencialidade de utilização. Outro objetivo é verificar se a utilização de dados monocanais resulta em maiores contribuições nos resultados finais de classificação em comparação aos resultados obtidos por intermédio de dados bivariados e polarimétricos completos. O resultado da análise é relevante para o estudo, uma vez que, na modelagem dos dados monocanais pela distribuição Gama existem expressões fechadas para o cálculo de distâncias estocásticas. Para a modelagem dos dados bivariados pela distribuição Par de Intensidades é necessário utilizar um método numérico, tornando este um caso de maior complexidade e bem mais demorado. Os dados polarimétricos completos, por outro lado, geralmente não estão disponíveis ao usuário e são bem mais caros que os incompletos. Como parte do processo de avaliação, além da influência da distribuição utilizada para a modelagem dos dados, examinaram-se também a intervenção da distância estocástica adotada nos resultados obtidos. A descrição dos dados utilizados é feita na Subseção 4.3.1 e os resultados da classificação são apresentados e discutidos na Subseção 4.3.2.

#### 4.3.1 Descrição dos dados utilizados

Os dados utilizados nesta Subseção pertencem à mesma área de estudo apresentada na Subseção 4.2.2 e as etapas de pré-processamentos não foram realizadas neste trabalho, pois o foco principal está no classificador. Portanto, os detalhes de como foram obtidas a segmentação, coletadas as amostras das classes, correções e registro de imagens são omitidos no texto, mas podem ser encontrados em Braga et al. (). A imagem óptica do sensor TM do satélite Landsat5, ilustrada na Figura 4.28, é de 12 de julho de 2009. A imagem de micro-ondas, mostrada na Figura 4.29, é oriunda do sensor Radarsat2 (banda C), possui as quatro polarizações (HH, HV, VH e VV) e é de 19 de setembro de 2009. As principais características das imagens Landsat5/TM e Radarsat são exibidas nas Tabelas 4.2 e 4.3, respectivamente. O número equivalente de *looks* estimado para a imagem Radarsat foi 8. Ambas as imagens estão corregradas, com resoluções de  $15 \times 15$  m, dimensões  $1217 \times 1682$  pixels e no sistema de projeção UTM e datum WGS84. As três imagens SAR em intensidade obtidas por meio dos elementos da diagonal principal da matriz de covariância são apresentadas nas Figuras 4.30 a 4.32.


Figura 4.28 - Imagem Landsat/TM em composição colorida 5(R)4(G)3(B).



Fonte: Produção do autor.



Figura 4.29 - Imagem Radarsat2 em composição colorida HH(R)HV(G)VV(B).



Fonte: Produção do autor.



Tabela 4.2 - Características da imagem TM.

Características	TM
Resolução espacial	30 m
Resolução radiométrica	8 bits
Resolução espectral	7 bandas: 0,45 a 0,52 $\mu\text{m}$ ; 0,52 a 0,60 $\mu\text{m}$ ; 0,63 a 0,69 $\mu\text{m}$ ; 0,76 a 0,90 $\mu\text{m}$ ; 1,55 a 1,75 $\mu\text{m}$ ; 10,4 a 12,5 $\mu\text{m}$ ; 2,08 a 2,35 $\mu\text{m}$ .

Fonte: Produção do autor.


Tabela 4.3 - Características da imagem Radarsat.

Características	Radarsat
Tipo de dado	SLC ( <i>Single Look Complex</i> )
Ângulo de incidência no <i>near range</i>	$\approx 32^\circ$
Ângulo de incidência no <i>far range</i>	$\approx 34^\circ$
Órbita	Ascendente
Número de visadas	1 $\times$ 1
Resolução	3 m a 100 m
Resolução radiométrica	32 Bits
Comprimento de onda	3,75 cm a 7,5 cm
Frequência	5,4GHz (Banda C)

Fonte: Adaptado de Braga et al. ().


A imagem segmentada utilizada nesta Subseção contém 6411 segmentos e cada segmento possui no mínimo 40 pixels, como é mostrado na Figura 4.33. A segmentação única foi obtida por meio do *software* ArcMap 10.2 e ambas as segmentações individuais foram obtidas por meio do SegSAR. Para a segmentação da imagem Radarsat utilizaram-se as bandas em intensidades, adotou-se o modelo de manchas em seis níveis, similaridade de 5,0 db e nível de confiabilidade de 95%. Para a segmentação da imagem TM, todas as seis bandas foram consideradas e utilizou-se o modelo de manchas em dois níveis, similaridade 10,0 db e coeficiente de variação 0,6. As sete classes de uso e cobertura empregadas nesta Seção foram: Floresta Primária (FP), Floresta Degradada (FD), Regeneração Intermediária (RM), Regeneração Inicial (RI), Pasto Sujo (PS), Pasto Limpo (PL) e Agricultura (AG) (BRAGA et al., ). As amostras de treinamento e de teste são apresentadas na Figura 4.34.

Figura 4.30 - Canal em intensidade HH da imagem Radarsat.




Fonte: Produção do autor.

Figura 4.31 - Canal em intensidade HV da imagem Radarsat.



Fonte: Produção do autor.


Figura 4.32 - Canal em intensidade VV da imagem Radarsat.



Fonte: Produção do autor.




Figura 4.33 - Segmentação única construída por meio da união das segmentações individuais das imagens TM e Radarsat.



Fonte: Produção do autor.

Figura 4.34 - Localização das amostras de treinamento e de teste sobre a imagem TM em composição colorida 1(R)2(G)3(B).



As amostras de teste estão representadas pelas formas sólidas e as amostras de teste estão representadas pelas linhas.

Fonte: Produção do autor.

### 4.3.2 Resultados obtidos

Como pode se notar na Seção 3.2, existem quatro fórmulas fechadas para o cálculo de distâncias entre *f.d.p.*'s Gama. Considerando a hipótese da condição de reciprocidade ( $HV = VH$ ), é possível formar 4 classificações distintas para cada uma das 3 componentes em intensidade (HH, HV e VV) da imagem radarsat, totalizando 12 classificações monofontes. Inicialmente, construíram-se as 12 classificações possíveis com a modelagem Gama. Adicionalmente, produziram-se as classificações da imagem em matriz de covariância com a modelagem Wishart complexa escalonada e dos pares em intensidade HH\_HV, HH\_VV e VV\_HV com a Par de Intensidades *multi-look*. Na estimação dos parâmetros das distribuições que modelam os dados, todas as amostras (segmentos e classes) foram subamostradas usando *lag* 0, nível de confiança 95% e  $\beta$  igual a 0,5 para a distância *Rényi*, com base em diversas referências (SILVA, 2013; BRAGA, 2016).

A validação das classificações ocorreu através dos índices de acurácias coeficiente *Kappa* e acurácia global, ambos adquiridos a partir da matriz de confusão. Para verificar o tempo de execução, o programa foi executado três vezes para cada classificação e a média dos tempos foi calculada. As configurações do computador utilizado para a execução do programa são listadas na Tabela 4.4. As 12 classificações monofontes mencionadas anteriormente estão descritas na Tabela 4.5, onde são apresentados os coeficientes *Kappas*, as acurácias globais e os tempos de execução correspondentes a cada uma das classificações monofontes produzidas. Os *Kappas* e as acurácias globais obtidas nas classificações monofontes podem ser melhor visualizadas e comparadas nos gráficos apresentados, respectivamente, nas Figuras 4.35 e 4.36.

Tabela 4.4 - Configurações do computador utilizado para os experimentos.

Sistema operacional	Ubuntu 14.04 LTS 64-bit
Processador	Intel Core i7 1,80 GHz
Memória RAM	6 GB

Fonte: Produção do autor.

Observa-se que as médias dos tempos de execução são praticamente as mesmas quando se variam as distâncias das distribuições e, portanto, a escolha da distância não altera no tempo de classificação. Ainda em relação aos tempos de execução, nota-se que, a classificação de pares de imagens em intensidade demora mais do

que a dos outros tipos de imagens. O tempo médio para esta imagem comparado as outras foi 6 vezes maior. Isso é esperado, uma vez que para calcular as distâncias entre distribuições Pares de Intensidade *multi-look* utiliza-se um método numérico. Para as distâncias entre as demais distribuições utilizam-se expressões fechadas. Os menores tempos foram obtidos nas classificações das imagens SAR monocanais em intensidade (média de 88 segundos). As imagens TM e PolSAR obtiveram a mesma média de 100 segundos de tempo de execução. Embora todas as distâncias entre as distribuições Gaussiana, Wishart e Gama sejam fórmulas fechadas, as diferenças entre os tempos médios de execução se explicam pelo número de bandas das imagens serem diferentes. Imagens SAR monocanais modeladas pela Gama tem uma única banda, já as imagens polarimétricas, SAR multivariadas em amplitude e ópticas modeladas pela Wishart e Gaussiana possuem  $n$  bandas ( $n \geq 1$ ).

Tabela 4.5 - Classificações monofontes.

Modelagem estatística	Imagem	Distância estocástica	Tempo de execução (s)	<i>Kappa</i>	Acurácia global (%)
Gaussiana multivariada	TM	<i>Bhattacharyya</i>	100,175	0,87	90,64
		<i>Kullback-Leibler</i>	100,442		90,61
Gama	HH	<i>Bhattacharyya</i>	88,352	0,41	49,28
		<i>Kullback-Leibler</i>	89,005		
		<i>Rényi</i>	88,281		
		<i>Hellinger</i>	88,221		
	HV	<i>Bhattacharyya</i>	87,491	0,52	59,11
		<i>Kullback-Leibler</i>	89,608		
		<i>Rényi</i>	88,154		
		<i>Hellinger</i>	88,292		
	VV	<i>Bhattacharyya</i>	88,389	0,52	59,11
		<i>Kullback-Leibler</i>	88,429		
		<i>Rényi</i>	88,116		
		<i>Hellinger</i>	89,416		
Wishart complexa escalonada	PolSAR	<i>Kullback-Leibler</i>	101,912	0,46	54,54
		<i>Rényi</i>	101,187		
		<i>Bhattacharyya</i>	101,482		
		<i>Hellinger</i>	103,935		
		Qui-quadrado	101,602	0,43	52,26
Par de Intensidades <i>multi-look</i>	HH,HV	<i>Bhattacharyya</i>	574,171	0,53	60,08
		Triangular	585,098		
	HH,VV	<i>Bhattacharyya</i>	567,912	0,50	57,45
		Triangular	615,026		
	VV,HV	<i>Bhattacharyya</i>	601,447	0,62	67,92
		Triangular	562,887		

Fonte: Produção do autor.




Figura 4.35 - Comparação dos *Kappas* obtidos nas classificações monofontes.



Fonte: Produção do autor.

Figura 4.36 - Comparação das acurácias globais obtidas nas classificações monofontes.



Fonte: Produção do autor.

Analisando-se o comportamento das classificações, verifica-se que, ao variar-se a modelagem e o tipo de dado, os resultados obtidos independem das distâncias adotadas neste trabalho. Analisando os resultados obtidos nas classificações das imagens monocanais em intensidade, modeladas por meio da distribuição Gama, nota-se que para HV e VV obtêm-se acurácias globais e índices *Kappas* iguais. Nota-se também que em comparação com a HH, o coeficiente *Kappa* e acurácia global, nesta ordem, apresentam valores 26,83% e 9,83% inferiores para as imagens HV e VV.

Observa-se que, de forma geral, a distribuição que apresenta as maiores acurácias globais e os maiores índices *Kappas* para a imagem Radarsat é a distribuição Par de Intensidades *multilook*. O par de imagens VV,HV apresentou resultados superiores às demais classificações produzidas. Sendo os valores da acurácia global e do *Kappa* 8,81% e 19,23%, respectivamente, superiores àqueles apresentados quando de adotam as imagens monocanais HV e VV. Comparando com a HH, notam-se os valores de 18,64% e 51,22% superiores para o par VV,HV.

Ainda para a distribuição Par de Intensidades *multilook*, observa-se entre o par HH,HV e as monocanais HV e VV uma acurácia global e um *Kappa* 0,97% e 1,92% superiores para o par HH,HV. Em relação à monocanal HH, esses valores são 10,80% e 29,27% superiores para o par de imagens. O único caso que os resultados foram diferentes, foi para o par HH,VV. Nesse caso, os índices das acurácias e dos *Kappas* das monocanais HV e VV foram 1,66% e 4,00% superiores aos do par HH,VV.

Para a modelagem da imagem Radarsat por meio da distribuição Wishart complexa escalonada, com exceção da distância Qui-quadrado, se notam valores de acurácia global e do *Kappa* 4,57% e 13,04% inferiores aos valores das monocanais HV e VV. Em comparação à monocanal HH, observa-se esses índices 5,26% e 12,19% superiores para a distribuição Wishart. Nota-se ainda que, os índices obtidos em todos os casos de classificações de pares de imagens em intensidade foram superiores em relação à imagem polarimétrica. Para a distância Qui-quadrado os índices foram inferiores aos resultados obtidos utilizando as demais distâncias entre distribuições Wishart. Esta distância também apresentou fraco desempenho nos trabalhos de outros autores, como por exemplo, [FRERY et al. \(2011\)](#) e [Silva \(2013\)](#).

Nota-se que a imagem TM, modelada por intermédio da distribuição Gaussiana multivariada, obteve valores de acurácia global e *Kappa* superiores aos obtidos em todas as classificações da imagem Radarsat, independente da distribuição adotada. Nota-se apenas uma variação muito pequena nas acurácias globais obtidas com as distâncias *Bhattacharyya* e *Kullback-Leibler*. Os índices obtidos para a imagem Ra-


darsat foram inferiores aos índices obtidos com a TM e dentre as justificativas para isso citam-se: as amostras das classes foram coletadas usando a imagem TM, as datas de aquisição das imagens TM e Radarsat não são as mesmas e a área de estudo é uma região transitória.

Refletindo acerca dos resultados discutidos, verifica-se que, os maiores valores de acurácia para a imagem Radarsat ocorrem quando se adota a distribuição Par de Intensidades *multilook* para modelagem dos dados, assim como a Gama quando se adotam as monocanais HV e VV. Como é possível observar, os valores dos índices obtidos nas classificações dos pares HH,HV e HH,VV e das monocanais HV e VV são similares, pois apresentam diferenças ligeiras. As duas monocanais obtiveram ainda índices de acurácia superiores aos da imagem polarimétrica modelada pela distribuição Wishart complexa escalonada.


Para a análise dos resultados de classificação adotou-se também a imagem de possibilidade relativa à incerteza da classificação. Nesta imagem, quanto o menor valor  $s$  obtido, maior a confiabilidade da classificação, e portanto, os valores em sua escala são apresentados na ordem decrescente. A exceção foi nos casos de classificações com a distribuição Gama, em que as imagens de probabilidade foram melhores representativas. A imagem de probabilidade é relativa à certeza da classificação e quanto maior o valor- $p$  obtido, maior a confiabilidade da classificação. As classificações monofontes são ilustradas nas Figuras 4.37 a 4.60. Nestas figuras apresentam-se (a) as imagens classificadas e (b) a imagem de possibilidade ou a imagem de probabilidade.

Nas imagens 4.37 e 4.38, referentes aos resultados das classificações da imagem TM com as distâncias de *Bhattacharyya* e *Kullback-Leibler*, respectivamente, são destacadas algumas regiões nas imagens classificadas. Essas regiões destacadas mostram que mesmo que os valores dos *Kappas* (apresentados na Tabela 4.5) sejam iguais para distâncias distintas, os resultados nas imagens classificadas podem ser diferentes. Isso acontece porque a validação da classificação é amostral, ou seja, são utilizadas amostras de teste e não a imagem inteira para obter os índices de avaliação. Outro exemplo é mostrado nas Figuras 4.57 e 4.37, correspondentes aos resultados das classificações do par de imagens HH,VV com as distâncias de *Bhattacharyya* e Triangular, respectivamente. Nessas figuras também são destacadas regiões rotuladas de forma diferente nas imagens classificadas. Já os índices *Kappas* e acurácias globais são iguais para as duas classificações, como mostrado na Tabela 4.5.

Figura 4.37 - Classificação da imagem TM com a distância de *Bhattacharyya*.



(a) Imagem classificada




(b) Imagem de possibilidade


As 3 regiões em destaque na (a) imagem classificada mostram regiões rotuladas com classes diferentes em relação à imagem classificada da Figura 4.38(a).

Fonte: Produção do autor.

Figura 4.38 - Classificação da imagem TM com a distância de *Kullback-Leibler*.



(a) Imagem classificada

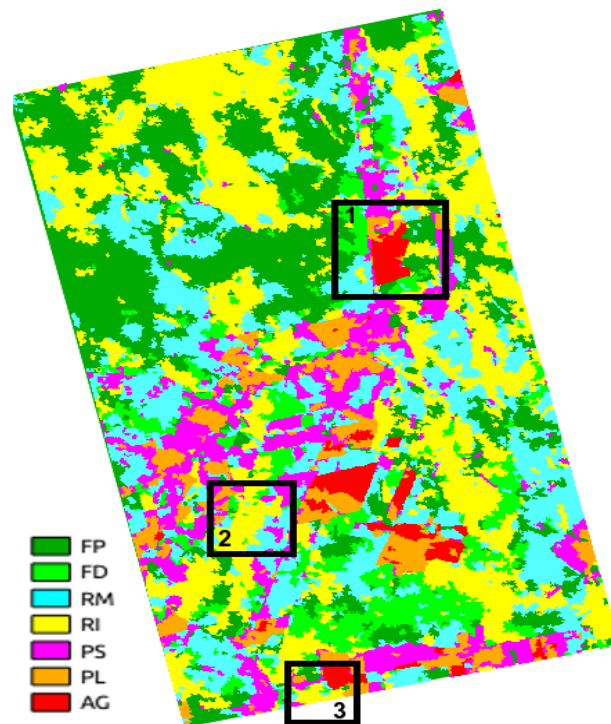


(b) Imagem de possibilidade


As 3 regiões em destaque na (a) imagem classificada mostram regiões rotuladas com classes diferentes em relação à imagem classificada da Figura 4.37(a).

Fonte: Produção do autor.

Figura 4.39 - Classificação do par de imagens HH,VV com a distância de *Bhattacharyya*.



(a) Imagem classificada

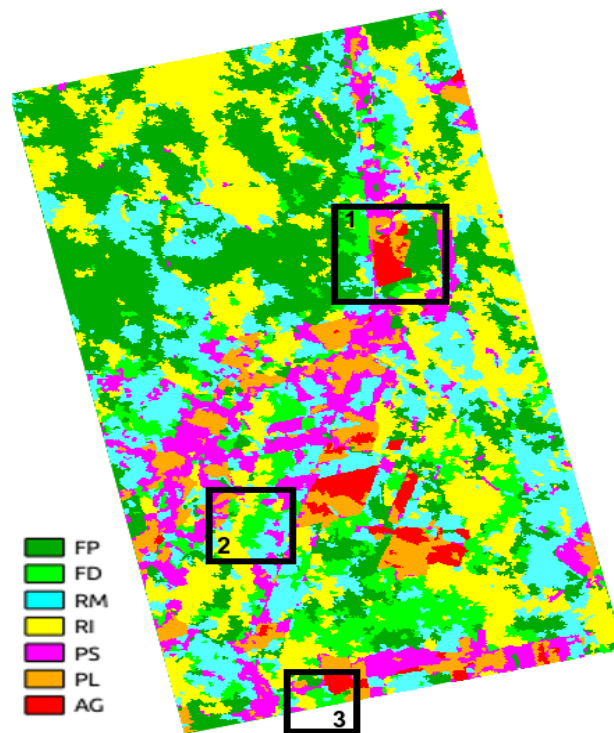


(b) Imagem de possibilidade


As 3 regiões em destaque na (a) imagem classificada mostram regiões rotuladas com classes diferentes em relação à imagem classificada da Figura 4.40(a).

Fonte: Produção do autor.

Figura 4.40 - Classificação do par de imagens HH,VV com a distância de Triangular.



(a) Imagem classificada




(b) Imagem de possibilidade

As 3 regiões em destaque na (a) imagem classificada mostram regiões rotuladas com classes diferentes em relação à imagem classificada da Figura 4.39(a).


Fonte: Produção do autor.



Figura 4.41 - Classificação da imagem monocanal HH com a distância de *Bhattacharyya*.



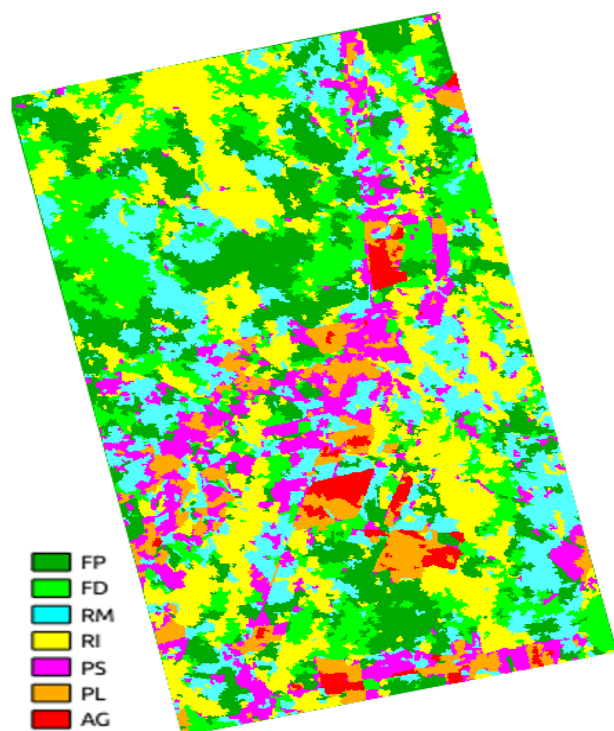
(a) Imagem classificada




(b) Imagem de probabilidade  
Fonte: Produção do autor.



Figura 4.42 - Classificação da imagem monocanal HH com a distância de *Kullback-Leibler*.



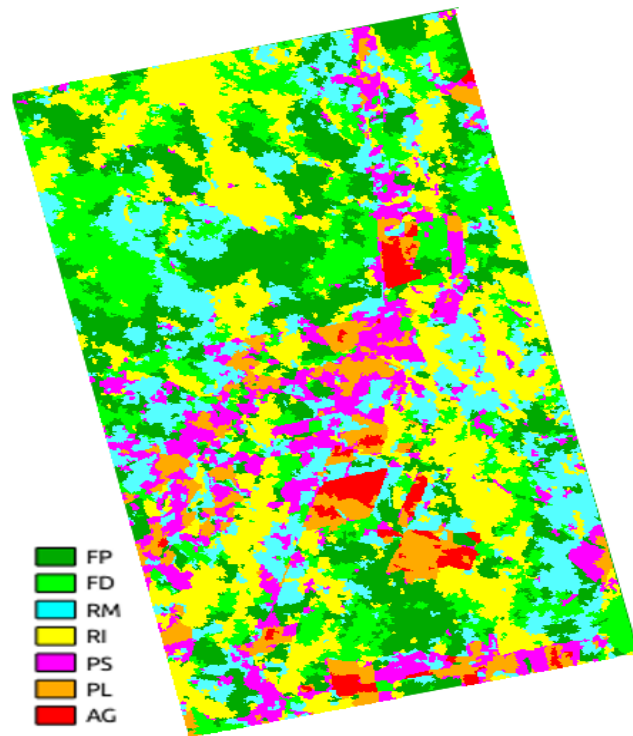
(a) Imagem classificada




(b) Imagem de probabilidade

Fonte: Produção do autor.

Figura 4.43 - Classificação da imagem monocanal HH com a distância de Rényi.

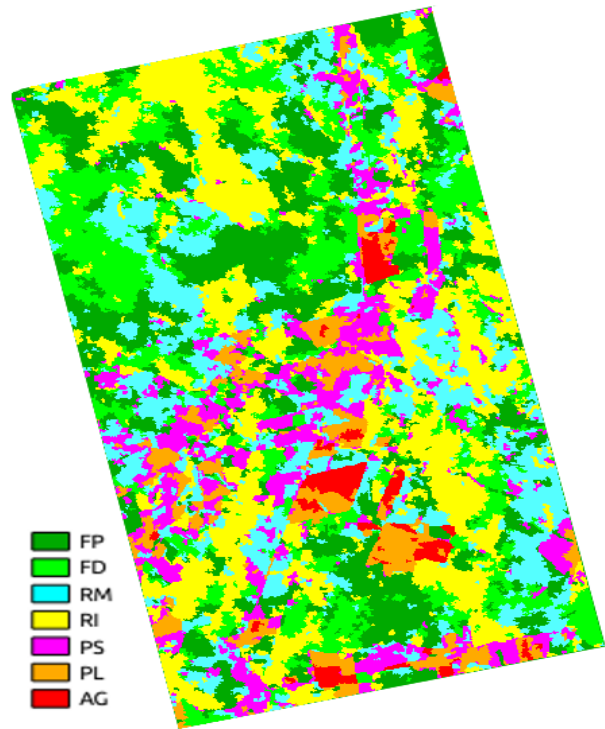


(a) Imagem classificada




(b) Imagem de probabilidade  
Fonte: Produção do autor.

Figura 4.44 - Classificação da imagem monocanal HH com a distância de *Helinger*.




(a) Imagem classificada




(b) Imagem de probabilidade  
Fonte: Produção do autor.

Figura 4.45 - Classificação da imagem monocanal HV com a distância de *Bhattacharyya*.

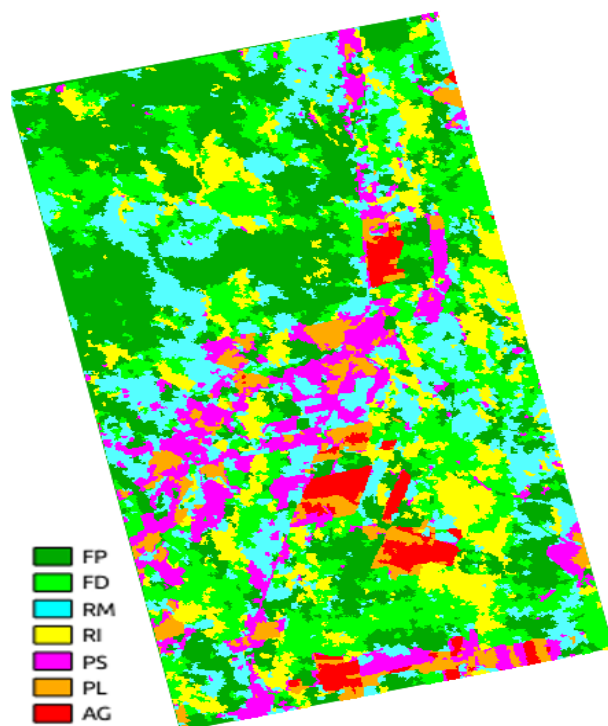


(a) Imagem classificada




(b) Imagem de probabilidade  
Fonte: Produção do autor.

Figura 4.46 - Classificação da imagem monocanal HV com a distância de *Kullback-Leibler*.




(a) Imagem classificada




(b) Imagem de probabilidade

Fonte: Produção do autor.

Figura 4.47 - Classificação da imagem monocanal HV com a distância de Rényi.




(a) Imagem classificada




(b) Imagem de probabilidade  
Fonte: Produção do autor.



Figura 4.48 - Classificação da imagem monocanal HV com a distância de *Hellinger*.

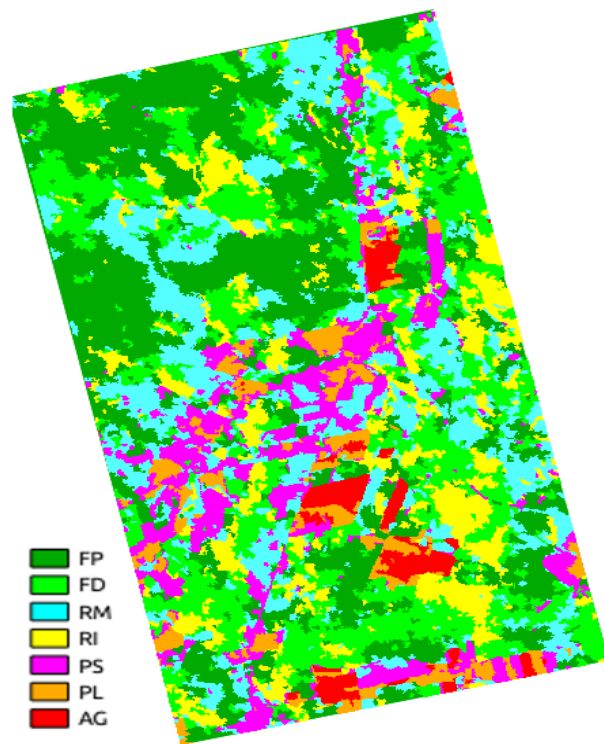


(a) Imagem classificada




(b) Imagem de probabilidade  
Fonte: Produção do autor.

Figura 4.49 - Classificação da imagem monocanal VV com a distância de *Bhattacharyya*.



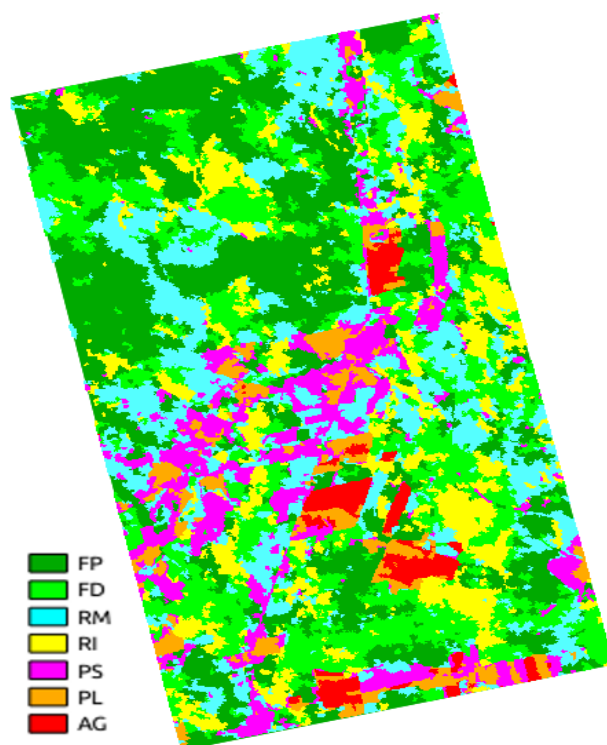
(a) Imagem classificada




(b) Imagem de probabilidade  
Fonte: Produção do autor.



Figura 4.50 - Classificação da imagem monocanal VV com a distância de *Kullback-Leibler*.



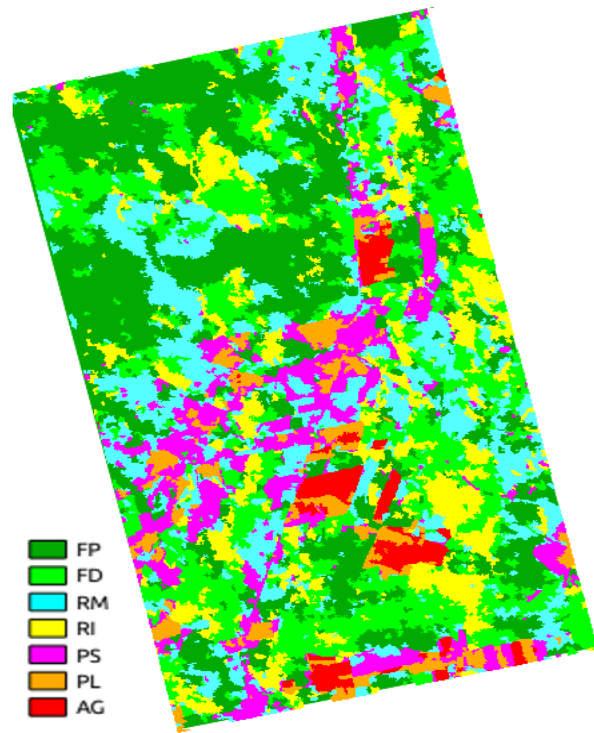
(a) Imagem classificada




(b) Imagem de probabilidade

Fonte: Produção do autor.

Figura 4.51 - Classificação da imagem monocanal VV com a distância de *Hellinger*.




(a) Imagem classificada




(b) Imagem de probabilidade  
Fonte: Produção do autor.

Figura 4.52 - Classificação da imagem monocanal VV com a distância de Rényi ( $\beta = 0,5$ ).



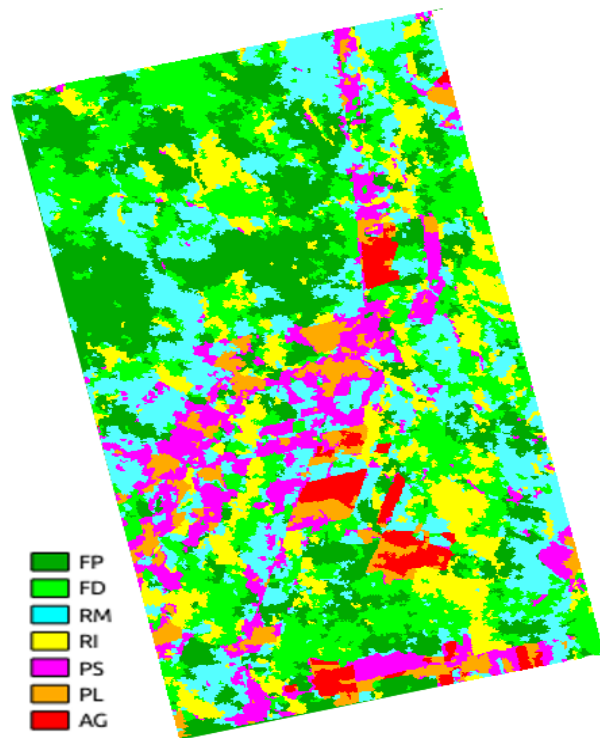
(a) Imagem classificada




(b) Imagem de probabilidade

Fonte: Produção do autor.

Figura 4.53 - Classificação da imagem PolSAR com a distância de *Bhattacharyya*.




(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.

Figura 4.54 - Classificação da imagem PolSAR com a distância de *Kullback-Leibler*.




(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.

Figura 4.55 - Classificação da imagem PolSAR com a distância de Rényi.

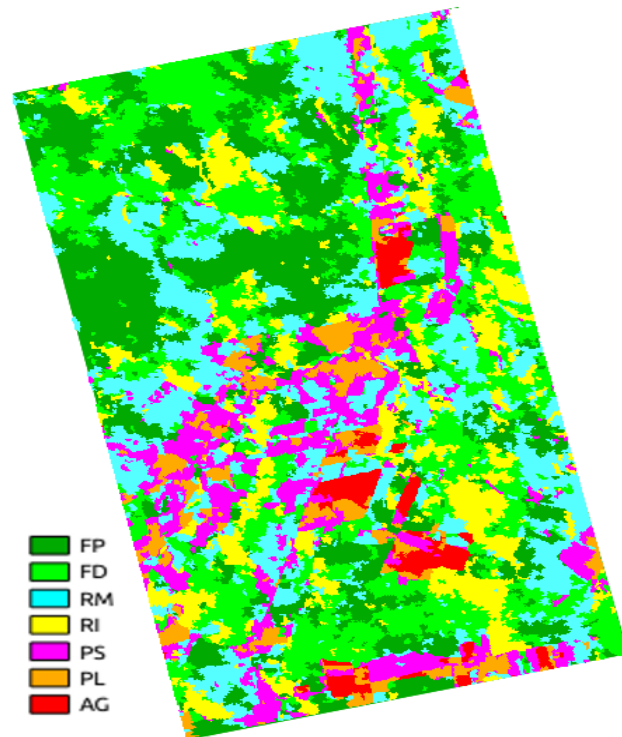


(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.

Figura 4.56 - Classificação da imagem PolSAR com a distância Qui-quadrado.



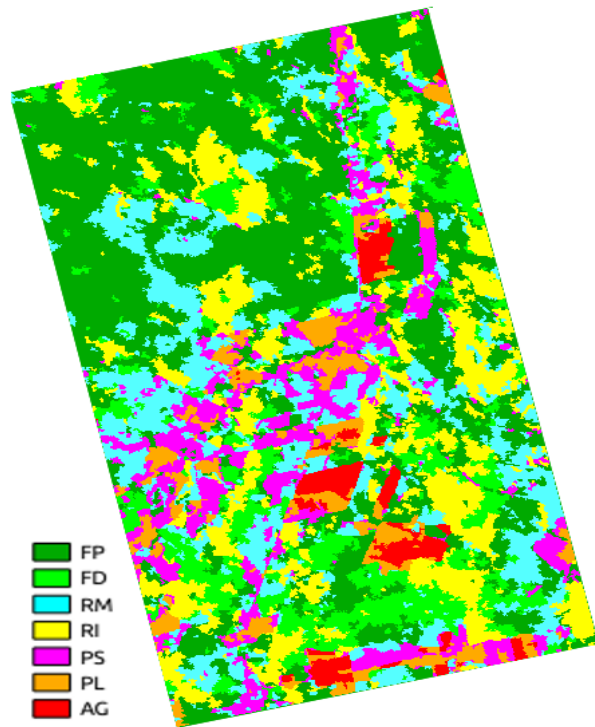
(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.



Figura 4.57 - Classificação do par de imagens HH,HV com a distância de *Bhattacharyya*.



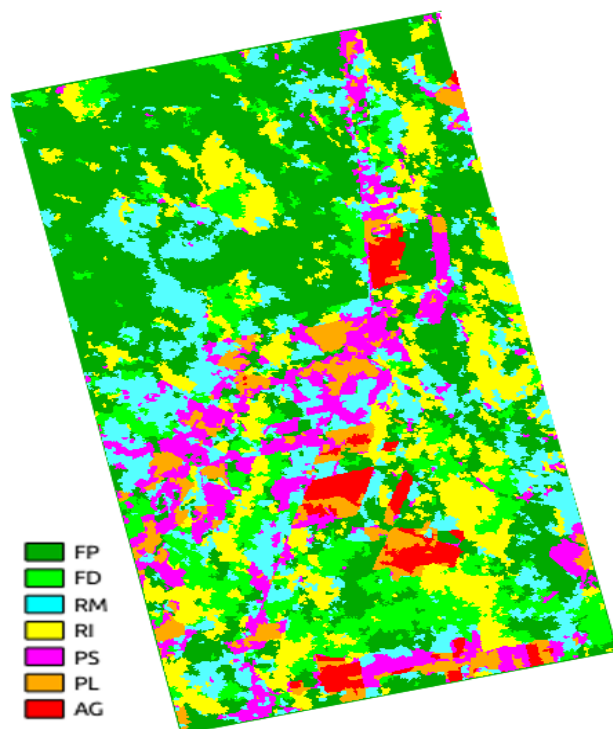
(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.



Figura 4.58 - Classificação do par de imagens HH,HV com a distância Triangular.

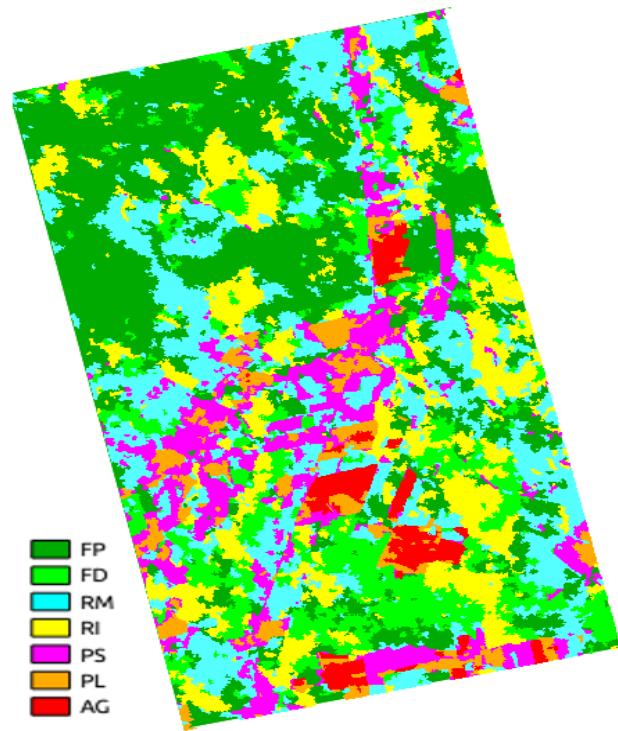


(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.

Figura 4.59 - Classificação do par de imagens VV,HV com a distância de *Bhattacharyya*.

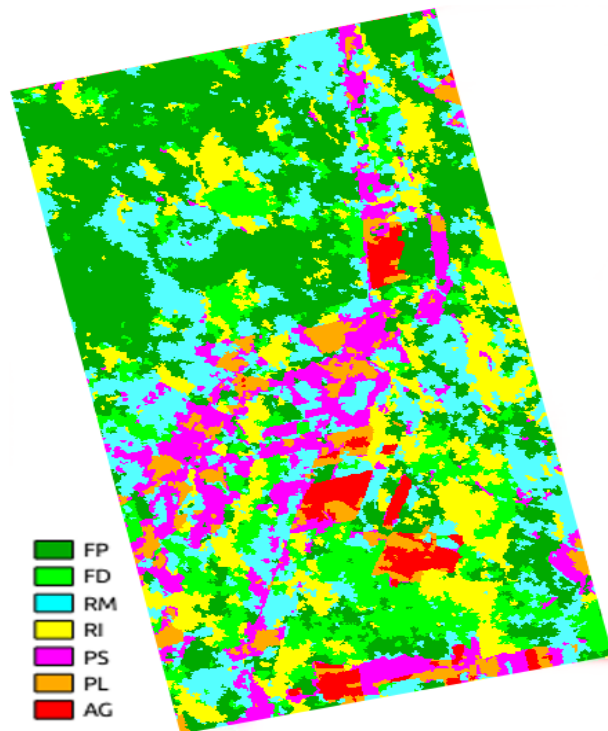


(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.

Figura 4.60 - Classificação do par de imagens VV,HV com a distância de Triangular.



(a) Imagem classificada



(b) Imagem de possibilidade  
Fonte: Produção do autor.

Para as classificações multifontes foram selecionadas os seguintes casos da imagem Radarsat, dada a construção monofonte *IMAGEM\_MODELAGEM\_DISTÂNCIA*:

- *HV\_Gama\_Bhattacharyya*,
- Matriz de covariância *\_Wishart\_Bhattacharyya* (refere-se à imagem polarimétrica e foi simplificado para *Matriz\_Wishart\_Bhattacharyya*),
- *HH,HV\_Par de Intensidades\_Bhattacharyya*,
- *HH,VV\_Par de Intensidades\_Bhattacharyya* e
- *VV,HV\_Par de Intensidades\_Bhattacharyya*.

Estas opções foram selecionadas por apresentarem os maiores índices de acurácia nas classificações monofontes e por contemplarem todas as modelagens e tipos de dados a partir da Radarsat. As classificações multifontes foram produzidas a partir de cada uma destas opções selecionadas da Radarsat com *TM\_Gaussiana\_Bhattacharyya*, gerando 5 classificações. As construções multifontes ficaram *IMAGEM1\_MODELAGEM1\_DISTÂNCIA1;IMAGEM2\_MODELAGEM2\_DISTÂNCIA2* e no texto foram simplificadas para *IMAGEM1\_IMAGEM2*. Os índices de acurácias estimados para as classificações multifontes e suas médias de tempos de execução com as combinações da soma, mínimos e produto encontram-se nas Tabelas 4.6 a 4.8, respectivamente. As acurácias globais obtidas nas combinações da soma, mínimos e produto também são apresentadas, nesta ordem, nos gráficos das Figuras 4.61 a 4.63.

Tabela 4.6 - Classificações multifontes com a combinação da soma.

	Classificação multifonte	<i>Kappa</i>	Acurácia global (%)	Tempo de execução (s)
I	<i>TM_Gaussiana_Bhattacharyya;</i> <i>HV_Gama_Bhattacharyya</i>	0,89	90,64	145,423
II	<i>TM_Gaussiana_Bhattacharyya;</i> <i>HH,HV_Par de Intensidades_Bhattacharyya</i>	0,89	90,64	689,463
III	<i>TM_Gaussiana_Bhattacharyya;</i> <i>HH,VV_Par de Intensidades_Bhattacharyya</i>	0,89	90,61	690,288
IV	<i>TM_Gaussiana_Bhattacharyya;</i> <i>VV,HV_Par de Intensidades_Bhattacharyya</i>	0,89	90,64	690,112
V	<i>TM_Gaussiana_Bhattacharyya;</i> <i>Matriz_Wishart_Bhattacharyya</i>	0,91	92,76	171,822

Fonte: Produção do autor.

Tabela 4.7 - Classificações multifontes com a combinação dos mínimos.

	Classificação multifonte	<i>Kappa</i>	Acurácia global (%)	Tempo de execução (s)
I	TM_Gaussiana_Bhattacharyya; HV_Gama_Bhattacharyya	0,51	59,04	146,811
II	TM_Gaussiana_Bhattacharyya; HH,HV_Par de Intensidades_Bhattacharyya	0,70	75,06	690,283
III	TM_Gaussiana_Bhattacharyya; HH,VV_Par de Intensidades_Bhattacharyya	0,89	90,61	691,593
IV	TM_Gaussiana_Bhattacharyya; VV,HV_Par de Intensidades_Bhattacharyya	0,67	72,08	690,992
V	TM_Gaussiana_Bhattacharyya; Matriz_Wishart_Bhattacharyya	0,48	56,82	172,636

Fonte: Produção do autor.

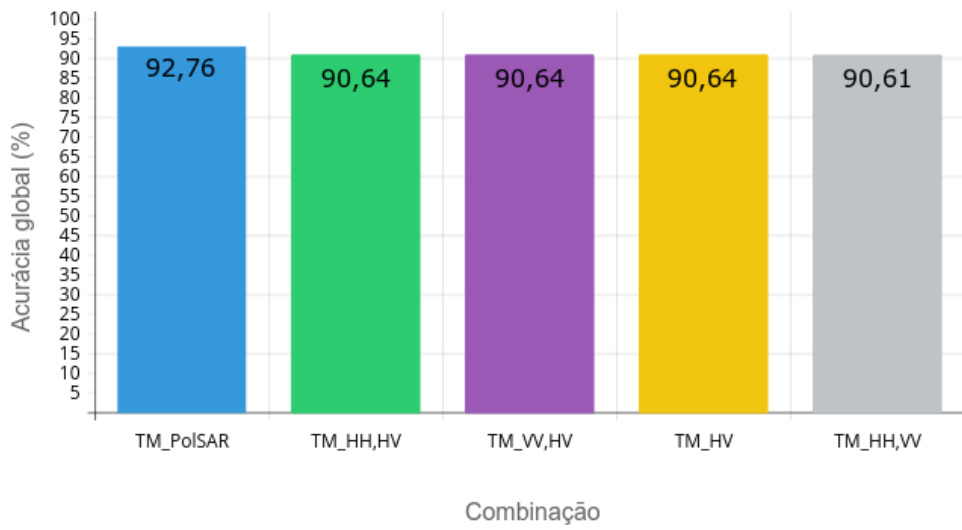
Tabela 4.8 - Classificações multifontes com a combinação do produto.

	Classificação multifonte	<i>Kappa</i>	Acurácia global (%)	Tempo de execução (s)
I	TM_Gaussiana_Bhattacharyya; HV_Gama_Bhattacharyya	0,66	71,46	145,845
II	TM_Gaussiana_Bhattacharyya; HH,HV_Par de Intensidades_Bhattacharyya	0,80	83,72	690,613
III	TM_Gaussiana_Bhattacharyya; HH,VV_Par de Intensidades_Bhattacharyya	0,75	79,37	691,714
IV	TM_Gaussiana_Bhattacharyya; VV,HV_Par de Intensidades_Bhattacharyya	0,93	94,03	689,472
V	TM_Gaussiana_Bhattacharyya; Matriz_Wishart_Bhattacharyya	0,85	87,61	172,498

Fonte: Produção do autor.


Observa-se nos *Kappas* da Tabela 4.6, que as classificações multifontes correspondentes à combinação da soma superaram todas as classificações monofontes. O resultado com maiores índices de acurácia foi obtido pela classificação V, que considera a imagem polarimétrica. O segundo resultado com maiores índices foi obtido pelas classificações I, II e IV, que consideram a monocanal HV e os pares em intensidade HH,HV e VV,HV. A classificação multifonte III obteve o mesmo índice *Kappa* que estas últimas, porém, apresentou uma pequena diferença de 0,03% a menos de acurácia global.

Figura 4.61 - Comparação das acurácias globais obtidas na combinação da soma.




Fonte: Produção do autor.

Figura 4.62 - Comparação das acurácias globais obtidas na combinação dos mínimos.



Fonte: Produção do autor.

Figura 4.63 - Comparação das acurácias globais obtidas na combinação do produto.



Fonte: Produção do autor.

Analisando-se os resultados das classificações multifontes correspondentes à combinação dos mínimos da Tabela 4.7, nota-se que os maiores índices de acurácias foram obtidos pelas classificações II, III e IV. Estas três classificações são correspondentes aos pares de imagens em intensidade, modeladas por intermédio da distribuição Par de Intensidades *multi-look*, e superaram as classificações multifontes correspondentes às imagens HV (modelada pela Gama) e polarimétrica (modelada pela Wishart complexa escalonada). O resultado obtido pela classificação multifonte I, correspondente à monocanal, superou a classificação multifonte correspondente à imagem polarimétrica.

Para as classificações multifontes correspondentes à combinação do produto, observa-se na Tabela 4.8 que, a classificação I que considera a imagem monocanal foi superada por todas as outras classificações. A classificação IV que considera o par VV,HV obteve os maiores índices de acurácia. O segundo resultado com maiores índices foi obtido pela classificação V, correspondente à imagem polarimétrica.

Por intermédio do índice denominado Melhora Quantitativa da Classificação (*QIC* - *Quantitative Improvement of Classification*) dado por  $QIC = (k_b - k_a)/(1 - k_a)$ , avalia-se o quanto o resultado de uma classificação  $k_b$  pode ser melhorado relati-

vamente ao resultado de outra classificação  $k_a$  (BRAGA, 2016). Através dos índices *Kappas* resultantes das classificações para o cálculo do *QIC* obtêm-se os resultados exibidos na Tabela 4.9. Para fins de simplificação, na tabela a distância de *Bhattacharyya* é denominada por *Bh*, a distribuição Par de Intensidades *multilook* é simplificada para o termo PI e a imagem Radarsat polarimétrica no formato matriz de covariância é chamada de Matriz. As siglas I, II, III, IV e V se referem às classificações multifontes construídas com as combinações da soma, mínimos e produto indicadas nas Tabelas 4.6 a 4.8, respectivamente. O símbolo  $\downarrow$  é usado para indicar *QIC* negativo, ou seja, quando não ocorreu melhora na classificação multifonte. As melhoras percentuais de *QIC* das classificações multifontes em relação às classificações individuais da imagem TM e Radarsat também são apresentadas nos gráficos das Figuras 4.64 e 4.65.

Observa-se na Tabela 4.9, que os resultados das classificações correspondentes à imagem TM são melhorados em 15% por intermédio das classificações multifontes I (Soma), II (Soma), III (Soma), III (Mínimos), IV (Soma), em 46% na IV (Produto) e em 31% por meio da classificação multifonte V (Soma). Em relação às classificações multifontes I (Mínimos), I (Produto), II (Mínimos), II (Produto), III (Produto), IV (Mínimos), V (Mínimos) e V (Produto) não houve melhoras para a classificação da imagem TM. Em relação aos resultados da classificação monofonte correspondente à imagem monocanal em intensidade HV, as classificações multifontes apresentaram melhoras de 77% em na classificação multifonte I (Soma) e 29% por intermédio da classificação multifonte I (Produto). Não houve melhora para a classificação multifonte I (Mínimos) em relação a classificação da imagem monocanal HV. Em relação aos resultados da classificação monofonte relativa ao par de intensidades HH,HV, obteve-se melhoras de 77% por meio da classificação multifonte II (Soma), 36% por intermédio da classificação multifonte II (Mínimos) e 57% por meio da classificação multifonte II (Produto). Os resultados da classificação monofonte do par de intensidades HH,VV são melhorados em 78% por meio das classificações multifontes III (Soma) e III (Mínimos) e em 50% por intermédio da classificação multifonte III (Produto). Em comparação aos resultados da classificação monofonte correspondente ao par de intensidades VV,HV, obteve-se melhoras de 71% por meio da classificação multifonte IV (Soma), 13% por intermédio da classificação multifonte IV (Mínimos) e 82% em relação à classificação multifonte IV (Produto). Em relação aos resultados da classificação monofonte da imagem polarimétrica, obteve-se melhoras de 83% em relação à classificação multifonte V (Soma), 4% por meio da classificação multifonte V (Mínimos) e 72% por intermédio da classificação multifonte V (Produto).

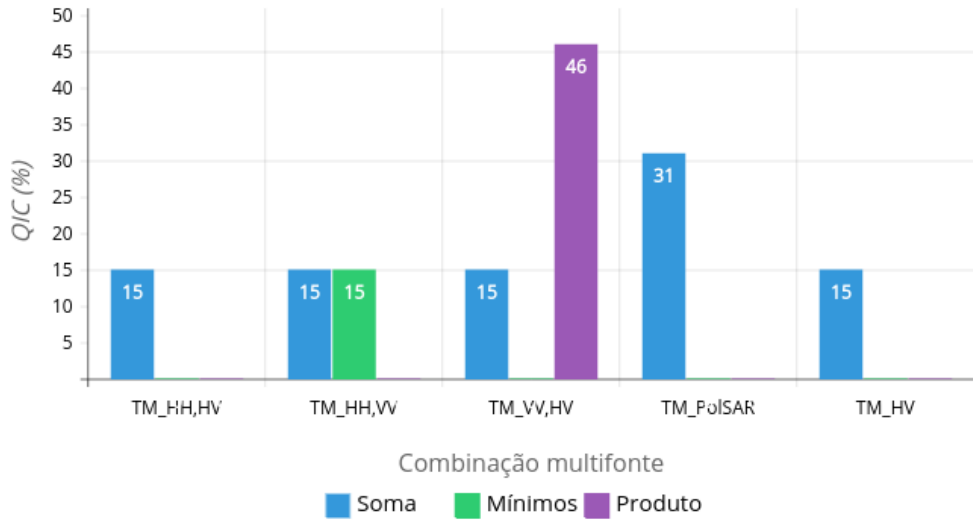


Tabela 4.9 - Melhora quantitativa das classificações multifontes em relação às classificações monofontes.

Melhora Quantitativa da Classificação						
Multifontes	TM_Gaussiana_Bh	HV_Gama_Bh	HH,HV_PI_Bh	HH,VV_PI_Bh	VV,HV_PI_Bh	Matriz_Wishart_Bh
I (Soma)	15%	77%				
I (Mínimos)	↓	↓				
I (Produto)	↓	29%				
II (Soma)	15%		77%			
II (Mínimos)	↓		36%			
II (Produto)	↓		57%			
III (Soma)	15%			78%		
III (Mínimos)	15%			78%		
III (Produto)	↓			50%		
IV (Soma)	15%				71%	
IV (Mínimos)	↓				13%	
IV (Produto)	46%				82%	
V (Soma)	31%					83%
V (Mínimos)	↓					4%
V (Produto)	↓					72%


Fonte: Produção do autor.

Figura 4.64 - Melhora quantitativa das classificações multifontes em relação às classificações monofontes da TM.



Fonte: Produção do autor.

Figura 4.65 - Melhora quantitativa das classificações multifontes em relação às classificações monofontes da Radarsat.



Fonte: Produção do autor.

Nota-se que, as classificações multifontes correspondentes à combinação da soma apresentaram os maiores percentuais de *QIC* comparados às outras combinações. Este é o mesmo resultado observado em Braga (2016). Observa-se também que, a combinação multifonte da soma melhorou as classificações de todas as imagens em estudo. Analisando os resultados que envolvem a imagem monocanal HV, modelada pela distribuição Gama, observa-se que a classificação multifonte com a combinação da soma (TM\_HV - I Soma) obteve o mesmo percentual de *QIC* (77%) que a combinação da soma com o par HH,HV (TM\_HH,HV - II Soma). O percentual do *QIC* da combinação da soma TM\_HV foi superior em 6% em relação à combinação da soma TM\_VV,HV e inferior em 1% e 6% às combinações da soma TM\_HH,VV e TM\_Matriz (imagem polarimétrica), respectivamente.

Ainda em relação às classificações multifontes correspondentes à combinação da soma, em todos os casos houve melhora em comparação com a classificação individual da imagem TM. A maior melhora foi obtida com a combinação da imagem polarimétrica (*QIC* = 31%). Para os outros casos, obteve-se 15% de melhora nas combinações que envolveram a imagem monocanal HV e os pares HH,HV, HH,VV e VV,HV.

Em relação à classificação multifonte correspondente à combinação dos mínimos e considerando apenas os dados do Radarsat, houve melhora em comparação a todas as classificações individuais, com exceção da classificação da HV. Considerando a classificação da imagem TM, houve apenas melhora na classificação multifonte com o par HH,VV (TM\_HH,VV - *QIC* = 15%).

Observa-se que, as classificações multifontes do produto apresentaram melhoras em relação à classificação monofonte da imagem TM apenas na combinação com o par de imagens VV,HV (TM\_VV,HV - *QIC* = 46%). A melhora percentual de *QIC* da classificação multifonte TM\_HV foi inferior em 28%, 21%, 17% e 43% em relação às classificações multifontes TM\_HH,HV, TM\_HH,VV, TM\_VV,HV e TM\_Matriz, respectivamente.

Refletindo sobre os resultados, nota-se que, de maneira geral, as classificações multifontes apresentaram contribuições para as classificações monofontes correspondentes. Levando-se em conta as imagens e classes de interesse utilizadas neste trabalho, conclui-se que para este conjunto de dados, o emprego de dados polarimétricos, bivariados ou monocanais é indiferente quando se envolvem imagens Radarsat utilizadas em conjunto com um dado óptico (no caso, imagem TM) na combinação da soma. Neste tipo de situação orienta-se optar por dados bivariados ou monoca-


nais devido aos seus baixos custos em relação a dados polarimétricos. Levando-se em conta o custo computacional, recomenda-se o emprego dos dados monocanais devido ao tempo de execução para a obtenção da classificação com esse tipo de dado ser muito menor que o tempo necessário para os dados bivariados. Para aplicações que envolvam a combinação dos mínimos, opta-se pelo emprego de dados bivariados. Para o caso em que se adota a combinação do produto, não recomendam-se os dados monocanais.

Em relação a todos os resultados obtidos nas diferentes etapas da análise dos dados, conclui-se que a metodologia aplicada a dados SAR monocanais em intensidade modelados por intermédio da distribuição Gama é efetiva, uma vez que foi possível alcançar índices similares e até maiores do que com dados modelados pelas outras distribuições, tanto nas classificações monofontes, quanto nas multifontes. De maneira geral, verificou-se que as classificações multifontes com a combinação da soma apresentaram valores superiores àqueles obtidos pelas classificações multifontes dos mínimos e do produto. Observou-se também que, de maneira geral, foi possível alcançar maiores índices por meio das classificações multifontes propostas em grande parte dos resultados.


Observa-se que as médias dos tempos de execução para as classificações multifontes não se diferem em relação às combinações. A classificação que envolve a imagem HV obteve os menores tempos com média de 145 segundos. A classificação que envolveu a imagem PolSAR teve o segundo maior tempo com média de 172 segundos. As classificações que envolveram os pares em intensidade demoraram em média 4,5 vezes mais que as classificações que envolveram as demais imagens.

As classificações multifontes da combinação da soma são ilustradas nas Figuras 4.66 a 4.70. As classificações da combinação dos mínimos são ilustradas nas Figuras 4.71 a 4.75 e do produto são ilustradas nas Figuras 4.76 a 4.80. Nestas figuras são apresentadas (a) as imagens classificadas e (b) as imagens de possibilidade ou a imagem de probabilidade (melhores representativas nas combinações que envolvem a imagem monocanal modelada pela distribuição Gama).

Figura 4.66 - Classificação multifontes I com a combinação da soma.




(a) Imagem classificada




(b) Imagem de probabilidade  
Fonte: Produção do autor.

Figura 4.67 - Classificação multifontes II com a combinação da soma.




(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.

Figura 4.68 - Classificação multifontes III com a combinação da soma.




(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.

Figura 4.69 - Classificação multifontes IV com a combinação da soma.




(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.



Figura 4.70 - Classificação multifontes V com a combinação da soma.




(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.

Figura 4.71 - Classificação multifontes I com a combinação dos mínimos.




(a) Imagem classificada




(b) Imagem de probabilidade  
Fonte: Produção do autor.

Figura 4.72 - Classificação multifontes II com a combinação dos mínimos.




(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.

Figura 4.73 - Classificação multifontes III com a combinação dos mínimos.




(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.

Figura 4.74 - Classificação multifontes IV com a combinação dos mínimos.




(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.

Figura 4.75 - Classificação multifontes V com a combinação dos mínimos.




(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.



Figura 4.76 - Classificação multifontes I com a combinação do produto.




(a) Imagem classificada




(b) Imagem de probabilidade  
Fonte: Produção do autor.

Figura 4.77 - Classificação multifontes II com a combinação do produto.




(a) Imagem classificada



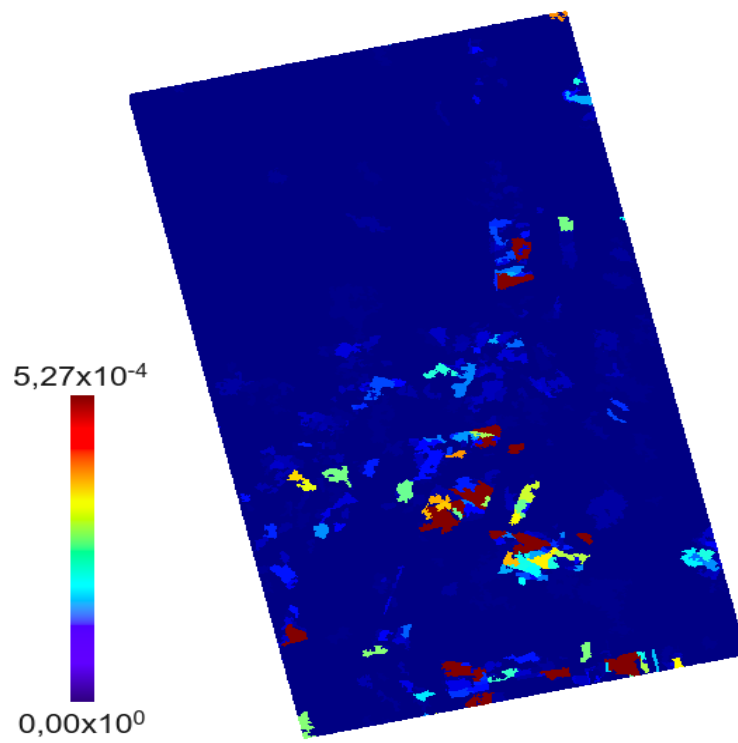
(b) Imagem de possibilidade  
Fonte: Produção do autor.



Figura 4.78 - Classificação multifontes III com a combinação do produto.




(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.

Figura 4.79 - Classificação multifontes IV com a combinação do produto.




(a) Imagem classificada




(b) Imagem de possibilidade  
Fonte: Produção do autor.

Figura 4.80 - Classificação multifontes V com a combinação do produto.



(a) Imagem classificada



(b) Imagem de possibilidade  
Fonte: Produção do autor.



## 5 CONCLUSÕES

A classificação é uma importante tarefa na análise e processamento de imagens em sensoriamento remoto. Sensores com características distintas são utilizados para o imageamento da superfície da Terra e dessa forma, diferentes técnicas são propostas e utilizadas para classificar os dados obtidos. Neste trabalho foi desenvolvido e implementado um sistema computacional livre para metodologias de classificação monofonte e multifontes baseadas em distâncias estocásticas e testes de hipóteses associados. Por intermédio desta ferramenta é possível classificar imagens ópticas e SAR, tanto separadamente quanto em conjunto.

O sistema foi implementado em C++, utilizando a biblioteca TerraLib como plataforma de desenvolvimento. Foram implementados quatro módulos para o classificador: Par de Intensidades responsável por dados SAR bivariados em intensidade, Gaussiana para imagens ópticas e SAR multivariadas em amplitude, Wishart para dados SAR polarimétricos e Gama para imagem SAR monocanal em intensidade. Em relação à classificação multifontes, a implementação do método foi realizada em quatro módulos: combinação da soma, combinação do produto, combinação dos mínimos e *Fuzzy*. A entrada do classificador consiste em  $W$  imagens co-registradas, uma imagem segmentada e amostras de treinamento e de teste das classes de interesse. O classificador gera como saída a imagem classificada, duas imagens de confiabilidade (imagem de possibilidade e imagem de probabilidade), um relatório da classificação, além de arquivos contendo os valores das distâncias estocásticas, estatísticas e valores- $p$  calculados no processo de classificação.

Foram realizados dois casos de teste empregando-se dados simulados e imagens reais. Estes testes evidenciaram a correteza, confiabilidade e completude do algoritmo implementado. As classificações construídas com os dados simulados mostraram que os resultados gerados por intermédio da ferramenta computacional foram iguais aos resultados esperados em todos os módulos implementados. Imagens reais foram testadas com a utilização de dados publicados anteriormente e que foram classificados por intermédio do *software* PolClass. Os resultados de classificações monofontes de imagens SAR polarimétricas foram diferentes quando comparados com os resultados das classificações feitas por meio do PolClass. Um caso de teste mais detalhado mostrou que há um problema no módulo do PolClass que é responsável por classificar esses tipos de dados. As outras classificações monofontes produzidas com os outros tipos de dados obtiveram resultados iguais nos dois sistemas computacionais.

Em geral, a aquisição de dados polarimétricos incompletos é mais acessível devido

a seu baixo custo em relação aos dados polarimétricos. A utilização de dados bivariados mostrou que tem resultados na classificação com acurácia igual a de dados completos. Neste trabalho foi realizada a avaliação da aplicação na metodologia de dados SAR monocanais em intensidade por intermédio da distribuição Gama. A partir dos resultados obtidos conclui-se que, com exceção do canal HH, os canais HV e VV foram tão eficazes quanto os dados bivariados e polarimétricos completos para a classificação monofonte dos dados em estudo.

Na comparação entre as combinações nas classificações multifontes envolvendo as imagens TM e Radarsat, pode-se observar, de maneira geral, resultados iguais para as classificações envolvendo o dado modelado por meio da distribuição Gama e os dados modelados por intermédio das outras distribuições. Os índices *Kappa* e acurácias globais da classificação envolvendo a imagem monocanal foram tão bons quanto os índices das classificações que envolveram os dados bivariados e polarimétricos completos na combinação da soma. Os índices na combinação dos mínimos foram iguais nas classificações que envolveram tanto a imagem monocanal, quanto a polarimétrica. Para a combinação do produto, a classificação multifonte envolvendo o dado modelado por meio da Gama obteve resultados inferiores às demais classificações.

Em relação ao desempenho computacional, as classificações monofontes e multifontes correspondentes aos dados monocanais foram mais rápidas que as classificações correspondentes aos dados bivariados. Essa vantagem se dá pelo fato de um método numérico ser utilizado no cálculo de distâncias entre distribuições Par de Intensidade *multi-look* por falta de expressões fechadas.

Um resumo das principais contribuições deste trabalho é apresentado a seguir:

- Adição da modelagem Gama, com a qual é possível classificar imagens de radar monocanal no formato intensidade, abrangendo mais o uso de dados polarimétricos incompletos (que são mais disponíveis e baratos do que os completos) e obter menos custo computacional quando comparada à Par de Intensidade *multi-look* por possuir expressões fechadas para o cálculo de distâncias estocásticas.
- Desenvolvimento da plataforma computacional amigável (intuitiva) e flexível (para diferentes sistemas operacionais), que significa a concretização da metodologia de classificação multifontes baseada em distâncias estocásticas e testes de hipóteses associados. Além de permitir que a técnica tenha acesso facilitado e possa ser disseminada na comunidade científica. Este último fato também serve para a técnica monofonte, uma vez que esta foi desenvolvida em uma plataforma não gratuita.

- O *software* contribui para a exploração plena dos dados disponíveis, pois, permite a aplicação de diferentes tipos de dados (como óptico, SAR e PolSAR), além de permitir a realização de classificação monofonte e multifontes.
- Implementação do sistema utilizando a TerraLib como plataforma de desenvolvimento, que permite que o classificador seja adicionado, no futuro, como um *plug-in* no TerraView (??), um Sistema de Informações Geográficas construído sobre a biblioteca TerraLib e distribuído gratuitamente pelo INPE.
- Embora a biblioteca TerraLib e o sistema TerraView sejam ferramentas bem completas, o desenvolvimento e implementação da técnica de classificação multifontes incorpora a esses sistemas pela primeira vez alguns dos últimos avanços no processamento e análise de imagens decorrentes da Teoria da Informação.

Como trabalhos futuros, recomenda-se realizar modificações no algoritmo do método numérico implementado no módulo Par de Intensidades para torná-lo mais eficiente em termos computacionais. Na aplicação de dados monocanais modelados por intermédio da distribuição Gama, análises mais detalhadas e específicas podem ser realizadas. A análise da acurácia por classe e dos erros registrados pode ser feita para se retirar a maior quantidade possível de informações da matriz de confusão da classificação correspondente aos dados SAR monocanais em intensidade.

Sugerem-se também estudos de outros tipos de normalização, da aplicação de outras distâncias no módulo Par de Intensidades e demais modelagens, aplicação de uma regra para gerar a classificação final no *Fuzzy*, inserir um sistema inteligente (inteligência artificial) para identificação de imagens e estimativa automática do conjunto de parâmetros, e realizar testes para verificar os motivos dos resultados dos índices das classificações da TM serem melhores que das imagens SAR.

Além disso, pode-se adaptar o sistema para permitir a:

- estimação do número equivalente de *looks* de imagens SAR;
- adição de novos tipos de combinação na classificação multifontes, como por exemplo, um caso particular de *Hellinger* (BRAGA, 2016);
- adição de *tooltips* (dicas) na interface gráfica com explicações dos parâmetros;
- utilização de *spin boxes* (caixas de rotação) na interface gráfica para alguns parâmetros, como por exemplo, o número de imagens;

- alteração na maneira de carregar as amostras das classes para que a entrada seja um arquivo único de *shapefiles*.



## REFERÊNCIAS BIBLIOGRÁFICAS

AKOGUZ, A.; PINAR, S. K.; ÖZDEMİR, A.; BAGIS, S.; YUCEL, M.; KARTAL, M. Remote sensing data fusion algorithms with parallel computing. **International Conference on Recent Advances in Space Technologies (RAST)**, p. 87–92, 2013. 8

BAEK, J.; KIM, J. W.; GYE, J. L.; LEE, D. Electromagnetic land surface classification through integration of optical and radar remote sensing data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 49, n. 4, p. 1214–1222, 2013. 9

BERNARDI, H. V. F. **Proposta para caracterização, estratificação ambiental e recuperação de matas ciliares de uma sub-bacia do Alto Rio Grande**. 2007. 122 p. Dissertação (Mestrado em Engenharia Florestal) — Universidade Federal de Lavras (UFLA), Lavras, 2007. Disponível em: <<http://repositorio.ufla.br/>>. Acesso em: 10 mar. 2016. 26

BINDILATTI, A. A. **Abordagens não-locais para filtragem de ruído Poisson**. 2014. 96 p. Dissertação (Mestrado em Ciência da Computação) — Universidade Federal de São Carlos (UFSCar), São Carlos, 2014. Disponível em: <[http://www.bdttd.ufscar.br/htdocs/tedeSimplificado//tde\\_busca/arquivo.php?codArquivo=7836](http://www.bdttd.ufscar.br/htdocs/tedeSimplificado//tde_busca/arquivo.php?codArquivo=7836)>. Acesso em: 28 abr. 2016. 18, 19, 20

BINS, L. S.; FONSECA, L. M. G.; ERTHAL, G. J.; MITSUO, F. Satellite imagery segmentation: a region growing approach. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8, 1996, Salvador, BH. Anais... São José dos Campos: INPE, 1996. p.677-680. 37

BISHOP, C. **Pattern recognition and machine learning**. USA: Springer, 2006. 1

BLATT, D.; HERO, A. O. On tests for global maximum of the log-likelihood function. **IEEE Transactions on Information Theory**, v. 53, p. 2510–2525, 2007. 18

BOOST LIBRARIES. 2017. Disponível em: <<http://www.boost.org/>>. 42, 46

BRAGA, B. C. **Distâncias estocásticas e testes de hipóteses associados aplicados à classificação de imagens provenientes de múltiplos sensores independentes**. 2016. 167 p. Sid.inpe.br/mtc-m21b/2016/07.04.21.38-TDI.

Dissertação (Mestrado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2016. 3, 4, 9, 10, 13, 14, 27, 28, 30, 31, 32, 35, 40, 42, 45, 46, 53, 57, 64, 65, 66, 67, 70, 71, 89, 122, 125, 145

BRAGA, B. C.; SANT'ANNA, S. J. S.; FREITAS, C. C. Integração de imagens radarsat-2 e alos/palsar para obtenção de classificações multifontes do uso e cobertura da terra. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 18, 2017, Santos, SP. Anais... São José dos Campos: INPE, 2017. p.3315-3322. 80, 83

BRELL, M.; ROGASS, C.; SEGL, K.; BOOKHAGEN, B.; GUANTER, L. Improving sensor fusion: A parametric method for the geometric coalignment of airborne hyperspectral and lidar data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 54, n. 6, p. 3460–3474, 2016. 8

CÂMARA, G.; SOUZA, R. C. M.; FREITAS, U. M.; GARRIDO, J. C. P. Spring: integrating remote sensing and GIS with object-oriented data modelling. **Computers and Graphics**, v. 15, n. 6, p. 13–22, 1996. 2

CÂMARA, G.; VINHAS, L.; QUEIROZ, G. R.; FERREIRA, K. R.; MONTEIRO, A. M.; CARVALHO, M.; CASANOVA, M. TerraLib: an open-source GIS library for large-scale environmental and socio-economic applications. In: HALL, B.; LEAHY, M. (Ed.). **Open source approaches in spatial data handling: advances in geographic information science**. [S.l.]: Springer, 2010. p. 247–270. 5, 35

CHANG, N.; VANNAH, B. Comparative data fusion between genetic programming and neural network models for remote sensing images of water quality monitoring. **IEEE International Conference on Systems, Man, and Cybernetics (SMC)**, p. 1046–1051, 2013. 7

CHEN, Y.; LI, C.; GHAMISI, P.; JIA, X.; GU, Y. Deep fusion of remote sensing data for accurate classification. **IEEE Geoscience and Remote Sensing Letters**, n. 99, p. 1–5, 2017. 3, 9, 10

CHEN, Y.; LI, J.; ZHANG, Y.; TAO, L.; SHEN, W. A framework of collaborative change detection with multiple operators and multi-source remote sensing images. **IEEE International Geoscience and Remote Sensing Symposium (IGARSS)**, p. 5169–5172, 2016. 3

CSISZAR, I. Information-type measures of difference of probability distributions and indirect observations. **Studia Scientiarum Mathematicarum Hungarica**, v. 2, p. 299–318, 1967. 18

DONOHO, D. L.; VETTERLI, M.; DEVORE, R. A.; DAUBECHIES, I. Data compression and harmonic analysis. **IEEE Transactions on Information Theory**, v. 44, n. 6, p. 2435–2476, 1998. 18

DUPUY, S.; LAINÉ, G.; TORMOS, T. Obia for combining lidar and multispectral data to characterize forested areas and land cover in tropical region. **GEOBIA**, p. 279–285, 2012. 9

ESCOLANO, F.; SUAU, P.; BONEV, B. **Information theory in computer vision and pattern recognition**. New York: Springer, 2009. 18

EXELIS. **IDL reference guide: interactive data language version 7.1**. 2010. Disponível em:  
<<http://www.harrisgeospatial.com/portals/0/pdfs/idl/refguide.pdf>>. Acesso em: 13 nov. 2017. 4, 30

FREITAS, C. C.; SANT'ANNA, S. J. S.; RENNO, C. D.; CORREIA, A. H. Utilização de imagens de radar de abertura sintética na classificação de uso e ocupação do solo. [S.I]: EMBRAPA, 1999. p.1-54. 10, 13, 14

FRERY, A. C.; MÜLLER, H. J.; YANASSE, C. C. F.; 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. 13

FRERY, A. C.; NASCIMENTO, A. D. C.; CINTRA, R. J. Information theory and image understanding: an application to polarimetric sar imagery. **Chilean Journal of Statistics**, v. 2, n. 2, p. 81–100, 2011. 18, 27, 92

GHANBARI, Z.; SAHEBI, M. R. Improved ihs algorithm for fusing high resolution satellite images of urban areas. **Journal Indian Society of Remote Sensing**, v. 42, n. 4, p. 689–699, 2014. 3, 9

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. 15

HEDHLI, I.; MOSER, G.; ZERUBIA, J.; SERPICO, S. B. Fusion of multitemporal and multiresolution remote sensing data and application to natural disasters.

**IEEE International Geoscience and Remote Sensing Symposium (IGARSS)**, p. 207–210, 2014. [7](#), [10](#)

HUANG, Z.; CHENG, G.; WANG, H.; LI, H.; SHI, L.; PAN, C. Building extraction from multi-source remote sensing images via deep deconvolution neural networks. **IEEE International Geoscience and Remote Sensing Symposium (IGARSS)**, p. 1835–1838, 2016. [9](#)

KHODADADZADEH, M.; LI, J.; PRASAD, S.; PLAZA, A. Fusion of hyperspectral and lidar remote sensing data using multiple feature learning. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 8, n. 6, p. 2971–2983, 2015. [9](#)

KRILOV, V. A.; MOSER, G.; SERPICO, S. B.; ZERUBIA, J. Probability density function estimation for classification of high-resolution SAR images. In: CHEN, C. (Ed.). **Signal and image processing for remote sensing**. USA: CRC Press, 2012. p. 339–363. [13](#)

KULLBACK, S. Information theory and statistics. **Journal of the American Statistical Association**, v. 54, n. 288, p. 825–827, 1959. [17](#)

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, 2001. [40](#)

LEE, J. S.; SHULER, D. L.; GRUNES, M. R. Statistical analysis and segmentation of multi-look sar imagery using partial polarimetric data. **International Geoscience and Remote Sensing Symposium**, v. 2, p. 1422–1424, 1995. [40](#)

LEE, J. S.; SHULER, D. L.; LANG, R. H.; J., R. K. K distribution for multi-look processed polarimetric SAR imagery. **International Geoscience and Remote Sensing Symposium**, v. 4, p. 2179–2181, 1994. [13](#), [15](#), [40](#)

LEVENBERG, K. A method for the solution of certain non-linear problems in least- squares. **Quarterly of Applied Mathematics**, v. 2, n. 2, p. 164–168, 1944. [41](#)

LI, J.; BAI, L.; LI, J.; NIE, Y.; YANG, P.; QIN, J.; QU, R. Monitoring and analysis of land use change in xiamen harbor area based on multi-source remote sensing images. **IEEE International Geoscience and Remote Sensing Symposium (IGARSS)**, p. 7303–7306, 2016. [7](#)

- LIMA, E. L. **Espaços métricos 4.ed.** Rio de Janeiro: IMPA, 2011. ISBN 978-85-244-0158-9. 19
- MA, H.; SONG, J.; WANG, J.; HUA, Y. Comparison of the inversion ability in extrapolating forest canopy height by integration of lidar data and different optical remote sensing products. **IEEE International Geoscience and Remote Sensing Symposium (IGARSS)**, p. 3363–3366, 2012. 7
- MAKARAU, A.; PALUBINSKAS, G.; REINARTZ, P. Multi-sensor data fusion for urban area classification. **Joint Urban Remote Sensing Event (JURSE)**, p. 21–24, 2011. 2, 9
- MARQUARDT, D. W. An algorithm for least-squares estimation of nonlinear parameters. **Journal of the Society for Industrial and Applied Mathematics**, v. 11, n. 2, p. 431–441, 1963. 41
- MERENTITIS, A.; DEBES, C. Many hands make light work - on ensemble learning techniques for data fusion in remote sensing. **IEEE Geoscience and Remote Sensing Magazine**, v. 3, n. 3, p. 86–99, 2015. 8
- MOIGNE, J.; COLE-RHODES, A.; EASTMAN, R.; P., J.; JOSHUA, A.; MEMARSADEGHI, N.; MOUNT, D.; NETANYAHU, N.; MORISETTE, J.; UKO-OZORO, E. Image registration and fusion studies for the integration of multiple remote sensing data. **IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)**, p. 1189–1192, 2006. 2, 3
- MURA, M. D.; PRASAD, S.; PACIFICI, F.; P., G.; CHANUSSOT, J.; BENEDIKTSSON, J. A. Challenges and opportunities of multimodality and data fusion in remote sensing. **Proceedings of the IEEE**, v. 103, n. 9, p. 1585–1601, 2015. 3, 7, 8
- NASCIMENTO, A. D. C. **Teoria estatística da informação para dados de radar de abertura sintética univariados e polarimétricos.** 2012. 280 p. Tese (Doutorado em Estatística) — Universidade Federal de Pernambuco (UFPE), Recife, 2012. 11, 13, 15, 19, 20, 21, 24, 25, 27
- 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. 13, 14, 19
- NASCIMENTO, A. D. C.; HORTA, M. M.; FRERY, A. C.; J., C. R. Comparing edge detection methods based on stochastic entropies and distances for PolSAR

imagery. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 2, p. 648–663, 2014. 18, 27

NEGRI, R. G. **Avaliação de dados polarimétricos do sensor ALOS PALSAR para classificação da cobertura da terra da Amazônia**. 2009. 170 p. Dissertação (Mestrado em Computação Aplicada) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2009. 14, 40

PEREIRA, L. O. **Avaliação de métodos de integração de imagens ópticas e de Radar para a classificação do uso e cobertura da terra na Região Amazônica**. 2012. 242 p. (sid.inpe.br/mtc-m19/2012/08.30.12.50-TDI). Dissertação (Mestrado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2012. 3, 30

POHL, C.; GENDEREN, J. V. **Remote sensing image fusion: a practical guide**. Boca Raton: Taylor And Francis Group, 2017. 1, 2, 3, 4, 7, 8, 9, 10

QGIS. 2017. Disponível em: <<http://www.qgis.org/en/site/>>. Acesso em: 29 out. 2017. 37

REN, W.; SONG, J.; TIAN, S.; ZHANG, X. Estimation of the equivalent number of looks in sar images based on singular value decomposition. **IEEE Geoscience and Remote Sensing Letters**, v. 12, n. 11, p. 2208–2212, 2015. 11

SALDANHA, M. F. S.; FREITAS, C. C.; SANT'ANNA, S. J. S. Segmentação de imagens SAR usando abordagem probabilística baseada na distribuição gama. **Revista Brasileira de Cartografia (RBC)**, n. 66, p. 29–43, 2013. 13, 27, 37, 53

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, 1994. 18, 23, 24

SANTOS, M. D. L.; SANT'ANNA, S. J. S.; SHIGUEMORI, E. H. Integração de métodos de classificação de imagens derivados da teoria da informação. In: PAGOT, C. A.; PETRONETTO, F. (Ed.). **Workshop of Works in Progress (WIP) in the 30th Conference on Graphics, Patterns and Images (SIBGRAPI'17)**. Niterói, RJ, Brazil: [s.n.], 2017. Disponível em: <<http://sibgrapi2017.ic.uff.br/>>. 3, 9, 13, 14

SATO, L. Y. **Dados ópticos e SAR para classificação de cobertura da Terra por árvore de decisão na região da Floresta Nacional de Tapajós, Pará**. 2012. 86 p. (sid.inpe.br/mtc-m19/2012/02.23.17.05-TDI). Dissertação

(Mestrado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2012. 9

SCHMITT, M.; ZHU, X. X. Data fusion and remote sensing: an ever-growing relationship. **IEEE Geoscience and Remote Sensing Magazine**, v. 4, n. 4, p. 6–23, 2016. 3, 8

SCHOWENGERDT, R. A. **Remote sensing: models and methods for image processing**. 3.ed. San Diego: Elsevier, 2007. 2

SHANNON, C. E. A mathematical theory of communication. **Bell System Technical Journal**, v. 27, p. 379–423, 1948. 17

SHEORAN, A.; HAACK, B. Optical and radar data comparison and integration: Kenya example. **Geocarto International**, v. 29, n. 4, p. 370–382, 2014. 3, 30

SILVA, W. B. **Classificação de regiões de imagens utilizando testes de hipóteses baseados em distâncias estocásticas: aplicações a dados polarimétricos**. 143 p. (sid.inpe.br/mtc-m19/2013/02.20.16-TDI). Tese (Doutorado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2013. 4, 9, 12, 14, 15, 20, 24, 27, 30, 35, 38, 39, 40, 48, 53, 54, 89, 92

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 Intensidade multi-look. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15, 2011, Curitiba, PR. Anais... São José dos Campos: INPE, 2011. p.8326-8333. 26

SOUSA-JÚNIOR, M. A. **Segmentação multi-níveis e multi-modelos para imagens de radar e ópticas**. 2005. 131 p. (INPE-14466-TDI/1147). Tese (Doutorado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2005. 11, 12, 37, 67

TEIXEIRA, A. A.; SILVA, A. M.; PIRES, A. C. B.; MORAES, R. A.; FILHO, C. R. S. Aplicação de técnicas de processamento digital de imagem em dados multifontes e sua relevância para integração de dados e seleção de áreas potenciais para exploração mineral. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12, 2005, Goiânia, GO. Anais... São José dos Campos: INPE, 2011. p.1915–1922. 7



- THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern recognition**. 4.ed. San Diego, CA: Academic Press, 2008. 1, 21
- TORRES, L.; SANT'ANNA, S. J. S.; FREITAS, C. C.; FRERY, A. C. Speckle reduction in polarimetric SAR imagery with stochastic distances and nonlocal means. **Pattern Recognition**, v. 47, p. 141–157, 2014. 27
- TORRES, L. J. T. M. **Um novo algoritmo para filtragem de speckle em imagens SAR de intensidade baseado em distâncias estocásticas**. 2012. 73 p. Dissertação (Mestrado em Modelagem Computacional de Conhecimento) — Universidade Federal de Alagoas (UFAL), Maceió, 2012. 17, 20, 21, 22, 23, 25, 41
- VOISIN, A.; KRYLOV, V. A.; MOSER, G.; SERPICO, S. B.; ZERUBIA, J. Classification of multi-sensor remote sensing images using an adaptive hierarchical markovian model. **European Signal Processing Conference (EUSIPCO)**, p. 2511–2515, 2012. 9
- WANG, N.; DU, C.; QIN, Q. M. Local spatial analysis in surface information extraction of coal mining areas with high fractional vegetation cover using multi-source remote sensing data. **IEEE International Geoscience and Remote Sensing Symposium (IGARSS)**, p. 2625–2628, 2013. 9
- WEBER, L.; KLEIN, P. A. T. **Aplicação da lógica fuzzy em software e hardware**. Canoas: ULBRA, 2003. 1st. 46
- WU, Y.; JI, K.; YU, W.; SU, Y. Region-based classification of polarimetric SAR images using Wishart MRF. **IEEE Geoscience and Remote Sensing Letters**, v. 5, n. 4, p. 668–672, 2008. 2, 26
- WU, Z.; GAO, F. Classification of remote sensing image data fusion considering spatial information. In: INTERNATIONAL CONFERENCE ON INFORMATION SCIENCE AND ENGINEERING (ICISE), 2., 2010. Proceedings... 2010. 9
- XIE, J.; LI, G. Implementing next-generation national earth observation data infrastructure to integrate distributed big earth observation data. **IEEE International Geoscience and Remote Sensing Symposium (IGARSS)**, p. 194–197, 2016. 2
- ZHANG, Y.; PRASAD, S. Locality preserving composite kernel feature extraction for multi-source geospatial image analysis. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 8, n. 3, p. 1385–1392, 2014. 2, 9



## APÊNDICE A - MANUAL DO USUÁRIO

Os arquivos dos algoritmos do classificador e os seus diretórios na TerraLib são exibidos na Tabela A.1.

Tabela A.1 - Arquivos dos códigos do classificador e seus diretórios na TerraLib.

Arquivo	Diretório
MultiSourceClassifier.cpp MultiSourceClassifier.h	scr/terralib/rp/radar
GaussianModel.cpp GaussianModel.h	
GammaModel.cpp GammaModel.h	
WishartModel.cpp WishartModel.h	
IntensityPairModel.cpp IntensityPairModel.h	
MultiSourceClassifierFirstDialog.cpp MultiSourceClassifierFirstDialog.h	scr/terralib/qt/widgets/rp
MultiSourceClassifierSecondDialog.cpp MultiSourceClassifierSecondDialog.h	
MultiSourceClassifierFirstDialogForm.ui MultiSourceClassifierSecondDialogForm.ui	scr/terralib/qt/widgets/rp/ui

Fonte: Produção do autor.

Para permitir a utilização do *software* na versão desenvolvida nesta Dissertação, foi gerado um arquivo executável. O classificador implementado está disponível com uma interface gráfica que consiste em duas janelas, como é mostrado nas Figuras A.1 e A.3, e segue-se uma breve explicação sobre os componentes de cada uma delas. Ao executar o programa, aparecerá a primeira janela (Figura A.1). Para realizar o processo de classificação, os insumos necessários que independem do tipo de imagem de entrada devem ser inseridos nesta janela.

No campo "*Number of Images*" deve ser informado o número de imagens de entrada. Vale ressaltar que caso o valor seja um, trata-se de classificação monofonte, e caso seja maior que um, trata-se de classificação multifonte. "*Segmented Image*" indica o local onde devem ser informados o arquivo e o caminho do diretório da imagem segmentada. Para isso, o usuário poderá clicar no botão à direita do campo e uma nova janela será aberta para que o arquivo seja selecionado. O arquivo correspondente à

imagem segmentada deverá estar no formato .TIF ou .TIFF.

Figura A.1 - Janela 1 da interface gráfica.

The image shows a software window titled "MultiSource Classifier" with a subtitle "MultiSource Classifier Based On Stochastic Distances". The window is divided into several sections:

- Input:** Contains four text input fields: "Number of Images:", "Segmented Image:", "Training Samples:", and "Test Samples:". Each field has a small "..." button to its right for file selection.
- Combination Type:** Features four radio button options: "Sum" (selected), "Multiplication", "Minimum", and "Fuzzy".
- Confidence Level (%):** A text input field containing the value "95".
- Horizontal Lag:** A text input field containing the value "0".
- Vertical Lag:** A text input field containing the value "0".
- Output:** Contains two text input fields: "Repository:" and "Layer Name:", each with a "..." button to its right.
- Save on Disk:** A section with two rows of checkboxes. The first row includes "Distances", "Statistics", "P-Values", and "Report", all of which are checked. The second row is labeled "Per class:" and includes "Distances", "Statistics", and "P-Values", all of which are also checked.

At the bottom of the window, there are three buttons: "Help", "Ok", and "Cancel".

Fonte: Produção do autor.

Em "*Training Samples*" o usuário deverá selecionar o diretório das amostras de treinamento, clicando no botão que está à direita. Em "*Test Samples*", ao clicar no botão

à direita, o usuário poderá definir o diretório das amostras de teste. As amostras de treinamento e de teste devem estar armazenadas em diretórios distintos, salvo o caso em que o usuário deseja utilizar o mesmo conjunto de amostras tanto para treinamento quanto para teste. Os arquivos das amostras devem estar no formato *shape file* (.shp) e devem estar separados por classe de interesse. A ordem de leitura das classes segue a ordem em que os arquivos estão dispostos no diretório.

Os botões exclusivos do campo "*Combination Type*" permitem que o usuário selecione a forma de combinação das informações das imagens na classificação multifontes. Portanto, os botões são habilitados somente quando o número de imagens informado em "*Number of Images*" é igual ou maior que dois. As opções de combinações disponíveis são soma ("*Sum*"), produto (*Multiplication*) e mínimos ("*Minimum*") das estatísticas, além da opção da classificação "*Fuzzy*". Em "*Confidence Level*" deve ser informado o percentual do nível de confiança, que é utilizado como parâmetro no cálculo do valor crítico das estatísticas de teste. Em "*Horizontal Lag*" e "*Vertical Lag*" devem ser definidos os valores de *lag* horizontal e vertical, respectivamente.

O campo "*Output*" está relacionado à saída do *software*. O botão correspondente ao "*Repository*" permite definir o diretório em que o usuário deseja salvar todos os arquivos de saída. Ao clicar no botão, uma janela aparecerá para selecionar o diretório e, neste momento, o usuário também deverá definir um nome, sem especificar qualquer formato ou extensão, que será usado pelo sistema para nomear todos os arquivos gerados. Este nome escolhido aparecerá no campo "*Layer Name*" para lembrar ao usuário que todos os arquivos serão nomeados daquela forma. As saídas consistem em três arquivos no formato TIF, a saber: a imagem classificada com o nome <Definição-do-Usuário>\_ClassifiedImage; a imagem das estatísticas de teste com o nome <Definição-do-Usuário>\_StatisticalTestMap; e a imagem de valores *p* com o nome <Definição-do-Usuário>\_PValueMap. Por exemplo, se o nome dos arquivos de saída definido pelo usuário for TESTE, então os três arquivos salvos no diretório escolhido serão os seguintes: TESTE\_ClassifiedImage.tif, TESTE\_StatisticalTestMap.tif e TESTE\_PValueMap.tif. Vale destacar que no caso da classificação *Fuzzy* são gerados  $k + 1$  imagens temáticas, onde  $k$  é o número de classes e é considerado mais uma banda correspondente às regiões não classificadas. Ao invés de serem gerados  $k + 1$  arquivos diferentes para cada imagem, é gerado um único arquivo (<Definição-do-Usuário>\_ClassifiedImage.tif) como se fosse uma única imagem com  $k + 1$  bandas. É gerado também um arquivo de mesmo nome, porém no formato txt (<Definição-do-Usuário>\_ClassifiedImage.txt) com as mesmas informações do arquivo tif com os valores de classificação *Fuzzy* para cada classe

separados por região.

Além dos três arquivos que sempre são gerados na classificação, em "*Save on Disk*" é possível escolher salvar no mesmo diretório definido pelo usuário outros cinco arquivos no formato txt. Um desses arquivos é gerado com os valores por região das distâncias estocásticas, estatísticas de teste e *p*-valores finais da classificação caso sejam selecionadas as opções "*Distances*", "*Statistics*" e "*P-Values*", respectivamente. O nome desse arquivo é definido por <Definição-do-Usuário>\_Attributes.txt. Outros três arquivos são gerados com os valores por região das distâncias, estatísticas e *p*-valores para cada classe caso sejam selecionadas as respectivas opções "*Distances*", "*Statistics*" e "*P-Values*", do campo "*Per class*". Os nomes dos respectivos arquivos são definidos por <Definição-do-Usuário>\_DistancePerClass.txt, <Definição-do-Usuário>\_StatisticPerClass.txt e <Definição-do-Usuário>\_PValuePerClass.txt. As duas opções para salvar as distâncias estocásticas são habilitadas somente quando o número de imagens informado no campo "*Number of Images*" é igual a um. Outro arquivo que pode ser gerado é o relatório que contém a matriz de confusão e os índices de avaliação de qualidade da classificação, caso a opção "*Report*" seja selecionada. O nome deste arquivo é definido por <Definição-do-Usuário>\_Report.txt.


Se o botão "*OK*" for pressionado e todos os campos obrigatórios estiverem preenchidos, a segunda janela (Figura A.3) aparecerá para o usuário. Caso contrário, uma mensagem será enviada ao usuário indicando os lugares que devem ser preenchidos. Se o botão "*Cancel*" for pressionado, a janela será fechada e encerrará a execução do programa. Se o botão "*Help*" for pressionado, uma nova janela é aberta contendo algumas informações sobre o *software* e formas de uso, como descritas neste apêndice.

A segunda janela (Figura A.3) permite que o usuário insira os dados referentes às imagens de entrada. A quantidade de vezes que ela aparecerá para o usuário é igual ao número de imagens que foi informado no campo "*Number of Images*" da primeira janela. Como mostra o fluxograma da Figura A.2, a segunda janela será chamada enquanto não atingir o número de imagens que o usuário informou. A seguir segue-se uma breve explicação sobre os componentes desta janela.

O marcador de "*Image number (starting in 0)*" é um contador do número de imagens que o usuário está inserindo. Por exemplo, em uma classificação multifontes hipotética de três imagens, a primeira vez que a janela aparecer o contador indicará 0. Na segunda aparição marcará 1 e na terceira marcará 2. Dessa forma, o usuário

saberá quantas imagens ele já inseriu no sistema e quantas ainda faltam.

Figura A.2 - Fluxograma da interface gráfica.



Fonte: Produção do autor.

No campo "*Statistic Model*" estão os botões exclusivos para definir o modelo estatístico da imagem de entrada. As opções são "*Gaussian*", "*Gamma*", "*Wishart*" e "*Intensity Pair*" para as distribuições Gaussiana multivariada, Gama, Wishart complexa escalonada e Par de Intensidades *multilook*, respectivamente.

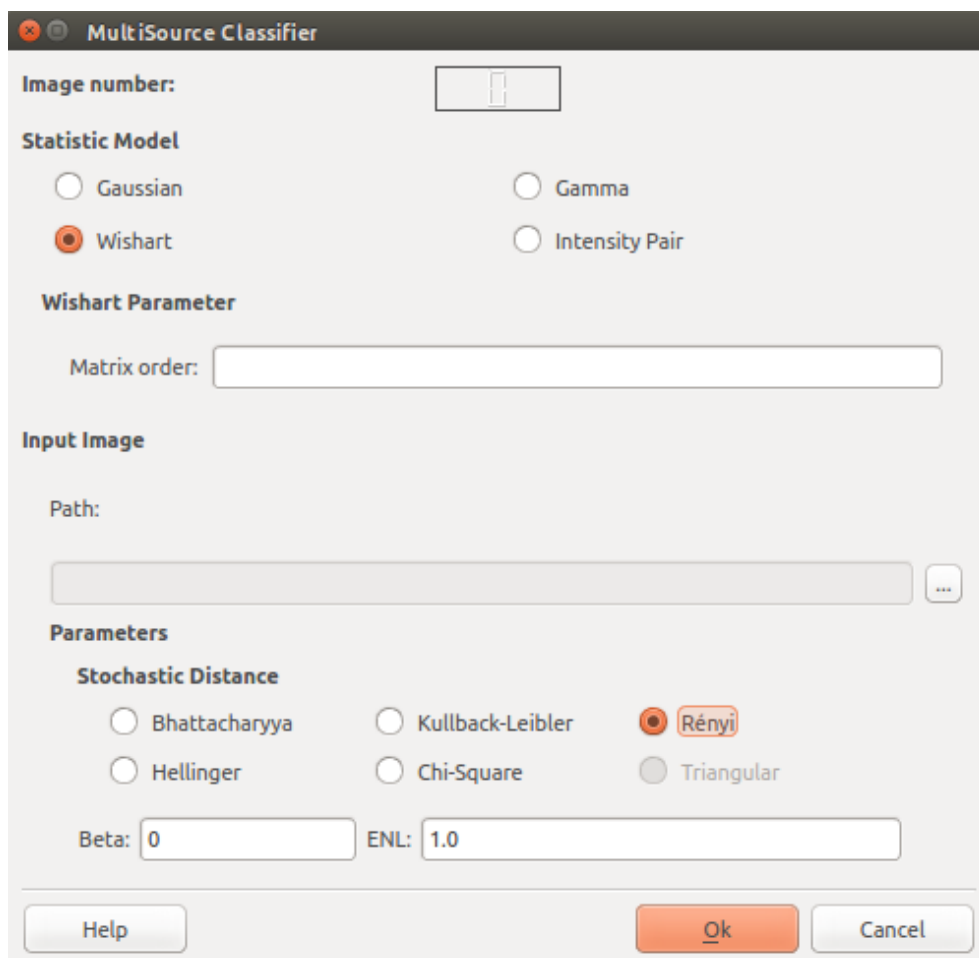
Em "*Wishart Parameter*" está o parâmetro específico "*Matrix order*" para a modelagem de dados por meio da distribuição Wishart complexa escalonada. Portanto, este campo é habilitado somente quando a opção "*Wishart*" é selecionada. "*Matrix order*" indica o local para informar a ordem da matriz de covariância.

"*Input Image*" é o lugar para inserir o arquivo da imagem. Ao clicar no botão à direita do campo "*Path*", uma janela será aberta para que o arquivo seja selecionado no diretório. Como o suporte aos dados geográficos são dados pela biblioteca TerraLib, o formato do arquivo das imagens de entrada pode ser qualquer um suportado

pela biblioteca GDAL<sup>1</sup>, como por exemplo, TIF, GeoTIFF e JPEG. Em relação aos dados SAR polarimétricos modelados por intermédio da distribuição Wishart complexa escalonada, as bandas da imagem no formato matriz de covariância devem começar pela posição (0,0) da matriz. A próxima banda deve ser a posição da coluna posterior na mesma linha da matriz, e assim por diante. Na troca da linha da matriz, a primeira posição a ser considerada deve ser a posição que pertence a diagonal principal. Dessa maneira, as bandas que formam a imagem são correspondentes às posições da diagonal principal e a parte superior dessa diagonal da matriz. Isso geralmente já é feito porque os elementos da parte inferior da diagonal principal da matriz são os complexos conjugados dos elementos da parte superior, e dessa forma, reduz-se os custos computacionais de armazenamento e processamento desses tipos

<sup>1</sup>Formatos disponíveis em [http://www.gdal.org/formats\\_list.html](http://www.gdal.org/formats_list.html)

Figura A.3 - Janela 2 da interface gráfica.



Fonte: Produção do autor.

de dados. A imagem A.4 ilustra essa explicação para o caso de matriz de covariância de ordem 3.

Figura A.4 - Exemplo da ordem das bandas das imagens polarimétricas de matriz de covariância de ordem 3.

$$\mathbf{C} = \begin{bmatrix} |S_{HH}|^2 & S_{HH}S_{HV}^* & S_{HH}S_{VV}^* \\ & |S_{HV}|^2 & S_{HV}S_{VV}^* \\ & & |S_{VV}|^2 \end{bmatrix}$$



Banda 1:  $|S_{HH}|^2$

Banda 2:  $S_{HH}S_{HV}^*$

Banda 3:  $S_{HH}S_{VV}^*$

Banda 4:  $|S_{HV}|^2$

Banda 5:  $S_{HV}S_{VV}^*$

Banda 6:  $|S_{VV}|^2$

Fonte: Produção do autor.

Em "*Parameters*" são definidos a distância estocástica ("*Stochastic Distance*"), o número equivalente de *looks* ("*ENL*") e o parâmetro *Beta* ("*Beta*"). Este último é um parâmetro da distância *Rényi*. As distâncias que podem ser escolhidas são *Bhatta-*

*charyya*, *Kullback-Leibler*, *Rényi*, *Hellinger*, *Chi-Square* (Qui-quadrado) e *Triangular*.

Quando o botão "OK" é pressionado, a segunda janela (Figura A.3) aparece novamente para o usuário se a quantidade de imagens não foi atingida ou, caso contrário, a execução do programa é iniciada. Se os campos obrigatórios não estiverem preenchidos uma mensagem é enviada ao usuário indicando os lugares que devem ser preenchidos. Quando o botão "Cancel" é pressionado, as janelas são fechadas e a execução do programa é encerrada. Quando o botão "Help" é pressionado, uma nova janela é aberta contendo algumas informações sobre o *software* e formas de uso, como descritas neste apêndice.



## APÊNDICE B - CASO DE TESTE I

O caso de teste apresentado neste apêndice foi introduzido na Seção 4.2.1. Objetiva-se neste caso de teste mostrar a corretude e confiabilidade da ferramenta computacional desenvolvida nesta Dissertação. Os dados utilizados são simulados, e dessa maneira, o comportamento dos alvos nas imagens é conhecido à priori. Os dados consistem em uma imagem polarimétrica, uma imagem em amplitude multivariada (canais HH, HV e VV) e duas imagens em intensidade (HH e HV). As classes definidas foram: Rio (RI), Caatinga (CA), Solo Preparado (SP) e Soja 1 (SO). A segmentação utilizada possui regiões quadradas de tamanhos  $30 \times 30$  pixels e contém 36 regiões. A Figura B.1 ilustra as posições das regiões na imagem e a que classe cada uma pertence.

Figura B.1 - Posições e classes das regiões das imagens do Caso de Teste 1.

0 RI	1 RI	2 RI	3 CA	4 CA	5 SP
6 RI	7 CA	8 RI	9 CA	10 CA	11 CA
12 RI	13 RI	14 RI	15 SO	16 CA	17 CA
18 RI	19 RI	20 SO	21 SP	22 SP	23 SP
24 SO	25 CA	26 SO	27 SP	28 SP	29 SP
30 SO	31 SO	32 SO	33 SP	34 SP	35 SP

Fonte: Produção do autor.

Foram construídas treze classificações monofontes, conforme é mostrado na Tabela B.1. As treze classificações monofontes produzidas abrangem todas as distâncias dos quatro módulos implementados no *software*, com o objetivo de verificar se as regiões são atribuídas às classes corretas em todos esses casos.

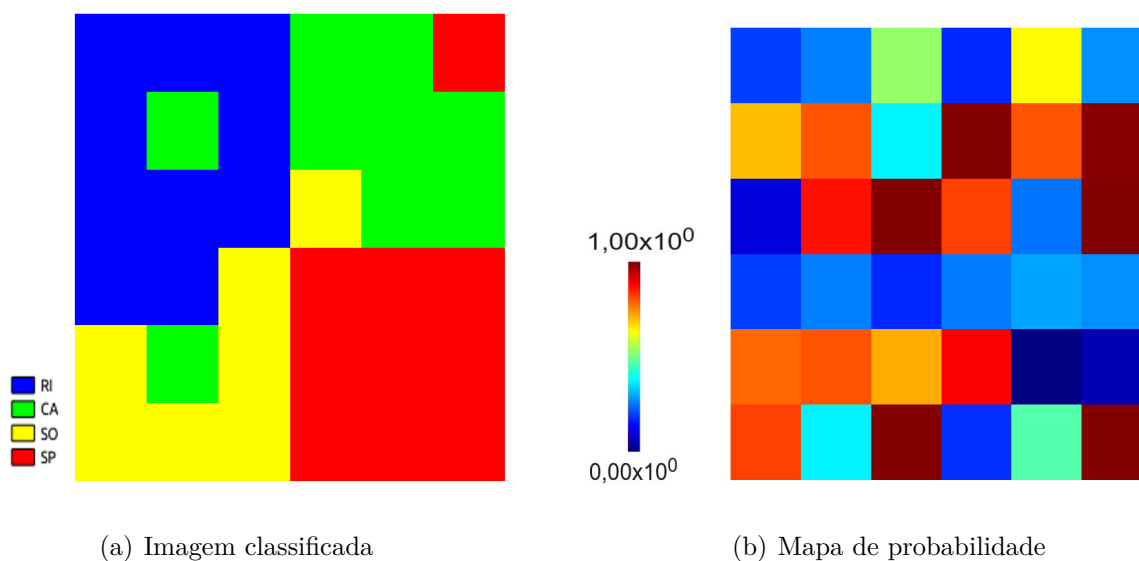
Tabela B.1 - Classificações monofontes com os dados simulados.

Imagem	Módulo	Distância estocástica	Classificação
Imagem polarimétrica	Wishart	<i>Bhattacharyya</i>	I
		<i>Kullback-Leibler</i>	II
		<i>Rényi</i>	III
		<i>Hellinger</i>	IV
		Qui-quadrado	V
Par de imagens em intensidade HH,HV	Par de Intensidades	<i>Bhattacharyya</i>	VI
		Triangular	VII
Imagem multivariada em amplitude	Gaussiana	<i>Bhattacharyya</i>	VIII
		<i>Kullback-Leibler</i>	IX
Imagem monocanal em intensidade HH	Gama	<i>Bhattacharyya</i>	X
		<i>Kullback-Leibler</i>	XI
		<i>Rényi</i>	XII
		<i>Hellinger</i>	XIII

Fonte: Produção do autor.


As imagens classificadas e de probabilidade geradas pelas classificações monofontes VII, IX, XI e XII são apresentadas nas Figuras B.2 a B.5.

Figura B.2 - Resultados para a classificação do par de imagens SAR simuladas HH,HV com a distância Triangular.



Fonte: Produção do autor.

Figura B.3 - Resultados para a classificação da imagem SAR simulada em amplitude multivarida com a distância de *Kullback-Leibler*.




(a) Imagem classificada

(b) Mapa de probabilidade

Fonte: Produção do autor.

Figura B.4 - Resultados para a classificação da imagem SAR simulada monocanal em intensidade HH com a distância de *Kullback-Leibler*.




(a) Imagem classificada

(b) Mapa de probabilidade

Fonte: Produção do autor.

Os resultados das classificações monofontes produzidas são exibidos nas Tabelas B.2 a B.14. Nas tabelas encontram-se os valores das distâncias, das estatísticas e dos valores-p calculados entre as regiões e as amostras das classes. São destacados os

Figura B.5 - Resultados para a classificação da imagem SAR simulada monocanal em intensidade HH com a distância de Rényi.



Fonte: Produção do autor.

menores valores das estatísticas obtidos para as regiões e são mostradas as classes que as regiões foram rotuladas.

Tabela B.2 - Resultados correspondentes à classificação monofonte I.

Região	Classe Verdadeira	Distâncias					Estatísticas					Valor $p$	Classe atribuída
		$d_{RI}$	$d_{CA}$	$d_{SO}$	$d_{SP}$	$d_{SRI}$	$s_{CA}$	$s_{SO}$	$s_{SP}$				
0	RI	<b>0,0013368</b>	13,529	7,1725	1,365	<b>4,8124</b>	48703	25821	4914,1	0,85034	RI		
1	RI	<b>0,0017792</b>	13,499	7,1433	1,3474	<b>6,4052</b>	48595	25716	4850,7	0,69878	RI		
2	RI	<b>0,0006233</b>	13,557	7,1939	1,3606	<b>2,2439</b>	48807	25898	4898,3	0,98699	RI		
3	CA	13,771	<b>0,0015919</b>	2,4494	9,9812	49576	<b>5,7308</b>	8817,8	35932	0,76653	CA		
4	CA	13,704	<b>0,0019547</b>	2,4135	9,9222	49335	<b>7,0367</b>	8688,5	35720	0,63329	CA		
5	SP	1,3774	9,9532	4,3769	<b>0,0013754</b>	4958,8	35831	15757	<b>4,9514</b>	0,83852	SP		
6	RI	<b>0,0010739</b>	13,576	7,2058	1,3626	<b>3,8661</b>	48875	25941	4905,3	0,92000	RI		
7	CA	13,723	<b>0,0017586</b>	2,4024	9,9384	49403	<b>6,3311</b>	8648,8	35778	0,70637	CA		
8	RI	<b>0,002031</b>	13,521	7,1586	1,3561	<b>7,3116</b>	48675	25771	4881,9	0,60471	RI		
9	CA	13,676	<b>0,00080601</b>	2,3824	9,8905	49233	<b>2,9016</b>	8576,6	35606	0,968067699	CA		
10	CA	13,723	<b>0,0017586</b>	2,4024	9,9384	49403	<b>6,3311</b>	8648,8	35778	0,70637	CA		
11	CA	13,652	<b>0,001911</b>	2,3923	9,8637	49148	<b>6,8796</b>	8612,4	35509	0,64964	CA		
12	RI	<b>0,0024651</b>	13,43	7,0841	1,3452	<b>8,8744</b>	48348	25503	4842,8	0,44895	RI		
13	RI	<b>0,00030629</b>	13,616	7,2427	1,4007	<b>1,1027</b>	49018	26074	5042,5	0,99916	RI		
14	RI	<b>0</b>	13,636	7,2636	1,4011	<b>0</b>	49088	26149	5044	<b>1</b>	RI		
15	SO	7,3124	2,3494	<b>0,00038747</b>	4,3398	26324	8457,9	<b>1,3949</b>	15623	0,99785	SO		
16	CA	13,734	<b>0,00080417</b>	2,4315	9,9413	49443	<b>2,895</b>	8753,4	35789	0,96831	CA		
17	CA	13,636	<b>0</b>	2,3734	9,8508	49088	<b>0</b>	8544,3	35463	<b>1</b>	CA		
18	RI	<b>0,0013368</b>	13,529	7,1725	1,365	<b>4,8124</b>	48703	25821	4914,1	0,85034	RI		
19	RI	<b>0,0017792</b>	13,499	7,1433	1,3474	<b>6,4052</b>	48595	25716	4850,7	0,69878	RI		
20	SO	7,3882	2,309	<b>0,0016804</b>	4,4053	26598	8312,6	<b>6,0493</b>	15859	0,73497	SO		
21	SP	1,3531	9,9865	4,4074	<b>0,0018881</b>	4871,1	35951	15867	<b>6,797</b>	0,65824	SP		
22	SP	1,3627	10,019	4,4402	<b>0,0034201</b>	4905,7	36069	15985	<b>12,312</b>	0,19627	SP		
23	SP	1,3774	9,9532	4,3769	<b>0,0013754</b>	4958,8	35831	15757	<b>4,9514</b>	0,83852	SP		
24	SO	7,316	2,3656	<b>0,0010608</b>	4,3533	26337	8516,3	<b>3,8189</b>	15672	0,92292	SO		
25	CA	13,723	<b>0,0017586</b>	2,4024	9,9384	49403	<b>6,3311</b>	8648,8	35778	0,70637	CA		
26	SO	7,2881	2,3696	<b>0,0012323</b>	4,3191	26237	8530,5	<b>4,4363</b>	15549	0,88042	SO		
27	SP	1,4084	9,9447	4,3796	<b>0,0015951</b>	5070,1	35801	15766	<b>5,7423</b>	0,76540	SP		
28	SP	1,3216	10,023	4,4265	<b>0,0032395</b>	4757,9	36084	15935	<b>11,662</b>	0,23302	SP		
29	SP	1,3303	10,046	4,452	<b>0,003891</b>	4788,9	36165	16027	<b>14,008</b>	0,12205	SP		
30	SO	7,3124	2,3494	<b>0,00038747</b>	4,3398	26324	8457,9	<b>1,3949</b>	15623	0,99785	SO		
31	SO	7,2626	2,3844	<b>0,00076275</b>	4,291	26145	8583,9	<b>2,7459</b>	15447	0,97352	SO		
32	SO	7,2636	2,3734	<b>0</b>	4,2981	26149	8544,3	<b>0</b>	15473	<b>1</b>	SO		

Tabela B.3 - Resultados correspondentes à classificação monofonte II.

Região	Classe Verdadeira	Distâncias				Estatísticas				Valor $p$	Classe atribuída
		$d_{RI}$	$d_{CA}$	$d_{SO}$	$d_{SP}$	$s_{RI}$	$s_{CA}$	$s_{SO}$	$s_{SP}$		
0	RI	<b>0,0053482</b>	312,37	67,183	6,5462	<b>4,8134</b>	2,8113e+05	60465	5891,6	0,85025	RI
1	RI	<b>0,007119</b>	309,03	66,672	6,4597	<b>6,4071</b>	2,7813e+05	60005	5813,7	0,69858	RI
2	RI	<b>0,0024936</b>	310,3	67,431	6,5628	<b>2,2442</b>	2,7927e+05	60688	5906,5	0,98699	RI
3	CA	326,37	<b>0,0063689</b>	13,883	130,44	2,9373e+05	<b>5,732</b>	12495	1,174e+05	0,76641	CA
4	CA	322,43	<b>0,0078212</b>	13,687	129,24	2,9019e+05	<b>7,0391</b>	12318	1,1632e+05	0,63305	CA
5	SP	6,6682	129,37	31,501	<b>0,0055027</b>	6001,4	1,1644e+05	28351	<b>4,9524</b>	0,83843	SP
6	RI	<b>0,0042962</b>	310,24	67,209	6,5747	<b>3,8665</b>	2,7921e+05	60488	5917,2	0,91997	RI
7	CA	317,84	<b>0,0070369</b>	13,457	127,8	2,8606e+05	<b>6,3332</b>	12111	1,1502e+05	0,7061	CA
8	RI	<b>0,0081261</b>	310,75	66,565	6,4955	<b>7,3135</b>	2,7968e+05	59909	5846	0,60451	RI
9	CA	315,39	<b>0,0032245</b>	13,324	126,42	2,8385e+05	<b>2,902</b>	11992	1,1378e+05	0,96805	CA
10	CA	317,84	<b>0,0070369</b>	13,457	127,8	2,8606e+05	<b>6,3332</b>	12111	1,1502e+05	0,7061	CA
11	CA	316,12	<b>0,0076461</b>	13,478	126,05	2,8451e+05	<b>6,8815</b>	12131	1,1345e+05	0,64945	CA
12	RI	<b>0,0098632</b>	305,1	65,799	6,4456	<b>8,8769</b>	2,7459e+05	59219	5801	0,44871	RI
13	RI	<b>0,0012252</b>	314,32	68,1	6,7924	<b>1,1027</b>	2,8289e+05	61290	6113,2	0,99916	RI
14	RI	<b>0</b>	315,93	68,667	6,7963	<b>0</b>	2,8434e+05	61801	6116,6	1	RI
15	SO	69,832	13,177	<b>0,00155</b>	31,329	62849	11860	<b>1,395</b>	28196	0,99785	SO
16	CA	321,15	<b>0,0032171</b>	13,728	128,16	2,8904e+05	<b>2,8954</b>	12355	1,1534e+05	0,96829	CA
17	CA	315,93	<b>0</b>	13,341	126,22	2,8434e+05	<b>0</b>	12006	1,136e+05	1	CA
18	RI	<b>0,0053482</b>	312,37	67,183	6,5462	<b>4,8134</b>	2,8113e+05	60465	5891,6	0,85025	RI
19	RI	<b>0,007119</b>	309,03	66,672	6,4597	<b>6,4071</b>	2,7813e+05	60005	5813,7	0,69858	RI
20	SO	71,382	12,901	<b>0,0067238</b>	32,146	64244	11611	<b>6,0514</b>	28932	0,73476	SO
21	SP	6,5095	130,31	32,017	<b>0,0075548</b>	5858,5	1,1728e+05	28816	<b>6,7993</b>	0,65800	SP
22	SP	6,5556	131,38	32,607	<b>0,013691</b>	5900	1,1824e+05	29347	<b>12,322</b>	0,19575	SP
23	SP	6,6682	129,37	31,501	<b>0,0055027</b>	6001,4	1,1644e+05	28351	<b>4,9524</b>	0,83843	SP
24	SO	70,052	13,347	<b>0,0042442</b>	31,723	63047	12012	<b>3,8198</b>	28551	0,92286	SO
25	CA	317,84	<b>0,0070369</b>	13,457	127,8	2,8606e+05	<b>6,3332</b>	12111	1,1502e+05	0,70616	CA
26	SO	69,573	13,331	<b>0,0049301</b>	31,186	62616	11998	<b>4,4371</b>	28068	0,88036	SO
27	SP	6,8257	128,7	31,789	<b>0,0063819</b>	6143,2	1,1583e+05	28610	<b>5,7437</b>	0,76526	SP
28	SP	6,3104	130,58	32,139	<b>0,012967</b>	5679,3	1,1752e+05	28925	<b>11,67</b>	0,23253	SP
29	SP	6,3557	131,47	32,609	<b>0,015577</b>	5720,1	1,1832e+05	29348	<b>14,019</b>	0,12165	SP
30	SO	69,832	13,177	<b>0,00155</b>	31,329	62849	11860	<b>1,395</b>	28196	0,99785	SO
31	SO	68,975	13,498	<b>0,0030513</b>	30,803	62077	12148	<b>2,7462</b>	27723	0,97351	SO
32	SO	68,667	13,341	<b>0</b>	30,763	61801	12006	<b>0</b>	27687	1	SO

Tabela B.4 - Resultados correspondentes à classificação monofonte III.

Região	Classe Verdadeira	Distâncias					Estatísticas					Valor $p$	Classe atribuída
		$d_{RI}$	$d_{CA}$	$d_{SO}$	$d_{SP}$	$s_{RI}$	$s_{CA}$	$s_{SO}$	$s_{SP}$				
0	RI	<b>0,0026735</b>	27,057	14,345	2,73	<b>4,8124</b>	48703	25821	4914,1	0,85034	RI		
1	RI	<b>0,0035584</b>	26,997	14,287	2,6948	<b>6,4052</b>	48595	25716	4850,7	0,69878	RI		
2	RI	<b>0,0012466</b>	27,115	14,388	2,7213	<b>2,2439</b>	48807	25898	4898,3	0,98699	RI		
3	CA	27,542	<b>0,0031838</b>	4,8988	19,962	49576	<b>5,7308</b>	8817,8	35932	0,76653	CA		
4	CA	27,408	<b>0,0039093</b>	4,8269	19,844	49335	<b>7,0367</b>	8688,5	35720	0,6332	CA		
5	SP	2,7549	19,906	8,7537	<b>0,0027508</b>	4958,8	35831	15757	<b>4,9514</b>	0,83852	SP		
6	RI	<b>0,0021478</b>	27,153	14,412	2,7251	<b>3,8661</b>	48875	25941	4905,3	0,920004	RI		
7	CA	27,446	<b>0,0035173</b>	4,8049	19,877	49403	<b>6,3311</b>	8648,8	35778	0,70637	CA		
8	RI	<b>0,004062</b>	27,042	14,317	2,7122	<b>7,3116</b>	48675	25771	4881,9	0,60471	RI		
9	CA	27,352	<b>0,001612</b>	4,7648	19,781	49233	<b>2,9016</b>	8576,6	35606	0,96806	CA		
10	CA	27,446	<b>0,0035173</b>	4,8049	19,877	49403	<b>6,3311</b>	8648,8	35778	0,70637	CA		
11	CA	27,305	<b>0,003822</b>	4,7847	19,727	49148	<b>6,8796</b>	8612,4	35509	0,64964	CA		
12	RI	<b>0,0049302</b>	26,86	14,168	2,6904	<b>8,8744</b>	48348	25503	4842,8	0,44895	RI		
13	RI	<b>0,00061258</b>	27,232	14,485	<b>2,8014</b>	1,1027	49018	26074	5042,5	0,99916	RI		
14	RI	<b>0</b>	27,271	14,527	2,8022	<b>0</b>	49088	26149	5044	1	RI		
15	SO	14,625	4,6988	<b>0,00077494</b>	8,6796	26324	8457,9	<b>1,3949</b>	15623	0,99785	SO		
16	CA	27,468	<b>0,0016083</b>	4,863	19,883	49443	<b>2,895</b>	8753,4	35789	0,96831	CA		
17	CA	27,271	<b>8,8818e-16</b>	4,7469	19,702	49088	<b>1,5987e-12</b>	8544,3	35463	1	CA		
18	RI	<b>0,0026735</b>	27,057	14,345	2,73	<b>4,8124</b>	48703	25821	4914,1	0,85034	RI		
19	RI	<b>0,0035584</b>	26,997	14,287	2,6948	<b>6,4052</b>	48595	25716	4850,7	0,69878	RI		
20	SO	14,776	4,6181	<b>0,0033607</b>	8,8106	26598	8312,6	<b>6,0493</b>	15859	0,73497	SO		
21	SP	2,7062	19,973	8,8147	<b>0,0037761</b>	4871,1	35951	15867	<b>6,797</b>	0,65824	SP		
22	SP	2,7254	20,038	8,8803	<b>0,0068402</b>	4905,7	36069	15985	<b>12,312</b>	0,19627	SP		
23	SP	2,7549	19,906	8,7537	<b>0,0027508</b>	4958,8	35831	15757	<b>4,9514</b>	0,83852	SP		
24	SO	14,632	4,7313	<b>0,0021216</b>	8,7065	26337	8516,3	<b>3,8189</b>	15672	0,92292	SO		
25	CA	27,446	<b>0,0035173</b>	4,8049	19,877	49403	<b>6,3311</b>	8648,8	35778	0,70637	CA		
26	SO	14,576	4,7392	<b>0,0024646</b>	8,6382	26237	8530,5	<b>4,4363</b>	15549	0,88042	SO		
27	SP	2,8167	19,889	8,7591	<b>0,0031902</b>	5070,1	35801	15766	<b>5,7423</b>	0,76540	SP		
28	SP	2,6433	20,047	8,8529	<b>0,0064791</b>	4757,9	36084	15935	<b>11,662</b>	0,23302	SP		
29	SP	2,6605	20,092	8,9039	<b>0,007782</b>	4788,9	36165	16027	<b>14,008</b>	0,12205	SP		
30	SO	14,625	4,6988	<b>0,00077494</b>	8,6796	26324	8457,9	<b>1,3949</b>	15623	0,99785	SO		
31	SO	14,525	4,7688	<b>0,0015255</b>	8,5819	26145	8583,9	<b>2,7459</b>	15447	0,97352	SO		
32	SO	14,527	4,7469	<b>0</b>	8,5961	26149	8544,3	<b>0</b>	15473	1	SO		

Tabela B.5 - Resultados correspondentes à classificação monofonte IV.

Região	Classe Verdadeira	Distâncias						Estatísticas				Valor $p$	Classe atribuída
		$d_{RI}$	$d_{CA}$	$d_{SO}$	$d_{SP}$	$s_{RI}$	$s_{CA}$	$s_{SO}$	$s_{SP}$				
0	RI	<b>0,0013359</b>	1	0,99923	0,74462	04,8092	3600	3597,2	2680,6	0,85061	RI		
1	RI	<b>0,0017776</b>	1	0,99921	0,74009	<b>6,3995</b>	3600	3597,2	2664,3	0,69936	RI		
2	RI	<b>0,00062311</b>	1	0,99925	0,7435	<b>2,2432</b>	3600	3597,3	2676,6	0,98701	RI		
3	CA	1	<b>0,0015906</b>	0,91365	0,99995	3600	<b>5,7262</b>	3289,2	3599,8	0,76697	CA		
4	CA	1	<b>0,0019527</b>	0,9105	0,99995	3600	<b>7,0299</b>	3277,8	3599,8	0,63400	CA		
5	SP	0,74778	0,99995	0,98744	<b>0,0013744</b>	2692	3599,8	3554,8	<b>4,948</b>	0,83881	SP		
6	RI	<b>0,0010733</b>	1	0,99926	0,744	<b>3,864</b>	3600	3597,3	<b>02678,4</b>	0,92013	RI		
7	CA	1	<b>0,0017571</b>	0,9095	0,99995	3600	<b>6,3255</b>	3274,2	3599,8	0,70694	CA		
8	RI	<b>0,0020289</b>	1	0,99922	0,74233	<b>7,3041</b>	3600	3597,2	2672,4	0,60548	RI		
9	CA	1	<b>0,00080568</b>	0,90767	0,99995	3600	<b>2,9005</b>	3267,6	3599,8	0,96811	CA		
10	CA	1	<b>0,0017571</b>	0,9095	0,99995	3600	<b>6,3255</b>	3274,2	3599,8	0,70694	CA		
11	CA	1	<b>0,0019092</b>	0,90858	0,99995	3600	<b>6,8731</b>	3270,9	3599,8	0,65033	CA		
12	RI	<b>0 0,0024621</b>	1	0,99916	0,73951	<b>08,8635</b>	3600	3597	2662,3	0,44997	RI		
13	RI	<b>0,00030625</b>	1	0,99928	0,75358	<b>1,1025</b>	3600	3597,4	2712,9	0,99916	RI		
14	RI	<b>0</b>	1	0,9993	0,75368	<b>0</b>	3600	3597,5	2713,2	1	RI		
15	SO	0,99933	0,90457	<b>0,00038739</b>	0,98696	3597,6	3256,5	<b>1,3946</b>	3553,1	0,99785	SO		
16	CA	1	<b>0,00080385</b>	0,9121	0,99995	3600	<b>2,8939</b>	3283,5	3599,8	0,96835	CA		
17	CA	1	<b>0</b>	0,90684	0,99995	3600	<b>0</b>	3264,6	3599,8	1	CA		
18	RI	<b>0,0013359</b>	1	0,99923	0,74462	<b>4,8092</b>	3600	3597,2	2680,6	0,85061	RI		
19	RI	<b>0,0017776</b>	1	0,99921	0,74009	<b>6,3995</b>	3600	3597,2	2664,3	0,69936	RI		
20	SO	0,99938	0,90064	<b>0,001679</b>	0,98779	3597,8	3242,3	<b>6,0442</b>	3556	0,73548	SO		
21	SP	0,74156	0,99995	0,98781	<b>0,0018863</b>	2669,6	3599,8	3556,1	<b>6,7906</b>	0,65891	SP		
22	SP	0,74403	0,99996	0,98821	<b>0,0034142</b>	2678,5	3599,8	3557,5	<b>12,291</b>	0,19738	SP		
23	SP	0,74778	0,99995	0,98744	<b>0,0013744</b>	2692	3599,8	3554,8	<b>4,948</b>	0,83881	SP		
24	SO	0,99934	0,90611	<b>0,0010603</b>	0,98714	3597,6	3262	<b>3,8169</b>	3553,7	0,92304	SO		
25	CA	1	<b>0,0017571</b>	0,9095	0,99995	3600	<b>6,3255</b>	3274,2	3599,8	0,70694	CA		
26	SO	0,99932	0,90648	<b>0,0012316</b>	0,98669	3597,5	3263,3	<b>4,4336</b>	3552,1	0,88063	SO		
27	SP	0,75546	0,99995	0,98747	<b>0,0015938</b>	2719,6	3599,8	3554,9	<b>5,7378</b>	0,76584	SP		
28	SP	0,73331	0,99996	0,98804	<b>0,0032343</b>	2639,9	3599,8	3557	<b>11,643</b>	0,23416	SP		
29	SP	0,73559	0,99996	0,98834	<b>0,0038834</b>	2648,1	3599,8	3558	<b>13,98</b>	0,12302	SP		
30	SO	0,99933	0,90457	<b>0,00038739</b>	0,98696	3597,6	3256,5	<b>1,3946</b>	3553,1	0,99785	SO		
31	SO	0,9993	0,90786	<b>0,00076246</b>	0,98631	3597,5	3268,3	<b>2,7449</b>	3550,7	0,97355	SO		
32	SO	0,9993	0,90684	<b>0</b>	0,98641	3597,5	3264,6	<b>0</b>	3551,1	1	SO		



Tabela B.6 - Resultados correspondentes à classificação monofonte V.

Região	Classe Verdadeira	Distâncias					Estatísticas					Valor $p$	Classe atribuída
		$d_{RI}$	$d_{CA}$	$d_{SO}$	$d_{SP}$	$s_{RI}$	$s_{CA}$	$s_{SO}$	$s_{SP}$				
0	RI	<b>0,0053863</b>	2,3703e+14	2,4196e+08	90,39	<b>4,8477</b>	2,1333e+17	2,1776e+11	81351	0,84737	RI		
1	RI	<b>0,0071872</b>	2,2434e+14	2,2878e+08	83,213	<b>6,4685</b>	2,019e+17	2,059e+11	74892	0,69226	RI		
2	RI	<b>0,0025027</b>	2,5598e+14	2,5931e+08	79,071	<b>2,2524</b>	2,3038e+17	2,3338e+11	71164	0,98681	RI		
3	CA	3,9715e+14	<b>0,0064208</b>	1414,4	1,3812e+11	3,5743e+17	<b>5,7787</b>	1,273e+06	1,2431e+14	0,76184	CA		
4	CA	3,4484e+14	<b>0,0079038</b>	1262,3	1,2054e+11	3,1036e+17	<b>7,1134</b>	1,1361e+06	1,0848e+14	0,62531	CA		
5	SP	90,886	1,3149e+11	2,4406e+05	<b>0,0055424</b>	81798	1,1834e+14	2,1966e+08	<b>4,9882</b>	0,83533	SP		
6	RI	<b>0,004319</b>	2,6805e+14	2,6998e+08	77,353	<b>3,8871</b>	2,4124e+17	2,4298e+11	69618	0,91868	RI		
7	CA	3,6631e+14	<b>0,0071056</b>	1281,3	1,2775e+11	3,2968e+17	<b>6,395</b>	1,1532e+06	1,1497e+14	0,69982	CA		
8	RI	<b>0,0082101</b>	2,3553e+14	2,3901e+08	85,806	<b>7,3891</b>	2,1198e+17	2,1511e+11	77225	0,59668	RI		
9	CA	3,317e+14	<b>0,0032383</b>	1196,5	1,1561e+11	2,9853e+17	<b>2,9145</b>	1,0769e+06	1,0405e+14	0,96758	CA		
10	CA	3,6631e+14	<b>0,0071056</b>	1281,3	1,2775e+11	3,2968e+17	<b>6,395</b>	1,1532e+06	1,1497e+14	0,69982	CA		
11	CA	3,1554e+14	<b>0,0077218</b>	1190,4	1,0972e+11	2,8399e+17	<b>6,9496</b>	1,0713e+06	9,8744e+13	0,64236	CA		
12	RI	<b>0,0099844</b>	1,9245e+14	1,9774e+08	93,417	<b>8,986</b>	1,7321e+17	1,7797e+11	84075	0,43856	RI		
13	RI	<b>0,001227</b>	2,8889e+14	2,9076e+08	91,519	<b>1,1043</b>	2,6e+17	2,6168e+11	82367	0,99915	RI		
14	RI	<b>8,8818e-16</b>	3,0057e+14	3,0293e+08	89,188	<b>7,9936e-13</b>	2,7051e+17	2,7264e+11	80269	1	RI		
15	SO	3,347e+08	1050,5	<b>0,0015534</b>	2,1834e+05	3,0123e+11	9,4548e+05	<b>1,398</b>	1,965e+08	0,99783	SO		
16	CA	3,7241e+14	<b>0,0032308</b>	1347,5	1,2919e+11	3,3517e+17	<b>2,9077</b>	1,2127e+06	1,1627e+14	0,96784	CA		
17	CA	3,0057e+14	<b>0</b>	1131,6	1,0482e+11	2,7051e+17	<b>0</b>	1,0184e+06	9,4341e+13	1	CA		
18	RI	<b>0,0053863</b>	2,3703e+14	2,4196e+08	90,39	<b>4,8477</b>	2,1333e+17	2,1776e+11	81351	0,84737	RI		
19	RI	<b>0,0071872</b>	2,2434e+14	2,2878e+08	83,213	<b>6,4685</b>	2,019e+17	2,059e+11	74892	0,69226	RI		
20	SO	3,9567e+08	925,53	<b>0,0067885</b>	2,5589e+05	3,5611e+11	8,3298e+05	<b>6,1096</b>	2,303e+08	0,72889	SO		
21	SP	84,425	1,4057e+11	2,6053e+05	<b>0,0076336</b>	75982	1,2651e+14	2,3447e+08	<b>6,8702</b>	0,65062	SP		
22	SP	95,675	1,5059e+11	2,7922e+05	<b>0,013972</b>	86107	1,3553e+14	2,513e+08	<b>12,575</b>	0,18280	SP		
23	SP	90,886	1,3149e+11	2,4406e+05	<b>0,0055424</b>	81798	1,1834e+14	2,1966e+08	<b>4,9882</b>	0,83533	SP		
24	SO	3,3737e+08	1074,1	<b>0,0042699</b>	2,2211e+05	3,0363e+11	9,6669e+05	<b>3,8429</b>	1,999e+08	0,92144	SO		
25	CA	3,6631e+14	<b>0,0071056</b>	1281,3	1,2775e+11	3,2968e+17	<b>6,395</b>	1,1532e+06	1,1497e+14	0,69982	CA		
26	SO	3,1367e+08	1113,4	<b>0,0049616</b>	2,0554e+05	2,823e+11	1,0021e+06	<b>4,4654</b>	1,8499e+08	0,87820	SO		
27	SP	111,19	1,2921e+11	2,4204e+05	<b>0,0064354</b>	1,0007e+05	1,1629e+14	2,1783e+08	<b>5,7918</b>	0,76055	SP		
28	SP	77,188	1,5402e+11	2,7956e+05	<b>0,013211</b>	69469	1,3862e+14	2,516e+08	<b>11,89</b>	0,21959	SP		
29	SP	84,517	1,6103e+11	2,9352e+05	<b>0,015928</b>	76066	1,4492e+14	2,6417e+08	<b>14,335</b>	0,11089	SP		
30	SO	3,347e+08	1050,5	<b>0,0015534</b>	2,1834e+05	3,0123e+11	9,4548e+05	<b>1,398</b>	1,965e+08	0,99783	SO		
31	SO	2,995e+08	1152,6	<b>0,0030628</b>	1,9499e+05	2,6955e+11	1,0374e+06	<b>2,7565</b>	1,7549e+08	0,97317	SO		
32	SO	3,0293e+08	1131,6	<b>0</b>	1,9853e+05	2,7264e+11	1,0184e+06	<b>0</b>	1,7867e+08	1	SO		

Tabela B.7 - Resultados correspondentes à classificação monofonte VI.

Região	Classe Verdadeira	Distâncias					Estatísticas					Valor $p$	Classe atribuída
		$d_{RI}$	$d_{CA}$	$d_{SO}$	$d_{SP}$	$d_{SI}$	$s_{CA}$	$s_{SO}$	$s_{SP}$	$s_{SI}$			
0	RI	<b>0,0028881</b>	10,922	5,2346	1,1529	<b>10,397</b>	39319	18844	4150,5	0,005524	RI		
1	RI	<b>0,0027605</b>	10,928	5,2371	1,1523	<b>9,9377</b>	39341	18854	4148,2	0,006950	RI		
2	RI	<b>0,0023846</b>	10,987	5,2859	1,1784	<b>8,5844</b>	39555	19029	4242,1	0,01367	RI		
3	CA	11,06	<b>0,0029506</b>	2,2371	6,8828	39818	<b>10,622</b>	8053,5	24778	0,004936	CA		
4	CA	11,052	<b>0,0022935</b>	2,2229	6,873	39787	<b>8,2565</b>	8002,6	24743	0,01611	CA		
5	SP	1,1824	6,9541	2,064	<b>0,0027254</b>	4256,5	25035	7430,4	<b>9,8116</b>	0,007403	SP		
6	RI	<b>0,0022421</b>	11,008	5,3039	1,1899	<b>8,0716</b>	39628	19094	4283,7	0,01767	RI		
7	CA	11,021	<b>00,0021719</b>	2,1933	6,8395	39676	<b>07,8189</b>	7895,8	24622	0,02005	CA		
8	RI	<b>0,0025691</b>	10,924	5,2376	1,1585	<b>9,2488</b>	39327	18855	4170,8	0,009809	RI		
9	CA	10,999	<b>0,0020497</b>	2,1806	6,8203	39597	<b>7,3788</b>	7850,2	24553	0,024986	CA		
10	CA	11,021	<b>0,0021719</b>	2,1933	6,8395	39676	<b>7,8189</b>	7895,8	24622	0,020051	CA		
11	CA	11,009	<b>0,0020576</b>	2,1941	6,8329	39631	<b>7,4072</b>	7898,7	24599	0,024634	CA		
12	RI	<b>0,0031978</b>	10,926	5,2321	1,1459	<b>11,512</b>	39335	18836	4125,3	0,003163	RI		
13	RI	<b>0,0021238</b>	10,957	5,2685	1,19	<b>7,6459</b>	39444	18967	4283,8	0,021863	RI		
14	RI	<b>0,0019722</b>	11	5,3023	1,1982	<b>7,0998</b>	39600	19088	4313,7	0,028728	RI		
15	SO	5,3168	2,1482	<b>0,0021566</b>	1,9969	19141	7733,4	<b>7,7636</b>	7188,8	0,020613	SO		
16	CA	10,96	<b>0,0027774</b>	2,1842	6,7949	39456	<b>9,9987</b>	7863	24462	0,006742	CA		
17	CA	11,002	<b>0,0019732</b>	2,1854	6,8243	39606	<b>7,1036</b>	7867,4	24568	0,028672	CA		
18	RI	<b>0,0028881</b>	10,922	5,2346	1,1529	<b>10,397</b>	39319	18844	4150,5	0,0055245	RI		
19	RI	<b>0,0027605</b>	10,928	5,2371	1,1523	<b>9,9377</b>	39341	18854	4148,2	0,0069509	RI		
20	SO	5,3272	2,0945	<b>0,0029466</b>	2,0124	19178	7540,4	<b>10,608</b>	7244,8	0,0049723	SO		
21	SP	1,1689	6,9696	2,0721	<b>0,0027671</b>	4207,9	25091	7459,5	<b>9,9615</b>	0,0068688	SP		
22	SP	1,1696	6,9591	2,067	<b>0,0026929</b>	4210,4	25053	7441,3	<b>9,6943</b>	0,0078505	SP		
23	SP	1,1824	6,9541	2,064	<b>0,0027254</b>	4256,5	25035	7430,4	<b>9,8116</b>	0,0074035	SP		
24	SO	5,3218	2,1756	<b>0,0021822</b>	1,9924	19158	7832,1	<b>7,8559</b>	7172,5	0,019684	SO		
25	CA	11,021	<b>00,0021719</b>	2,1933	6,8395	39676	<b>07,8189</b>	7895,8	24622	0,020051	CA		
26	SO	5,3129	2,1734	<b>0,0022298</b>	1,9873	19127	7824,1	<b>8,0274</b>	7154,2	0,018066	SO		
27	SP	1,1932	6,8691	2,0128	<b>0,0021143</b>	4295,6	24729	7246,1	<b>7,6115</b>	0,022242	SP		
28	SP	1,1392	7,0102	2,0964	<b>0,0037643</b>	4101,3	25237	7546,9	<b>13,552</b>	0,0011410	SP		
29	SP	1,1387	6,9847	2,0837	<b>0,0033943</b>	4099,3	25145	7501,3	<b>12,219</b>	0,0022211	SP		
30	SO	5,3168	2,1482	<b>00,0021566</b>	1,9969	19141	7733,4	<b>07,7636</b>	7188,8	0,020613	SO		
31	SO	5,3163	2,1964	<b>0,0025755</b>	1,9824	19139	7907	<b>9,2717</b>	7136,5	0,0096977	SO		
32	SO	5,3023	2,1847	<b>0,0019723</b>	1,9834	19088	7864,9	<b>7,1001</b>	7140,2	0,028723	SO		

Tabela B.8 - Resultados correspondentes à classificação monofonte VII.

Região	Classe Verdadeira	Distâncias				Estatísticas				Valor $p$	Classe atribuída
		$d_{RI}$	$d_{CA}$	$d_{SO}$	$d_{SP}$	$s_{RI}$	$s_{CA}$	$s_{SO}$	$s_{SP}$		
0	RI	<b>0,0035739</b>	1,8097	1,8464	1,569	<b>3,2165</b>	1628,8	1661,8	1412,1	0,20023	RI
1	RI	<b>0,0030765</b>	1,8095	1,8466	1,5688	<b>2,7689</b>	1628,6	1662	1411,9	0,25046	RI
2	RI	<b>0,0016181</b>	1,8093	1,8464	1,5805	<b>1,4563</b>	1628,3	1661,8	1422,4	0,48280	RI
3	CA	1,8107	<b>0,0038142</b>	1,8176	1,8361	1629,6	<b>3,4328</b>	1635,9	1652,5	0,17971	CA
4	CA	1,8096	<b>0,0012515</b>	1,8168	1,8359	1628,6	<b>1,1263</b>	1635,1	1652,3	0,56941	CA
5	SP	1,5827	1,8357	1,8005	<b>0,0029472</b>	1424,5	1652,1	1620,5	<b>2,6524</b>	0,2654	SP
6	RI	<b>0,001062</b>	1,8092	1,8462	1,5855	<b>0,95584</b>	1628,3	1661,6	1426,9	0,62007	RI
7	CA	1,809	<b>0,00077676</b>	1,8135	1,8357	1628,1	<b>0,69909</b>	1632,2	1652,1	0,70501	CA
8	RI	<b>0,002333</b>	1,8097	1,8462	1,5714	<b>2,0997</b>	1628,7	1661,6	1414,3	0,34999	RI
9	CA	1,8091	<b>0,00029919</b>	1,8123	<b>1,836</b>	1628,2	0,26927	1631,1	1652,4	0,87403	CA
10	CA	1,809	<b>0,00077676</b>	1,8135	1,8357	1628,1	<b>0,69909</b>	1632,2	1652,1	0,70501	CA
11	CA	1,8095	<b>0,00033014</b>	1,8139	1,8363	1628,6	<b>0,29713</b>	1632,5	1652,6	0,86194	CA
12	RI	<b>0,0047868</b>	1,8094	1,8471	1,5659	<b>4,3082</b>	1628,4	1662,3	1409,3	0,11600	RI
13	RI	<b>0,00060527</b>	1,8092	1,8454	1,5849	<b>0,54474</b>	1628,3	1660,8	1426,4	0,76157	RI
14	RI	<b>0</b>	1,8093	1,8456	1,5888	<b>0</b>	1628,4	1661	1429,9	<b>1</b>	RI
15	SO	1,8456	1,8087	<b>0,00072321</b>	1,7902	1661,1	1627,8	<b>0,65089</b>	1611,2	0,72220	SO
16	CA	1,8119	<b>0,0031621</b>	1,8123	1,8375	1630,7	<b>2,8459</b>	1631,1	1653,7	0,24100	CA
17	CA	1,8092	<b>3,8355e-07</b>	1,813	1,8361	1628,3	<b>0,0003452</b>	1631,7	1652,5	0,99982	CA
18	RI	<b>0,0035739</b>	1,8097	1,8464	1,569	<b>3,2165</b>	1628,8	1661,8	1412,1	0,20023	RI
19	RI	<b>0,0030765</b>	1,8095	1,8466	1,5688	<b>2,7689</b>	1628,6	1662	1411,9	0,25046	RI
20	SO	1,8459	1,8019	<b>0,0038093</b>	1,792	1661,3	1621,7	<b>3,4284</b>	1612,8	0,18010	SO
21	SP	1,5769	1,8353	1,8013	<b>0,0031058</b>	1419,2	1651,8	1621,2	<b>2,7952</b>	0,24718	SP
22	SP	1,5771	1,8354	1,8006	<b>0,0028163</b>	1419,4	1651,9	1620,5	<b>2,5346</b>	0,28158	SP
23	SP	1,5827	1,8357	1,8005	<b>0,0029472</b>	1424,5	1652,1	1620,5	<b>2,6524</b>	0,2654	SP
24	SO	1,8453	1,8122	<b>0,00082067</b>	1,7897	1660,8	1631	<b>0,73861</b>	1610,7	0,69121	SO
25	CA	1,809	<b>0,00077676</b>	1,8135	1,8357	1628,1	<b>0,69909</b>	1632,2	1652,1	0,70501	CA
26	SO	1,8455	1,8118	<b>0,0010075</b>	1,7889	1660,9	1630,6	<b>0,90672</b>	1610	0,6354	SO
27	SP	1,5869	1,8361	1,7931	<b>0,00055752</b>	1428,2	1652,5	1613,8	<b>0,50177</b>	0,7781	SP
28	SP	1,5635	1,8346	1,8039	<b>0,006969</b>	1407,2	1651,1	1623,5	<b>6,2721</b>	0,043453	SP
29	SP	1,563	1,8347	1,802	<b>0,0055367</b>	1406,7	1651,3	1621,8	<b>4,9831</b>	0,082783	SP
30	SO	1,8456	1,8087	<b>0</b>	1,7902	1661,1	1627,8	<b>0,65089</b>	1611,2	0,72220	SO
31	SO	1,8452	1,8147	<b>0,0023562</b>	1,7882	1660,7	1633,2	<b>2,1206</b>	1609,4	0,34634	SO
32	SO	1,8456	1,8129	<b>0</b>	1,7886	1661	1631,6	<b>0</b>	1609,8	<b>1</b>	SO

Tabela B.9 - Resultados correspondentes à classificação monofonte VIII.

Região	Classe Verdadeira	Distâncias					Estatísticas					Valor $p$	Classe atribuída
		$d_{RI}$	$d_{CA}$	$d_{SO}$	$d_{SP}$	$d_{SRI}$	$s_{CA}$	$s_{SO}$	$s_{SP}$				
0	RI	<b>0,0026825</b>	8,5921	5,1189	1,3362	<b>9,6569</b>	30931	18428	4810,5	0,37896	RI		
1	RI	<b>0,0015323</b>	8,6025	5,135	1,3255	<b>5,5165</b>	30969	18486	4771,9	0,78716	RI		
2	RI	<b>0,0021156</b>	8,6264	5,1716	1,3471	<b>7,6163</b>	31055	18618	4849,4	0,57322	RI		
3	CA	8,2935	<b>0,0018817</b>	2,2202	6,4218	29857	<b>6,7743</b>	7992,6	23118	0,66060	CA		
4	CA	8,7013	<b>0,0022737</b>	2,2585	6,7296	31325	<b>8,1852</b>	8130,5	24226	0,51559	CA		
5	SP	1,3973	6,7026	2,8753	<b>0,0017659</b>	5030,2	24129	10351	<b>6,3574</b>	0,70368	SP		
6	RI	<b>0,001679</b>	8,6401	5,1763	1,3343	<b>6,0445</b>	31104	18635	4803,6	0,73545	RI		
7	CA	8,5859	<b>0,001244</b>	2,2297	6,5971	30909	<b>4,4783</b>	8026,9	23749	0,87721	CA		
8	RI	<b>0,0019987</b>	8,626	5,1683	1,3263	<b>7,1953</b>	31054	18606	4774,7	0,61679	RI		
9	CA	9,0958	<b>0,0026267</b>	2,3675	7,0601	32745	<b>9,456</b>	8523	25416	0,3962	CA		
10	CA	8,5859	<b>0,001244</b>	2,2297	6,5971	30909	<b>4,4783</b>	8026,9	23749	0,87721	CA		
11	CA	8,8196	<b>0,0013942</b>	2,2799	6,8379	31750	<b>5,0193</b>	8207,5	24616	0,83262	CA		
12	RI	<b>0,003105</b>	8,5841	5,119	1,3327	<b>11,178</b>	30903	18429	4797,8	0,26371	RI		
13	RI	<b>0</b>	0,001038	5,1775	1,3471	<b>03,7367</b>	31106	18639	4849,5	0,92787	RI		
14	RI	<b>0</b>	8,6874	5,2296	1,3773	<b>0</b>	31275	18827	4958,4	1	RI		
15	SO	5,3129	2,2388	<b>0,00081761</b>	2,8592	19127	8059,8	<b>2,9434</b>	10293	0,9664	SO		
16	CA	8,7015	<b>0,002644</b>	2,2479	6,7644	31325	<b>9,5183</b>	8092,4	24352	0,39087	CA		
17	CA	8,6874	<b>0</b>	2,2534	6,6377	31275	<b>0</b>	8112,2	23896	1	CA		
18	RI	<b>0,0026825</b>	8,5921	5,1189	1,3362	<b>9,6569</b>	30931	18428	4810,5	0,37896	RI		
19	RI	<b>0,0015323</b>	8,6025	5,135	1,3255	<b>5,5165</b>	30969	18486	4771,9	0,78716	RI		
20	SO	5,2015	2,1651	<b>0,0031523</b>	2,9308	18725	7794,3	<b>11,348</b>	10551	0,25258	SO		
21	SP	1,4029	6,7415	2,9168	<b>0,0026043</b>	5050,4	24270	10500	<b>9,3756</b>	0,40334	SP		
22	SP	1,3383	6,7114	2,8793	00,0013064	4817,8	24161	10365	04,703	0,85939	SP		
23	SP	1,3973	6,7026	2,8753	<b>0,0017659</b>	5030,2	24129	10351	<b>6,3574</b>	0,70368	SP		
24	SO	5,3773	2,253	<b>0,00064007</b>	2,8689	19358	8110,9	<b>2,3043</b>	10328	0,98569	SO		
25	CA	8,5859	<b>0,001244</b>	2,2297	6,5971	30909	<b>4,4783</b>	8026,9	23749	0,87721	CA		
26	SO	5,2571	2,2602	<b>0,0027761</b>	2,8372	18926	8136,9	<b>9,9939</b>	10214	0,35098	SO		
27	SP	1,4033	6,6712	2,8485	<b>0,0015614</b>	5051,7	24016	10255	<b>5,621</b>	0,77717	SP		
28	SP	1,3552	6,7895	2,9487	<b>0,0028988</b>	4878,6	24442	10615	<b>10,436</b>	0,31637	SP		
29	SP	1,3336	6,7226	2,8871	<b>0,0022325</b>	4800,8	24201	10394	<b>8,0372</b>	0,53040	SP		
30	SO	5,3129	2,2388	<b>0,00081761</b>	2,8592	19127	8059,8	<b>2,9434</b>	10293	0,9664	SO		
31	SO	5,2254	2,2524	<b>0,0022001</b>	2,8411	18811	8108,7	<b>7,9202</b>	10228	0,54220	SO		
32	SO	5,2296	2,2534	<b>0</b>	2,7996	18827	8112,2	<b>0</b>	10079	1	SO		

Tabela B.10 - Resultados correspondentes à classificação monofonte IX.

Região	Classe Verdadeira	Distâncias				Estatísticas				Valor $p$	Classe atribuída
		$d_{RI}$	$d_{CA}$	$d_{SO}$	$d_{SP}$	$s_{RI}$	$s_{CA}$	$s_{SO}$	$s_{SP}$		
0	RI	<b>0,021496</b>	841,81	122,85	13,919	<b>19,347</b>	7,5763e+05	1,1057e+05	12527	0,022402	RI
1	RI	<b>0,01228</b>	883,88	127,74	13,939	<b>11,052</b>	7,955e+05	1,1497e+05	12545	0,27214	RI
2	RI	<b>0,016953</b>	895,43	132,97	14,953	<b>15,257</b>	8,0589e+05	1,1968e+05	13457	0,084105	RI
3	CA	919,56	<b>0,015087</b>	33,235	296,35	8,276e+05	<b>13,578</b>	29911	2,6671e+05	0,13814	CA
4	CA	910,89	<b>0,01823</b>	32,972	295,14	8,198e+05	<b>16,407</b>	29674	2,6563e+05	0,058849	CA
5	SP	14,828	309,1	39,531	<b>0,014143</b>	13345	2,7819e+05	35578	<b>12,729</b>	0,17525	SP
6	RI	<b>0,013466</b>	860,14	127,28	14,259	<b>12,119</b>	7,7413e+05	1,1456e+05	12833	0,20668	RI
7	CA	889,79	<b>0,0099558</b>	31,963	286,66	8,0081e+05	<b>8,9602</b>	28767	2,5799e+05	0,44095	CA
8	RI	<b>0,016022</b>	901,76	130,94	14,027	<b>14,42</b>	8,1158e+05	1,1785e+05	12625	0,10815	RI
9	CA	887,66	<b>0,02105</b>	32,153	287,01	7,989e+05	<b>18,945</b>	28938	2,5831e+05	0,025664	CA
10	CA	889,79	<b>0,0099558</b>	31,963	286,66	8,0081e+05	<b>8,9602</b>	28767	2,5799e+05	0,44095	CA
11	CA	898,01	<b>0,011166</b>	32,437	291,02	8,0821e+05	<b>10,05</b>	29193	2,6192e+05	0,34647	CA
12	RI	<b>0,024874</b>	907,79	131,49	14,245	<b>22,386</b>	8,1701e+05	1,1834e+05	12820	0,00773	RI
13	RI	<b>0,008312</b>	855,57	125,36	14,135	<b>7,4808</b>	7,7001e+05	1,1283e+05	12721	0,58719	RI
14	RI	<b>0</b>	890,68	131,91	14,988	<b>0</b>	8,0161e+05	1,1872e+05	13490	1	RI
15	SO	133,48	31,486	<b>0,0065457</b>	37,854	1,2013e+05	28337	<b>5,8911</b>	34068	0,75076	SO
16	CA	907,03	<b>0,021193</b>	32,754	292,63	8,1633e+05	<b>19,074</b>	29478	2,6337e+05	0,024571	CA
17	CA	890,68	<b>0</b>	31,974	287,18	8,0161e+05	<b>0</b>	28776	2,5846e+05	1	CA
18	RI	<b>0,021496</b>	841,81	122,85	13,919	<b>19,347</b>	7,5763e+05	1,1057e+05	12527	0,022402	RI
19	RI	<b>0,01228</b>	883,88	127,74	13,939	<b>11,052</b>	7,955e+05	1,1497e+05	12545	0,27214	RI
20	SO	136,15	29,415	<b>0,025293</b>	38,927	1,2254e+05	26474	<b>22,763</b>	35034	0,0067503	SO
21	SP	14,555	319,59	41,82	<b>0,020902</b>	13099	2,8763e+05	37638	<b>18,812</b>	0,026839	SP
22	SP	14,447	302,65	39,648	<b>0,010457</b>	13003	2,7239e+05	35683	<b>9,4116</b>	0,40017	SP
23	SP	14,828	309,1	39,531	<b>0,014143</b>	13345	2,7819e+05	35578	<b>12,729</b>	0,17525	SP
24	SO	132,89	32,417	<b>0,005124</b>	37,996	1,196e+05	29175	<b>4,6116</b>	34197	0,86677	SO
25	CA	889,79	<b>0,0099558</b>	31,963	286,66	8,0081e+05	<b>8,9602</b>	28767	2,5799e+05	0,44095	CA
26	SO	132,28	33,061	<b>0,022289</b>	37,297	1,1905e+05	29755	<b>20,061</b>	33567	0,01754	SO
27	SP	15,105	302,98	39,426	<b>0,012497</b>	13594	2,7268e+05	35484	<b>11,248</b>	0,2591	SP
28	SP	14,005	318,36	42,136	<b>0,023266</b>	12604	2,8652e+05	37923	<b>20,94</b>	0,012921	SP
29	SP	14,045	310,55	39,678	<b>0,017879</b>	12640	2,7949e+05	35711	<b>16,091</b>	0,06501	SP
30	SO	133,48	31,486	<b>0,0065457</b>	37,854	1,2013e+05	28337	<b>5,8911</b>	34068	0,75076	SO
31	SO	131,55	32,495	<b>0,01763</b>	37,113	1,1839e+05	29246	<b>15,867</b>	33402	0,069714	SO
32	SO	131,91	31,974	<b>0</b>	37,626	1,1872e+05	28776	<b>0</b>	33863	1	SO

Tabela B.11 - Resultados correspondentes à classificação monofonte X.

Região	Classe Verdadeira	Distâncias					Estatísticas					Valor $p$	Classe atribuída
		$d_{RI}$	$d_{CA}$	$d_{SO}$	$d_{SP}$	$d_{SI}$	$s_{CA}$	$s_{SO}$	$s_{SP}$				
0	RI	<b>0,00090417</b>	4,4916	2,3692	0,75352	<b>3,255</b>	16170	8529,1	2712,7	0,071205	RI		
1	RI	<b>0,00072286</b>	4,5001	2,3767	0,75857	<b>2,6023</b>	16200	8556,2	2730,9	0,10670	RI		
2	RI	<b>0,00015089</b>	4,5392	2,4112	0,78192	<b>0,54319</b>	16341	8680,4	2814,9	0,46111	RI		
3	CA	4,6304	<b>0,0004733</b>	0,69241	2,2772	16670	<b>1,7039</b>	2492,7	8198	0,19178	CA		
4	CA	4,5727	<b>5,1896e-08</b>	0,6598	2,2272	16462	<b>0,00018683</b>	2375,3	8017,8	0,98909	CA		
5	SP	0,79464	2,2369	0,61368	<b>1,9393e-05</b>	2860,7	8052,7	2209,3	<b>0,069816</b>	0,7916	SP		
6	RI	<b>3,5888e-05</b>	4,556	2,4261	0,79208	<b>0,1292</b>	16402	8734,1	2851,5	0,71926	RI		
7	CA	4,6069	<b>0,0001689</b>	0,67906	2,2568	16585	<b>0,60804</b>	2444,6	8124,6	0,43552	CA		
8	RI	<b>0,00057443</b>	4,5079	2,3836	0,76322	<b>2,068</b>	16228	8581	2747,6	0,15042	RI		
9	CA	4,5878	<b>3,4247e-05</b>	0,66826	2,2402	16516	<b>0,12329</b>	2405,7	8064,8	0,72549	CA		
10	CA	4,6069	<b>0,0001689</b>	0,67906	2,2568	16585	<b>0,60804</b>	2444,6	8124,6	0,43552	CA		
11	CA	4,56	<b>2,0226e-05</b>	0,65273	2,2162	16416	<b>0,072812</b>	2349,8	7978,4	0,78728	CA		
12	RI	<b>0,0007158</b>	4,5004	2,377	0,75878	<b>2,5769</b>	16202	8557,3	2731,6	0,10843	RI		
13	RI	<b>2,4237e-05</b>	4,5853	2,452	0,80981	<b>0,087255</b>	16507	8827,3	2915,3	0,76769	RI		
14	RI	<b>0</b>	4,5721	2,4403	0,80179	<b>0</b>	16459	8785,2	2886,4	1	RI		
15	SO	2,4692	0,64139	<b>0,00014708</b>	0,62496	8889,1	2309	<b>0,52948</b>	2249,8	0,4668	SO		
16	CA	4,6206	<b>0,00032686</b>	0,6868	2,2687	16634	<b>1,1767</b>	2472,5	8167,2	0,27803	CA		
17	CA	4,5721	<b>0</b>	0,65946	2,2266	16459	<b>0</b>	2374,1	8015,9	1	CA		
18	RI	<b>0,00090417</b>	4,4916	2,3692	0,75352	<b>3,255</b>	16170	8529,1	2712,7	0,071205	RI		
19	RI	<b>0,00072286</b>	4,5001	2,3767	0,75857	<b>2,6023</b>	16200	8556,2	2730,9	0,10670	RI		
20	SO	2,5016	0,6214	<b>0,00066093</b>	0,64499	9005,7	2237	<b>2,3793</b>	2322	0,12294	SO		
21	SP	0,77599	2,2638	0,63061	<b>0,00025523</b>	2793,6	8149,5	2270,2	<b>0,91884</b>	0,33777	SP		
22	SP	0,78029	2,2575	0,62668	<b>0,00017693</b>	2809	8127,1	2256	<b>0,63695</b>	0,424817	SP		
23	SP	0,79464	2,2369	0,61368	<b>1,9393e-05</b>	2860,7	8052,7	2209,3	<b>0,069816</b>	0,7916	SP		
24	SO	2,4724	0,63942	<b>0,00018113</b>	0,62691	8900,5	2301,9	<b>0,65205</b>	2256,9	0,41937	SO		
25	CA	4,6069	<b>0,0001689</b>	0,67906	2,2568	16585	<b>0,60804</b>	2444,6	8124,6	0,43552	CA		
26	SO	2,4747	0,63793	<b>0,00020922</b>	0,62839	8909,1	2296,5	<b>0,75319</b>	2262,2	0,38546	SO		
27	SP	0,80319	2,2247	0,60605	<b>7,4089e-07</b>	2891,5	8008,8	2181,8	<b>0,0026672</b>	0,9588	SP		
28	SP	0,74189	2,3139	0,6625	<b>0,001401</b>	2670,8	8329,9	2385	<b>5,0436</b>	0,024717	SP		
29	SP	0,74919	2,303	0,65557	<b>0,0010761</b>	2697,1	8290,9	2360	<b>3,8739</b>	0,04904	SP		
30	SO	2,4692	0,64139	<b>0,00014708</b>	0,62496	8889,1	2309	<b>0,52948</b>	2249,8	0,4668	SO		
31	SO	2,4835	0,63254	<b>0,00032821</b>	0,63376	8940,4	2277,1	<b>1,1816</b>	2281,5	0,27703	SO		
32	SO	2,4403	0,65946	<b>0</b>	0,6073	8785,2	2374,1	<b>0</b>	2186,3	1	SO		

Tabela B.12 - Resultados correspondentes à classificação monofonte XI.

Região	Classe Verdadeira	Distâncias				Estatísticas				Valor $p$	Classe atribuída
		$d_{RI}$	$d_{CA}$	$d_{SO}$	$d_{SP}$	$s_{RI}$	$s_{CA}$	$s_{SO}$	$s_{SP}$		
0	RI	<b>0,0036175</b>	67,582	18,155	3,6604	<b>3,2557</b>	60824	16340	3294,4	0.07117	RI
1	RI	<b>0,002892</b>	67,904	18,253	3,6899	<b>2,6028</b>	61114	16428	3320,9	0.10667	RI
2	RI	<b>0,00060357</b>	69,403	18,71	3,8272	<b>0,54321</b>	62462	16839	3444,5	0.46110	RI
3	CA	73,017	<b>0,0018934</b>	3,3095	16,98	65716	<b>1,7041</b>	2978,6	15282	0.19175	CA
4	CA	70,711	<b>2,0758e-07</b>	3,1266	16,362	63640	<b>0,00018683</b>	2814	14726	0.98909	CA
5	SP	3,9027	16,48	2,873	<b>7,7574e-05</b>	3512,4	14832	2585,7	<b>0,069817</b>	0.79160	SP
6	RI	<b>0,00014355</b>	70,058	18,91	3,8874	<b>0,1292</b>	63052	17019	3498,7	0.71926	RI
7	CA	72,07	<b>0,00067563</b>	3,2343	16,726	64863	<b>00,60806</b>	2910,9	15053	0.43551	CA
8	RI	<b>0,0022981</b>	68,201	18,344	3,7171	<b>2,0683</b>	61381	16510	3345,4	0.15039	RI
9	CA	71,307	<b>0,00013699</b>	3,1738	16,522	64176	<b>0,12329</b>	2856,4	14869	0.72549	CA
10	CA	72,07	<b>0,00067563</b>	3,2343	16,726	64863	<b>0,60806</b>	2910,9	15053	0.43551	CA
11	CA	70,214	<b>8,0903e-05</b>	3,0874	16,229	63193	<b>0,072812</b>	2778,7	14606	0.78728	CA
12	RI	<b>0,0028637</b>	67,918	18,258	3,6912	<b>2,5774</b>	61126	16432	3322	0.10840	RI
13	RI	<b>9,695e-05</b>	71,208	19,261	3,9933	<b>0,087255</b>	64087	17335	3593,9	0.76769	RI
14	RI	<b>0</b>	70,687	19,102	3,9453	<b>0</b>	63618	17192	3550,8	1	RI
15	SO	19,496	3,0247	<b>0,00058833</b>	2,9345	17546	2722,2	<b>0,5295</b>	2641	0.46681	SO
16	CA	72,618	<b>0,0013075</b>	3,2778	16,873	65357	<b>1,1768</b>	2950,1	15185	0.27801	CA
17	CA	70,687	<b>0</b>	3,1247	16,356	63618	<b>0</b>	2812,3	14720	1	CA
18	RI	<b>0,0036175</b>	67,582	18,155	3,6604	<b>3,2557</b>	60824	16340	3294,4	0.071173	RI
19	RI	<b>0,002892</b>	67,904	18,253	3,6899	<b>2,6028</b>	61114	16428	3320,9	0.10667	RI
20	SO	19,945	2,915	<b>0,0026442</b>	3,0446	17950	2623,5	<b>2,3797</b>	2740,1	0.12291	SO
21	SP	3,7922	16,812	2,9654	<b>0,001021</b>	3413	15131	2668,9	<b>0,9189</b>	0.33776	SP
22	SP	3,8175	16,735	2,9439	<b>0,00070775</b>	3435,8	15061	2649,5	<b>0,63698</b>	0.42480	SP
23	SP	3,9027	16,48	2,873	<b>7,7574e-05</b>	3512,4	14832	2585,7	<b>0,069817</b>	0.79160	SP
24	SO	19,539	3,0138	<b>00,00072454</b>	2,9451	17585	2712,4	<b>0,65208</b>	2650,6	0.41936	SO
25	CA	72,07	<b>00,00067563</b>	3,2343	16,726	64863	<b>00,60806</b>	2910,9	15053	0.43551	CA
26	SO	19,572	3,0056	<b>0,00083692</b>	2,9532	17615	2705,1	<b>0,75323</b>	2657,9	0.38545	SO
27	SP	3,9536	16,331	2,8316	<b>2,9636e-06</b>	3558,3	14698	2548,4	<b>0,0026672</b>	0.95881	SP
28	SP	3,5928	17,441	3,1417	<b>0,0056059</b>	3233,6	15697	2827,5	<b>5,0454</b>	0.02469	SP
29	SP	3,6352	17,304	3,1031	<b>0,0043055</b>	3271,7	15574	2792,8	<b>3,8749</b>	0.04901	SP
30	SO	19,496	3,0247	<b>0,00058833</b>	2,9345	17546	2722,2	<b>0,5295</b>	2641	0.46681	SO
31	SO	19,693	2,976	<b>00,001313</b>	2,9827	17723	2678,4	<b>1,1817</b>	2684,4	0.27701	SO
32	SO	19,102	3,1247	<b>0</b>	2,8383	17192	2812,3	<b>0</b>	2554,5	1	SO

Tabela B.13 - Resultados correspondentes à classificação monofonte XII.

Região	Classe Verdadeira	Distâncias						Estatísticas						Valor $p$	Classe atribuída
		$d_{RI}$	$d_{CA}$	$d_{SO}$	$d_{SP}$	$s_{RI}$	$s_{CA}$	$s_{SO}$	$s_{SP}$						
0	RI	<b>0,0018083</b>	8,9831	4,7384	1,507	<b>0,81375</b>	4042,4	2132,3	678,17	0,36701	RI				
1	RI	<b>0,0014457</b>	9,0001	4,7534	1,5171	<b>0,65057</b>	4050,1	2139	682,72	0,41990	RI				
2	RI	<b>0,00030177</b>	9,0783	4,8224	1,5638	<b>0,1358</b>	4085,2	2170,1	703,73	0,71249	RI				
3	CA	9,2609	<b>0,0009466</b>	1,3848	4,5545	4167,4	<b>0,42597</b>	623,17	2049,5	0,51397	CA				
4	CA	9,1454	<b>1,0379e-07</b>	1,3196	4,4544	4115,4	<b>4,6706e-05</b>	593,82	2004,5	0,9945	CA				
5	SP	1,5893	4,4737	1,2274	<b>3,8787e-05</b>	715,18	2013,2	552,32	<b>0,017454</b>	0,89489	SP				
6	RI	<b>7,1776e-05</b>	9,112	4,8523	1,5842	<b>00,032299</b>	4100,4	2183,5	712,87	0,85737	RI				
7	CA	9,2139	<b>0,0003378</b>	1,3581	4,5137	4146,2	<b>0,15201</b>	611,16	2031,1	0,69662	CA				
8	RI	<b>0,0011489</b>	9,0158	4,7672	1,5264	<b>0,51699</b>	4057,1	2145,2	686,9	0,47212	RI				
9	CA	9,1755	<b>6,8495e-05</b>	1,3365	4,4804	4129	<b>0,030823</b>	601,43	2016,2	0,86063	CA				
10	CA	9,2139	<b>0,0003378</b>	1,3581	4,5137	4146,2	<b>0,15201</b>	611,16	2031,1	0,69662	CA				
11	CA	9,12	<b>4,0451e-05</b>	1,3055	4,4325	4104	<b>0,018203</b>	587,46	1994,6	0,89267	CA				
12	RI	<b>0,0014316</b>	9,0008	4,754	1,5176	<b>0,64422</b>	4050,4	2139,3	682,9	0,42218	RI				
13	RI	<b>4,8475e-05</b>	9,1705	4,9041	1,6196	<b>0,021814</b>	4126,7	2206,8	728,83	0,88258	RI				
14	RI	<b>0</b>	9,1441	4,8807	1,6036	<b>0</b>	4114,9	2196,3	721,61	1	RI				
15	SO	4,9384	1,2828	<b>0,00029416</b>	1,2499	2222,3	577,25	<b>0,13237</b>	562,46	0,71598	SO				
16	CA	9,2411	<b>0,00065372</b>	1,3736	4,5373	4158,5	<b>0,29417</b>	618,12	2041,8	0,58755	CA				
17	CA	9,1441	<b>0</b>	1,3189	4,4533	4114,9	<b>0</b>	593,51	2004	1	CA				
18	RI	<b>0,0018083</b>	8,9831	4,7384	1,507	<b>0,81375</b>	4042,4	2132,3	678,17	0,36701	RI				
19	RI	<b>0,0014457</b>	9,0001	4,7534	1,5171	<b>0,65057</b>	4050,1	2139	682,72	0,41990	RI				
20	SO	5,0032	1,2428	<b>0,0013219</b>	1,29	2251,4	559,26	<b>0,59484</b>	580,49	0,44055	SO				
21	SP	1,552	4,5275	1,2612	<b>00,00051047</b>	698,39	2037,4	567,55	<b>00,22971</b>	0,63173	SP				
22	SP	1,5606	4,5151	1,2534	<b>0,00035386</b>	702,26	2031,8	564,01	<b>0,15924</b>	0,68985	SP				
23	SP	1,5893	4,4737	1,2274	<b>3,8787e-05</b>	715,18	2013,2	552,32	<b>0,017454</b>	0,89489	SP				
24	SO	4,9447	1,2788	<b>0,00036225</b>	1,2538	2225,1	575,48	<b>0,16301</b>	564,22	0,68639	SO				
25	CA	9,2139	<b>0,0003378</b>	1,3581	4,5137	4146,2	<b>0,15201</b>	611,16	2031,1	0,69662	CA				
26	SO	4,9495	1,2759	<b>0,00041844</b>	1,2568	2227,3	574,14	<b>0,1883</b>	565,55	0,66433	SO				
27	SP	1,6064	4,4493	1,2121	<b>1,4818e-06</b>	722,87	2002,2	545,45	<b>0,0006668</b>	0,97939	SP				
28	SP	1,4838	4,6277	1,325	<b>0,002802</b>	667,7	2082,5	596,25	<b>1,2609</b>	0,26148	SP				
29	SP	1,4984	4,6061	1,3111	<b>0,0021522</b>	674,27	2072,7	590,01	<b>0,96847</b>	0,32506	SP				
30	SO	4,9384	1,2828	<b>0,00029416</b>	1,2499	2222,3	577,25	<b>0,13237</b>	562,46	0,71598	SO				
31	SO	4,9669	1,2651	<b>0,00065643</b>	1,2675	2235,1	569,29	<b>0,29539</b>	570,38	0,58678	SO				
32	SO	4,8807	1,3189	<b>0</b>	1,2146	2196,3	593,51	<b>0</b>	546,57	1	SO				



Tabela B.14 - Resultados correspondentes à classificação monofonte XIII.

Região	Classe Verdadeira	Distâncias						Estatísticas						Valor $p$	Classe atribuída
		$d_{RI}$	$d_{CA}$	$d_{SO}$	$d_{SP}$	$s_{RI}$	$s_{CA}$	$s_{SO}$	$s_{SP}$						
0	RI	<b>0,00090376</b>	0,9888	0,90644	0,52929	<b>3,2535</b>	3559,7	3263,2	1905,5	0,071269	RI				
1	RI	<b>0,0007226</b>	0,98889	0,90714	0,53167	<b>2,6014</b>	3560	3265,7	1914	0,10677	RI				
2	RI	<b>0,00015087</b>	0,98932	0,91029	0,54248	<b>0,54315</b>	3561,5	3277,1	1952,9	0,46113	RI				
3	CA	0,99025	<b>0,00047319</b>	0,49963	0,89743	3564,9	<b>1,7035</b>	1798,7	3230,8	0,19183	CA				
4	CA	0,98967	<b>5,1896e-08</b>	0,48305	0,89217	3562,8	<b>0,00018683</b>	1739	3211,8	0,98909	CA				
5	SP	0,54826	0,89321	0,45865	<b>1,9393e-05</b>	1973,7	3215,5	1651,1	<b>0,069816</b>	0,79161	SP				
6	RI	<b>3,5887e-05</b>	0,9895	0,91162	0,5471	<b>0,12919</b>	3562,2	3281,8	1969,5	0,71927	RI				
7	CA	0,99002	<b>0,00016888</b>	0,49291	0,89532	3564,1	<b>0,60799</b>	1774,5	3223,1	0,43555	CA				
8	RI	<b>0,00057427</b>	0,98898	0,90778	0,53384	<b>0,0674</b>	3560,3	3268	1921,8	0,15048	RI				
9	CA	0,98982	<b>3,4247e-05</b>	0,4874	0,89357	3563,4	<b>0,12329</b>	1754,6	3216,8	0,72549	CA				
10	CA	0,99002	<b>0,00016888</b>	0,49291	0,89532	3564,1	<b>0,60799</b>	1774,5	3223,1	0,43555	CA				
11	CA	0,98954	<b>2,0225e-05</b>	0,47938	0,89098	3562,3	<b>0,072811</b>	1725,8	3207,5	0,78729	CA				
12	RI	<b>0,00071555</b>	0,9889	0,90717	0,53176	<b>2,576</b>	3560	3265,8	1914,3	0,1085	RI				
13	RI	<b>2,4237e-05</b>	0,9898	0,91388	0,55506	<b>0,087254</b>	3563,3	3290	1998,2	0,7677	RI				
14	RI	<b>0</b>	0,98966	0,91287	0,55147	<b>0</b>	3562,8	3286,3	1985,3	1	RI				
15	SO	0,91535	0,47344	<b>0,00014707</b>	0,46472	3295,2	1704,4	<b>0,52944</b>	1673	0,46684	CA				
16	CA	0,99015	<b>0,00032681</b>	0,49681	0,89655	3564,6	<b>1,1765</b>	1788,5	3227,6	0,27807	CA				
17	CA	0,98966	<b>0</b>	0,48287	0,89211	3562,8	<b>0</b>	1738,3	3211,6	1	CA				
18	RI	<b>0,00090376</b>	0,9888	0,90644	0,52929	<b>3,2535</b>	3559,7	3263,2	1905,5	0,071269	RI				
19	RI	<b>0,0007226</b>	0,98889	0,90714	0,53167	<b>2,6014</b>	3560	3265,7	1914	0,10677	RI				
20	SO	0,91804	0,46281	<b>0,00066071</b>	0,47533	3305	1666,1	<b>2,3786</b>	1711,2	0,12301	CA				
21	SP	0,53975	0,89604	0,46773	<b>0,0002552</b>	1943,1	3225,7	1683,8	<b>0,91873</b>	0,33781	SP				
22	SP	0,54173	0,89539	0,46564	<b>0,00017691</b>	1950,2	3223,4	1676,3	<b>0,63689</b>	0,42484	SP				
23	SP	0,54826	0,89321	0,45865	<b>1,9393e-05</b>	1973,7	3215,5	1651,1	<b>0,069816</b>	0,79161	SP				
24	SO	0,91561	0,4724	<b>0,00018111</b>	0,46576	3296,2	1700,6	<b>0,652</b>	1676,7	0,4194	CA				
25	CA	0,99002	<b>0,00016888</b>	0,49291	0,89532	3564,1	<b>0,60799</b>	1774,5	3223,1	0,43555	CA				
26	SO	0,91582	0,47161	<b>0,0002092</b>	0,46655	3296,9	1697,8	<b>0,75311</b>	1679,6	0,38549	CA				
27	SP	0,5521	0,8919	0,4545	<b>7,4089e-07</b>	1987,6	3210,8	1636,2	<b>0,0026672</b>	0,95881	SP				
28	SP	0,52379	0,90112	0,48444	<b>0,0014</b>	1885,6	3244	1744	<b>5,0401</b>	0,024768	SP				
29	SP	0,52725	0,90004	0,48085	<b>0,0010755</b>	1898,1	3240,2	1731,1	<b>3,8718</b>	0,049104	SP				
30	SO	0,91535	0,47344	<b>0,00014707</b>	0,46472	3295,2	1704,4	<b>0,52944</b>	1673	0,46684	CA				
31	SO	0,91655	0,46876	<b>0,00032816</b>	0,46941	3299,6	1687,5	<b>1,1814</b>	1689,9	0,27708	CA				
32	SO	0,91287	0,48287	<b>0</b>	0,45518	3286,3	1738,3	<b>0</b>	1638,6	1	CA				



## APÊNDICE C - CASO DE TESTE II

Este caso de teste foi feito a partir dos dados simulados visando investigar as diferenças encontradas entre os resultados gerados pela ferramenta desenvolvida neste trabalho e pelo PolClass nas classificações de dados modelados por intermédio da distribuição Wishart complexa escalonada.

Foram realizados testes que mostraram que há um problema na estimativa do parâmetro matriz de covariância  $\Sigma$  da distribuição Wishart complexa escalonada correspondente às classes no PolClass. A fim de exemplificar o problema encontrado e atestar a corretude do algoritmo implementado neste trabalho, selecionou-se uma região dos dados simulados. A região tem dimensões  $30 \times 30$  pixels, pertence à classe Rio e foi utilizada no teste como amostra de treinamento.

Para o teste, a saída esperada foi produzida por intermédio do *software* MatLab. A Tabela C.1 apresenta os valores estimados dos elementos do parâmetro  $\Sigma$  esperados, bem como os obtidos por meio do PolClass e da ferramenta desenvolvida neste trabalho. Nota-se que, os resultados gerados pelo *software* desenvolvido são exatamente os mesmos que os resultados esperados. Observa-se também que os resultados do PolClass se diferem dos esperados. Esse fato verificado influencia no cálculo da distância entre as amostras das classes e das regiões da imagem, prejudicando os resultados finais de classificação, conforme foi visto na seção 4.2.2. Na tabela,  $(\cdot)^*$  representa o conjugado de uma variável aleatória e os valores são representados por (parte real, parte imaginária).

Tabela C.1 - Comparação dos valores dos parâmetros de matriz de covariância  $\Sigma$  da distribuição Wishart complexa escalonada.

Resultados	Elementos da matriz de covariância					
	$ S_{HH} ^2$	$S_{HH}S_{HV}^*$	$S_{HH}S_{VV}^*$	$ S_{HV} ^2$	$S_{HV}S_{VV}^*$	$ S_{VV} ^2$
Esperados	(0,0029636894; 0)	(0,0000198012; 0,0000871783)	(0,0034639699; 0,0003296903)	(0,0003422974; 0)	(0,0000163142; 0,0001646255)	(0,0001646255; 0)
Do <i>software</i>	(0,0029636894; 0)	(0,0000198012; 0,0000871783)	(0,0034639699; 0,0003296903)	(0,0003422974; 0)	(0,0000163142; 0,0001646255)	(0,0001646255; 0)
Do <i>Do PolClass</i>	(0,0029798783; 0)	(0,0000195109; 0,0000881691;	(0,0034897705; 0,0003154800)	(0,0003423805; 0)	(0,0000101346; 0,0001636543)	(0,011826879; 0)

Fonte: Produção do autor.

## 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). Contam 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.