



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21b/2016/07.04.21.38-TDI

**DISTÂNCIAS ESTOCÁSTICAS E TESTES DE
HIPÓTESES ASSOCIADOS APLICADOS À
CLASSIFICAÇÃO DE IMAGENS PROVENIENTES DE
MÚLTIPLOS SENSORES INDEPENDENTES**

Bruna Cristina Braga

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Sidnei João Siqueira
Sant'Anna, e Corina da Costa
Freitas, aprovada em 07 de julho
de 2016.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3M2MERE>>

INPE
São José dos Campos
2016

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

Fax: (012) 3208-6919

E-mail: pubtc@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 (CST)

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

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

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

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

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

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

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon

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

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

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

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

EDITORAÇÃO ELETRÔNICA:

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

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



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21b/2016/07.04.21.38-TDI

**DISTÂNCIAS ESTOCÁSTICAS E TESTES DE
HIPÓTESES ASSOCIADOS APLICADOS À
CLASSIFICAÇÃO DE IMAGENS PROVENIENTES DE
MÚLTIPLOS SENSORES INDEPENDENTES**

Bruna Cristina Braga

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Sidnei João Siqueira
Sant'Anna, e Corina da Costa
Freitas, aprovada em 07 de julho
de 2016.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3M2MERE>>

INPE
São José dos Campos
2016

Dados Internacionais de Catalogação na Publicação (CIP)

Braga, Bruna Cristina.

B73d Distâncias estocásticas e testes de hipóteses associados aplicados à classificação de imagens provenientes de múltiplos sensores independentes / Bruna Cristina Braga. – São José dos Campos : INPE, 2016.

xxxiv + 167 p. ; (sid.inpe.br/mtc-m21b/2016/07.04.21.38-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016.

Orientadores : Drs. Sidnei João Siqueira Sant'Anna, e Corina da Costa Freitas.

1. Classificação multifontes. 2. Distâncias estocásticas. 3. Testes de hipóteses. 4. Imagem ópticas. 5. Imagem SAR. I.Título.

CDU 528.854:528.8.044.2



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

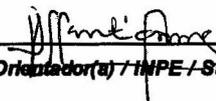
This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): **Bruna Cristina Braga**

Título: " DISTÂNCIAS ESTOCÁSTICAS E TESTE DE HIPÓTESES ASSOCIADOS APLICADOS À CLASSIFICAÇÃO DE IMAGENS PROVENIENTES DE MÚLTIPLOS SENSORES INDEPENDENTES".

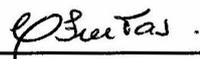
Aprovado (a) pela Banca Examinadora em cumprimento ao requisito exigido para obtenção do Título de **Mestre** em **Sensoriamento Remoto**

Dr. Sidnei João Siqueira Sant'Anna



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

Dra. Corina da Costa Freitas



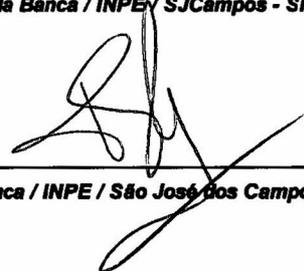
Orientador(a) / INPE / SJC Campos - SP

Dr. Camilo Daleles Rennó



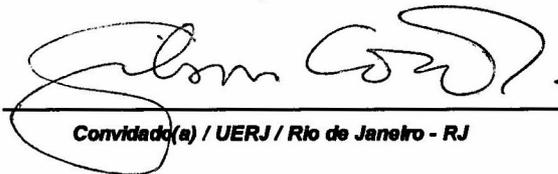
Membro da Banca / INPE / SJC Campos - SP

Dr. Thales Sehn Körting



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

Dr. Gilson Alexandre Ostwald Pedro da Costa



Convidado(a) / UERJ / Rio de Janeiro - RJ

Este trabalho foi aprovado por:

maioria simples

unanimidade

São José dos Campos, 07 de Julho de 2016

“Se eu vi mais longe, foi porque estava sobre ombros de gigantes.”

Isaac Newton em carta para Robert Hooke em fevereiro de 1676.

*Dedico única e exclusivamente a meus pais, Luiz Angelo Braga e
Lucilene Maria Braga.*

AGRADECIMENTOS

Presto reconhecimentos primeiramente a Deus pelas infinitas oportunidades que sempre me proporcionou no decorrer de meus vinte e oito anos de existência.

Agradeço a meus pais, Luiz Angelo Braga e Lucilene Maria Braga pelo apoio constante e amor demonstrado em todas as fases de minha vida.

Agradeço por sempre me convidarem para suas diversas viagens mesmo sabendo que eu não poderia estar presente devido a meus estudos.

Agradeço pelos cuidados que sempre tiveram em relação à família, eu e meus irmãos.

Agradeço por terem sido e serem pais maravilhosos.

Agradeço a meus pais científicos, Dr. Sidnei João Siqueira Sant'Anna e Dra. Corina da Costa Freitas por serem exemplos vivos de que apesar de toda a crise em que se encontra nosso país, apesar dos déficits existentes, em especial na educação, ainda existem professores dispostos a ensinar, a ensinar o passo a passo do conhecimento científico, a ensinar o ato de cooperação humana e principalmente a ensinar a um indivíduo que o objetivo principal da existência humana é ser feliz, cada um com suas crenças e verdades. Agradeço pela paciência infinita em ensinar, agradeço pelo atendimento 24 horas, pelos ensinamentos, pelas dicas, pelas risadas e descontrações e principalmente pelo excelente papel prestado como orientadores. Agradeço pelos elogios e incentivos constantes, por todo conhecimento transmitido e pela oportunidade de trabalhar na equipe.

Agradeço aos colegas de turma e companheiros de trabalho que sempre se mostraram dispostos a ajudar. Em especial à Mariane Souza Reis por todas as perguntas respondidas, por todas as vezes que me socorreu seja com dúvidas teóricas ou práticas.

Agradeço ao Wanderson Santos Costa, Adeline Marinho Maciel, Maria Antônia Falcão de Oliveira, Évlyn Márcia Pôssa, Rennan de Freitas Bezerra Marujo, Sacha Maruã Ortiz Siani, Heloísa da Silva Victorino, João Arthur Pompeu Pavanelli, Daniela Souza dos

Anjos, Rafael França, Aline Daniele Jacon, Greison Moreira de Souza e João Felipe Cardoso dos Santos, pelas vezes que pararam o próprio trabalho para me oferecer algum tipo de orientação.

Agradeço à Luciana de Oliveira Pereira pela disponibilidade em ajudar e pela preocupação.

Agradeço ao José Guilherme Fronza e David Guimarães Monteiro França pelas conversas filosóficas e por todo apoio prestado no decorrer desta dissertação.

Agradeço à Anielli Rosane de Souza, Bruna Maria Pechini Bento e Vanessa Priscila Camphora pela amizade e pela constante companhia nos melhores momentos e também nos mais difíceis.

Agradeço aos professores doutores que me atenderam prontamente para solução de algum problema ou resposta a alguma dúvida, em especial Dr. Fábio Furlan Gama, Dr. José Claudio Mura, Dr. Thales Sehn Körting, Dr. Camilo Daleles Rennó, Dr. João Pedro C. Cordeiro e Dra. Maria Isabel Sobral Escada.

Agradeço às secretárias por todo suporte prestado, em especial à Melissa de Medeiros, Denise Cristina Nascimento, Thaís Costa Fernandes e Noêmia.

Agradeço à CAPES pelo apoio financeiro no decorrer destes dois anos de mestrado. Agradeço ao INPE pelo espaço disponibilizado assim como pelas ferramentas fornecidas necessárias para execução desta dissertação.

RESUMO

Neste trabalho de dissertação, propõe-se uma nova metodologia de integração de dados classificados baseada em distâncias estocásticas e testes de hipóteses, denominada “Classificação Multifonte”. O grande diferencial do método de integração proposto se origina do fato da classificação multifonte ser obtida a partir do cálculo das distâncias estocásticas entre a função densidade de probabilidade (*f.d.p.*) conjunta dos dados oriundos das múltiplas fontes sem, no entanto, conhecê-la. Estas distâncias (e estatísticas de teste associadas) são computadas a partir das distâncias marginais (e estatísticas de teste marginais), independentemente do conhecimento da *f.d.p.* conjunta. O resultado da classificação multifonte é, então, construído utilizando-se funções matemáticas baseadas nas estatísticas de teste empregadas nas classificações e que são obtidas de maneira teórica e empírica. Demonstra-se matematicamente que a função teórica é a soma das estatísticas de teste. Para avaliação da metodologia, foram utilizadas duas imagens SAR (Alos/Palsar e Radarsat2) e uma imagem Landsat5/TM. Foram geradas 12 classificações individuais utilizando-se as três imagens e variando-se suas respectivas modelagens. Selecionaram-se para cada uma das imagens a classificação que apresentou os melhores índices de acurácia (coeficiente *Kappa* e acurácia global). Por intermédio das classificações escolhidas, construíram-se 10 combinações por meio das quais foi aplicada a metodologia proposta. Para tais combinações, originaram-se três Cenários multifontes, o primeiro, nomeado Cenário multifonte da soma, segue a abordagem teórica enquanto os dois últimos, denominados Cenário multifonte dos mínimos e Cenário multifonte do produto seguem uma abordagem empírica. Como mais um exemplo de criação de Cenário, foi gerado um Cenário multifonte *Fuzzy* que segue também a abordagem empírica. Apresentaram-se as classificações multifontes para as combinações que obtiveram os melhores resultados. O Cenário multifonte da soma envolvendo as três imagens conjuntamente apresenta melhora no coeficiente *Kappa* relativa às classificações individuais de 45%, 32% e 6% para imagens Palsar, Radarsat e TM, respectivamente. De modo geral, combinações envolvendo somente os dados SAR resultaram, na maior parte, em classificações com maiores índices de acurácia do que aqueles apresentados pelas imagens individualmente. Para combinações envolvendo as imagens SAR e TM os índices foram elevados em algumas situações. Para os Cenários multifontes empíricos dos mínimos e do produto, observou-se que, em comparação à imagem Palsar, ambos os Cenários obtiveram valores superiores de índice *Kappa* e acurácia global. Para a imagem Radarsat, somente o Cenário multifonte do produto apresentou valores superiores para os mesmos índices. Já para a imagem TM, ambos os Cenários apresentaram índices inferiores. A classificação baseada na lógica *Fuzzy* permitiu uma classificação em classes mistas com alta confiabilidade e altos valores de acurácia por classe. Isto pode ser visto como um fator positivo na metodologia de classificação proposta. Dada a variedade de Cenários multifontes distintos possíveis de serem construídos concluiu-se que é possível melhorar os resultados de classificação utilizando-se a metodologia multifonte proposta.

STOCHASTIC DISTANCES AND HYPOTHESIS TESTS APPLIED TO THE IMAGES CLASSIFICATION FROM MULTIPLE INDEPENDENT SENSORS

ABSTRACT

A new data integration methodology named “Multisource Classification” is proposed and assessed in this work. It is based on stochastic distances and their associated hypothesis tests. The great advantage of this new method is the generation of multisource classification by means of stochastic distances between unknown joint probability density function (*p. d. f.*). These distances (and statistical tests) are computed from marginal distances (and marginal statistical tests) regardless the joint *p. d. f.* knowledge. The multisource classification result is generated using mathematical functions based on statistical tests and they can be obtained by theoretical or empirical approaches. For some distances, it is also mathematically, shown that the theoretical function is given by the sum of statistical tests. The classification performance is evaluated using images obtained from three different sensors: two SAR (Alos and Radarsat2) and one TM (Landsat5). Twelve individual classifications were generated using these three images and by varying the data modeling. The classifications presenting the best accuracy (*Kappa* coefficient and overall accuracy) were selected for each image. Ten combinations were then constructed using these selected classifications in order to employ the proposed methodology. For each combination it was constructed three multisource scenarios, called sum, minimum and product multisource scenarios. The first is based on the theoretical approach whereas the two latter follow an empirical approach. In addition, an empirical *Fuzzy* multisource scenario was also created. The sum multisource scenario compound by the three images exhibited 45%, 32% and 6% of improvement related to Palsar, Radarsat and TM image classifications, respectively. In general, the majority of SAR data combinations resulted in classifications with highest rates of accuracy than those presented by the individual classifications. In some situations, SAR and TM images combinations high values of accuracy indexes were observed. It was observed that the empirical minimum and product multisource scenarios, using the three images, presented high values of *Kappa* coefficient and overall accuracy regarding to Palsar image classification. However, relatively to Radarsat image classification, only the product multisource scenario reached high values for the same indexes. On the other hand, based on TM image classification, both scenarios showed low improvement values. The *Fuzzy* multisource scenario allowed mixed classes classification with high values of accuracy per class. This is an interesting and positive factor in the proposed methodology of classification. Given the great variety of feasible multisource scenarios that can be implemented and the obtained results, it was concluded that it is possible to improve classification results using the proposed multisource methodology.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 – Ilustração do processo de classificação monofonte.	30
Figura 4.1 – Representação gráfica da metodologia de classificação multifonte.....	47
Figura 5.1 – Localização da área de estudo e recorte da imagem Landsat5/TM de 12 de julho de 2009 em composição colorida 5(R) 4(G) 3(B).....	57
Figura 5.2 – Etapas para o pré-processamento.	61
Figura 5.3 – Imagem TM na composição 5(R)4(G)3(B).....	64
Figura 5.4 – Imagem Palsar na composição $hh(R)hv(G)hh(B)$	65
Figura 5.5 – Imagem Radarsat na composição $hh(R)hv(G)hh(B)$	66
Figura 5.6 – Segmentação unificada sobreposta à imagem TM na composição colorida 5(R)4(G)3(B).....	68
Figura 5.7 – Localização das amostras de Treinamento (polígonos hachurados) e Teste (polígonos sólidos) sobre imagem TM na composição colorida 1(R)2(G)3(B).....	70
Figura 5.8 – Visão geral da modelagem dos dados.	71
Figura 6.1 – Resultados para o Cenário monofonte $\{P, Wi, Bh\}$	83
Figura 6.2 – Resultados para o Cenário monofonte $\{R, Wi, Bh\}$	84
Figura 6.3 – Resultados para o Cenário monofonte $\{T, Ga, Bh\}$	85
Figura 6.4 – Combinação II: Resultados para a classificação multifonte da soma $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$	90
Figura 6.5 – Combinação IV: Resultados para a classificação multifonte da soma $\{R, Wi, Bh; T, Ga, Bh\}$	91
Figura 6.6 – Relação entre as acurácias por classe para a classificação multifonte da soma resultante da combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$ e as classificações monofontes Palsar, Radarsat e TM.....	92
Figura 6.7 – Relação entre as acurácias por classe para a classificação multifonte da soma resultante da combinação IV $\{R, Wi, Bh; T, Ga, Bh\}$ e as classificações monofontes Radarsat e TM.	92
Figura 6.8 – Relação entre os erros de comissão e omissão por classe para a classificação multifonte da soma resultante da combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$ e as classificações monofontes Palsar, Radarsat e TM.	93
Figura 6.9 – Relação entre os erros de comissão e omissão por classe para a classificação multifonte da soma resultante da combinação IV $\{R, Wi, Bh; T, Ga, Bh\}$ e as classificações monofontes Radarsat e TM.	93
Figura 6.10 – Combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$: Resultados para o Cenário multifonte dos mínimos.	97
Figura 6.11 – Combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$: Resultados para o Cenário multifonte do produto.	98
Figura 6.12 – Relação entre as acurácias por classe para a classificação multifonte dos mínimos resultante da combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$ e as classificações monofontes das imagens Palsar, Radarsat e TM.	99

Figura 6.13 – Relação entre as acurácias por classe para a classificação multifonte do produto resultante da combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$ e as classificações monofontes das imagens Palsar, Radarsat e TM.	99
Figura 6.14 – Relação entre os erros de comissão e omissão por classe para a classificação multifonte dos mínimos resultante da combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$ e as classificações Palsar, Radarsat e TM.	100
Figura 6.15 – Relação entre os erros de comissão e omissão por classe para a classificação multifonte do produto resultante da combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$ e as classificações Palsar, Radarsat e TM.	100
Figura 6.16 – Relações entre os índices de acurácia para as classificações desenvolvidas através da combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$	101
Figura 6.17 – Combinação IV $\{R, Wi, Bh; T, Ga, Bh\}$: Classificação multifonte <i>Fuzzy</i>	102
Figura 6.18 – Combinação IV $\{R, Wi, Bh; T, Ga, Bh\}$: Mapa de possibilidade da classificação <i>Fuzzy</i>	102
Figura 6.19 – Resultados para a classificação multifonte da soma $\{P, Pi, Bh; R, Pi, Bh; T, Ga, Bh\}$	109
Figura 6.20 – Resultados para a classificação multifonte da soma $\{P, Pi, Bh; R, Wi, Bh; T, Ga, Bh\}$	110
Figura 6.21 – Resultados para a classificação multifonte da soma $\{P, Wi, Bh; R, Pi, Bh; T, Ga, Bh\}$	111
Figura 6.22 – Resultados para a classificação multifonte da soma $\{P, Pi, Bh; T, Ga, Bh\}$	112
Figura 6.23 – Resultados para a classificação multifonte da soma $\{R, Pi, Bh; T, Ga, Bh\}$	113
Figura 6.24 – Resultados para a classificação multifonte da soma $\{P, Pi, Bh; R, Wi, Bh\}$	114
Figura 6.25 – Resultados para a classificação multifonte da soma $\{P, Wi, Bh; R, Pi, Bh\}$	115
Figura B.1 – Resultados para os Cenários monofontes $\{P, Wi, Re\}$ e $\{P, Wi, KL\}$	131
Figura B.2 – Resultados para os Cenários monofontes $\{R, Wi, Re\}$, $\{R, Wi, Bh\}$, $\{R, Wi, KL\}$ e $\{R, Wi, He\}$	132
Figura B.3 – Resultados para o Cenário monofonte $\{T, Ga, KL\}$	133
Figura B.4 – Resultados para o Cenário monofonte $\{T, Ga, Bh\}$	134
Figura B.5 – Resultados para o Cenário monofonte $\{P, Pi, Bh\}$	135
Figura B.6 – Resultados para o Cenário monofonte $\{R, Pi, Bh\}$	136
Figura C.1 – Combinação I: resultados para a classificação multifonte da soma $\{P, Wi, Re; R, Wi, Re\}$	137
Figura C.2 – Combinação III: resultados para a classificação multifonte da soma $\{P, Wi, Bh; T, Ga, Bh\}$	138
Figura C.3 – Combinação V: resultados para a classificação multifonte da soma $\{P, Wi, Bh; R, Wi, Bh\}$	139
Figura C.4 – Combinação VI: resultados para a classificação multifonte da soma $\{P, Wi, KL; T, Ga, KL\}$	140

Figura C.5 – Combinação VII: resultados para a classificação multifonte da soma $\{R, Wi, KL; T, Ga, KL\}$	141
Figura C.6 – Combinação VIII: resultados para a classificação multifonte da soma $\{P, Wi, KL; R, Wi, KL\}$	142
Figura C.7 – Combinação IX: resultados para a classificação multifonte da soma $\{P, PI, Bh; R, PI, Bh\}$	143
Figura C.8 – Combinação I: resultados para a classificação multifonte da soma $\{P, Wi, He; R, Wi, He\}$	144
Figura D.1 – Combinação I: classificação multifonte dos mínimos $\{P, Wi, Re; R, Wi, Re\}$	145
Figura D.2 – Combinação I: classificação multifonte do produto $\{P, Wi, Re; R, Wi, Re\}$	146
Figura D.3 – Combinação III: classificação multifonte dos mínimos $\{P, Wi, Bh; T, Ga, Bh\}$	147
Figura D.4 – Combinação III: classificação multifonte do produto $\{P, Wi, Bh; T, Ga, Bh\}$	148
Figura D.5 – Combinação IV: classificação multifonte dos mínimos $\{R, Wi, Bh; T, Ga, Bh\}$	149
Figura D.6 – Combinação IV: classificação multifonte do produto $\{R, Wi, Bh; T, Ga, Bh\}$	150
Figura D.7 – Combinação V: classificação multifonte dos mínimos $\{P, Wi, Bh; R, Wi, Bh\}$	151
Figura D.8 – Combinação V: classificação multifonte do produto $\{P, Wi, Bh; R, Wi, Bh\}$	152
Figura D.9 – Combinação VI: classificação multifonte dos mínimos $\{P, Wi, KL; T, Ga, KL\}$	153
Figura D.10 – Combinação VI: classificação multifonte do produto $\{P, Wi, KL; T, Ga, KL\}$	154
Figura D.11 – Combinação VII: classificação multifonte dos mínimos $\{R, Wi, KL; T, Ga, KL\}$	155
Figura D.12 – Combinação VII: classificação multifonte do produto $\{R, Wi, KL; T, Ga, KL\}$	156
Figura D.13 – Combinação VIII: classificação multifonte dos mínimos $\{P, Wi, KL; R, Wi, KL\}$	157
Figura D.14 – Combinação VIII: classificação multifonte do produto $\{P, Wi, KL; R, Wi, KL\}$	158
Figura D.15 – Combinação IX: classificação multifonte dos mínimos $\{P, PI, Bh; R, PI, Bh\}$	159
Figura D.16 – Combinação IX: classificação multifonte do produto $\{P, PI, Bh; R, PI, Bh\}$	160
Figura D.17 – Combinação X: classificação multifonte dos mínimos $\{P, Wi, He; R, Wi, He\}$	161
Figura D.18 – Combinação X: classificação multifonte do produto $\{P, Wi, He; R, Wi, He\}$	162

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1 – Distâncias tipo ($h - \phi$) e funções h e ϕ relacionadas.....	21
Tabela 5.1 – Descrição das características da imagem TM.....	58
Tabela 5.2 – Descrição das características da imagem Palsar.....	59
Tabela 5.3 - Descrição das características da imagem Radarsat.....	59
Tabela 5.4 – Data de aquisição das imagens utilizadas.....	60
Tabela 5.5 - Especificações das amostras coletadas.....	71
Tabela 6.1 – Coeficiente $Kappa$ e acurácia global relativos às classificações monofontes.....	76
Tabela 6.2 – Acurácia por classe e erros relativos às classificações monofontes para as classes em estudo.....	78
Tabela 6.3 – Coeficiente $Kappa$, variância do $Kappa$ e acurácia global relativos aos Cenários multifontes da soma.....	86
Tabela 6.4 – Melhora quantitativa das classificações monofontes em relação às classificações multifontes da soma.....	87
Tabela 6.5 - Acurácia por classe e erros relativos as classificações multifontes teóricas para as classes em estudo.....	89
Tabela 6.6 – Coeficiente $Kappa$ e acurácia global relativos aos Cenários multifontes empíricos para a combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$	95
Tabela 6.7 – Melhora quantitativa das classificações monofontes em relação às classificações multifontes da empíricas dos mínimos e produto.....	96
Tabela 6.8 – Erros relativos as classificações multifontes empíricas dos mínimos e do produto para a combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$	96
Tabela 6.9 – Dados para análise da acurácia do Cenário <i>Fuzzy</i>	104
Tabela 6.10 – Relação da acurácia por classe entre os Cenários monofontes da combinação IV e o Cenário multifonte <i>Fuzzy</i>	105
Tabela 6.11 – Índices de acurácia para Cenários monofontes.....	106
Tabela 6.12 – Índices de acurácia de classificação para os Cenários multifontes da soma.....	107
Tabela A.1 – Matriz de correlação linear de Pearson entre as bandas das imagens TM (T), Palsar (P) e Radarsat (R).....	129
Tabela E.1 – Relação da acurácia por classe entre os Cenários resultantes da combinação I (CI) $\{P, Wi, Re; R, Wi, Re\}$	163
Tabela E.2 – Relação da acurácia por classe entre os Cenários resultantes da combinação II (CII) $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$	163
Tabela E.3 – Relação da acurácia por classe entre os Cenários resultantes da combinação III (CIII) $\{P, Wi, Bh; T, Ga, Bh\}$	164
Tabela E.4 – Relação da acurácia por classe entre os Cenários resultantes da combinação IV (CIV) $\{R, Wi, Bh; T, Ga, Bh\}$	164
Tabela E.5 – Relação da acurácia por classe entre os Cenários resultantes da combinação V (CV) $\{P, Wi, Bh; R, Wi, Bh\}$	165

Tabela E.6 – Relação da acurácia por classe entre os Cenários resultantes da combinação VI (CVI) $\{P, Wi, KL; T, Ga, KL\}$.	165
Tabela E.7 – Relação da acurácia por classe entre os Cenários resultantes da combinação VII (CVII) $\{R, Wi, KL; T, Ga, KL\}$.	166
Tabela E.8 – Relação da acurácia por classe entre os Cenários resultantes da combinação VIII (CVIII) $\{P, Wi, KL; R, Wi, KL\}$.	166
Tabela E.9 – Relação da acurácia por classe entre os Cenários resultantes da combinação IX (CIX) $\{P, PI, Bh; R, PI, Bh\}$.	167
Tabela E.10 – Relação da acurácia por classe entre os Cenários resultantes da combinação X (CX) $\{P, PI, Bh; R, PI, Bh\}$.	167

LISTA DE SIGLAS E ABREVIATURAS

INPE	Instituto Nacional de pesquisas espaciais
CAPES	Coordenação de aperfeiçoamento de pessoal de nível superior
IBAMA	Instituto Brasileiro do meio ambiente e dos recursos naturais renováveis
RBC	Revista Brasileira de Cartografia
IGARSS	<i>International Geoscience and Remote Sensing Symposium</i>
JSTARS	<i>Journal of Selected Topics in Applied Earth Observations and Remote Sensing.</i>
JAXA	<i>Japan Aerospace Exploration Agency</i>
MDA	<i>MacDonald, Dettwiler and Associates</i>
RADAR	<i>Radio Detection and Ranging</i>
SLAR	<i>Side Looking Airbone Radar</i>
RAR	<i>Real Aperture Radar</i>
PolSAR	<i>Polarimetric SAR</i>
PCA	<i>Principal Component Analysis</i>
ALOS	<i>Advanced Land Observing System</i>
TM	<i>Tematic Mapper</i>
SAR	<i>Synthetic Aperture Radar</i>
PALSAR	<i>Phase Array L-Band Synthetic Aperture Radar</i>
SLC	<i>Single Look Complex</i>
MLC	<i>Multi-Look Complex</i>
<i>sr</i>	<i>Slant range</i>
<i>gr</i>	<i>Ground range</i>
PolClass	Classificador polarimétrico
<i>f.d.p.</i>	Função densidade de probabilidade
<i>f.d.p.</i> 's	Funções densidades de probabilidade
<i>QIC</i>	Índice da Melhora quantitativa da classificação
<i>norm</i>	Normalizado
<i>c.q.d.</i>	Como queríamos demonstrar
FP	Floresta Primária
RA	Regeneração Antiga

RT	Regeneração Intermediária
RI	Regeneração Inicial
PS	Pasto Sujo
PL	Pasto Limpo
SE	Solo Exposto
FP_FP	Classe <i>Fuzzy</i> Floresta Primária e Floresta Primária
FP_RA	Classe <i>Fuzzy</i> Floresta Primária e Regeneração Antiga
FP_RT	Classe <i>Fuzzy</i> Floresta Primária e Regeneração Intermediária
FP_RI	Classe <i>Fuzzy</i> Floresta Primária e Regeneração Inicial
FP_PS	Classe <i>Fuzzy</i> Floresta Primária e Pasto Sujo
FP_PL	Classe <i>Fuzzy</i> Floresta Primária e Pasto Limpo
FP_SE	Classe <i>Fuzzy</i> Floresta Primária e Solo Exposto
RA_RA	Classe <i>Fuzzy</i> Regeneração Antiga e Regeneração Antiga
RA_RT	Classe <i>Fuzzy</i> Regeneração Antiga e Regeneração Intermediária
RA_RI	Classe <i>Fuzzy</i> Regeneração Antiga e Regeneração Inicial
RA_PS	Classe <i>Fuzzy</i> Regeneração Antiga e Pasto Sujo
RA_PL	Classe <i>Fuzzy</i> Regeneração Antiga e Pasto Limpo
RA_SE	Classe <i>Fuzzy</i> Regeneração Antiga e Solo Exposto
RT_RT	Classe <i>Fuzzy</i> Regeneração Intermediária e Regeneração Intermediária
RT_RI	Classe <i>Fuzzy</i> Regeneração Intermediária e Regeneração Inicial
RT_PS	Classe <i>Fuzzy</i> Regeneração Intermediária e Pasto Sujo
RT_PL	Classe <i>Fuzzy</i> Regeneração Intermediária e Pasto Limpo
RT_SE	Classe <i>Fuzzy</i> Regeneração Intermediária e Solo Exposto
RI_RI	Classe <i>Fuzzy</i> Regeneração Inicial e Regeneração Inicial
RI_PS	Classe <i>Fuzzy</i> Regeneração Inicial e Pasto Sujo
RI_PL	Classe <i>Fuzzy</i> Regeneração Inicial e Pasto Limpo
RI_SE	Classe <i>Fuzzy</i> Regeneração Inicial e Solo Exposto
PS_PS	Classe <i>Fuzzy</i> Pasto Sujo e Pasto Sujo
PS_PL	Classe <i>Fuzzy</i> Pasto Sujo e Pasto Limpo
PS_SE	Classe <i>Fuzzy</i> Pasto Sujo e Solo Exposto
PL_PL	Classe <i>Fuzzy</i> Pasto Limpo e Pasto Limpo

PL_SE	Classe <i>Fuzzy</i> Pasto Limpo e Solo Exposto
SE_SE	Classe <i>Fuzzy</i> Solo Exposto e Solo Exposto
CII	Combinação II
CIII	Combinação III
CIV	Combinação IV
CV	Combinação V
MONOTM	Cenário de classificação monofonte TM
MONOPal	Cenário de classificação monofonte Palsar
MONORad	Cenário de classificação monofonte Radarsat
MULTMin	Cenário de classificação multifonte dos mínimos
MULTProd	Cenário de classificação multifonte do produto
MULTSom	Cenário de classificação multifonte da soma
A	Acurácia por classe
AG	Acurácia global
C	Erro de comissão
O	Erro de omissão
CP	Erros de comissão relativos à classificação monofonte da imagem Palsar
CR	Erros de comissão relativos à classificação monofonte da imagem Radarsat
CT	Erros de comissão relativos à classificação monofonte da imagem TM
CCII	Erros de comissão relativos à classificação resultante da combinação II
CCIV	Erros de comissão relativos à classificação resultante da combinação IV
CMIN	Erros de comissão relativos à classificação monofonte dos mínimos
CPROD	Erros de comissão relativos à classificação monofonte do produto
OP	Erros de omissão relativos à classificação monofonte da imagem Palsar
OR	Erros de omissão relativos à classificação monofonte da imagem Radarsat
OT	Erros de omissão relativos à classificação monofonte da imagem TM
OCII	Erros de omissão relativos à classificação resultante da combinação II
OCIV	Erros de omissão relativos à classificação resultante da combinação IV
OMIN	Erros de omissão relativos à classificação monofonte dos mínimos
OPROD	Erros de omissão relativos à classificação monofonte do produto
Ga	Gaussiana multivariada

<i>Pi</i>	Par de intensidades <i>multi-look</i>
<i>Wi</i>	<i>Wishart</i> complexa escalonada
<i>Bh</i>	<i>Bhattacharyya</i>
<i>KL</i>	<i>Kullback-Leibler</i>
<i>Re</i>	<i>Rényi</i> de ordem β
<i>He</i>	<i>Hellinger</i>

LISTA DE SÍMBOLOS

X	Variável aleatória.
μ	Medida de posição: média.
$\boldsymbol{\mu}$	Vetor de médias.
$\boldsymbol{\Sigma}$	Matriz de covariância complexa.
\boldsymbol{c}	Matriz de covariância real.
σ^2	Variância
\overline{X}_n	Média aritmética de n variáveis aleatórias.
n	Número total de variáveis aleatórias independentes e identicamente distribuídos.
\mathbb{R}^n	Conjunto dos números reais n dimensionais.
\xrightarrow{D}	Convergência em distribuição.
f_{X_1, \dots, X_n}	Função de distribuição conjuntas de n variáveis aleatórias.
x_1	Ocorrência da variável aleatória X_1 .
$f_{X_1}(x_1)$	Distribuição de probabilidade marginal da variável aleatória X_1 .
i	Contador.
\forall	Qualquer que seja.
\in	Pertencente.
χ_{GL}^2	Distribuição <i>Chi</i> -quadrado com GL graus de liberdade.
GL	Graus de liberdade de uma distribuição <i>Chi</i> -quadrado.
\sim	Atribuição de distribuição estatística.
h	Polarização horizontal.
v	Polarização vertical.
\mathcal{S}	Matriz de espalhamento complexa.
\mathcal{S}_{ij}	Elemento da matriz de espalhamento complexa nas polarizações de transmissão i e recepção j .
i	Polarização de transmissão vertical ou horizontal (amplitude de espalhamento).
j	Polarização de recepção vertical ou horizontal (amplitude de espalhamento).
\mathfrak{i}	Unidade imaginária.
N	Números de difusores de uma célula de resolução.

$ \mathcal{S}_{ij} $	Amplitude de \mathcal{S}_{ij} .
ϕ_{ij}	Fase de \mathcal{S}_{ij} .
∞	Símbolo do infinito.
$\exp\{\cdot\}$	Função exponencial.
\mathbf{V}_S	Vetor de espalhamento complexo.
L	Número equivalente de <i>looks</i> .
$V_S(i)$	i -ésima amostra de 1- <i>look</i> .
$\mathbf{V}_S^{(L)}$	matriz de covariância para L - <i>looks</i> .
$V_S^H(i)$	transposto conjugado de $V_S(i)$.
\mathbf{A}	Matriz complexa.
\mathbf{A}_1	Matriz real.
\mathbf{A}_2	Matriz real.
\mathbf{g}	Vetor complexo.
\mathbb{C}^n	Conjunto dos números complexos de dimensão n .
$(\cdot)^H$	Operador transposto conjugado.
\mathbb{N}	Conjunto dos números naturais.
\mathcal{G}	Matriz de mesma dimensão que \mathbf{A} .
Z	Variável aleatória.
\mathcal{X}	Variável aleatória.
\mathcal{Y}	Variável aleatória.
Z	Variável aleatória
z	Valor observado da variável aleatória Y .
\mathbf{Z}	Vetor aleatório.
q	Número total de variáveis aleatórias
f_Z	Função densidade de probabilidade do vetor aleatório \mathbf{Z} .
$E(\cdot)$	Operador de esperança estatística.
$ \Sigma $	Determinante da matriz Σ .
$(\cdot)^T$	Transposto de um vetor.
$Cov(\mathbf{Y}, \mathbf{X})$	covariância entre \mathbf{Y}, \mathbf{X} .
σ	Desvio padrão.

$\Gamma(\cdot)$	Função Gama.
$\text{Tr}(\cdot)$	Traço de uma matriz
Z_1	Variável aleatória.
Z_2	Variável aleatória.
h_{11}	Esperanças das variáveis aleatórias Z_1 .
h_{22}	Esperanças das variáveis aleatórias Z_2 .
I_{L-1}	Função modificada de Bessel de ordem $L-1$
ρ_c	Coefficiente de correlação complexo.
v	Número complexo.
$\mathcal{R}[\cdot]$	Parte real de um número complexo.
\mathcal{S}	Componente da matriz de espalhamento
Θ	Diferença de fase entre os retornos de duas polarizações.
$ \rho_c $	Módulo do coeficiente de correlação complexo.
ϕ	Função convexa.
h	Função estritamente crescente.
$h - \phi$	Família de divergências.
Ω	Conjunto das matrizes hermitianas positivas definidas.
θ_1	Vetor de parâmetros.
θ_2	Vetor de parâmetros.
h'	derivada de primeira ordem da função h .
$d_\phi^h(\mathbf{X}, \mathbf{Y})$	Distância $h - \phi$ entre \mathbf{X} e \mathbf{Y} .
$D_\phi^h(\mathbf{X}, \mathbf{Y})$	Divergência $h - \phi$ entre \mathbf{X} e \mathbf{Y} .
Λ	Subconjunto de Ω .
$d_B(\mathbf{X}, \mathbf{Y})$	Distância de <i>Bhattacharyya</i> entre \mathbf{X} e \mathbf{Y} .
$d_H(\mathbf{X}, \mathbf{Y})$	Distância de <i>Hellinger</i> entre \mathbf{X} e \mathbf{Y} .
$d_{KL}(\mathbf{X}, \mathbf{Y})$	Distância <i>Kullback-Leibler</i> entre \mathbf{X} e \mathbf{Y} .
$d_R^\beta(\mathbf{X}, \mathbf{Y})$	Distância de <i>Rényi</i> de ordem β entre \mathbf{X} e \mathbf{Y} .
β	Ordem da distância de <i>Rényi</i>
d_{GB}	Distância de <i>Bhattacharyya</i> entre distribuições Gaussianas multivariadas
d_{GKL}	Distância de <i>Kullback-Leibler</i> entre distribuições Gaussianas multivariadas

\mathbb{I}_q	Matriz identidade de ordem q
d_{WB}	Distâncias de <i>Bhattacharyya</i> entre distribuições <i>Wishart</i> complexas escalonadas
d_{WH}	Distâncias de <i>Hellinger</i> entre distribuições <i>Wishart</i> complexas escalonadas
d_{WKL}	Distâncias de <i>Kullback-Leibler</i> entre distribuições <i>Wishart</i> complexas escalonadas
d_{WR}^β	Distâncias <i>Rényi</i> de ordem β entre distribuições <i>Wishart</i> complexas escalonadas
$W(\Sigma_1, L)$	Distribuição <i>Wishart</i> complexa escalonada de parâmetro Σ_1 e L .
$\hat{\theta}_1$	Estimador de máxima verosimilhança de θ_1
M	Número de parâmetros do vetor de parâmetros
m	Tamanhos das amostras referentes aos segmentos da imagem.
n	Tamanho das amostras referentes as classes em estudo.
H_0	Hipótese nula.
H_1	Hipótese alternativa.
$s = S_\phi^h$	estatística de teste de hipótese
ν	Constante.
ϕ''	2ª derivadas da função ϕ .
χ_M^2	distribuição <i>Chi-quadrado</i> com M graus de liberdade
Pr	Probabilidade
η	Nível de significância
α	Nível de confiança
S_{GB}	Estatística de teste para as distâncias de <i>Bhattacharyya</i> entre distribuições Gaussianas multivariadas.
S_{GKL}	Estatística de teste para as distâncias de <i>Kullback-Leibler</i> entre distribuições Gaussianas multivariadas.
S_{WB}	Estatística de teste para as distâncias de <i>Bhattacharyya</i> entre distribuições <i>Wishart</i> complexas escalonadas.
S_{WKL}	Estatística de teste para as distâncias de <i>Kullback-Leibler</i> entre distribuições <i>Wishart</i> complexas escalonadas.
S_{WR}^β	Estatística de teste para as distâncias <i>Rényi</i> de ordem β entre distribuições <i>Wishart</i> complexas escalonadas.
r	Número de regiões/segmentos na imagem.

R_i	Representação da região i .
i	Contador do número de regiões
k	Número total de classes em estudo
ℓ	Contador do número de classes
j	j –ésima classe.
H_0	Hipótese nula
$\Pr(\cdot)$	Probabilidade.
p	valor- p .
w	Número de imagens ou fontes distintas.
j	Contador do número de imagens ou fontes.
Z_j	Imagem proveniente da fonte j .
$f_{i\{w\}}$	Função de distribuição conjunta que modela a região i da segmentação.
$g_{\ell\{w\}}$	Função de distribuição conjunta que modela a amostra da classe ℓ .
f_{ij}	Função de distribuição que modela os pixels da imagem Z_j na região i da segmentação.
$g_{\ell j}$	Função de distribuição relativa a imagem Z_j que modela os pixels presentes na amostra de classe ℓ .
θ_{ij}	Vetor de parâmetro da função que modela os pixels das imagens no segmento i .
$\theta_{\ell j}$	Vetor de parâmetro da função que modela a classe ℓ .
$V_{i\ell}^j$	Vetor de atributos
C_i^j	Vetor de classificação.
t	Números de imagens em uma combinação

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1. Objetivo	4
1.1.1. Objetivos específicos	5
1.2. Contribuições	5
1.3. Organização do documento	6
2 MODELAGEM DOS DADOS	7
2.1. Teoremas.....	7
2.1.1. Teorema Central do Limite.....	7
2.1.2. Relação entre funções conjuntas e marginais de variáveis aleatórias independentes	7
2.1.3. Aditividade da distribuição χ^2	8
2.2. Definições	8
2.2.1. Radar de abertura sintética	8
2.2.2. Radar de abertura sintética polarimétrico	8
2.2.3. Ruído <i>speckle</i> e processamento <i>multi-look</i>	9
2.2.4. Matriz de espalhamento complexa	9
2.2.5. Matriz de covariância para <i>L-looks</i>	10
2.2.6. Matriz hermitiana positiva definida.....	11
2.3. Distribuições	11
2.3.1. Modelo aditivo.....	12
2.3.2. Modelo multiplicativo	14
2.4. Medidas da teoria da informação e classificação de imagens.....	18
2.4.1. Divergências, distâncias estocásticas e estatísticas de testes de hipótese. 19	
2.4.2. Classificação supervisionada por regiões baseada em distâncias estocásticas e estatísticas de teste de hipóteses	26
3 DESENVOLVIMENTO TEÓRICO DE DISTÂNCIAS ESTOCÁSTICAS E ESTATÍSTICAS DE TESTES ENTRE <i>F.D. P'S</i> CONJUNTAS DE DADOS MULTIFONTE.....	33
4 CLASSIFICAÇÃO MULTIFONTE DE IMAGENS BASEADA EM DISTÂNCIAS ESTOCÁSTICAS	47

4.1.	Tratamento dos dados de entrada.....	48
4.2.	Geração dos planos de informação	49
4.3.	Classificação multifonte	49
4.4.	Construção dos Cenários de classificação	51
5	MATERIAIS E MÉTODOS	57
5.1.	Área de estudo e aquisição dos dados.....	57
5.2.	Processamento dos dados.....	60
5.2.1.	Pré-processamento dos dados.....	61
5.2.2.	Segmentação da imagem	67
5.2.3.	Coleta das amostras de treinamento e teste	69
5.2.4.	Modelagem estatística dos dados e Cenários de classificação	71
6	RESULTADOS	75
6.1.	Avaliação dos Cenários monofontes.....	75
6.2.	Avaliação dos Cenários multifontes teóricos.....	86
6.3.	Avaliação dos Cenários multifontes empíricos	95
6.4.	Avaliação entre dados polarimétricos e dados bivariados	105
7	CONCLUSÕES E TRABALHOS FUTUROS	116
	REFERÊNCIAS BIBLIOGRÁFICAS	121
	APÊNDICE A –VERIFICAÇÃO DA INDEPENDÊNCIA ENTRE OS SENSORES	129
A.1	– Análise da correlação linear entre as bandas das imagens TM, Palsar e Radarsat.	129
	APÊNDICE B – CENÁRIOS MONOFONTES	131
B.1	- Cenário monofonte da imagem Palsar correspondente às combinações I, VI e VIII.	131
B.2	- Cenário monofonte da imagem Radarsat correspondente às combinações I, II, IV, V, VII, VIII e X.	132
B.3	- Cenário monofonte da imagem TM correspondente às combinações VI e VII. .	133
B.4	- Cenário monofonte da imagem TM correspondente às combinações II a IV. ...	134
B.5	- Cenário monofonte da imagem Palsar correspondente à combinação IX.....	135
B.6	- Cenário monofonte da imagem Radarsat correspondente à combinação IX.....	136
	APÊNDICE C – CENÁRIOS MULTIFONTES DA SOMA.....	137
C.1	- Cenário da soma para combinação I.....	137
C.2	- Cenário da soma para combinação III	138

C.3 - Cenário da soma para combinação V	139
C.4 - Cenário da soma para combinação VI.....	140
C.5 - Cenário da soma para combinação VII.....	141
C.6 - Cenário da soma para combinação VIII	142
C.7 - Cenário da soma para combinação IX.....	143
C.8 - Cenário da soma para combinação X	144
APÊNDICE D – CENÁRIOS MULTIFONTES EMPÍRICOS.	145
D.1 - Cenário dos mínimos para a combinação I	145
D.2 - Cenário do produto para a combinação I.....	146
D.3 - Cenário dos mínimos para a combinação III.....	147
D.4 - Cenário do produto para a combinação III.....	148
D.5 - Cenário dos mínimos para a combinação IV.....	149
D.6 - Cenário do produto para a combinação IV.....	150
D.7 - Cenário dos mínimos para a combinação V	151
D.8 - Cenário do produto para a combinação V	152
D.9 - Cenário dos mínimos para a combinação VI.....	153
D.10 - Cenário do produto para a combinação VI.....	154
D.11 - Cenário dos mínimos para a combinação VII	155
D.12 - Cenário do produto para a combinação VII	156
D.13 Cenário dos mínimos para a combinação VIII	157
D.14 - Cenário do produto para a combinação VIII	158
D.15 - Cenário dos mínimos para a combinação IX.....	159
D.16 - Cenário do produto para a combinação IX.....	160
D.17 - Cenário dos mínimos para a combinação X.....	161
D.18 - Cenário do produto para a combinação X.....	162
APÊNDICE E – ACURÁCIA GLOBAL (AG), ACURÁCIA POR CLASSE E COEFICIENTE <i>KAPPA</i> (K) PARA AS COMBINAÇÕES.	163
E.1 – Resultados correspondentes aos Cenários para a combinação I	163
D.2 – Resultados correspondentes aos Cenários para a combinação II.....	163
E.3 – Resultados correspondentes aos Cenários para a combinação III.....	164
E.4 – Resultados correspondentes aos Cenários para a combinação IV	164
E.5 – Resultados correspondentes aos Cenários para a combinação V.....	165
E.6 – Resultados correspondentes aos Cenários para a combinação VI	165
E.7 – Resultados correspondentes aos Cenários para a combinação VII	166

E.8 – Resultados correspondentes aos Cenários para a combinação VIII.....	166
E.9 – Resultados correspondentes aos Cenários para a combinação IX	167
E.10 – Resultados correspondentes aos Cenários para a combinação X.....	167

1 INTRODUÇÃO

O uso eficaz de diferentes tipos de dados de sensoriamento remoto para a avaliação de recursos naturais e mapeamento da superfície terrestre encontra-se em fase de constante avanço em muitos países. Isto ocorre devido à quantidade de dados obtidos por intermédio de aeronaves e/ou plataformas orbitais, o que facilita o acesso a várias imagens oriundas de fontes diversas. Estas imagens são obtidas sob diferentes condições de imageamento e possuem limitações que podem afetar os resultados de classificações conduzindo a índices de acurácia insatisfatórios. A busca por informações mais precisas, atrelada à quantidade de dados disponíveis, submete a um tema de pesquisa em constante desenvolvimento: a integração de dados provenientes de sensores remotos.

As diferenças relevantes entre imagens ópticas e de micro-ondas, principalmente relacionadas ao comportamento dos dados, vêm sendo observadas nos últimos anos (ASCHBACHER; LICHTENEGGER, 1990; GERSTL, 1990; HAACK *et al.*, 2002). Diversos autores têm empregado técnicas para integração destes dados com o intuito de obter classificações com índices de acurácia mais satisfatórios, além de melhores interpretações visuais (PARIS; KWONG, 1988; ASCHBACHER; LICHTENEGGER, 1990; SCHISTAD-SOLBERG *et al.*, 1994; SCHISTAD-SOLBERG *et al.*, 1996; POHL; VAN GENDEREN, 1997; BRISCO; BROWN, 1999; HAACK *et al.*, 2000; HAACK; BECHDOL, 2000; SIMONE *et al.*, 2002; AMARSAIKHAN; DOUGLAS, 2004; HUANG *et al.*, 2007; SANTOS; MESSINA, 2008; AMARSAIKHAN *et al.*, 2012; PEREIRA, 2012; PEREIRA *et al.*, 2013; REICHE *et al.*, 2013; DUSSEUX *et al.*, 2014; FORKUOR *et al.*, 2014; FURTADO *et al.*, 2015; BRAGA *et al.*, 2015a; BRAGA *et al.*, 2015b; BRAGA *et al.*, 2015c). Em geral, os métodos de integração analisados apresentaram resultados melhores do que aqueles obtidos individualmente.

Segundo Pohl e Van Genderen (1997), a integração de dados pode ocorrer basicamente de duas formas: pelo método da fusão de imagens ou pela combinação multissensor. Na fusão, integram-se os dados contidos em duas ou mais bandas de uma imagem para formar uma nova imagem sintética ou um grupo de imagens, enquanto que na combinação integram-se

as imagens empilhando-as em camadas (*stacking layers*), sem criar um novo conjunto de imagens. A fusão de dados é a técnica mais comum encontrada na literatura para a integração de dados provenientes de múltiplos sensores.

Lu *et al.* (2011) realizaram comparações entre métodos de integração para classificação do uso e cobertura da terra na Amazônia brasileira. Foram analisadas diferentes técnicas de fusão (*Principal Component Analysis* - PCA, *Wavelet-Merging*, *HPF Resolution-Merging* e *Normalized Multiplication* - NMM) entre dados Landsat/TM, Alos/Palsar e Radarsat2. Em geral, os resultados indicaram que dados de radar individualmente fornecem classificações com acurácias inferiores quando comparadas às classificações efetuadas com dados ópticos e com dados de fusão.

Pereira (2012) avaliou diferentes formas de integração de dados ópticos e de micro-ondas, especificamente, dados de radar de abertura sintética (*Synthetic Aperture Radar* - SAR), visando indicar a mais adequada para o mapeamento do uso e cobertura da terra de uma região de fronteira agrícola da Amazônia brasileira. Neste trabalho, identificaram-se as classes que foram melhores discriminadas com a utilização conjunta dos dados ópticos e SAR e seus respectivos métodos de integração. Em grande parte dos resultados, o uso conjunto dos dados ópticos com SAR (fusão ou combinação) melhorou os índices *Kappa* das classificações. Todavia, diferentes métodos de fusão se mostraram mais eficientes para a discriminação das classes definidas no estudo.

Furtado *et al.* (2015), também em uma região da Amazônia, fizeram uma comparação entre dois métodos de integração de dados, a fusão sintética de imagens ópticas e SAR e a classificação multissensor de imagens ópticas e SAR pareadas. Neste trabalho, os autores concluíram que o método multissensor se mostrou mais apropriado para classificações de uso do solo na várzea da Amazônia.

Na literatura, paralelamente ao estudo de métodos de fusão e combinação de imagens, medidas da Teoria da Informação, tais como, entropia, divergências e distâncias estocásticas, estão sendo aplicadas em busca de soluções para diversos problemas existentes no processamento digital de imagens. Por exemplo, Frery *et al.* (2011) examinaram o uso de medidas de dissimilaridade provenientes da Teoria da Informação

para o estudo da análise de contraste em imagens de radar de abertura sintética polarimétrica (PolSAR). Nascimento *et al.* (2011) utilizaram estas medidas para o desenvolvimento de técnicas de detecção de bordas. Torres (2012) implementou um novo algoritmo para filtragem de ruído *speckle* (característico de imagens SAR) com base em distâncias estocásticas e testes entre distribuições. Outros autores (SILVA, 2013; SILVA *et al.*, 2013) utilizaram essas medidas para desenvolvimento de uma ferramenta computacional para classificação de imagens de sensores remotos.

No classificador desenvolvido por Silva (2013), a classificação de uma imagem é obtida a partir dos cálculos das distâncias entre segmentos de uma imagem e classes previamente definidas. Portanto, é um classificador supervisionado por regiões. No desenvolvimento deste classificador, admite-se que são conhecidas as funções densidades de probabilidade (*f.d.p.*'s) que modelam os dados e as fórmulas (sejam analíticas ou numéricas) das distâncias entre estas distribuições supondo-se, em geral, a existência de um único sensor. Basicamente utilizam-se as seguintes funções de distribuição de probabilidade: Gaussiana Multivariada para a modelagem de imagens ópticas; Par de intensidade *multi-look* para a modelagem de imagens SAR em intensidade; e *Wishart* complexa escalonada para a modelagem de imagens SAR polarimétricas. A utilização de distâncias entre *f.d.p.*'s conjuntas (como é o caso de múltiplos sensores) ainda é um problema em aberto.

Considerando-se a quantidade de métodos de integração de dados existentes na literatura e os benefícios provenientes da utilização destes métodos em classificação de imagens, é plausível, pensar no uso de medidas de dissimilaridades oriundas da Teoria da Informação para obtenção de classificações de dados adquiridos por múltiplos e distintos sensores. Suponha w imagens corregistradas oriundas de sensores (fontes) distintos. Identificando-se as *f.d.p.*'s (funções marginais) que modelam os dados, é possível obter individualmente a classificação destas imagens por meio da classificação por regiões baseada em distâncias estocásticas. No contexto da integração de dados, se tais imagens forem utilizadas em conjunto, de forma que, informações relativas a cada uma sejam levadas em consideração no processo de classificação, os dados deveriam, a princípio, ser modelados por *f.d.p.*'s conjuntas,

também chamadas de funções conjuntas. No entanto, tais distribuições não são necessariamente conhecidas em razão da mistura das informações.

Desta forma, fica evidente que o principal problema nesta combinação de dados de múltiplos sensores utilizando a classificação por regiões baseada em distâncias estocásticas é o desconhecimento da *f.d.p.* conjunta que modela os dados combinados ou integrados. Em geral, a obtenção de uma fórmula fechada para o cálculo da distância estocástica entre distribuições conjuntas é uma tarefa complexa e, em muitos casos, inviável. Todavia, adotando-se como hipótese inicial a independência entre os múltiplos sensores e conhecendo-se as *f.d.p.*'s que modelam os dados individualmente, é possível calcular distâncias estocásticas entre as *f.d.p.*'s conjuntas sem obrigatoriamente conhecê-las. Este é o objeto de estudo da presente dissertação, e através dele torna-se viável a classificação de imagens de múltiplos sensores baseada em distâncias estocásticas.

1.1. Objetivo

O objetivo central deste trabalho é a proposição de uma nova metodologia de integração de dados classificados baseada em distâncias estocásticas e testes de hipóteses, denominada "Classificação multifonte". Neste caso, a integração é realizada a partir dos dados classificados de cada um dos distintos sensores (classificações individuais), desde que se conheçam suas distribuições marginais e distâncias estocásticas associadas (aqui denominada de distância marginal).

O grande diferencial do método de integração proposto se origina do fato de a classificação ser obtida a partir do cálculo das distâncias estocásticas entre a *f.d.p.* conjunta dos dados oriundos das múltiplas fontes sem, no entanto, conhecê-la. Estas distâncias (e estatísticas de teste associadas) são computadas a partir das distâncias marginais (e estatísticas de teste marginais), independentemente do conhecimento das *f.d.p.*'s conjuntas. O resultado da classificação multifonte é, então, construído utilizando-se funções matemáticas que se baseiam nas estatísticas de teste empregadas nas classificações individuais.

1.1.1. Objetivos específicos

- ✓ No âmbito da pesquisa com distâncias estocásticas e testes de hipótese associados, pode-se considerar como um objetivo específico a prova matemática da metodologia proposta. Isto é, provar matematicamente que é possível desenvolver distâncias estocásticas entre funções densidade de probabilidade conjuntas não conhecidas a partir das distâncias entre as distribuições marginais conhecidas, quando se supõe a independência entre fontes distintas que geraram os dados.
- ✓ Um outro objetivo específico que se vislumbra, agora no contexto da classificação de imagens, é a demonstração de que, por meio de informações provenientes de múltiplas fontes, é possível obter resultados de classificação por regiões com melhores índices de acurácia (coeficiente *Kappa* e acurácia global) do que os apresentados por classificações individuais.

1.2. Contribuições

Por meio da metodologia proposta é viável identificar contribuições relevantes para a ciência na área de sensoriamento remoto no que diz respeito ao processamento digital de imagens, especificamente, na classificação de imagens, a saber:

- a) Cálculo de distâncias entre funções densidades de probabilidades conjuntas não conhecidas;
- b) Introdução de um método de integração de dados inédito na literatura;
- c) Apresentação da fundamentação matemática teórica necessária para a proposição e desenvolvimento de um classificador por regiões supervisionado multifonte capaz de obter resultados de classificações com melhores indicadores de acurácia do que aqueles obtidos em classificações individuais.

1.3. Organização do documento

Esta dissertação está organizada em sete capítulos. Além do capítulo introdutório atual, no Capítulo 2 são apresentados teoremas e definições básicas para compreensão do trabalho em questão, a modelagem estatística dos dados e os fundamentos teóricos necessários para o entendimento dos demais capítulos. A descrição da metodologia é desenvolvida nos Capítulos 3 e 4. No Capítulo 5, descrevem-se os materiais e métodos adotados para aplicação da técnica proposta, no Capítulo 6 apresentam-se resultados da aplicação da metodologia e finalmente, no Capítulo 7 são delineadas as considerações finais e os trabalhos futuros.

2 MODELAGEM DOS DADOS

Neste capítulo, são apresentados teoremas e conceitos fundamentais para a compreensão da metodologia desenvolvida nesta dissertação, assim como a modelagem estatística dos dados.

2.1. Teoremas

É importante ressaltar que, embora alguns dos tópicos exibidos na presente seção tratem de propriedades ou características específicas, tais resultados são intitulados neste trabalho como teoremas.

2.1.1. Teorema Central do Limite

Sejam X_1, \dots, X_n variáveis aleatórias independentes e identicamente distribuídas, com média comum μ e variância comum σ^2 , onde $0 < \sigma^2 < \infty$. Seja \bar{X}_n a média amostral, definida como a média aritmética das variáveis X_1, \dots, X_n . Então (JAMES, 2010):

$$\sqrt{n} \left(\frac{\bar{X}_n - \mu}{\sigma} \right) \xrightarrow{D} N(0,1), \text{ quando } n \rightarrow \infty$$

onde \xrightarrow{D} representa a convergência em distribuição e $N(0,1)$ é a distribuição normal padrão.

2.1.2. Relação entre funções conjuntas e marginais de variáveis aleatórias independentes

Se X_1, \dots, X_n são variáveis aleatórias independentes, com distribuição de probabilidade conjunta $f_{X_1, \dots, X_n}(x_1, \dots, x_n)$ e distribuição de probabilidade marginal $f_{X_1}(x_1), \dots, f_{X_n}(x_n)$, então, temos que (JAMES, 2010):

$$f_{X_1, \dots, X_n}(x_1, \dots, x_n) = \prod_{i=1}^n f_{X_i}(x_i), \forall (x_1, \dots, x_n) \in \mathbb{R}^n$$

ou seja, a distribuição de probabilidade conjunta é expressa através do produto das distribuições marginais.

2.1.3. Aditividade da distribuição χ^2

Seja χ_{GL}^2 uma variável aleatória *Chi-quadrado* com GL graus de liberdade. Se X_1, \dots, X_n são independentes e $X_i \sim \chi_{GL_i}^2$, então $\sum_{i=1}^n X_i \sim \chi_{\sum_{i=1}^n GL_i}^2$, onde Σ representa o operador de somatório e \sim representa a atribuição de distribuição estatística.

Desta forma, a distribuição da variável aleatória, representada pela soma de variáveis aleatórias *Chi-quadrado*, é também uma densidade *Chi-quadrado* cujo grau de liberdade é dado pela soma dos graus de liberdade de cada uma das variáveis aleatórias (CASELA, 2010).

2.2. Definições

As seguintes definições foram empregadas no desenvolvimento desta dissertação.

2.2.1. Radar de abertura sintética

Em geral, os sensores podem ser classificados em ativos e passivos. Sensores ativos possuem sua própria fonte de radiação eletromagnética enquanto sensores passivos necessitam de uma fonte externa de iluminação. O RADAR (*Radio Detection and Ranging*) é um tipo de sensor ativo que opera na faixa de micro-ondas (1 mm a 1 m). Os radares imageadores compreendem os sistemas de antena rotatória e os de visada lateral (SLAR - *Side Looking Airbone Radar*). Os radares de visada lateral são classificados em abertura real (RAR - *Real Aperture Radar*) e abertura sintética (SAR - *Synthetic Aperture Radar*) (FREITAS *et al.*, 2003). A diferença entre eles esta no fato do SAR sintetizar eletronicamente uma antena de maior dimensão que o RAR a fim de melhorar a resolução azimutal do sensor.

2.2.2. Radar de abertura sintética polarimétrico

No processo de formação de uma imagem, um sistema SAR, junto a uma plataforma que normalmente se desloca linearmente, transmite pulsos de energia com polarizações horizontal (h) ou vertical (v). Ao atingirem alvos na superfície terrestre, estes pulsos interagem com os mesmos fazendo com que somente parte da energia retorne ao ponto de

transmissão. A energia de retorno é registrada em uma das polarizações e posteriormente utilizada para geração da imagem. Radares imageadores tradicionais operam com um único canal e com uma antena de polarização fixa, tanto para transmissão como para recepção do sinal, nestes casos somente as informações de amplitude ou intensidade são medidas. Como consequência, qualquer informação adicional sobre a superfície contida na informação da fase dos sinais refletidos é perdida. Por intermédio de sistemas SAR polarimétricos (PolSAR - *Polarimetric SAR*) é possível medir a amplitude e fase relativa de todas as componentes do sinal na transmissão e na recepção (hh, hv, vv, vh), para todos os elementos de resolução da cena. A primeira e segunda letra de cada componente significa respectivamente a polarização da onda transmitida e recebida pelo radar (CORREIA, 1998; SALDANHA, 2013).

2.2.3. Ruído *speckle* e processamento *multi-look*

Imagens SAR possuem um ruído característico denominado *speckle*. O *speckle* é um ruído multiplicativo que é proporcional à intensidade do sinal recebido. Em uma célula de resolução no terreno pode existir um número muito grande de alvos difusores, aleatoriamente distribuídos, de tal forma que a energia espalhada por estes alvos podem sofrer interferência construtiva ou destrutiva. A interferência destrutiva causa o cancelamento do sinal refletido e a interferência construtiva a sua soma, fazendo aparecer variações súbitas na intensidade da imagem, caracterizando o ruído *speckle*. O efeito visual é um padrão granuloso que degrada a qualidade visual da imagem para fins de interpretação (MENESES; ALMEIDA, 2012).

As imagens SAR podem receber um processamento específico a fim de reduzir o efeito de seu ruído característico. Este processamento, chamado *multi-look*, consiste em dividir a abertura sintética da antena em alguns setores (*looks*). A média das imagens de cada setor, geradas separadamente, irá compor a imagem final.

2.2.4. Matriz de espalhamento complexa

Em dados SAR polarimétricos, o sinal retroespalhado pelos alvos pode ser decomposto em componentes do sinal transmitido e recebido pelo sensor, levando-se em conta as

suas polarizações. Este sinal pode ser representado pela matriz de espalhamento complexa, que é expressa por:

$$\mathcal{S} = \begin{pmatrix} \mathcal{S}_{vv} & \mathcal{S}_{vh} \\ \mathcal{S}_{hv} & \mathcal{S}_{hh} \end{pmatrix} \quad (2.1)$$

Os termos \mathcal{S}_{ij} da matriz, onde $i, j \in \{h, v\}$, são conhecidos como coeficiente de espalhamento complexo. Segundo Sarabandi (1992), tem-se

$$\mathcal{S}_{ij} = |\mathcal{S}_{ij}| \exp\{i\phi_{ij}\} = \sum_{i=1}^N |\mathcal{S}_{ij}^i| \exp\{i\phi_{ij}^i\}, \quad (2.2)$$

onde N é o número de difusores de uma célula de resolução, cada um retroespalhando um sinal com amplitude $|\mathcal{S}_{ij}^i|$ e uma fase ϕ_{ij}^i . O vetor resultante da soma vetorial do retroespalhamento de todos os difusores terá amplitude $|\mathcal{S}_{ij}|$ e fase ϕ_{ij} . O termo $\exp\{\cdot\}$ representa a função exponencial e i a unidade imaginária.

Considerando-se o Teorema de Reciprocidade (ULABY; ELACHI, 1990), os termos \mathcal{S}_{vh} e \mathcal{S}_{hv} são considerados iguais e a matriz \mathcal{S} pode ser, então representada pelo vetor de espalhamento complexo dado por:

$$\mathbf{V}_{\mathcal{S}} = \begin{bmatrix} \mathcal{S}_{hh} \\ \mathcal{S}_{hv} \\ \mathcal{S}_{vv} \end{bmatrix}. \quad (2.3)$$

Sob certas condições (GOODMAN, 1963), em que o teorema central do limite é válido, pode-se provar que as partes reais e imaginárias de \mathcal{S}_{ij} $i, j \in \{h, v\}$, possuem distribuição Gaussiana com média zero e mesma variância.

2.2.5. Matriz de covariância para *L-looks*

O vetor de espalhamento complexo $\mathbf{V}_{\mathcal{S}}$ é conhecido na literatura como dado PolSAR de 1 - *look* ou SLC (*Single Look Complex*). Este vetor representa dados complexos com polarizações (componentes) distintas que produzem um grande volume de dados da superfície imageada (FREITAS *et al.*, 2003). Para compressão destes dados e redução do ruído *speckle*, os dados SAR polarimétricos são frequentemente processados com o aumento do número de *looks* (*multi-look*), e denominados MLC (*Multi Look Complex*).

Sendo assim, a partir do vetor $V_S(i)$ que representa a i -ésima amostra de 1 - look, pode-se obter a matriz de covariância para L - looks, dada por (LEE *et al.*, 1995):

$$\mathbf{V}_S^{(L)} = \frac{1}{L} \sum_{i=1}^L V_S(i) V_S^H(i), \quad (2.4)$$

onde $V_S^H(i)$ representa o vetor transposto conjugado de $V_S(i)$.

2.2.6. Matriz hermitiana positiva definida

Uma matriz complexa $\mathbf{A} = \mathbf{A}_1 + \mathbf{i}\mathbf{A}_2$ com \mathbf{A}_1 e \mathbf{A}_2 matrizes reais, é hermitiana positiva definida se $\mathbf{A}^H = \mathbf{A}$ e para todo $\mathbf{g} \in \mathbb{C}^n$, $\mathbf{g}^H \mathbf{A} \mathbf{g} > 0$, onde $(\cdot)^H$ representa o operador transposto conjugado e \mathbb{C}^n o conjunto n dimensional dos números complexos. Essas matrizes de acordo com Nascimento (2012) possuem as seguintes características:

- a) todos os seus autovalores e menores principais são positivos;
- b) se \mathbf{A} é não singular, sua inversa também será uma matriz hermitiana;
- c) os autovalores de \mathbf{A} são reais;
- d) para $i \in \mathbb{N}$, \mathbf{A}^i é hermitiana;
- e) $\mathbf{g}^H \mathbf{A} \mathbf{g}$ é real para todo $\mathbf{g} \in \mathbb{C}^n$;
- f) $\mathbf{G}^H \mathbf{A} \mathbf{G}$ é hermitiana para toda matriz \mathbf{G} com mesma dimensão que \mathbf{A} .

2.3. Distribuições

Nesta dissertação, a construção de modelos e métodos para a descrição dos dados segue uma abordagem estatística. Os dados envolvidos tratam-se de imagens de sensoriamento remoto provenientes de sensores orbitais, especificamente sensores ópticos e de micro-ondas.

Em geral, os sensores podem ser especificados de acordo com a faixa do espectro eletromagnético em que operam. Os sensores ópticos, assim chamados por operarem na faixa óptica do espectro eletromagnético (0,30 a 15,0 μm), são os sensores nos quais os

especialistas possuem maior experiência dentro do sensoriamento remoto. A necessidade de uma fonte externa de iluminação (desconsiderando-se os sensores termais) e a grande dependência das condições climáticas são algumas das desvantagens vinculadas ao uso destes sensores (FREITAS *et al.*, 2003).

Embora o imageamento por sistemas ópticos seja uma técnica madura em sensoriamento remoto, suas limitações conduzem à utilização de sensores operando em outras bandas do espectro eletromagnético. Entre estes se destacam os sensores de micro-ondas (GERSTL, 1990). Imagens provenientes destes sensores vêm sendo intensamente utilizadas uma vez que, por meio destes, torna-se possível a aquisição de dados pouco influenciados pelas condições climáticas, sem a necessidade da iluminação solar.

Em regra, sensores ópticos fornecem informações quanto às características químicas, físicas e biológicas dos alvos enquanto sensores de micro-ondas fornecem informações a respeito das propriedades dielétricas e da geometria (forma, textura e estrutura) dos alvos imageados. Observando-se as características distintas entre ambos os sensores, conclui-se que modelar dados provenientes de sensores ópticos da mesma forma que se modelam dados provenientes de sensores de micro-ondas não é a opção mais adequada visto que cada um destes sensores capta informações diferentes. Embora, em alguns casos, utilize-se um mesmo modelo para abordagem destes dados, existem na literatura modelos específicos para tratamento de dados de micro-ondas que permitem sua melhor representação.

Neste trabalho de dissertação serão utilizadas duas distribuições de probabilidade para modelagem dos dados provenientes de sensores de micro-ondas, a saber, a distribuição *Wishart* complexa escalonada e a distribuição Par de intensidades *multi-look*. Para a modelagem dos dados obtidos por meio de sensores ópticos será utilizada a distribuição Gaussiana multivariada. Cada uma destas distribuições é detalhada nas subseções a seguir.

2.3.1. Modelo aditivo

Segundo a literatura, usualmente, imagens oriundas de sensores ópticos são modeladas estatisticamente pela distribuição Gaussiana, também conhecida como distribuição Normal. Imagens ópticas apresentam ruído aditivo e, neste caso, é comum a suposição

de que tal ruído possua uma distribuição Gaussiana ou uniforme. Ruídos seguindo uma distribuição Normal são muito comuns e têm suas origens no teorema central do limite (Teorema 2.1.1) que afirma que a soma de um número elevado de termos representando ruídos aleatórios tende a produzir um ruído tipo Gaussiano.

Considere \mathcal{Z} a soma de variáveis aleatórias Gaussianas independentes e identicamente distribuídas \mathcal{X} e \mathcal{Y} . Então,

$$\mathcal{Z} = \mathcal{X} + \mathcal{Y} \quad (2.5)$$

onde \mathcal{Z} refere-se ao sinal recebido, \mathcal{X} representa o sinal da cena e \mathcal{Y} o ruído do sistema. Neste caso, o dado observado (imagem) é modelado através de uma distribuição Gaussiana.

A modelagem por meio da distribuição Gaussiana é mais simples, pois, mesmo no caso multivariado, têm-se apenas dois parâmetros (vetor de média e matriz de covariância) embora se trabalhe com matrizes. Além disso, no modelo aditivo, o tratamento matemático é mais simples, tanto no domínio espacial quanto no domínio de frequência (GONZALEZ; WOODS, 2002).

2.3.1.1. Distribuição Gaussiana multivariada

A distribuição Gaussiana multivariada pode ser útil para a modelagem de diversos tipos de dados tais como, imagens de sensores ópticos ou imagens SAR (Definição 2.2.1) multivariadas em amplitude com grande número de visadas. Neste trabalho, a utilização desta distribuição se limita à modelagem de dados ópticos.

Sejam Z_1, \dots, Z_q variáveis aleatórias Gaussianas com médias μ_1, \dots, μ_q e variâncias $\sigma_1^2, \dots, \sigma_q^2$. Seja o vetor aleatório $\mathbf{Z} = (Z_1, \dots, Z_q)^\top$. Diz-se que \mathbf{Z} possui uma distribuição Normal q -variada com vetor de média $\boldsymbol{\mu}$ e matriz de covariância \mathbf{C} , denotado por $\mathbf{Z} \sim N(\boldsymbol{\mu}, \mathbf{C})$, se sua função densidade de probabilidade (*f. d. p.*) é dada por:

$$f_{\mathbf{Z}}(\mathbf{z}; \boldsymbol{\mu}, \mathbf{C}) = |\mathbf{C}|^{-\frac{1}{2}} (2\pi)^{-\frac{q}{2}} \exp\left\{-\frac{1}{2}(\mathbf{z} - \boldsymbol{\mu})^\top \mathbf{C}^{-1}(\mathbf{z} - \boldsymbol{\mu})\right\} \quad (2.6)$$

onde $|\cdot|$ denota o determinante da matriz, $(\cdot)^T$ representa o operador transposto, $(\cdot)^{-1}$ indica a inversa da matriz e o vetor de médias $\boldsymbol{\mu}$ é dado por:

$$\boldsymbol{\mu} = E(\mathbf{Z}) = \begin{bmatrix} E(Z_1) \\ \dots \\ E(Z_q) \end{bmatrix} = \begin{bmatrix} \mu_1 \\ \dots \\ \mu_q \end{bmatrix}$$

em que $E(\cdot)$ representa o operador de esperança estatística. Representa-se a matriz de covariância \mathbf{C} por:

$$\mathbf{C} = Cov(\mathbf{Z}) = \begin{bmatrix} \sigma_{11}^2 & \dots & \sigma_{1q} \\ \vdots & \ddots & \vdots \\ \sigma_{q1} & \dots & \sigma_{qq}^2 \end{bmatrix}.$$

onde $\sigma_{ij} = \sigma_{ji} = cov(Z_i, Z_j)$, em que $cov(Z_i, Z_j)$ representa a covariância entre as variáveis aleatórias Z_i e Z_j . Neste caso, σ_{ii} representa a variância de Z_i .

Na maioria das técnicas multivariadas presume-se que os dados possam ser modelados por uma distribuição Gaussiana multivariada. Embora tal pressuposição não seja sempre correta, a função densidade de probabilidade Gaussiana multivariada se constitui em uma aproximação adequada e útil da verdadeira distribuição populacional. A modelagem de dados através desta distribuição é comumente utilizada. Todavia, esta quase sempre não é a mais adequada para representação de dados de sensores de micro-ondas. Desta forma, utilizam-se neste trabalho outras duas funções de probabilidade para modelagem deste tipo de dados. Descrições de ambas as distribuições são dadas nas seções a seguir.

2.3.2. Modelo multiplicativo

O modelo multiplicativo é o modelo mais aceito atualmente para a modelagem de dados gerados por sensores de micro-ondas. Imagens de micro-ondas, especificamente de sensores SAR, utilizam radiação coerente e desta forma apresentam ruído multiplicativo. No modelo multiplicativo, supõe-se que o valor observado em cada pixel é a ocorrência de uma variável aleatória Z , expressa por:

$$\mathbf{Z} = \mathcal{X} \cdot \mathcal{Y} \quad (2.7)$$

onde \mathcal{X} representa a variável aleatória modelando o retroespalhamento (o que o alvo está retornando), \mathcal{Y} representa a variável aleatória modelando o ruído do sistema e \mathbf{Z} representa a variável aleatória modelando o valor detectado pelo sensor (antena). A variável \mathcal{X} será sempre considerada real e positiva enquanto \mathcal{Y} pode ser complexa ou real e positiva dependendo apenas do formato de representação dos dados (FREITAS *et al.*, 2003). A variável \mathcal{Y} representa o *speckle* e, portanto não depende do alvo, enquanto a modelagem da variável aleatória \mathcal{X} varia de alvo para alvo. Dependendo da modelagem de \mathcal{X} , tem-se determinada distribuição para a variável \mathbf{Z} , já que a modelagem de \mathcal{Y} é sempre a mesma.

Diferentes *f.d.p.*'s têm sido propostas para a modelagem de dados de sensores micro-ondas. Estes modelos diferem, dependendo do tipo de dado (intensidade, amplitude ou complexos) e do tipo de alvo imageado. Neste trabalho é utilizada a distribuição *Wishart* complexa escalonada para representar o retorno \mathbf{Z} para dados polarimétricos. Quando se tem dados bivariados em intensidade a função utilizada é a de Par de intensidades *multi-look*, que é um caso especial da função *Wishart*. Estas duas funções são apresentadas a seguir.

2.3.2.1. Distribuição *Wishart* complexa escalonada

Seja $\mathbf{Z} = (Z_1, \dots, Z_q)^\top$ um vetor cuja *f.d.p.* é descrita por uma função Gaussiana complexa q -variada com média zero e matriz de covariância hermitiana positiva definida $\mathbf{\Sigma}$ (Definição 2.2.6) dada por:

$$f_{\mathbf{Z}}(\mathbf{z}; \mathbf{0}, \mathbf{\Sigma}) = \frac{1}{\pi^q |\mathbf{\Sigma}|} \exp\{-\mathbf{z}^H \mathbf{\Sigma}^{-1} \mathbf{z}\} \quad (2.8)$$

em que $(\cdot)^{-1}$ denota a matriz inversa e $\mathbf{\Sigma} = \mathbf{E}(\mathbf{Z}\mathbf{Z}^H)$ descreve a matriz de covariância de \mathbf{Z} . A *f.d.p.* dada em (2.8) é utilizada para a modelagem do vetor de espalhamento $\mathbf{V}_{\mathcal{S}}$, Equação (2.3), da Definição 2.2.4.

Para dados *multi-look* (Definição 2.2.5) em que considera-se a média de L vetores aleatórios independentes e identicamente distribuídos, a matriz de covariância L -looks é dada por:

$$\mathbf{E} = \frac{1}{L} \sum_{i=1}^L \mathbf{z}_i \mathbf{z}_i^H. \quad (2.9)$$

A variável aleatória \mathbf{E} possui uma distribuição *Wishart* complexa escalonada com parâmetro L e matriz de covariância $\mathbf{\Sigma}$, se possui função densidade de probabilidade expressa por:

$$f_{\mathbf{E}}(\mathbf{e}, \mathbf{\Sigma}, L) = \frac{L^{qL} |\mathbf{e}|^{L-q}}{|\mathbf{\Sigma}|^L \Gamma_q(L)} \exp\{-L \mathbf{Tr}(\mathbf{\Sigma}^{-1} \mathbf{e})\} \quad (2.10)$$

em que $\Gamma_q = \pi^{q(q-1)/2} \prod_{i=0}^{q-1} \Gamma(L-i)$, $L \geq q$, $\Gamma(\cdot)$ é a função Gama, $\mathbf{Tr}(\cdot)$ representa o traço da matriz e q representa a dimensão do vetor \mathbf{e} . O parâmetro L , na modelagem dos dados SAR representa o número equivalente de *looks*.

A distribuição *Wishart* complexa escalonada é muito útil para a modelagem de dados PolSAR (Definição 2.2.2) em áreas homogêneas (o retroespalhamento é modelado por uma constante). Em áreas heterogêneas seu uso não é recomendado, mas sim outros modelos mais complexos, tais como a distribuição K complexa multivariada (LEE *et al.*, 1994) ou a distribuição G^0 complexa multivariada (FREITAS *et al.*, 2005). Dentre as vantagens na utilização da distribuição *Wishart* pode-se citar a sua menor complexidade analítica, tocante ao desenvolvimento de distâncias estocásticas baseadas nesta distribuição (NASCIMENTO *et al.*, 2010), e também à indisponibilidade até o momento de expressões fechadas para distâncias entre modelos mais complexos presentes na literatura.

2.3.2.2. Distribuição Par de intensidades *multi-look*

A distribuição Par de intensidades *multi-look*, derivada da distribuição *Wishart* complexa escalonada por Lee *et al.* (1994) é de grande importância na modelagem estatística de dados polarimétricos incompletos, ou seja, dados que não possuem todas

suas componentes de polarização, a saber hh, hv, vh, vv . Em Negri (2009), verificou-se que, para determinado número de classes de uso e cobertura da terra, a classificação com base neste modelo alcançou resultados similares àqueles obtidos por dados polarimétricos completos.

Sejam duas variáveis aleatórias Z_1 e Z_2 , representando duas imagens em intensidade L -looks, obtidas a partir de duas componentes (\mathcal{S}_r e \mathcal{S}_s) da matriz de espalhamento (Definição 2.2.4), segundo as equações:

$$Z_1 = \frac{1}{L} \sum_{i=1}^L |\mathcal{S}_r(i)|^2 \quad \text{e} \quad Z_2 = \frac{1}{L} \sum_{i=1}^L |\mathcal{S}_s(i)|^2.$$

A função densidade de probabilidade do Par de intensidades *multi-look* é definida por:

$$f_{Z_1 Z_2}(z_1, z_2) = \frac{L^{L+1} (z_1 z_2)^{\frac{L-1}{2}} \exp \left\{ -\frac{L \left(\frac{z_1}{h_{11}} + \frac{z_2}{h_{22}} \right)}{1 - |\rho_c|^2} \right\}}{(h_{11} h_{22})^{\frac{(L+1)}{2}} \Gamma(L) (1 - |\rho_c|^2) |\rho_c|^{L-1}} \cdot I_{L-1} \left(\frac{2L |\rho_c|}{1 - |\rho_c|^2} \sqrt{\frac{z_1 z_2}{h_{11} h_{22}}} \right) \quad (2.11)$$

em que L é o número equivalente de *looks*, h_{11} e h_{22} as esperanças das variáveis aleatórias Z_1 e Z_2 respectivamente,

$$h_{11} = E(Z_1) \quad (2.12)$$

$$h_{22} = E(Z_2) \quad (2.13)$$

I_{L-1} é a função modificada de Bessel de ordem $L - 1$ e ρ_c é o coeficiente de correlação complexo. Dado $v \in \mathbb{C}$, uma função modificada de Bessel de ordem v é definida como

$$I_v(z) = \frac{z^v}{\Gamma\left(v + \frac{1}{2}\right) \Gamma\left(\frac{1}{2}\right)} \int_0^\pi \cosh(z \cos \theta) \sin^{2v} \theta d\theta \quad (2.14)$$

com $\Re\left[v + \frac{1}{2}\right] > 0$, em que $\Re[\cdot]$ representa a parte real de um número complexo, $\cosh(\cdot)$, $\cos(\cdot)$ e $\sin(\cdot)$ representam respectivamente as funções cosseno hiperbólico, cosseno e seno.

De acordo com Lee *et al.* (1994), sendo \mathcal{S}_i e \mathcal{S}_j duas componentes da matriz de espalhamento complexa, o coeficiente de correlação complexa ρ_c é dado por:

$$\rho_c = \frac{E(\mathcal{S}_i \mathcal{S}_j^*)}{\sqrt{E(|\mathcal{S}_i|^2)E(|\mathcal{S}_j|^2)}} = |\rho_c| \exp\{j\Theta\} \quad (2.15)$$

em que $0 \leq |\rho_c| \leq 1$ e Θ é a diferença de fase entre os retornos de cada polarização. Lee *et al.* (1994) também mostram que o módulo do coeficiente de correlação complexo ($|\rho_c|$) pode ser estimado a partir de duas imagens “*multi-look*” em intensidade (Z_1 e Z_2)

$$|\rho_c|^2 = \frac{E((Z_1 - h_{11})(Z_2 - h_{22}))}{\sqrt{E((Z_1 - h_{11})^2)E((Z_2 - h_{22})^2)}}. \quad (2.16)$$

2.4. Medidas da teoria da informação e classificação de imagens

A Teoria da Informação, também conhecida como Teoria Matemática da Comunicação cujo alicerce foi firmado por Claude Shannon (1916 a 2001), é um ramo da probabilidade e matemática estatística responsável pelo estudo da quantificação de informação (KULLBACK, 1959). Assim como a probabilidade e estatística possui um vasto campo de aplicações que se estende da física à psicologia, uma vez que as formulações da Teoria da Informação são aplicáveis a qualquer sistema de informações probabilístico ou estatístico, encontra também aplicação em diversas áreas do conhecimento. Na primeira subseção, serão apresentadas as definições das principais medidas de entropia provenientes desta teoria, utilizadas no desenvolvimento desta dissertação. Na segunda subseção será descrita aplicação destas medidas no processamento digital de imagens, especificamente, na classificação por regiões de imagens.

2.4.1. Divergências, distâncias estocásticas e estatísticas de testes de hipótese

Em estatística, existem diversos parâmetros de separabilidade, também chamados de medidas de distância entre distribuições, que objetivam determinar se duas distribuições de probabilidade são similares (NASCIMENTO, 2012). Entre essas se encontra a divergência, cuja definição surgiu com o desenvolvimento da Teoria da Informação. A divergência pode ser definida como uma função não negativa entre duas medidas de probabilidade que obedece as propriedades de definitividade e não negatividade. Por meio desta medida obtêm-se distâncias entre distribuições de probabilidade. Segundo Nascimento (2012), após os primeiros conceitos de divergência, deu-se início ao estudo de classes desta medida. Entre elas pode-se citar a classe de divergências ϕ ou família de divergências ϕ desenvolvida por Csiszár (1967). Esta classe caracteriza-se por um procedimento analítico formalizado que permite a obtenção de medidas de divergência a partir da escolha adequada de uma função convexa ϕ satisfazendo determinadas condições (SILVA, 2013). Uma extensão deste procedimento foi proposta por Salicrú *et al.* (1994) onde uma nova função h foi inserida permitindo assim a geração de expressões para um número muito maior de divergências conhecidas em relação às obtidas pela classe definida por Csiszár (1967). A família de divergências desenvolvidas por Salicrú *et al.* (1994) ficou conhecida como família $h - \phi$.

Definição de classe de divergência $h - \phi$: Sejam X e Y matrizes aleatórias definidas sobre um mesmo domínio Ω correspondente ao conjunto das matrizes hermitianas positivas definidas (Definição 2.2.6). Considere que as matrizes aleatórias possuem distribuições de probabilidade caracterizadas pelas densidades $f_X(z, \theta_1)$ e $f_Y(z, \theta_2)$ em que θ_1 e θ_2 são vetores de parâmetros. De acordo com Salicrú *et al.* (1994) a divergência $h - \phi$ entre X e Y é expressa por

$$D_{\phi}^h(X, Y) = h \left(\int_{z \in \Omega} \phi \left(\frac{f_X(z; \theta_1)}{f_Y(z; \theta_2)} \right) f_Y(z; \theta_2) dz \right), \quad (2,17)$$

onde $\phi: (0, \infty) \rightarrow [0, \infty)$ 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 .

Como citado, por meio de medidas de divergências, é possível obter expressões para distâncias entre distribuições de probabilidade denominadas distâncias estocásticas ou simplesmente distâncias. Uma distância estocástica é uma divergência que além de satisfazer as propriedades de não negatividade e definitividade, satisfaz a propriedade de simetria. Uma solução para obtenção de distâncias a partir de divergências não simétricas é o cálculo (simetrização) de

$$d_{\phi}^h(\mathbf{X}, \mathbf{Y}) = \frac{D_{\phi}^h(\mathbf{X}, \mathbf{Y}) + D_{\phi}^h(\mathbf{Y}, \mathbf{X})}{2} \quad (2.18)$$

Definição de distância estocástica: Uma distância estocástica em um conjunto $\Lambda \subset \Omega$ é uma função $d_{\phi}^h: \Lambda \times \Lambda \rightarrow \mathbb{R}$, onde \mathbb{R} representa o conjunto dos números reais, 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 $\mathbf{X}, \mathbf{Y} \in \Lambda$:

$$\text{Propriedade 1) } d_{\phi}^h(\mathbf{X}, \mathbf{Y}) = 0 \Leftrightarrow \mathbf{X} = \mathbf{Y} \text{ (Definitividade);} \quad (2.19)$$

$$\text{Propriedade 2) Se } \mathbf{X} \neq \mathbf{Y} \text{ então } d_{\phi}^h(\mathbf{X}, \mathbf{Y}) > 0 \text{ (Não-Negatividade);} \quad (2.20)$$

$$\text{Propriedade 3) } d_{\phi}^h(\mathbf{X}, \mathbf{Y}) = d_{\phi}^h(\mathbf{Y}, \mathbf{X}) \text{ (Simetria).} \quad (2.21)$$

Se uma distância estocástica satisfaz a desigualdade triangular, esta distância é chamada de métrica (LIMA, 2011). Se \mathbf{X} e \mathbf{Y} possuem a mesma distribuição com parâmetros diferentes, é suficiente escrever $d_{\phi}^h(\boldsymbol{\theta}_1, \boldsymbol{\theta}_2)$. Ao fazê-lo, tem-se que $d_{\phi}^h(\boldsymbol{\theta}_1, \boldsymbol{\theta}_2) \geq 0$ onde $d_{\phi}^h(\boldsymbol{\theta}_1, \boldsymbol{\theta}_2) = 0$ se, e somente se $\boldsymbol{\theta}_1 = \boldsymbol{\theta}_2$, isto é, as distribuições de \mathbf{X} e \mathbf{Y} são iguais. Portanto, a distância entre elas é nula.

A Tabela 2.1 apresenta as funções h e ϕ para as distâncias de *Bhattacharyya*, *Hellinger*, *Kullback-Leibler* e *Rényi* de ordem β (NASCIMENTO, 2010). Essas distâncias, utilizadas neste trabalho, são apresentadas nas Equações (2.22) a (2.26). Para fins de simplificação foram omitidos o domínio de integração e a dependência da variável x . Observa-se que as expressões listadas dependem unicamente das densidades envolvidas.

Tabela 2.1 – Distâncias tipo $(h - \phi)$ e funções h e ϕ relacionadas.

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

Fonte: Adaptada de Nascimento (2012).

Distância de *Bhattacharyya*

$$d_B(\mathbf{X}, \mathbf{Y}) = -\log \int \sqrt{f_X f_Y} \quad (2.22)$$

Distância de *Hellinger*

$$d_H(\mathbf{X}, \mathbf{Y}) = 1 - \int \sqrt{f_X f_Y} \quad (2.23)$$

Distância *Kullback-Leibler*

$$d_{KL}(\mathbf{X}, \mathbf{Y}) = \frac{1}{2} [D_{KL}(\mathbf{X}, \mathbf{Y}) + D_{KL}(\mathbf{Y}, \mathbf{X})] = \frac{1}{2} \int (f_X - f_Y) \log \frac{f_X}{f_Y} \quad (2.24)$$

Distância de Rényi de ordem β com $0 < \beta < 1$

$$\tilde{d}_R^\beta(\mathbf{X}, \mathbf{Y}) = \frac{1}{2} [D_R^\beta(\mathbf{X}, \mathbf{Y}) + D_R^\beta(\mathbf{Y}, \mathbf{X})] = \frac{\log \int f_X^\beta f_Y^{1-\beta} + \log \int f_X^{1-\beta} f_Y^\beta}{2(\beta - 1)} \quad (2.25)$$

aplicando-se a desigualdade de Fejér apresentada por Neuman (1990)

$$d_R^\beta(\mathbf{X}, \mathbf{Y}) \triangleq \frac{1}{(\beta - 1)} \log \left(\frac{\int f_X^\beta f_Y^{1-\beta} + \int f_X^{1-\beta} f_Y^\beta}{2} \right) \leq \tilde{d}_R^\beta(\mathbf{X}, \mathbf{Y}) \quad (2.26)$$

Assim como foram desenvolvidas expressões analíticas para as distâncias estocásticas de *Bhattacharyya* (KAILATH, 1967) e *Kullback-Leibler* (SEGHOUANE; AMARI, 2007) entre distribuições Gaussianas multivariadas, Nascimento *et al.* (2010), utilizando a definição de divergência $h - \phi$ e as funções h e ϕ apropriadas, obtiveram as expressões de divergências entre distribuições G_1^0 adequadas à modelagem de dados SAR em intensidade: *Bhattacharyya*, *Kullback-Leibler*, *Hellinger*, *Rényi* de ordem β , *Triangular*, *Jensen-Shannon*, *aritmética-geométrica* e *média harmônica*. Além destas, também desenvolveram cinco expressões fechadas para distâncias estocásticas entre distribuições *Wishart* complexas escalonadas, a saber: *Bhattacharyya*, *Kullback-Leibler*, *Hellinger*, *Rényi* de ordem β e *Chi-quadrado* (NASCIMENTO *et al.* 2010; FRERY *et al.* 2010; NASCIMENTO, 2012; FRERY *et al.*, 2011).

Nesta dissertação, foram utilizadas algumas distâncias entre distribuições Gaussianas multivariadas, *Wishart* complexa escalonada e Par de intensidades *multi-look*. As expressões obtidas para as distâncias estocásticas correspondentes são apresentadas nas Equações (2.27) a (2.32).

Para o cálculo de dissimilaridade entre distribuições Gaussianas multivariadas, foram utilizadas expressões fechadas para as distâncias de *Bhattacharyya* e *Kullback-Leibler*. As Equações (2.27) e (2.28) apresentam respectivamente as expressões para o cálculo das distâncias de *Bhattacharyya* e *Kullback-Leibler* entre distribuições Gaussianas multivariadas, com parâmetros $\boldsymbol{\mu}_i$ e $\boldsymbol{\Sigma}_i, i \in \{1,2\}$ em que $\boldsymbol{\mu}_1$ e $\boldsymbol{\mu}_2$ representam os vetores de média e $\boldsymbol{\Sigma}_1$ e $\boldsymbol{\Sigma}_2$ são matrizes de covariância

$$d_{GB}(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_1; \boldsymbol{\mu}_2, \boldsymbol{\Sigma}_2) = \frac{1}{8} \left[(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^\top \left(\frac{\boldsymbol{\Sigma}_1 + \boldsymbol{\Sigma}_2}{2} \right)^{-1} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2) \right] + \frac{1}{2} \log \frac{|\frac{\boldsymbol{\Sigma}_1 + \boldsymbol{\Sigma}_2}{2}|}{\sqrt{|\boldsymbol{\Sigma}_1| |\boldsymbol{\Sigma}_2|}} \quad (2.27)$$

$$\begin{aligned} d_{GKL}(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_1; \boldsymbol{\mu}_2, \boldsymbol{\Sigma}_2) &= \\ &= \frac{1}{2} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^\top (\boldsymbol{\Sigma}_1^{-1} + \boldsymbol{\Sigma}_2^{-1}) (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2) + \frac{1}{2} \text{Tr}(\boldsymbol{\Sigma}_1^{-1} \boldsymbol{\Sigma}_2 + \boldsymbol{\Sigma}_2^{-1} \boldsymbol{\Sigma}_1 - 2\mathbb{I}_q) \end{aligned} \quad (2.28)$$

onde \mathbb{I}_q é a matriz identidade de ordem q , $\text{Tr}(\cdot)$ representa o traço da matriz, $(\cdot)^{-1}$ indica a inversa da matriz, $|\cdot|$ denota o determinante da matriz e $(\cdot)^\top$ representa o operador transposto.

Para o cálculo da dissimilaridade entre distribuições *Wishart* complexas escalonadas foram utilizadas as distâncias de *Bhattacharyya*, *Hellinger*, *Kullback-Leibler* e *Rényi* de ordem β . As equações para as distâncias citadas entre duas distribuições *Wishart* complexas escalonadas representadas por $\mathbf{X} \sim W(\boldsymbol{\Sigma}_1, L_1)$ e $\mathbf{Y} \sim W(\boldsymbol{\Sigma}_2, L_2)$ foram desenvolvidas por Nascimento (2010), em que $\boldsymbol{\Sigma}_1$ e $\boldsymbol{\Sigma}_2$ são matrizes de covariância complexa e L_1 e L_2 são os números equivalentes de *looks*. Para o caso em que $L_1 = L_2 = L$, estas fórmulas são dadas respectivamente por:

$$d_{WB}(\boldsymbol{\Sigma}_1, \boldsymbol{\Sigma}_2) = L \left[\frac{|2^{-1}(\boldsymbol{\Sigma}_1^{-1} + \boldsymbol{\Sigma}_2^{-1})^{-1}|}{\sqrt{|\boldsymbol{\Sigma}_1| |\boldsymbol{\Sigma}_2|}} \right]^L \quad (2.29)$$

$$d_{WH}(\boldsymbol{\Sigma}_1, \boldsymbol{\Sigma}_2) = 1 - \left[\frac{|2^{-1}(\boldsymbol{\Sigma}_1^{-1} + \boldsymbol{\Sigma}_2^{-1})^{-1}|}{\sqrt{|\boldsymbol{\Sigma}_1||\boldsymbol{\Sigma}_2|}} \right]^L \quad (2.30)$$

$$d_{WKL}(\boldsymbol{\Sigma}_1, \boldsymbol{\Sigma}_2) = L \left[\frac{\text{Tr}(\boldsymbol{\Sigma}_1^{-1}\boldsymbol{\Sigma}_2 + \boldsymbol{\Sigma}_2^{-1}\boldsymbol{\Sigma}_1)}{2} - q \right] \quad (2.31)$$

$$d_{WR}^\beta(\boldsymbol{\Sigma}_1, \boldsymbol{\Sigma}_2) = \frac{\log(2)}{1-\beta} + \frac{1}{\beta-1} \log \left\{ [|\boldsymbol{\Sigma}_1|^{-\beta} |\boldsymbol{\Sigma}_2|^{\beta-1} |(\beta\boldsymbol{\Sigma}_1^{-1} + (1-\beta)\boldsymbol{\Sigma}_2^{-1})^{-1}|]^L \right. \\ \left. + [|\boldsymbol{\Sigma}_1|^{\beta-1} |\boldsymbol{\Sigma}_2|^{-\beta} |(\beta\boldsymbol{\Sigma}_1^{-1} + (1-\beta)\boldsymbol{\Sigma}_2^{-1})^{-1}|]^L \right\} \quad (2.32)$$

Note que o número equivalente de *looks* que define as distribuições de \mathbf{X} e \mathbf{Y} é o mesmo, pois em uma classificação supervisionada por regiões serão comparadas amostras de classes, extraídas da imagem, com segmentos desta mesma imagem. As expressões até aqui citadas para o cálculo das distâncias entre distribuições Gaussianas multivariadas e distribuições *Wishart* complexas escalonadas foram obtidas por meio de soluções analíticas. Para o cálculo de dissimilaridade entre distribuições do Par de intensidades (Equação 2.11), foi aplicada a distância de *Bhattacharyya*. Isto é, realizou-se o cômputo da expressão (2.22) quando tanto f_X quanto f_Y representam *f.d.p.*'s do Par de intensidades, as quais são funções bidimensionais. Neste caso, a distância foi obtida por meio de soluções numéricas. A seguir são definidas as estatísticas de teste obtidas em função destas distâncias.

Suponha que se deseja testar a hipótese de igualdade entre os parâmetros $\boldsymbol{\theta}_1$ e $\boldsymbol{\theta}_2$. Com base no desenvolvimento proposto por Salicrú *et al.* (1994), a estatística de teste é dada pela formulação descrita a seguir.

Definição de estatística de teste de hipótese): 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 verosimilhança de $\boldsymbol{\theta}_1$ e $\boldsymbol{\theta}_2$ com M parâmetros, baseados em amostras independentes de tamanhos m e n , respectivamente.

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_ϕ^h é dada por:

$$S_\phi^h(\widehat{\boldsymbol{\theta}}_1, \widehat{\boldsymbol{\theta}}_2) = \frac{2mn\nu}{m+n} d_\phi^h(\widehat{\boldsymbol{\theta}}_1, \widehat{\boldsymbol{\theta}}_2), \quad (2.33)$$

onde $\nu = \frac{1}{h'(0)\phi''(1)}$ é uma constante que depende das funções h e ϕ , específicas para a distância estocástica d_ϕ^h utilizada e h' , ϕ'' são as 1ª e 2ª derivadas de h e ϕ nesta ordem.

Obedecendo a algumas condições específicas de regularidade (SALICRÚ *et al.*, 1994), se m e $n \rightarrow \infty$ e $\boldsymbol{\theta}_1 = \boldsymbol{\theta}_2$ então

$$\frac{2mn\nu}{m+n} d_\phi^h(\widehat{\boldsymbol{\theta}}_1, \widehat{\boldsymbol{\theta}}_2) \xrightarrow{D} \chi_M^2, \quad (2.34)$$

em que \xrightarrow{D} denota convergência em distribuição e χ_M^2 é a distribuição *Chi-quadrado* com M graus de liberdade, onde M corresponde ao número de parâmetros em $\boldsymbol{\theta}_i, i \in \{1,2\}$. Portanto, para valores suficientemente grandes de m e n , a hipótese nula é rejeitada ao nível de significância η se $\Pr(\chi_M^2 > s) \leq \eta$ em que $s = S_\phi^h(\widehat{\boldsymbol{\theta}}_1, \widehat{\boldsymbol{\theta}}_2)$ (FRERY *et al.*, 2010).

As estatísticas de teste correspondentes às distâncias de *Bhattacharyya* e *Kullback-Leibler* entre distribuições Gaussianas multivariadas são apresentadas nas Equações (2.35) e (2.36), respectivamente. As Equações (2.37) a (2.40) representam as estatísticas de teste correspondentes às distâncias de *Bhattacharyya*, *Kullback-Leibler*, *Rényi* de ordem β e *Hellinger* entre distribuições *Wishart* complexa escalonada.

$$S_{GB} = \frac{mn}{m+n} \left[(\widehat{\boldsymbol{\mu}}_1 - \widehat{\boldsymbol{\mu}}_2)^T \left(\frac{\widehat{\boldsymbol{\Sigma}}_1 + \widehat{\boldsymbol{\Sigma}}_2}{2} \right)^{-1} (\widehat{\boldsymbol{\mu}}_1 - \widehat{\boldsymbol{\mu}}_2) + 4 \log \frac{|\frac{\widehat{\boldsymbol{\Sigma}}_1 + \widehat{\boldsymbol{\Sigma}}_2}{2}|}{\sqrt{|\widehat{\boldsymbol{\Sigma}}_1| |\widehat{\boldsymbol{\Sigma}}_2|}} \right] \quad (2.35)$$

$$S_{GKL} = \frac{mn}{m+n} [(\hat{\boldsymbol{\mu}}_1 - \hat{\boldsymbol{\mu}}_2)^T (\hat{\boldsymbol{\Sigma}}_1^{-1} + \hat{\boldsymbol{\Sigma}}_2^{-1}) (\hat{\boldsymbol{\mu}}_1 - \hat{\boldsymbol{\mu}}_2) + \text{Tr}(\hat{\boldsymbol{\Sigma}}_1^{-1} \hat{\boldsymbol{\Sigma}}_2 + \hat{\boldsymbol{\Sigma}}_2^{-1} \hat{\boldsymbol{\Sigma}}_1 - 2\mathbb{I}_q)] \quad (2.36)$$

$$S_{WB}(\hat{\boldsymbol{\Sigma}}_1, \hat{\boldsymbol{\Sigma}}_2) = \frac{8mn}{m+n} L \left[\frac{\log|\hat{\boldsymbol{\Sigma}}_1| + \log|\hat{\boldsymbol{\Sigma}}_2|}{2} - \log \left| \left(\frac{\hat{\boldsymbol{\Sigma}}_1^{-1} + \hat{\boldsymbol{\Sigma}}_2^{-1}}{2} \right)^{-1} \right| \right] \quad (2.37)$$

$$S_{WKL}(\hat{\boldsymbol{\Sigma}}_1, \hat{\boldsymbol{\Sigma}}_2) = \frac{2mn}{m+n} L \left[\frac{\text{Tr}(\hat{\boldsymbol{\Sigma}}_1^{-1} \hat{\boldsymbol{\Sigma}}_2 + \hat{\boldsymbol{\Sigma}}_2^{-1} \hat{\boldsymbol{\Sigma}}_1)}{2} - q \right] \quad (2.38)$$

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

$$S_{WH}(\hat{\boldsymbol{\Sigma}}_1, \hat{\boldsymbol{\Sigma}}_2) = \frac{8mn}{m+n} \left\{ 1 - \left[\frac{|2^{-1}(\hat{\boldsymbol{\Sigma}}_1^{-1} + \hat{\boldsymbol{\Sigma}}_2^{-1})^{-1}|^L}{\sqrt{|\hat{\boldsymbol{\Sigma}}_1| |\hat{\boldsymbol{\Sigma}}_2|}} \right] \right\} \quad (2.40)$$

2.4.2. Classificação supervisionada por regiões baseada em distâncias estocásticas e estatísticas de teste de hipóteses

A classificação de imagens é uma técnica de reconhecimento de padrões muito utilizada para o mapeamento da superfície terrestre. Neste caso, são extraídas informações em imagens em busca de padrões e regiões homogêneas de acordo com o objeto de interesse.

A classificação de imagens pode ser dividida em dois tipos: supervisionada e não supervisionada. No primeiro, é necessário um conhecimento prévio da área em estudo, conhecimento este que irá compor a referência. Sendo assim, todas as informações desconhecidas contidas na imagem serão comparadas a essa referência para posteriormente serem classificadas. No segundo tipo não é necessário conhecimento

inicial da área em estudo, uma vez que um algoritmo será utilizado para o reconhecimento de classes na imagem da região, sem um treinamento prévio.

Os classificadores presentes na literatura subdividem-se em "pixel a pixel", contextuais e por regiões. Nos classificadores "pixel a pixel", utilizam-se individualmente a informação espectral de cada pixel em busca de regiões homogêneas. Classificadores contextuais e por regiões, além da informação de cada pixel, utilizam a relação espacial de vizinhança entre os pixels para o reconhecimento de regiões homogêneas. Os classificadores contextuais utilizam a informação de uma vizinhança para classificar um pixel, enquanto os classificadores por região utilizam esta informação para classificar uma região inteira. Neste último caso, a qualidade da segmentação que fornecerá as regiões a serem classificadas é de extrema importância, assim como a coleta de amostras de treinamento (para treinar o classificador) e de teste (para testar o classificador).

Neste trabalho, a abordagem de classificação adotada é a classificação supervisionada por regiões de imagens. Na literatura, no contexto de classificação por modelagem estatística, uma técnica clássica é a classificação por intermédio da mínima distância estocástica entre a distribuição estatística que modela os pixels presentes nas regiões pré-segmentadas da imagem e a distribuição estatística que modela os pixels das amostras representantes das classes. Um exemplo deste tipo de classificador é o classificador por mínima distância de *Bhattacharyya* entre distribuições Gaussianas multivariadas presente no *software* SPRING (CAMARA *et al.*, 1996).

Ainda no mesmo contexto, uma metodologia de classificação supervisionada por regiões, baseada em medidas da Teoria da Informação foi proposta por Silva (2013) e Silva *et al.*(2013). Esta metodologia possui diversos diferenciais quando comparada a métodos tradicionais, tais como: a) a atribuição dos pixels presentes em determinada região da imagem é feita pela mínima estatística de teste e não pela mínima distância estocástica; b) um mapa de confiabilidade da classificação pode ser gerado através das estatísticas de teste ou valores-*p* associados a esta estatística de teste; c) para a modelagem de dados SAR, outras funções densidade de probabilidade podem ser empregadas além da Gaussiana multivariada como, por exemplo, a função *Wishart*

complexa escalonada, utilizada para modelar a matriz de covariância de dados de radar de abertura sintética polarimétricos e a distribuição Par de intensidades *multi-look* utilizada para modelar dados bivariados em intensidade. Desta forma, tal metodologia, além de aplicar-se tanto a dados ópticos quanto a dados de micro-ondas, permite a modelagem de dados de micro-ondas por intermédio de distribuições mais adequadas a este tipo de dado. A metodologia de classificação por regiões ocorre da maneira descrita a seguir.

Considere uma imagem particionada em r regiões (segmentos) disjuntas, representadas por R_i , onde $1 \leq i \leq r$. Para cada segmento existe um vetor de parâmetros θ_i estimado pelo método de Máxima Verossimilhança $\hat{\theta}_i$. Definidas k classes de interesse, para as quais foram retiradas amostras de treinamento, estima-se pelo mesmo método o vetor de parâmetros θ_ℓ em que $1 \leq \ell \leq k$. Logo, adotando-se a hipótese nula $H_0: \hat{\theta}_i = \hat{\theta}_\ell$, são calculadas $r \times k$ distâncias estocásticas, de acordo com a modelagem em questão, e conseqüentemente, $r \times k$ estatísticas de teste, denotadas por $S_\phi^h(\hat{\theta}_i, \hat{\theta}_\ell)$, $1 \leq i \leq r$ e $1 \leq \ell \leq k$, para verificação da hipótese nula para cada região e cada classe. A classificação é obtida por meio da menor estatística de teste, onde se atribui ao segmento R_i à j -ésima classe se $S_\phi^h(\hat{\theta}_i, \hat{\theta}_j) < S_\phi^h(\hat{\theta}_i, \hat{\theta}_\ell), \forall j \neq \ell$. Se ao segmento R_i for rotulada a classe j , o valor- p do teste de hipótese é obtido por intermédio do cálculo da probabilidade $p_{i,j} = \mathbf{Pr}(\chi_M^2 > S_\phi^h(\hat{\theta}_i, \hat{\theta}_j))$.

Para dados que possuem distribuição Gaussiana q -variada tem-se que $M = q(q + 3)/2$, para dados que possuem distribuição de *Wishart* representadas por uma matriz de covariância $q \times q$ tem-se $M = q^2$, e para dados com a distribuição Par de intensidades *multi-look* $M = 3$. Note que os graus de liberdade da distribuição *Chi-quadrado* são dados pelo número de parâmetros a ser estimado em cada uma das distribuições. Além da imagem classificada, um mapa de confiabilidade da classificação é obtido, atribuindo-se, para cada segmento i ($1 \leq i \leq r$) o valor $p_{i,j}$ correspondente (FRERY *et al.*, 2011).

Neste trabalho, para a classificação de cada uma das w imagens em estudo, utiliza-se o método de classificação por regiões descrito acima e aqui denominado “Classificação

monofonte". Além da obtenção da classificação, no processo são adquiridos os atributos necessários para construção de dois mapas de confiabilidade de classificação. Na Figura 2.1, apresenta-se um esquema do processo de classificação monofonte (para uma imagem) em que se utilizam os valores- p e as mínimas estatísticas de teste normalizadas (s_n^{ij}) ($1 \leq i \leq r$; $1 \leq j \leq w$) para composição dos mapas de confiabilidade onde $s_n^{ij} = \text{normalize}(\min(s_{i\ell}^j))$ e $0 \leq s_n^{ij} \leq 1$.

Note que no processo de classificação da imagem j ($1 \leq j \leq w$), é gerado o seguinte vetor de atributos ($V_{i\ell}^j$) para a região i ($1 \leq i \leq r$) e classe ℓ ($1 \leq \ell \leq k$):

$$V_{i\ell}^j = (d_{i\ell}^j, s_{i\ell}^j, p_{i\ell}^j) \quad (2.41)$$

onde $p_{i\ell}^j = \mathbf{Pr}(\chi_{M_j}^2 > s_{i\ell}^j)$, $s_{i\ell}^j = \frac{2m_i n_\ell v}{m_i + n_\ell} d_{i\ell}^j$, em que m_i e n_ℓ representam o número de amostras independentes da região i e da classe ℓ e $d_{i\ell}^j$ representam as distâncias entre distribuições relativa ao segmento i e a classe ℓ . Esse vetor é composto pelos insumos necessários para obtenção da classificação monofonte.

A classificação monofonte, correspondente à classificação de cada uma das w imagens, é construída com a obtenção do vetor de classificação. Dada uma imagem j , para cada região i e para cada classe ℓ é definido o seguinte vetor de classificação:

$$C_i^j = (\ell_i^{*j}, s_i^j, p_i^j) \quad (2.42)$$

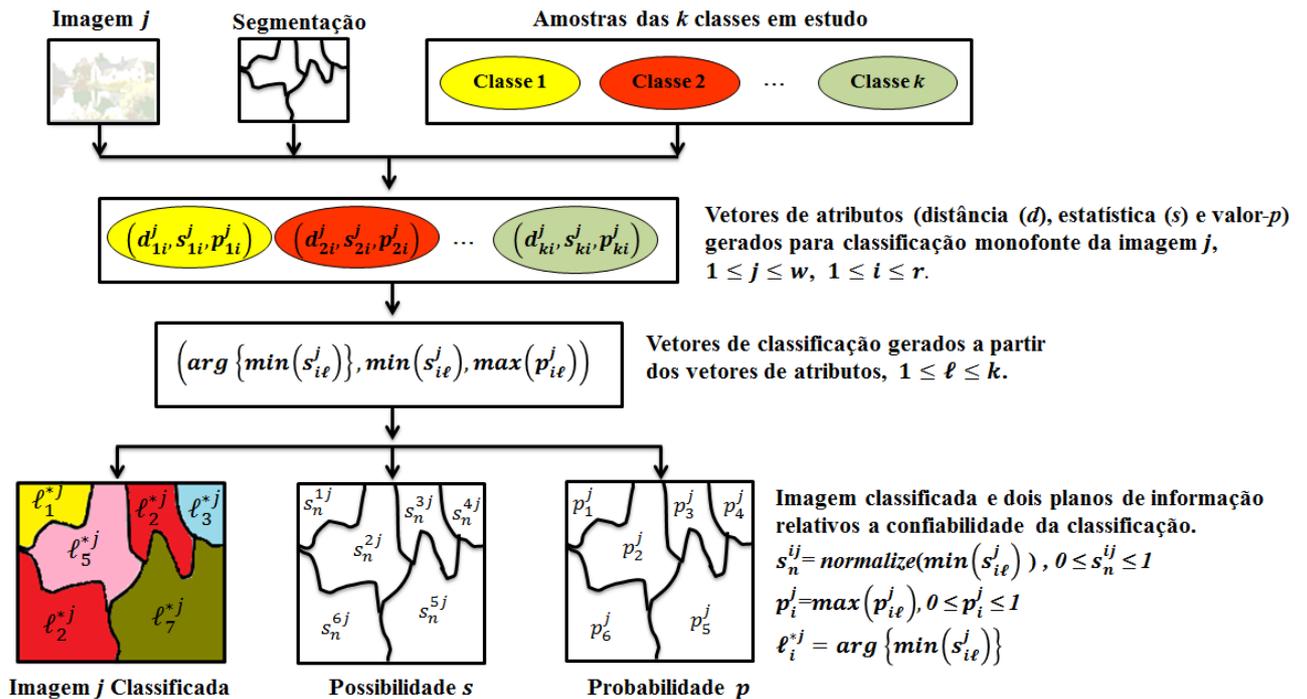
em que $\ell_i^{*j} = \arg_{\ell} \{\min_{\ell} \{s_{i\ell}^j\}\}$, $s_i^j = \min_{\ell} \{s_{i\ell}^j\}$ e $p_i^j = \max_{\ell} \{p_{i\ell}^j\}$,

ou seja, ℓ_i^{*j} é a classe que possui a menor estatística de teste normalizada para o segmento i e imagem j ($1 \leq i \leq r$; $1 \leq j \leq w$). A espacialização dos ℓ_i^{*j} fornece o mapa de classificação j . A confiabilidade da classificação é fornecida pelos mapas constituídos pelos respectivos valores de s_n^{ij} , p_i^j .

O mapa de confiabilidade pode ser composto tanto pela mínima estatística de teste de hipótese normalizada quanto pelo máximo valor- p correspondente à mínima estatística

uma vez que essas são grandezas inversamente relacionadas. É importante enfatizar que um mapa de confiabilidade formado pela normalização das mínimas estatísticas de teste, refere-se a um mapa de possibilidades enquanto que, um mapa composto por valores- p máximos trata-se de um mapa de probabilidades.

Figura 2.1 – Ilustração do processo de classificação monofonte.



Fonte: Produção do autor.

Neste capítulo, expuseram-se os conceitos básicos necessários para compreensão deste trabalho, relatou-se a abordagem adotada para a modelagem dos dados e descreveram-se as três distribuições utilizadas para o tratamento destes dados. A distribuição Gaussiana multivariada será usada para dados ópticos e as distribuições Par de intensidades *multi-look* e *Wishart* complexa escalonada serão utilizadas para modelar os dados SAR. Foram também expostas as definições de distâncias estocásticas e estatísticas de teste de hipóteses. Apresentaram-se as expressões para cálculo das distâncias de *Bhattacharyya*, e *Kullback-Leibler* entre distribuições Gaussianas multivariadas e das distâncias de *Bhattacharyya*, *Hellinger*, *Kullback-Leibler* e *Rényi* de ordem β para distribuições *Wishart* complexas escalonadas, assim como as expressões para as respectivas estatísticas de teste de hipóteses. Por fim, descreveu-se a técnica de classificação por regiões baseada

em distâncias estocásticas. Esta técnica é denominada de “Classificação Monofonte” neste trabalho, uma vez que, em geral, uma única *f.d.p.* é utilizada durante o processo de classificação, *f.d.p.* esta representativa dos dados do sensor em questão. Nesta técnica de classificação monofonte, um pré-requisito fundamental para o procedimento de classificação é o conhecimento prévio das distribuições que modelam o conjunto de dados envolvidos. Uma vez conhecidas as funções densidade de probabilidade que modelam os dados, dá-se prosseguimento com os cálculos das distâncias estocásticas entre as distribuições.

O presente trabalho avança na metodologia de classificação por regiões através de distâncias estocásticas, uma vez que permite que sejam utilizados dados de vários sensores, com *f.d.p.*'s distintas. A condição para a aplicação de tal metodologia é que os dados de diferentes sensores sejam independentes, suposição esta válida em grande parte dos casos, principalmente quando se consideram sensores atuando em diferentes faixas do espectro eletromagnético.

A metodologia de classificação multifonte aqui proposta é inédita na literatura, uma vez que se propõe o cálculo de distâncias (e respectivas estatísticas de teste) entre funções densidades de probabilidade (*f.d.p.*) multivariadas, em função das distâncias entre as *f.d.p.*'s marginais. Nota-se que embora não se conheçam as distribuições conjuntas resultantes do produto de w distribuições marginais conhecidas, somente o conhecimento destas últimas é suficiente para o cômputo das distâncias e estatísticas de teste. Tais resultados são apresentados no capítulo a seguir.

3 DESENVOLVIMENTO TEÓRICO DE DISTÂNCIAS ESTOCÁSTICAS E ESTATÍSTICAS DE TESTES ENTRE *F.D. P*'S CONJUNTAS DE DADOS MULTIFONTE

Considere w imagens georreferenciadas de uma mesma localidade, provenientes de w sensores distintos e independentes, cada uma, representada por $\mathbf{Z}_j, 1 \leq j \leq w$. Suponha também a existência de uma única segmentação em r regiões disjuntas, válida para as w imagens em questão. Sejam ainda, k classes de interesse num processo de classificação e $f_{ij}(\mathbf{Z}_j; \boldsymbol{\theta}_{ij})$ e $g_{\ell j}(\mathbf{Z}_j; \boldsymbol{\theta}_{\ell j})$ as funções densidade de probabilidade que modelam, respectivamente os pixels da região i ($1 \leq i \leq r$) e os pixels da amostra ℓ ($1 \leq \ell \leq k$) ambos da imagem \mathbf{Z}_j . Admitindo-se, agora, que as funções $f_{ij}(\mathbf{Z}_j; \boldsymbol{\theta}_{ij})$ e $g_{\ell j}(\mathbf{Z}_j; \boldsymbol{\theta}_{\ell j})$ sejam conhecidas (aqui denominadas de distribuições marginais) é, teoricamente, possível gerar classificações que levem em conta as informações presentes nas w imagens. Este tipo de classificação é denominado por “Classificação Multifonte”.

Observe também que é perfeitamente viável que se realize uma classificação multifonte baseada em distância estocástica e seguindo a mesma metodologia da classificação monofonte. Para isto, basta que se conheça a distância estocástica derivada da distribuição que modela conjuntamente (aqui denominada distribuição conjunta) os pixels de todas as imagens das diversas fontes envolvidas no processo de classificação. No entanto, esta distribuição, geralmente, não é analiticamente conhecida, dificultando assim o processo de classificação. Contudo, a derivação analítica e de forma inédita de algumas distâncias estocásticas e suas estatísticas de teste a partir apenas de distribuições marginais é foco principal deste capítulo.

Na técnica de classificação monofonte, supõe-se que para cada $\mathbf{Z}_j, 1 \leq j \leq w$, $f_{ij}(\mathbf{Z}_j; \boldsymbol{\theta}_{ij})$ e $g_{\ell j}(\mathbf{Z}_j; \boldsymbol{\theta}_{\ell j}), 1 \leq i \leq r, 1 \leq \ell \leq k$ são provenientes de uma mesma família de distribuições, e conhecida, exceto pelos seus vetores de parâmetros $\boldsymbol{\theta}_{ij}$ e $\boldsymbol{\theta}_{\ell j}$. O objetivo da classificação multifonte é a integração das w imagens. Supondo que essas funções marginais são independentes, mas não necessariamente provenientes da mesma

família de distribuições. O processo de classificação multifonte é análogo ao da classificação monofonte, sendo a única diferença o fato da classificação monofonte utilizar as *f.d.p.*'s marginais, enquanto que a classificação multifonte utiliza as *f.d.p.*'s conjuntas. Estas *f.d.p.*'s conjuntas são obtidas através do produto das distribuições marginais, como descrito no lema a seguir, resultado direto da aplicação do Teorema 2.1.2 e por este motivo sua demonstração foi suprimida.

Lema: Sejam w imagens de uma mesma localidade, georreferenciadas, provindas de w sensores distintos, representadas, cada uma por $\mathbf{Z}_j, 1 \leq j \leq w$. Suponha a existência de uma segmentação contendo r segmentos disjuntos, e amostras de treinamento de k classes de interesse. Se os dados provenientes dos diferentes sensores (fontes) forem considerados independentes, então a distribuição conjunta que modela as regiões da imagem segmentada ($f_{i\{w\}}(\mathbf{Z}_j; \boldsymbol{\theta}_{i\{w\}})$) e a distribuição conjunta que modela as amostras de treinamento ($g_{\ell\{w\}}(\mathbf{Z}_j; \boldsymbol{\theta}_{\ell\{w\}})$) serão representadas respectivamente por:

$$f_{i\{w\}}(\mathbf{Z}_j; \boldsymbol{\theta}_{i\{w\}}) = \prod_{j=1}^w f_{ij}(\mathbf{Z}_j; \boldsymbol{\theta}_{ij}), 1 \leq i \leq r \quad (3.1)$$

$$g_{\ell\{w\}}(\mathbf{Z}_j; \boldsymbol{\theta}_{\ell\{w\}}) = \prod_{j=1}^w g_{\ell j}(\mathbf{Z}_j; \boldsymbol{\theta}_{\ell j}), 1 \leq \ell \leq k$$

onde $\boldsymbol{\theta}_{ij}$ representa o vetor de parâmetros da região i e $\boldsymbol{\theta}_{\ell j}$ representa o vetor de parâmetros da classe ℓ ambos para a imagem $\mathbf{Z}_j, 1 \leq j \leq w$. As variáveis aleatórias relativas às densidades marginais $f_{ij}(\mathbf{Z}_j; \boldsymbol{\theta}_{ij})$ e $g_{\ell j}(\mathbf{Z}_j; \boldsymbol{\theta}_{\ell j})$ são matrizes aleatórias definidas sobre um mesmo suporte $\Omega_j, 1 \leq j \leq w$ e as variáveis aleatórias relativas às densidades conjuntas $f_{i\{w\}}(\mathbf{Z}_j; \boldsymbol{\theta}_{i\{w\}})$ e $g_{\ell\{w\}}(\mathbf{Z}_j; \boldsymbol{\theta}_{\ell\{w\}})$ são matrizes aleatórias definidas sobre um mesmo suporte $\Omega = \Omega_1 \times \Omega_2 \times \dots \times \Omega_w$, em que o operador \times representa o produto cartesiano entre os conjuntos $\Omega_j, 1 \leq j \leq w$. A estatística de teste $S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}})$ entre $f_{i\{w\}}(\mathbf{Z}_j; \boldsymbol{\theta}_{i\{w\}})$ e $g_{\ell\{w\}}(\mathbf{Z}_j; \boldsymbol{\theta}_{\ell\{w\}})$ de acordo com a Equação (2.33) é definida como:

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} d_{\phi}^h(f_{i\{w\}}(\mathbf{Z}_j; \boldsymbol{\theta}_{i\{w\}}), g_{\ell\{w\}}(\mathbf{Z}_j; \boldsymbol{\theta}_{\ell\{w\}})) \quad (3.2)$$

onde $d_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}})$ representa a distância estocástica entre as distribuições $f_{i\{w\}}(\mathbf{Z}_j; \boldsymbol{\theta}_{i\{w\}})$ e $g_{\ell\{w\}}(\mathbf{Z}_j; \boldsymbol{\theta}_{\ell\{w\}})$, m_i é o tamanho da amostra representativa da região i e n_{ℓ} é o tamanho da amostra correspondente a classe ℓ .

Para maior clareza optou-se, neste trabalho, pela notação das estatísticas de teste por $S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}})$ ao invés da notação pelos parâmetros $S_{\phi}^h(\boldsymbol{\theta}_{i\{w\}}, \boldsymbol{\theta}_{\ell\{w\}})$. Também, em algumas situações, omitiram-se os parâmetros das distribuições marginais e conjuntas, nestes casos, as representações $f_{ij}(\mathbf{Z}_j; \boldsymbol{\theta}_{ij})$, $g_{\ell j}(\mathbf{Z}_j; \boldsymbol{\theta}_{\ell j})$, $f_{i\{w\}}(\mathbf{Z}_j; \boldsymbol{\theta}_{i\{w\}})$ e $g_{\ell\{w\}}(\mathbf{Z}_j; \boldsymbol{\theta}_{\ell\{w\}})$ passam a ser f_{ij} , $g_{\ell j}$, $f_{i\{w\}}$ e $g_{\ell\{w\}}$.

O Lema mostra que as *f. d. p.*'s conjuntas que modelam as amostras dos dados oriundos de w fontes independentes equivalem ao produto das *f. d. p.*'s marginais que modelam as amostras dos dados provenientes de cada um dos w sensores. Com esse resultado torna-se possível o cálculo das distâncias estocásticas e estatísticas de teste entre as *f. d. p.*'s conjuntas mesmo não tendo conhecimento de suas distribuições. Basta para isso o conhecimento das distribuições marginais que modelam as imagens individualmente.

Estabelecidas as distribuições marginais que modelam os dados individualmente e fixadas as distâncias estocásticas desejadas, conhecidas na literatura, torna-se admissível a obtenção de uma expressão que permita o cálculo das distâncias entre as *f. d. p.*'s conjuntas por intermédio das distâncias entre as *f. d. p.*'s marginais.

Expressões analíticas e fechadas para as distâncias de *Bhattacharyya*, *Kullback-Leibler*, *Rényi* de ordem β e *Hellinger* e para suas respectivas estatísticas de teste são exibidas nos resultados seguintes.

Resultado I: Sob as mesmas condições apresentadas no Lema 1, se $d_B(f_{i\{w\}}, g_{\ell\{w\}})$ representa a distância de *Bhattacharyya* entre as distribuições $f_{i\{w\}}$ e $g_{\ell\{w\}}$ então, a estatística de teste será definida como:

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \sum_{j=1}^w S_{\phi}^h(f_{ij}, g_{\ell j}) = \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \sum_{j=1}^w d_B(f_{ij}, g_{\ell j}) \xrightarrow{D} \chi_M^2 \quad (3.3)$$

em que χ_M^2 denota a distribuição *Chi-quadrado* com $M = \sum_{j=1}^w M_j$ graus de liberdade onde M_j representa o grau de liberdade da distribuição *Chi-quadrado* relativa à imagem j , m_i é o tamanho da amostra representativa da região i e n_{ℓ} é o tamanho da amostra correspondente a classe ℓ .

Demonstração I: Uma vez que as funções de distribuições conjuntas $f_{i\{w\}}$ e $g_{\ell\{w\}}$ são separáveis, como demonstrado no Lema 1, torna-se possível representá-las por meio do produto de suas distribuições marginais. Sendo assim, substituindo (3.1) em (2.22) vem que:

$$d_B(f_{i\{w\}}, g_{\ell\{w\}}) = -\log \int \sqrt{\prod_{j=1}^w f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}) \cdot \prod_{j=1}^w g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j})} d_{\mathbf{z}_j}$$

$$d_B(f_{i\{w\}}, g_{\ell\{w\}}) = -\log \prod_{j=1}^w \int \sqrt{f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}) \cdot g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j})} d_{\mathbf{z}_j}.$$

Pela propriedade logarítmica do produto segue que

$$d_B(f_{i\{w\}}, g_{\ell\{w\}}) = - \left[\sum_{j=1}^w \log \left(\int \sqrt{f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}) \cdot g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j})} d_{\mathbf{z}_j} \right) \right]$$

$$d_B(f_{i\{w\}}, g_{\ell\{w\}}) = \sum_{j=1}^w -\log \left(\int \sqrt{f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}) \cdot g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j})} d_{\mathbf{z}_j} \right)$$

$$d_B(f_{i\{w\}}, g_{\ell\{w\}}) = \sum_{j=1}^w d_B(f_{ij}, g_{\ell j}) \quad (3.4)$$

Isto é, a distância estocástica de *Bhattacharyya* calculada para a distribuição conjunta é a soma das distâncias estocásticas de *Bhattacharyya* obtida a partir de cada uma das w distribuições marginais. Agora, substituindo (3.4) em (2.33) chega-se a estatística de teste que da mesma forma que a distância é a soma das estatísticas de teste proveniente das distribuições marginais.

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \sum_{j=1}^w d_B(f_{ij}, g_{\ell j})$$

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \sum_{j=1}^w S_{\phi}^h(f_{ij}, g_{\ell j}) \quad (3.5)$$

onde m_i e n_{ℓ} representam o número de amostras independentes da região i e da classe ℓ . Como apresentado na Equação (2.34), a estatística de teste, sob determinadas condições de regularidade, converge para uma distribuição *Chi-quadrado* com M graus de liberdade. Desta forma, como

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \left[\frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot d_B(f_{i1}, g_{\ell 1}) + \dots + \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot d_B(f_{iw}, g_{\ell w}) \right]$$

$$\text{onde, } \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot d_B(f_{i1}, g_{\ell 1}) \xrightarrow{D} \chi_{M_1}^2, \dots, \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot d_B(f_{iw}, g_{\ell w}) \xrightarrow{D} \chi_{M_w}^2$$

Aplicando-se a propriedade de aditividade dos graus de liberdade (Teorema 2.1.3) da distribuição χ^2 tem-se que

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \left[\frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot d_B(f_{i1}, g_{\ell 1}) + \dots + \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot d_B(f_{iw}, g_{\ell w}) \right] \xrightarrow{D} \chi_{M_1 + \dots + M_w}^2$$

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \left[\sum_{j=1}^w d_B(f_{ij}, g_{\ell j}) \right] \xrightarrow{D} \chi_M^2$$

Portanto, no caso em questão, a estatística de teste segue uma distribuição *Chi-quadrado* com M graus de liberdade onde $M = \sum_{j=1}^w M_j$.

c.q.d.

Resultado II: Sob as mesmas condições apresentadas no Lema 1, se $d_{KL}(f_{i\{w\}}, g_{\ell\{w\}})$ representa a distância de *Kullback-Leibler* entre as distribuições $f_{i\{w\}}$ e $g_{\ell\{w\}}$ então, a estatística de teste será definida como:

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \sum_{j=1}^w S_{\phi}^h(f_{ij}, g_{\ell j}) = \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \sum_{j=1}^w d_{KL}(f_{ij}, g_{\ell j}) \xrightarrow{D} \chi_M^2 \quad (3.6)$$

em que χ_M^2 denota a distribuição *Chi-quadrado* com $M = \sum_{j=1}^w M_j$ graus de liberdade onde M_j representa o grau de liberdade da distribuição *Chi-quadrado* relativa à imagem j , m_i é o tamanho da amostra representativa da região i e n_ℓ é o tamanho da amostra correspondente a classe ℓ .

Demonstração II: Uma vez que a distância de *Kullback-Leibler* é a simetrização de suas divergências, para simplificação dos cálculos trabalharemos com as divergências e posteriormente obteremos a distância desejada por meio do processo de simetrização. Se $f_{i\{w\}}$ e $g_{\ell\{w\}}$ tratam-se de funções de distribuições conjuntas, substituindo (3.1) na divergência presente na Equação (2.24) vem que:

$$D_{KL}(f_{i\{w\}}, g_{\ell\{w\}}) = \int \prod_{j=1}^w f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}) \log \frac{\prod_{j=1}^w f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij})}{\prod_{j=1}^w g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j})} d\mathbf{z}_j$$

Aplicando-se as propriedades logarítmicas do produto e quociente obtém-se

$$\begin{aligned} D_{KL}(f_{i\{w\}}, g_{\ell\{w\}}) &= \\ &= \int \prod_{j=1}^w f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}) \left[\sum_{j=1}^w \log f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}) - \sum_{j=1}^w \log g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j}) \right] d\mathbf{z}_j \\ D_{KL}(f_{i\{w\}}, g_{\ell\{w\}}) &= \\ &= \int \prod_{j=1}^w f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}) \left\{ \sum_{j=1}^w [\log f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}) - \log g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j})] \right\} d\mathbf{z}_j \\ D_{KL}(f_{i\{w\}}, g_{\ell\{w\}}) &= \int \prod_{j=1}^w f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}) \left[\sum_{j=1}^w \log \frac{f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij})}{g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j})} \right] d\mathbf{z}_j \\ D_{KL}(f_{i\{w\}}, g_{\ell\{w\}}) &= \int f_{i1} \log \frac{f_{i1}(\mathbf{z}_1; \boldsymbol{\theta}_{i1})}{g_{\ell 1}(\mathbf{z}_1; \boldsymbol{\theta}_{\ell 1})} d\mathbf{z}_1 \cdot \int \prod_{j=2}^w f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}) d\mathbf{z}_j + \dots + \\ &+ \int f_{iw} \log \frac{f_{iw}(\mathbf{z}_w; \boldsymbol{\theta}_{iw})}{g_{\ell w}(\mathbf{z}_w; \boldsymbol{\theta}_{\ell w})} d\mathbf{z}_w \cdot \int \prod_{j=1}^{w-1} f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}) d\mathbf{z}_j \end{aligned}$$

$$\begin{aligned}
D_{KL}(f_{i\{w\}}, g_{\ell\{w\}}) &= \\
&= D_{KL}(f_{i1}, g_{\ell1}) \cdot \prod_{j=2}^w \int f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}) d\mathbf{z}_j + \cdots + D_{KL}(f_{iw}, g_{\ell w}) \\
&\quad \cdot \prod_{j=1}^{w-1} \int f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}) d\mathbf{z}_j
\end{aligned}$$

Pela definição de função de densidade de probabilidade (f) temos que a área total sob o gráfico de f é igual a 1, ou seja, a integral de uma distribuição contínua sobre todo seu domínio é igual a 1. Assim tem-se

$$D_{KL}(f_{i\{w\}}, g_{\ell\{w\}}) = D_{KL}(f_{i1}, g_{\ell1}) + \cdots + D_{KL}(f_{iw}, g_{\ell w})$$

Simetrizando, a distância é dada por:

$$\begin{aligned}
d_{KL}(f_{i\{w\}}, g_{\ell\{w\}}) &= \\
&= \frac{1}{2} [D_{KL}(f_{i1}, g_{\ell1}) + \cdots + D_{KL}(f_{iw}, g_{\ell w}) + D_{KL}(g_{\ell1}, f_{i1}) + \cdots + D_{KL}(g_{\ell w}, f_{iw})]
\end{aligned}$$

$$d_{KL}(f_{i\{w\}}, g_{\ell\{w\}}) = \frac{1}{2} \sum_{j=1}^w [D_{KL}(f_{ij}, g_{\ell j}) + D_{KL}(g_{\ell j}, f_{ij})]$$

Substituindo em (2.33) obtemos a estatística de teste.

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \sum_{j=1}^w \frac{1}{2} [D_{KL}(f_{ij}, g_{\ell j}) + D_{KL}(g_{\ell j}, f_{ij})]$$

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot \frac{1}{2} [D_{KL}(f_{i1}, g_{\ell1}) + D_{KL}(g_{\ell1}, f_{i1})] + \cdots$$

$$+ \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot \frac{1}{2} [D_{KL}(f_{iw}, g_{\ell w}) + D_{KL}(g_{\ell w}, f_{iw})]$$

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} d_{KL}(f_{i1}, g_{\ell1}) + \cdots + \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} d_{KL}(f_{iw}, g_{\ell w})$$

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = S_{\phi}^h(f_{i1}, g_{\ell1}) + \dots + S_{\phi}^h(f_{iw}, g_{\ell w})$$

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \sum_{j=1}^w S_{\phi}^h(f_{ij}, g_{\ell j}).$$

Como apresentado na Equação (2.34), a estatística de teste, sob determinadas condições de regularidade, converge para uma distribuição *Chi-quadrado* com M graus de liberdade. Desta forma,

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \left[\frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot d_{KL}(f_{i1}, g_{\ell1}) + \dots + \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot d_{KL}(f_{iw}, g_{\ell w}) \right]$$

$$\text{onde, } \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot d_{KL}(f_{i1}, g_{\ell1}) \xrightarrow{D} \chi_{M_1}^2, \dots, \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot d_{KL}(f_{iw}, g_{\ell w}) \xrightarrow{D} \chi_{M_w}^2.$$

Aplicando-se o Teorema 2.1.3 tem-se que

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \left[\frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot d_{KL}(f_{i1}, g_{\ell1}) + \dots + \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot d_{KL}(f_{iw}, g_{\ell w}) \right] \xrightarrow{D}$$

$$\xrightarrow{D} \chi_{M_1 + \dots + M_w}^2$$

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \left[\sum_{j=1}^w d_{KL}(f_{ij}, g_{\ell j}) \right] \xrightarrow{D} \chi_M^2$$

Portanto, no caso em questão, a estatística de teste segue uma distribuição *Chi-quadrado* com M graus de liberdade onde $M = \sum_{j=1}^w M_j$.

c.q.d.

Resultado III: Sob as mesmas condições apresentadas no Lema 1, se $d_R^{\beta}(f_{i\{w\}}, g_{\ell\{w\}})$ representa a distância de Rényi de ordem β entre as distribuições $f_{i\{w\}}$ e $g_{\ell\{w\}}$ então, a estatística de teste será definida como:

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \sum_{j=1}^w S_{\phi}^h(f_{ij}, g_{\ell j}) = \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \sum_{j=1}^w d_R^{\beta}(f_{ij}, g_{\ell j}) \xrightarrow{D} \chi_M^2 \quad (3.7)$$

em que χ_M^2 denota a distribuição *Chi-quadrado* com $M = \sum_{j=1}^w M_j$ graus de liberdade onde M_j representa o grau de liberdade da distribuição *Chi-quadrado* relativa à imagem j , m_i é o tamanho da amostra representativa da região i e n_ℓ é o tamanho da amostra correspondente a classe ℓ .

Demonstração III: A demonstração será feita utilizando-se $\tilde{d}_R^\beta(\mathbf{X}, \mathbf{Y})$, Equação (2.25), e posteriormente, aplicando-se a desigualdade de Fejér (NEUMAN, 1990) chegando a $d_R^\beta(\mathbf{X}, \mathbf{Y})$ - Equação (2.26).

Substituindo-se (3.1) em (2.25) obtém-se

$$\begin{aligned} \tilde{d}_R^\beta(f_{i\{w\}}, g_{\ell\{w\}}) &= \frac{\log \int (\prod_{j=1}^w \int f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}))^\beta (\prod_{j=1}^w \int g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j}))^{1-\beta} d_{z_1} d_{z_2} \cdots d_{z_w}}{2(\beta - 1)} + \\ &+ \frac{\log \int (\prod_{j=1}^w \int f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}))^{1-\beta} (\prod_{j=1}^w \int g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j}))^\beta d_{z_1} d_{z_2} \cdots d_{z_w}}{2(\beta - 1)} \end{aligned}$$

pela propriedade do logaritmo do produto

$$\begin{aligned} \tilde{d}_R^\beta(f_{i\{w\}}, g_{\ell\{w\}}) &= \\ &= \frac{1}{2(\beta - 1)} \left\{ \log \left[\int \left(\prod_{j=1}^w f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}) \right)^\beta \left(\prod_{j=1}^w g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j}) \right)^{1-\beta} d_{z_1} \cdots d_{z_w} \right. \right. \\ &\quad \left. \left. \cdot \int \left(\prod_{j=1}^w f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}) \right)^{1-\beta} \left(\prod_{j=1}^w g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j}) \right)^\beta d_{z_1} \cdots d_{z_w} \right] \right\} \end{aligned}$$

$$\begin{aligned} \tilde{d}_R^\beta(f_{i\{w\}}, g_{\ell\{w\}}) &= \\ &= \frac{1}{2(\beta - 1)} \left\{ \log \left[\prod_{j=1}^w \int (f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}))^\beta \cdot (g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j}))^{1-\beta} d_{z_1} \cdots d_{z_w} \right. \right. \\ &\quad \left. \left. \cdot \prod_{j=1}^w \int (f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}))^{1-\beta} \cdot (g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j}))^\beta d_{z_1} \cdots d_{z_w} \cdot \right] \right\} \end{aligned}$$

$$\begin{aligned} \tilde{d}_R^\beta(f_{i\{w\}}, g_{\ell\{w\}}) &= \\ &= \frac{1}{2(\beta - 1)} \left\{ \log \left[\prod_{j=1}^w \int (f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}))^\beta \cdot (g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j}))^{1-\beta} \cdot \int (f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}))^{1-\beta} \right. \right. \\ &\quad \left. \left. \cdot (g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j}))^\beta d_{\mathbf{z}_1} \cdots d_{\mathbf{z}_w} \right] \right\} \end{aligned}$$

aplicando-se a propriedade do logaritmo do produto novamente

$$\begin{aligned} \tilde{d}_R^\beta(f_{i\{w\}}, g_{\ell\{w\}}) &= \\ &= \frac{1}{2(\beta - 1)} \left\{ \sum_{j=1}^w \log \left[\int (f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}))^\beta \cdot (g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j}))^{1-\beta} \cdot \int (f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}))^{1-\beta} \right. \right. \\ &\quad \left. \left. \cdot (g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j}))^\beta d_{\mathbf{z}_1} \cdots d_{\mathbf{z}_w} \right] \right\} \end{aligned}$$

$$\begin{aligned} \tilde{d}_R^\beta(f_{i\{w\}}, g_{\ell\{w\}}) &= \\ &= \frac{1}{2(\beta - 1)} \left\{ \sum_{j=1}^w \left[\log \int (f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}))^\beta \cdot (g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j}))^{1-\beta} d_{\mathbf{z}_1} \cdots d_{\mathbf{z}_w} \right. \right. \\ &\quad \left. \left. + \log \int (f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}))^{1-\beta} \cdot (g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j}))^\beta d_{\mathbf{z}_1} \cdots d_{\mathbf{z}_w} \right] \right\} \end{aligned}$$

$$\therefore \tilde{d}_R^\beta(f_{i\{w\}}, g_{\ell\{w\}}) = \sum_{j=1}^w \tilde{d}_R^\beta(f_{ij}, g_{\ell j})$$

aplicando-se a desigualdade de Fejér

$$\therefore d_R^\beta(f_{i\{w\}}, g_{\ell\{w\}}) = \sum_{j=1}^w d_R^\beta(f_{ij}, g_{\ell j})$$

Substituindo em (2.33) obtêm-se a estatística de teste:

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \left[\sum_{j=1}^w d_R^{\beta}(f_{ij}, g_{\ell j}) \right]$$

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \left[d_R^{\beta}(f_{i1}, g_{\ell 1}) \right] + \dots + \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \left[d_R^{\beta}(f_{iw}, g_{\ell w}) \right]$$

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} d_R^{\beta}(f_{i1}, g_{\ell 1}) + \dots + \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} d_R^{\beta}(f_{iw}, g_{\ell w})$$

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = S_{\phi}^h(f_{i1}, g_{\ell 1}) + \dots + S_{\phi}^h(f_{iw}, g_{\ell w})$$

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \sum_{j=1}^w S_{\phi}^h(f_{ij}, g_{\ell j}).$$

Como apresentado na Equação (2.34), a estatística de teste, sob determinadas condições de regularidade, converge para uma distribuição *Chi-quadrado* com M graus de liberdade. Como

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \left[\frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot d_R^{\beta}(f_{i1}, g_{\ell 1}) + \dots + \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot d_R^{\beta}(f_{iw}, g_{\ell w}) \right]$$

$$\text{onde, } \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot d_R^{\beta}(f_{i1}, g_{\ell 1}) \xrightarrow{D} \chi_{M_1}^2, \dots, \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot d_R^{\beta}(f_{iw}, g_{\ell w}) \xrightarrow{D} \chi_{M_w}^2$$

Aplicando-se o (Teorema 2.1.3) tem-se que

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \left[\frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot d_R^{\beta}(f_{i1}, g_{\ell 1}) + \dots + \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \cdot d_R^{\beta}(f_{iw}, g_{\ell w}) \right] \xrightarrow{D}$$

$$\xrightarrow{D} \chi_{M_1 + \dots + M_w}^2$$

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \left[\sum_{j=1}^w d_R^{\beta}(f_{ij}, g_{\ell j}) \right] \xrightarrow{D} \chi_M^2$$

Portanto, no caso em questão, a estatística de teste segue uma distribuição *Chi-quadrado* com M graus de liberdade onde $M = \sum_{j=1}^w M_j$.

c.q.d.

Resultado IV: Sob as mesmas condições apresentadas no Lema 1, se $d_H(f_{i\{w\}}, g_{\ell\{w\}})$ representa a distância de *Hellinger* entre as distribuições $f_{i\{w\}}$ e $g_{\ell\{w\}}$ então, a estatística de teste será definida como

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \frac{2m_i n_{\ell} v}{m_i + n_{\ell}} \left[1 - \prod_{j=1}^w (1 - d_H(f_{ij}, g_{\ell j})) \right] \xrightarrow{D} \chi_M^2 \quad (3.8)$$

com $M = \sum_{j=1}^w M_j$ graus de liberdade onde M_j representa o grau de liberdade da distribuição *Chi-quadrado* relativa à imagem j , m_i é o tamanho da amostra representativa da região i e n_{ℓ} é o tamanho da amostra correspondente a classe ℓ .

Demonstração IV: Utilizando-se as Equações (2.23) e (3.1) chega-se a

$$d_H(f_{i\{w\}}, g_{\ell\{w\}}) = 1 - \int \cdots \int \sqrt{\prod_{j=1}^w f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}) \cdot \prod_{j=1}^w g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j})} \cdot d_{z_1} \cdot d_{z_2} \cdots d_{z_w}$$

$$d_H(f_{i\{w\}}, g_{\ell\{w\}}) = 1 - \prod_{j=1}^w \int \sqrt{f_{ij}(\mathbf{z}_j; \boldsymbol{\theta}_{ij}) \cdot g_{\ell j}(\mathbf{z}_j; \boldsymbol{\theta}_{\ell j})} d_{z_j}$$

Como $d_H(f_{ij}, g_{\ell j}) = 1 - \int \sqrt{f_{ij} \cdot g_{\ell j}}$ tem-se $\int \sqrt{f_{ij} \cdot g_{\ell j}} = 1 - d_H(f_{ij}, g_{\ell j})$. Assim

$$d_H(f_{i\{w\}}, g_{\ell\{w\}}) = 1 - [1 - d_H(f_{i1}, g_{\ell 1})] \cdot \cdots \cdot [1 - d_H(f_{iw}, g_{\ell w})]$$

$$d_H(f_{i\{w\}}, g_{\ell\{w\}}) = 1 - \prod_{j=1}^w [1 - d_H(f_{ij}, g_{\ell j})] \quad (3.9)$$

Substituindo (3.9) em (2.33) obtém-se a estatística de teste que, segundo Salicrú *et al.* (1994) tende para uma distribuição *Chi-quadrado* com graus de liberdade igual ao número de parâmetros da distribuição. No caso, o número de parâmetros da distribuição conjunta coincide com a soma dos graus de liberdade das distribuições marginais correspondentes.

$$S_{\phi}^h(f_{i\{w\}}, g_{\ell\{w\}}) = \frac{2m_i n_{\ell} \nu}{m_i + n_{\ell}} \left[1 - \prod_{j=1}^w (1 - d_H(f_{ij}, g_{\ell j})) \right] \xrightarrow{D} \chi_M^2$$

Portanto, a estatística de teste segue uma distribuição *Chi-quadrado* com M graus de liberdade onde $M = \sum_{j=1}^w M_j$.

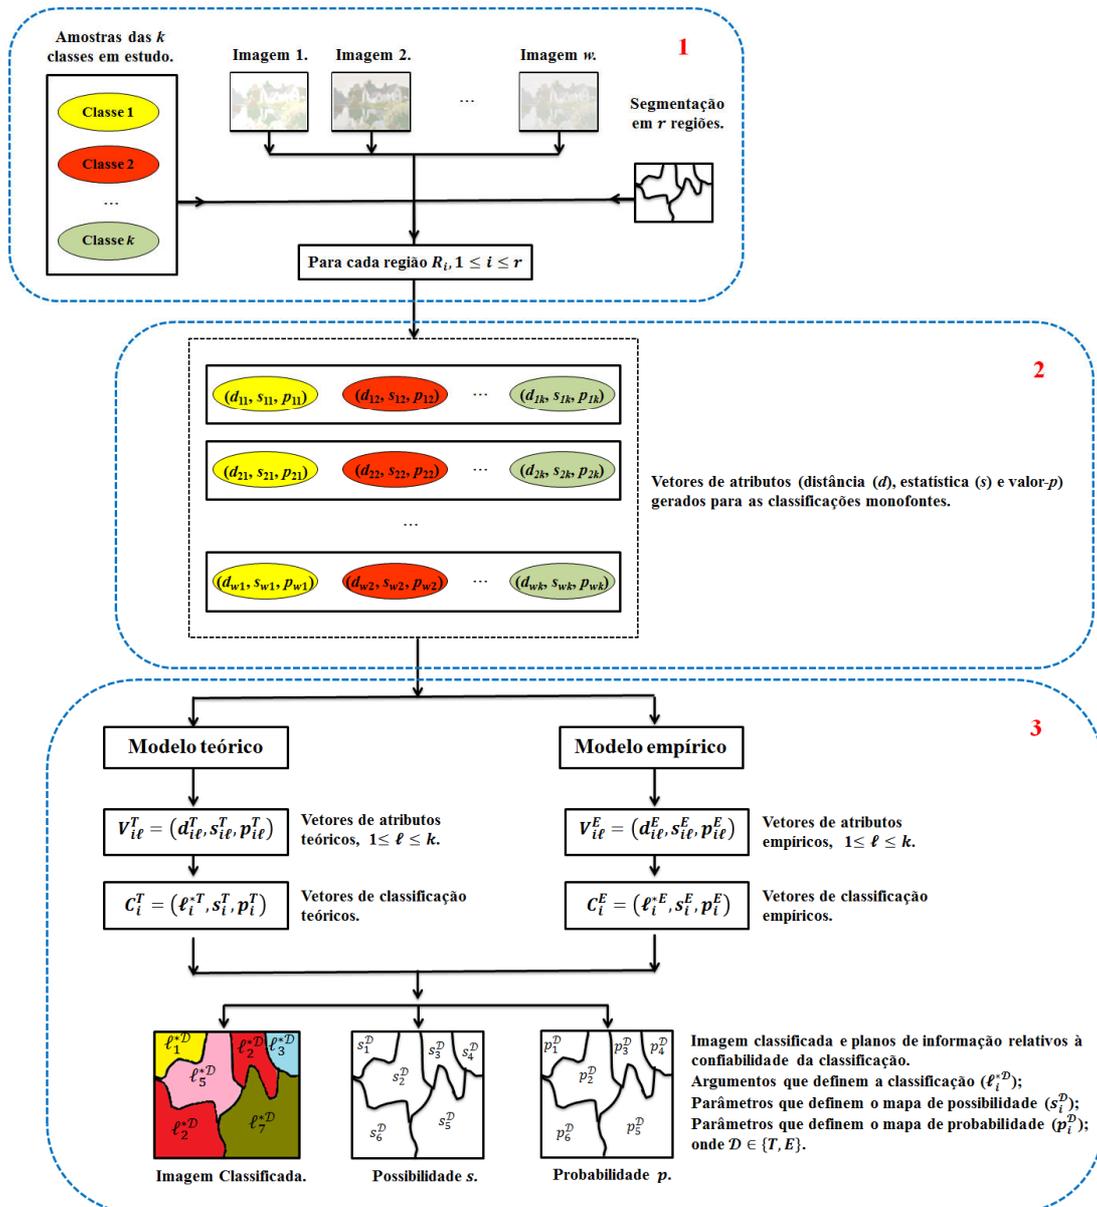
c.q.d.

Neste capítulo, demonstraram-se analiticamente resultados que tornam possível a execução da metodologia de classificação multifonte a partir do conhecimento das distribuições marginais (distribuição de cada classificação monofonte). Nota-se que, para as distâncias de *Bhattacharyya*, *Kullback-Leibler* e *Rényi* ordem β , provou-se que a estatística de teste entre distribuições conjuntas equivale ao somatório das estatísticas de teste entre as distribuições marginais. No caso da distância de *Hellinger*, não foi possível obter os mesmos resultados. Todavia, a convergência da estatística de teste para uma distribuição *Chi-quadrado* ainda é válida segundo Salicrú *et al.* (1994). A estatística de teste para a distância de *Hellinger*, em função das distâncias estocásticas entre as distribuições marginais é apresentada na Equação (3.8). Embora para a distância de *Hellinger*, a estatística de teste entre distribuições conjuntas não seja o somatório das estatísticas de teste entre as distribuições marginais, no próximo capítulo será possível compreender que, apesar de tal resultado não ter sido obtido, a aplicação da metodologia de classificação multifonte ainda assim poderá ser executada.

4 CLASSIFICAÇÃO MULTIFONTE DE IMAGENS BASEADA EM DISTÂNCIAS ESTOCÁSTICAS

Neste capítulo, descreve-se a metodologia proposta de classificação multifonte de imagens. As etapas concernentes à execução do método são ilustradas na Figura 4.1.

Figura 4.1 – Representação gráfica da metodologia de classificação multifonte.



Fonte: Produção do autor.

Três etapas compõem a metodologia proposta, a saber: 1) Tratamento dos dados de entrada; 2) Geração dos planos de informação e 3) Classificação Multifonte. Cada uma das fases apresentadas no fluxograma é detalhada nas seções a seguir.

4.1. Tratamento dos dados de entrada

A classificação multifonte proposta conta com w imagens de entrada, as quais são provenientes de w sensores distintos e supostamente independentes. Portanto, é através da etapa do tratamento dos dados de entrada que as imagens são colocadas em um sistema de referência comum. Esta primeira etapa subdivide-se em três passos realizados para preparação dos dados de entrada. São eles: pré-processamento das imagens; segmentação e coleta das amostras de treinamento e teste.

O pré-processamento das imagens não se restringe à correção de possíveis problemas que as imagens originais possam apresentar. No pré-processamento dos dados são incluídas etapas fundamentais para a execução, o mais correto possível, da metodologia multifonte. Nesta fase, fazem-se as correções de cada uma das w imagens individualmente. É de fundamental importância enfatizar que, uma vez que as imagens são provenientes de fontes distintas, as correções (radiométricas e geométricas) das mesmas podem exigir tratamentos distintos. Como exemplo, tem-se que o processo de correção de imagens ópticas ocorre de forma diferente que o processo de correção de imagens de micro-ondas.

Para aplicação da metodologia multifonte é fundamental que as w imagens envolvidas sejam de uma mesma região da superfície terrestre e que tais imagens estejam corrigidas entre si. Não é necessário que as imagens possuam a mesma resolução, visto que, no processo de correção, os pixels das imagens são reamostrados para um valor definido pelo usuário. No entanto, imagens com resoluções espaciais muito díspares podem prejudicar o processo de classificação multifonte.

Um ponto importante em todo o processo da classificação multifontes está diretamente relacionado à segmentação utilizada como dado de entrada. Neste caso, utiliza-se uma única segmentação válida para todas as w imagens em estudo. É

relevante enfatizar que um bom resultado de classificação está diretamente relacionado à segmentação da imagem.

O processo de classificação multifonte é supervisionado, portanto é necessária a coleta de amostras das classes de interesse para treinar o classificador (amostras de treinamento). Por outro lado também se faz necessária a seleção de amostras das mesmas classes a fim de validar o resultado obtido de classificação. Vale ressaltar que as amostras de treinamento e amostras de teste também são as mesmas para todas as w imagens a serem classificadas. Obtêm-se tais amostras de diversas maneiras, por exemplo, por meio de dados de campo, chave de interpretação ou série histórica de imagens.

4.2. Geração dos planos de informação

Nesta etapa, são gerados os planos de informação que contêm os atributos necessários para construção da classificação multifonte. A origem desses planos de informação segue a mesma metodologia adotada para obtenção dos vetores de atributos para as classificações monofontes, descrita na Subseção 2.4.2.

Considere um conjunto A formado por w diferentes imagens registradas entre si, provenientes de fontes supostamente independentes, que se deseja classificar em k classes. Supõe-se também a existência de uma única segmentação destas imagens em r segmentos (regiões). Para cada imagem j ($1 \leq j \leq w$) são gerados $3 \times k$ planos de informação. Isto é, fixada a imagem j , para cada classe de estudo ℓ ($1 \leq \ell \leq k$) são gerados 3 planos de informação relativos aos valores calculados de distância estocástica ($d_{i\ell}^j$), estatística de teste ($s_{i\ell}^j$) e probabilidade ($p_{i\ell}^j$) para cada região i ($1 \leq i \leq r$). Em posse destes planos de informação iniciam-se as etapas da classificação multifonte.

4.3. Classificação multifonte

Uma vez gerados os $3 \times k$ planos de informação, a ideia é, por meio de combinações entre os valores contidos nos planos gerados para cada imagem, criar novos Cenários de classificação de origem multifonte de forma a obter resultados de classificação mais

acurados que aqueles obtidos nas classificações individuais. Vale ressaltar que um Cenário de classificação é definido pela imagem classificada e seus mapas de confiabilidade.

O processo de classificação multifonte pode seguir uma abordagem teórica ou empírica. Provou-se no Capítulo 3 que, usando-se a teoria de classificação de regiões baseada em distâncias estocásticas e testes estatísticos (especificamente para as distâncias de *Bhattacharyya*, *Kullback-Leibler* e *Rényi* de ordem β), uma maneira adequada de combinar as informações provenientes de diferentes sensores (considerando-se fontes independentes) é por meio da soma dos valores de estatística das classes atribuídas a cada região em cada fonte de dados. Já para a distância de *Hellinger*, a Equação (3.8) deve ser utilizada.

A implementação dessas combinações também pode ocorrer de forma empírica. Neste caso, a hipótese inicial de independência entre as fontes não é necessária. Essas combinações empíricas podem envolver diversas operações matemáticas, como por exemplo, o mínimo do produto entre as w estatísticas de teste, o produto dos mínimos entre as w estatísticas de teste, ou até mesmo uma combinação que envolva a lógica *Fuzzy*, onde todos os resultados individuais de classificação poderão ser considerados gerando-se assim novas classes mistas ou até mesmo uma combinação de funções matemáticas das estatísticas que seja diferente das apresentadas.

Em ambas as abordagens (teórica (T) ou empírica (E)), por meio dos planos de informação construídos na etapa anterior, tem-se acesso a vetores de atributos da forma $V_{i\ell}^{\mathcal{D}} = (d_{i\ell}^{\mathcal{D}}, s_{i\ell}^{\mathcal{D}}, p_{i\ell}^{\mathcal{D}})$, $\mathcal{D} \in \{T, E\}$ em que os atributos $p_{i\ell}^j$ (probabilidade) e $s_{i\ell}^j$ (estatística) estão relacionados a confiabilidade da atribuição da classe ℓ à região i na imagem j e $d_{i\ell}^j$ (distância estocástica) representa a distância calculada entre as distribuições. Através de funções matemáticas entre elementos destes vetores, obtêm-se vetores de classificação $C_i^{\mathcal{D}}$ que originam diferentes Cenários de classificação. Alguns destes possíveis Cenários, desenvolvidos neste trabalho, são descritos na subseção a seguir.

4.4. Construção dos Cenários de classificação

Nesta subseção, serão apresentados quatro diferentes Cenários de classificação multifontes sendo que um deles corresponde à abordagem multifonte teórica desenvolvida no Capítulo 3 e é denominado Cenário multifonte da soma. Os Cenários restantes estão relacionados à abordagem empírica e são chamados respectivamente: Cenário multifonte dos mínimos, Cenário multifonte do produto e Cenário *Fuzzy*.

Considere \mathbb{F} e \mathbb{G} dois conjuntos contendo respectivamente w sensores distintos e k classes de interesse, $\{\mathbb{F}_j\} = \{\mathbb{F}_1, \mathbb{F}_2, \dots, \mathbb{F}_w\}$, $1 \leq j \leq w$ e $\{\mathbb{G}_\ell\} = \{\mathbb{G}_1, \mathbb{G}_2, \dots, \mathbb{G}_k\}$, $1 \leq \ell \leq k$.

Sejam w diferentes imagens, provenientes dos w sensores que compõem o conjunto \mathbb{F} , as quais se deseja classificar nas k classes pertencentes ao conjunto \mathbb{G} . Suponha também uma única segmentação dessas imagens em r regiões. Os seguintes Cenários podem ser construídos:

Cenário multifonte da soma: está relacionado à classificação multifonte utilizando-se informações das w imagens, e de seus respectivos planos de informação. O presente Cenário foi originado a partir da dedução matemática apresentada no Capítulo 3. Inicialmente são formados os vetores de atributos para a região i e classe ℓ dados por:

$$V_{i\ell}^{sum} = (d_{i\ell}^{sum}, s_{i\ell}^{sum}, p_{i\ell}^{sum})$$

onde $d_{i\ell}^{sum}$ representa as distâncias entre *f. d. p.*'s relativas ao segmento i e à classe ℓ .

As estatísticas de teste são definidas como

$$s_{i\ell}^{sum} = \begin{cases} \sum_{j=1}^w s_{i\ell}^j & (\text{distâncias de Bhattacharyya, Kullback-Leibler e Rényi de ordem } \beta) \\ \text{Equação (3.8)} & (\text{distância de Hellinger}) \end{cases}$$

e os valores- p são definidos como $p_{i\ell}^{sum} = \mathbf{Pr}(\chi_M^2 > s_{i\ell}^{sum})$, no qual $M = \sum_{j=1}^w M_j$, onde M_j é o número de parâmetros da *f. d. p.* representativa da imagem j .

Por intermédio dos vetores de atributos definem-se os vetores de classificação da região i para este Cenário como

$$C_i^{sum} = (\ell_i^{*sum}, s_i^{sum}, p_i^{sum}),$$

onde $s_i^{sum} = \min_{\ell} \{normalize(s_{i\ell}^{sum} - s_c^{sum})\}$ em que s_c^{sum} representa o valor crítico para o teste da distribuição *Chi-quadrado* da soma (resultante das somas das estatísticas). A função de normalização é definida por

$$normalize(s_{i\ell}^{sum} - s_c^{sum}) = \frac{(s_{i\ell}^{sum} - s_c^{sum}) - \min(s_{i\ell}^{sum} - s_c^{sum})}{\max(s_{i\ell}^{sum} - s_c^{sum}) - \min(s_{i\ell}^{sum} - s_c^{sum})}$$

o valor- p é dado por $p_i^{sum} = \max_{\ell} \{p_{i\ell}^{sum}\}$ e $\ell_i^{*sum} = arg_{\ell} \{s_i^{sum}\}$ ou seja, ℓ_i^{*sum} é a classe que possui a menor estatística de teste s_i^{sum} .

As espacializações de ℓ_i^{*sum} , s_i^{sum} e p_i^{sum} fornecem, respectivamente, os mapas de classificação, de possibilidade e de probabilidade do Cenário multifonte da soma. Os dois últimos estão relacionados à confiabilidade da classificação.

Nota-se no procedimento para construção do vetor de classificação, a normalização de estatísticas precedido da subtração de um valor crítico desta mesma medida. A partir do momento em que se normalizam as estatísticas transferindo-as do intervalo $[0, \infty]$ para o intervalo $[0,1]$ a espacialização destes valores passa a representar um mapa de possibilidades. As justificativas para subtração de um valor crítico das estatísticas de teste estão diretamente relacionadas ao trabalho com diferentes imagens. Como o processo de integração envolve diferentes tipos de dados, a normalização foi baseada nas diferenças entre as estatísticas de teste e seu respectivo valor crítico considerando-se, desta forma, o quão longe as estatísticas estariam em relação a esse valor crítico. O valor crítico depende do grau de liberdade e do nível de significância adotado e representa o limitante inferior para rejeição da hipótese nula do teste.

Cenário multifonte dos mínimos: Esse e os próximos Cenários foram construídos de maneira empírica e desta forma independem das demonstrações teóricas apresentadas no

Capítulo 3. Os vetores de atributos para a região i e classe ℓ são definidos como no Cenário monofonte (Subseção 2.4.2), dados por:

$$V_{i\ell}^j = (d_{i\ell}^j, s_{i\ell}^j, p_{i\ell}^j)$$

onde $d_{i\ell}^j$ representa as distâncias entre distribuições, $s_{i\ell}^j = \frac{2m_i n_\ell v}{m_i + n_\ell} d_{i\ell}^j$, em que m_i e n_ℓ representam o número de amostras independentes da região i e da classe ℓ e o valor- p é definido como $p_{i\ell}^j = \Pr(\chi_{M_j}^2 > s_{i\ell}^j)$.

Os vetores de classificação da região i para este Cenário são definidos por

$$C_i^{min} = (\ell_i^{*min}, s_i^{min}, p_i^{min}),$$

onde $s_i^{min} = \min_{\ell,j} \{normalize(s_{i\ell}^j - s_c^j)\}$ em que s_c^j representa o valor crítico para o teste da distribuição *Chi-quadrado* para as estatísticas de teste da imagem j . A função de normalização é definida por

$$normalize(s_{i\ell}^j - s_c^j) = \frac{(s_{i\ell}^j - s_c^j) - \min(s_{i\ell}^j - s_c^j)}{\max(s_{i\ell}^j - s_c^j) - \min(s_{i\ell}^j - s_c^j)}$$

O valor- p obtido por $p_i^{min} = \max_{\ell,j} \{p_{i\ell}^j\}$ e $\ell_i^{*min} = \arg_{\ell} \{s_i^{min}\}$ isto é, ℓ_i^{*min} é a classe que possui a menor estatística de teste s_i^{min} .

As espacializações de ℓ_i^{*min} , s_i^{min} e p_i^{min} fornecem, respectivamente, os mapas de classificação, de possibilidade e de probabilidade do Cenário multifonte dos mínimos. Os dois últimos estão relacionados à confiabilidade da classificação.

Cenário multifonte do produto: este Cenário também representa uma classificação que utiliza informações das w imagens. Os vetores de atributos para a região i e classe ℓ são definidos como:

$$V_{i\ell}^{prod} = (d_{i\ell}^{prod}, s_{i\ell}^{prod}, p_{i\ell}^{prod})$$

onde $d_{i\ell}^{prod}$ representa as distâncias entre distribuições, $s_i^{prod} = \prod_{j=1}^w s_{i\ell}^j$ e o valor- p é definido como $p_i^{prod} = \prod_{j=1}^w p_{i\ell}^j$.

Os vetores de classificação da região i para este Cenário são definidos por

$$C_i^{prod} = (\ell_i^{*prod}, s_i^{prod}, p_i^{prod})$$

onde $s_i^{prod} = \min_{\ell} \{normalize(s_{i\ell}^{prod} - s_c^j)\}$ em que s_c^j representa o valor crítico para o teste da distribuição *Chi-quadrado* para as estatísticas de teste da imagem j . A função de normalização é definida por

$$normalize(s_{i\ell}^{prod} - s_c^j) = \frac{(s_{i\ell}^{prod} - s_c^j) - \min(s_{i\ell}^j - s_c^j)}{\max(s_{i\ell}^j - s_c^j) - \min(s_{i\ell}^j - s_c^j)}$$

O valor- p é dado por $p_i^{prod} = \prod_{j=1}^w p_{i\ell^{\#}}^j$ no qual $\ell^{\#} = \ell_i^{*prod}$ e $\ell_i^{*prod} = arg_{\ell} \{s_i^{prod}\}$ ou seja, ℓ_i^{*prod} é a classe que possui a menor estatística de teste s_i^{prod} .

As espacializações de ℓ_i^{*prod} , s_i^{prod} e p_i^{prod} fornecem respectivamente os mapas de classificação, de possibilidade e de probabilidade do Cenário multifonte do produto. Os dois últimos estão relacionados à confiabilidade da classificação.

Cenário multifonte Fuzzy: a construção deste Cenário baseia-se num tipo de lógica que tem por objetivo modelar modos de raciocínio aproximados ao invés de precisos. Neste caso, as proposições podem ter valores intermediários entre verdadeiro e falso e a veracidade destas é uma função que pode assumir qualquer valor entre zero (absolutamente falso) e um (absolutamente verdadeiro). Essa lógica é conhecida como lógica *Fuzzy* (ou difusa).

O objetivo da utilização deste tipo de lógica na classificação de imagens é mostrar que uma tomada de decisão pela classificação mais representativa da realidade pode ser relativa. Isto porque a imagem de uma determinada região pode não possuir necessariamente uma classificação exata. Desta maneira, as classes neste Cenário não são formadas apenas pelas classes de interesse definidas para a classificação, mas por

combinações destas. Este é o único Cenário de classificação que depende diretamente dos resultados de classificação provenientes dos Cenários monofontes.

Sejam w imagens provenientes de sensores distintos e k classes de interesses. O número de classes (n) possíveis no Cenário *Fuzzy* são:

$$n = \begin{cases} 2^k - 1, & k \leq w \\ \sum_{j=1}^w \binom{k}{j}, & k > w \end{cases}$$

Exemplificando, considere \mathbb{F} e \mathbb{G} dois conjuntos contendo, respectivamente, 2 sensores distintos ($w=2$) e k classes, isto é, $\{\mathbb{F}_j\} = \{\mathbb{F}_1, \mathbb{F}_2\}$ e $\{\mathbb{G}_\ell\} = \{\mathbb{G}_1, \mathbb{G}_2, \dots, \mathbb{G}_k\}$. Se para a região i a classificação monofonte relativa à imagem proveniente do sensor \mathbb{F}_1 associou a classe \mathbb{G}_a ($1 \leq a \leq k$) e, por outro lado a classificação monofonte correspondente à imagem proveniente do sensor \mathbb{F}_2 associou à mesma região i a classe \mathbb{G}_b ($1 \leq b \leq k$), no Cenário *Fuzzy*, a região i será associada a uma nova classe denominada $\mathbb{G}_a_ \mathbb{G}_b$. Esta nova classe é, então, uma combinação das classes \mathbb{G}_a e \mathbb{G}_b , não importando aqui a ordem em que elas ocorrem. Isto é, admite-se que as classes $\mathbb{G}_a_ \mathbb{G}_b$ e $\mathbb{G}_b_ \mathbb{G}_a$, com ($1 \leq a, b \leq k$), são idênticas. A confiabilidade desta nova classe será o resultado do produto das mínimas estatísticas s_{ia}^1 e s_{ib}^2 (que compõem os mapas de possibilidades dos Cenários monofontes) e o produto dos máximos valores - p correspondentes p_{ia}^1 e p_{ib}^2 (que compõem os mapas de probabilidades dos Cenários monofontes). Ao proceder deste modo, pode-se, então gerar para as k classes de interesse e $w=2$, $k(k+1)/2$ classes *Fuzzy*.

De modo geral, os vetores de atributos para a região i e classe ℓ são definidos como no na classificação monofonte (Subseção 2.4.2), dados por:

$$V_{i\ell}^j = (d_{i\ell}^j, s_{i\ell}^j, p_{i\ell}^j)$$

onde $d_{i\ell}^j$ representa as distâncias entre distribuições, $s_{i\ell}^j = \frac{2m_i n_\ell v}{m_i + n_\ell} d_{i\ell}^j$, em que m_i e n_ℓ representam o número de amostras independentes da região i e da classe ℓ e o valor - p é definido por $p_{i\ell}^j = \mathbf{Pr}(\chi_{M_j}^2 > s_{i\ell}^j)$.

Os vetores de classificação da região i para este Cenário de classificação são definidos por

$$C_i^{fuzzy} = (\ell_i^{*fuzzy}, s_i^{fuzzy}, p_i^{fuzzy})$$

onde ℓ_i^{*fuzzy} será a classe resultante da combinação entre as classes que possuem menores estatísticas de teste para o segmento i e imagem j (definidas nas classificações monofontes de cada imagem j). As estatísticas de teste e valores- p são obtidos por

$$s_i^{fuzzy} = \prod_{j=1}^w \min_{\ell,j} \{normalize(s_{i\ell}^j - s_c^j)\}$$

em que s_c^j representa o valor crítico para o teste da distribuição *Chi-quadrado* para as estatísticas de teste da imagem j .

$$normalize(s_{i\ell}^j - s_c^j) = \frac{(s_{i\ell}^j - s_c^j) - \min(s_{i\ell}^j - s_c^j)}{\max(s_{i\ell}^j - s_c^j) - \min(s_{i\ell}^j - s_c^j)}$$

$$p_i^{fuzzy} = \prod_{j=1}^w \max_{\ell,j} \{p_{i\ell}^j\}.$$

As espacializações de ℓ_i^{*fuzzy} , s_i^{fuzzy} e p_i^{fuzzy} fornecem respectivamente os mapas de classificação, de possibilidade e de probabilidade do Cenário multifonte *Fuzzy*. Os dois últimos estão relacionados à confiabilidade da classificação.

Neste capítulo descreveram-se os passos para desenvolvimento da metodologia de classificação multifontes e alguns dos possíveis Cenários de classificação oriundos desta metodologia. Note que fornecidas a modelagem estatísticas dos dados, as distâncias estocásticas e as funções matemáticas empregadas na geração da classificação multifonte, o número de Cenários de classificação possíveis é muito elevado. A seguir, apresentam-se os dados utilizados e passos executados na aplicação desta metodologia.

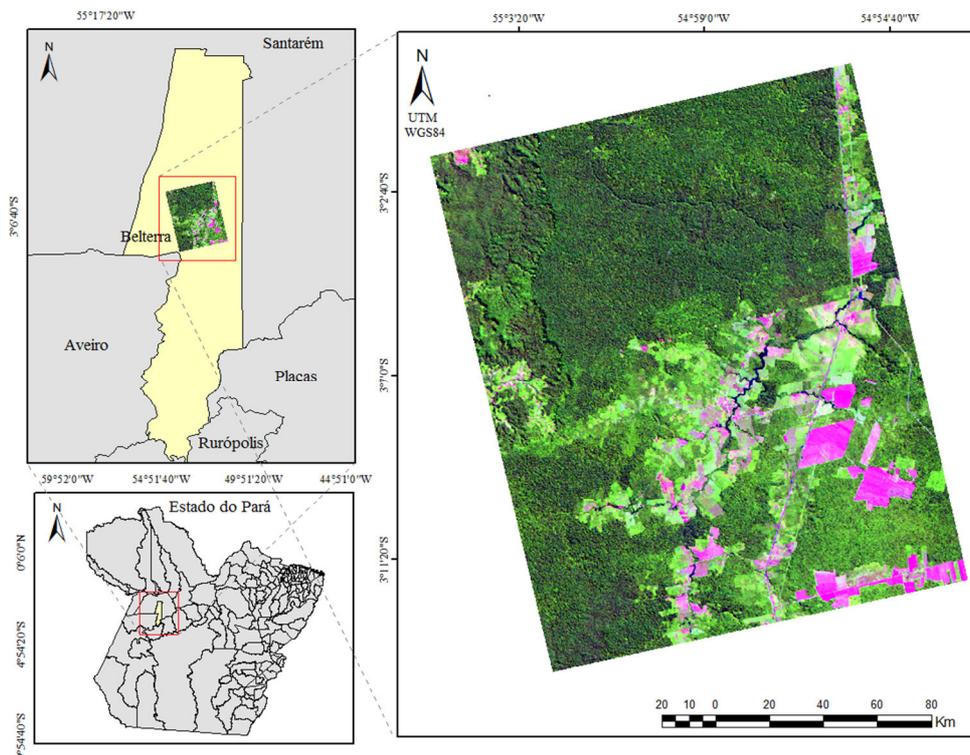
5 MATERIAIS E MÉTODOS

Neste capítulo, descrevem-se os dados utilizados para a análise da metodologia proposta, apresenta-se a região onde os estudos foram realizados, as etapas executadas no pré-processamento e processamento dos dados, e os passos adotados para a aplicação da metodologia.

5.1. Área de estudo e aquisição dos dados

A área de estudo utilizada para a aplicação da metodologia refere-se ao entorno de parte da Floresta Nacional (Flona) do Tapajós. Esta região, ilustrada na Figura 5.1, faz parte de uma importante unidade de conservação da natureza localizada na Amazônia brasileira às margens do Rio Tapajós, na região do estado do Pará, Brasil.

Figura 5.1 – Localização da área de estudo e recorte da imagem Landsat5/TM de 12 de julho de 2009 em composição colorida 5(R) 4(G) 3(B).



Fonte: Adaptado de INPE (2015).

Segundo o Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA), com a ocupação deste território, iniciada em junho de 1970, acentuou-se o processo de desmatamento. Essa intensificação se deve principalmente às atividades de extração de madeira, abertura de áreas agrícolas e pastagens. Devido à rica diversidade quanto ao uso e ocupação da terra presente nesta localidade, diversos trabalhos de mapeamento foram elaborados nesta área de estudo, como por exemplo, (PEREIRA, 2012; PEREIRA *et al.*, 2013; GUERRA, 2008; ABOUD NETA, 2009; REIS, 2014), entre outros. Para exemplificar a metodologia de classificação multifonte proposta neste trabalho, selecionaram-se três imagens, uma óptica e duas de micro-ondas, desta região.

A imagem óptica é proveniente do sensor *Thematic Mapper* (TM) do satélite Landsat5. A imagem de órbita/ponto 227/62 datada de 12 de julho de 2009 foi obtida do catálogo do Instituto Nacional de Pesquisas Espaciais - INPE (INPE, 2015) e será denominada no decorrer do texto pelo termo imagem TM. Imagens Landsat5/TM cobrem cada uma, uma área de 185 km × 185 km. As imagens são fornecidas sem custo com sete bandas disponíveis, seis bandas multiespectrais e uma banda termal. Dentre estas, utilizaram-se as seis bandas multiespectrais, a saber, as bandas 1 a 5 e a banda 7. As principais características da imagem TM utilizada são apresentadas na Tabela 5.1.

Tabela 5.1 – Descrição das características da imagem TM.

Características	Imagem
Dimensão (pixel)	8010 × 6734
Resolução espacial (m)	30
Resolução radiométrica	8 bits
Resolução espectral (µm)	0,45 a 0,52; 0,52 a 0,60; 0,63 a 0,69; 0,76 a 0,90; 1,55 a 1,75; 2,08 a 2,35.
Resolução temporal	16 dias
Faixa imageada (km)	185
Datum padrão	WGS84
Projeção padrão	UTM
Nível de correção padrão	Nível 2: correção radiométrica + correção geométrica de sistema

Fonte: Adaptada de INPE (2015).

Uma das imagens de micro-ondas *full* polarimétricas utilizadas é originária do sensor *Phase Array L-Band Synthetic Aperture Radar 2* (Palsar 2) do satélite *Advanced Land Observing System 2*

(Alos 2). A imagem Alos 2/Palsar 2, referida neste trabalho como Palsar, data de 28 de abril de 2009 e suas principais características são descritas na Tabela 5.2.

Tabela 5.2 – Descrição das características da imagem Palsar.

Características	Imagem
Tipo de dado	SLC (<i>Single Look Complex</i>)
Dimensão (pixel)	1248 × 18432
Ângulo de incidência no <i>near range</i>	≈23°
Ângulo de incidência no <i>far range</i>	≈25°
Nível de processamento	1.1
Polarizações	<i>Full (hh, hv, vv, vh)</i>
Órbita	Ascendente
Número de visadas	1 × 1
Resolução (m)	24 a 88
Resolução radiométrica	32 bits
Espaçamento entre pixels (m)	9,36 em range / 3,56 em azimuth
Comprimento de onda (cm)	15-30
Frequência	1,27 GHz (Banda L)

Fonte: Adaptado de JAXA (2009).

A segunda imagem de micro-ondas de 19 de setembro de 2009 é oriunda do sensor Radarsat2. Assim como a imagem Palsar, esta possui as quatro polarizações (*hh, hv, vv, vh*) e será chamada neste trabalho de imagem Radarsat. Suas principais características podem ser visualizadas na Tabela 5.3.

Tabela 5.3 - Descrição das características da imagem Radarsat.

Características	Imagem
Tipo de dado	SLC (<i>Single Look Complex</i>)
Dimensão (pixel)	3164 × 5332
Ângulo de incidência no <i>near range</i>	≈32°
Ângulo de incidência no <i>far range</i>	≈34°
Nível de processamento	1.1
Polarizações	<i>Full (hh, hv, vv, vh)</i>
Órbita	Ascendente
Número de visadas	1 × 1
Resolução (m)	3 a 100
Resolução radiométrica	16 bits
Espaçamento entre pixels (m)	4,73 em range / 4,75 em azimuth
Comprimento de onda (cm)	3,75 - 7,5
Frequência	5,4 GHz (Banda C)

Fonte: Adaptado de MDA (2011).

O ideal para aplicação da metodologia é trabalhar com imagens adquiridas numa mesma data, todavia, os dados disponíveis para análise são compostos pelas imagens descritas na Tabela 5.4. A data de aquisição da imagem óptica, em média, dista de 73 dias das datas de obtenção dos dados SAR. A data de aquisição das imagens SAR diferem entre si de 146 dias.

Tabela 5.4 – Data de aquisição das imagens utilizadas.

Imagens	Data de aquisição
Palsar	28/04/2009
TM	12/07/2009
Radarsat	19/09/2009

Fonte: Produção do autor.

Na região em estudo, observam-se atividades de pecuária extensiva e cultivo de grãos, tais como, soja, milho, feijão, sorgo e arroz. Segundo Escada *et al.* (2009), o calendário agrícola inicia-se em dezembro e a colheita é realizada em abril. Alguns agricultores realizam duas safras e neste caso, o segundo plantio é realizado entre março e abril e a colheita entre julho e agosto. No geral, nos meses de julho a dezembro a atividade de plantio é reduzida.

Levando-se em consideração esses fatores e as datas em que os dados foram adquiridos, espera-se que, para algumas regiões da imagem, ocorram confusões nas classificações devido à presença de áreas agrícolas em determinada época e a ausência das mesmas em outras épocas, acarretando na presença da classe Solo Exposto. Prevê-se que esta confusão seja maior ao se comparar as imagens Radarsat e TM com a imagem Palsar, uma vez que esta última foi adquirida no mês de abril, época em que existe atividade de cultivo de grãos. Para a comparação entre as imagens Radarsat e TM, não se esperam grandes confusões já que ambas foram adquiridas em épocas em que a atividade de plantio é reduzida.

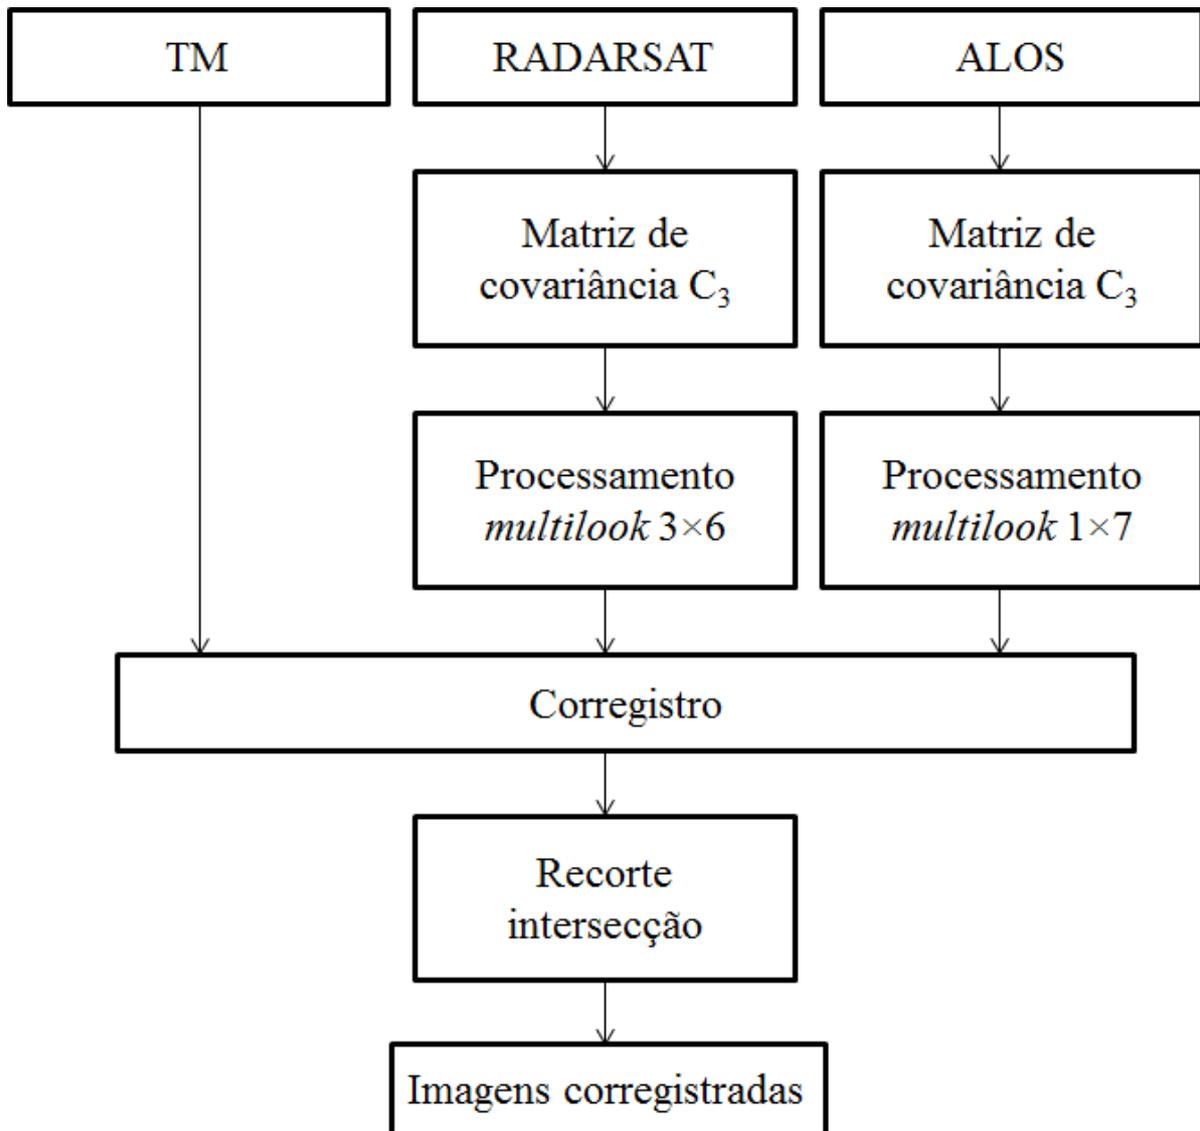
5.2. Processamento dos dados

A aquisição de dados de uma mesma data (ou datas o mais próximas possíveis) é um dos fatores fundamentais para a aplicação da metodologia proposta. Além deste, é imprescindível que as imagens estejam registradas entre si e que exista uma segmentação única válida para todas as imagens. Os passos para preparação dos dados obtidos são descritos nesta seção.

5.2.1. Pré-processamento dos dados

As etapas realizadas no pré-processamento dos dados estão ilustradas na Figura 5.2. Não foram necessárias correções na imagem TM uma vez que o produto padrão disponibilizado pelo catálogo do INPE (INPE, 2015) possui correções radiométricas e geométricas de sistema.

Figura 5.2 – Etapas para o pré-processamento.



Fonte: Produção do autor.

Posto que a metodologia para modelagem de dados segue uma abordagem estatística, procurou-se executar poucas operações nas imagens SAR de forma a alterar o mínimo possível suas propriedades estatísticas. Extraiu-se de cada uma destas imagens a matriz de covariância C_3 em razão da adoção do teorema de reciprocidade aplicado a dados polarimétricos (ULABY; ELACHI, 1990), pois neste caso tem-se que $hv = vh$. Isto significa que os dados obtidos em polarizações cruzadas são idênticos, portanto, dados completamente redundantes. Desta forma, usa-se apenas a informação contida em uma destas polarizações e assim os dados utilizados no processamento foram as polarizações hh, hv e vv . A matriz de covariância C_3 é resultado da média do produto complexo entre o vetor de espalhamento (Equação (2.3)), e seu transposto conjugado, isto é, $C_3 = \langle \mathbf{V}_S \cdot (\mathbf{V}_S)^H \rangle$, em que $\langle \cdot \rangle$ indica a operação de média espacial e $(\mathbf{V}_S)^H$ o transposto conjugado do vetor de espalhamento \mathbf{V}_S .

Para construção das matrizes, empregou-se um algoritmo implementado em linguagem IDL desenvolvido e disponibilizado por Silva (2013). No processo de geração da matriz de covariância, o algoritmo permite a aplicação do processamento *multilook* solicitando do usuário os fatores de compressão desejados para as linhas e colunas. Segundo (SARTORI, 2011) se tais fatores forem aplicados com as devidas proporções, além da aplicação do processamento *multilook* na imagem, o algoritmo retorna a matriz de covariância da imagem, inicialmente em *slant range*, projetada para *ground range*. Os fatores de compressão (colunas/linhas) aplicados foram de 1×7 para a imagem Palsar e 3×6 para a imagem Radarsat. Tais valores foram obtidos por intermédio do seguinte raciocínio: a imagem Palsar, inicialmente em *slant range*, possui como apresentado na Tabela 5.2 espaçamento linear entre pixel de 9,36 m em range e 3,56 m em azimute. Para transformação da imagem com pixels retangulares em uma imagem com pixels aproximadamente quadrados, é necessária projeção desta no plano do terreno. Tal processo é influenciado pelo ângulo de incidência no centro da cena que, para o sensor em questão é de aproximadamente 24° . A fórmula para projeção da imagem em *slant range* (sr) para *ground range* (gr) para o espaçamento em pixel (resolução em range) é

$$gr = sr / \text{sen}(\theta) \tag{5.1}$$

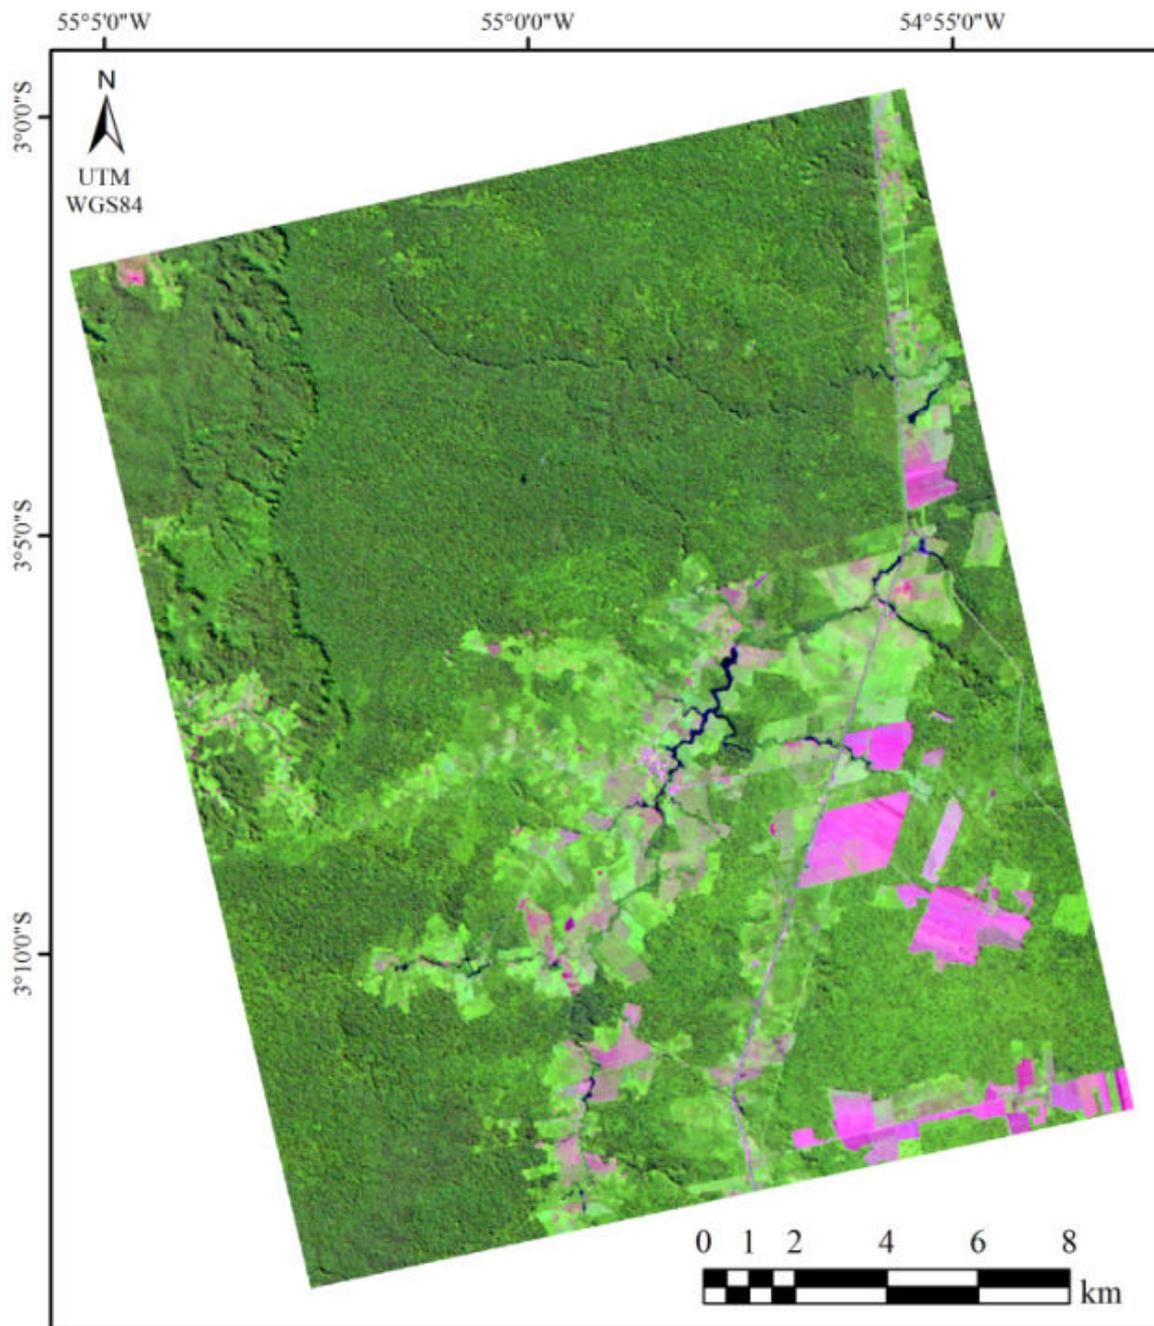
Substituindo em sr o valor de 9,36, obtém-se $gr \cong 23$ m. Desta forma, o espaçamento linear (resolução azimutal) deve ser multiplicado por 7 para tornar o mais próximo possível da resolução em range: $3,56 \times 7 = 24,92$ m.

De forma geral, no processo converte-se o espaçamento de 3,56 m em azimute \times 9,36 m em range para 25 m em azimute \times 23 m em range da imagem em *slant range* projetada no terreno. O mesmo processo foi aplicado à imagem Radarsat para obtenção do fator adotado.

Com o objetivo de registrar as três imagens entre si, admitiu-se como referência a imagem de melhor resolução, no caso, a imagem Radarsat e adotou-se uma projeção. No programa ASF *MapyReader*, utilizando-se a imagem Radarsat original em formato SLC, por meio do comando “*Geocode to a map projection*” reamostrou-se, pelo método do vizinho mais próximo, os pixels para 15×15 m obtendo-se uma imagem modelo em amplitude, na projeção UTM, zona 21 sul, datum WGS84. Utilizou-se a polarização hv desta imagem para corregristo da matriz de covariância da imagem Radarsat. Por intermédio do *software* ENVI 4.7, a imagem relativa à matriz de covariância do dado Radarsat foi reamostrada para 15 metros e corregristada à imagem modelo. Após tal etapa, o mesmo processo foi aplicado às imagens TM e Palsar. Neste caso, primeiramente corregristou-se a imagem TM a imagem relativa à matriz de covariância do dado Radarsat e posteriormente coregristou-se a imagem relativa à matriz de covariância do dado Palsar a imagem correspondente a matriz de covariância do dado Radarsat. Finalmente, após o corregristo, recortou-se a área comum às três imagens resultando em três imagens com tamanho de pixel de 15×15 m e dimensões 1623×1817 pixels. Estas imagens são ilustradas nas Figura 5.3 a 5.5.

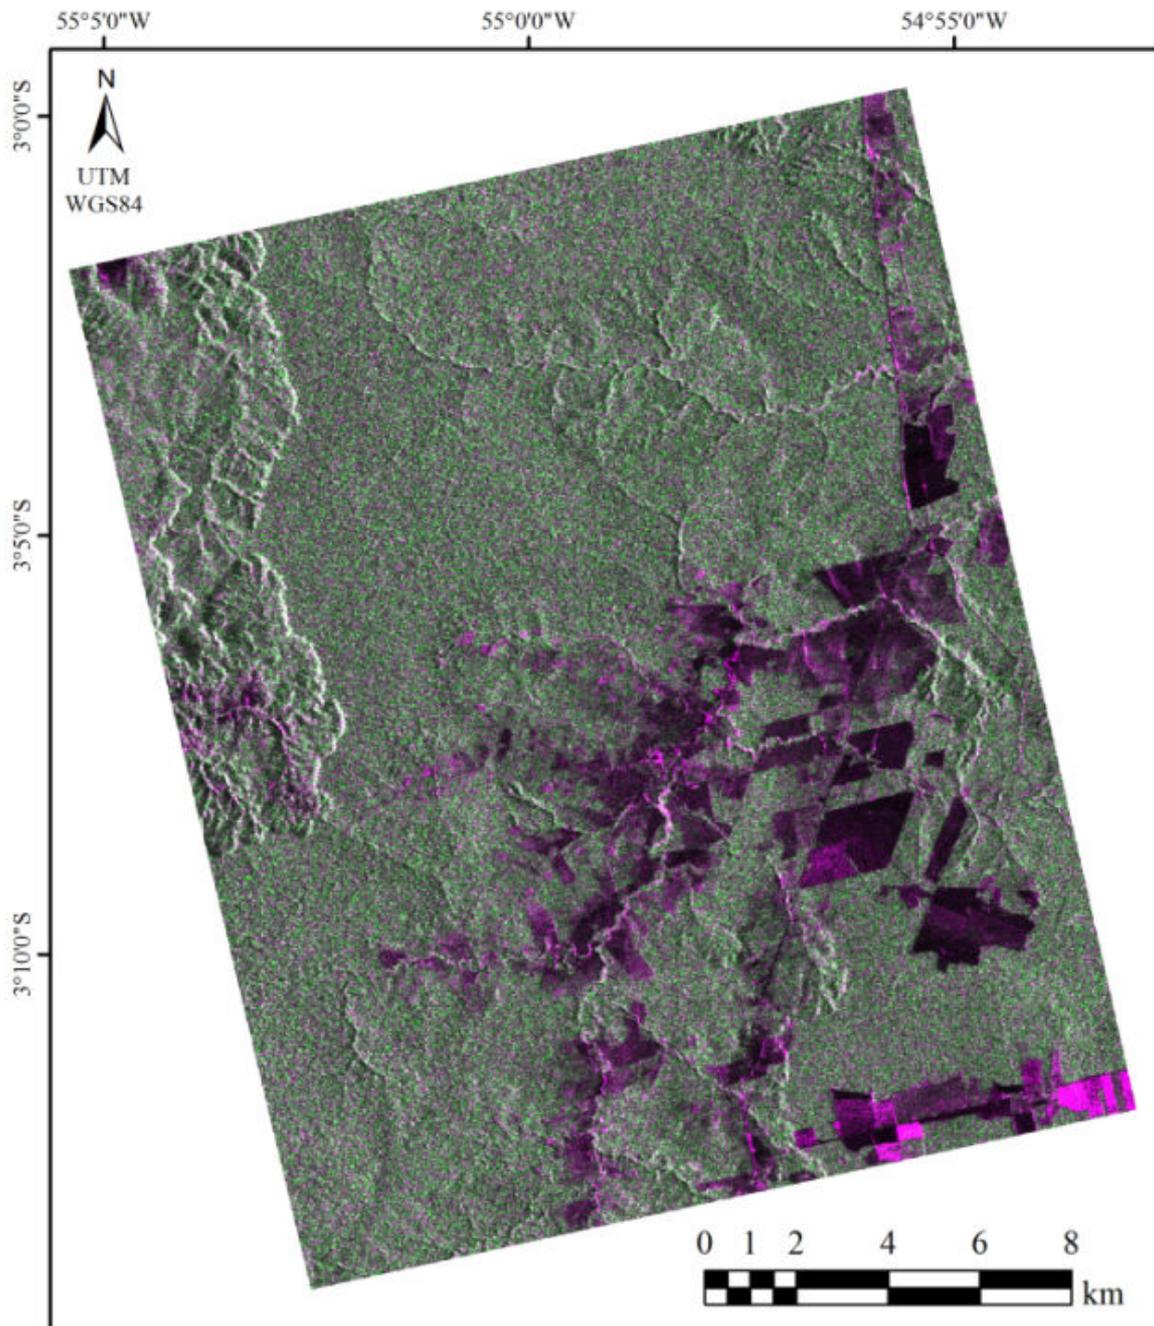
Estimou-se o número equivalente de *looks* das imagens SAR resultantes por intermédio do *software* desenvolvido por Correia (1998). Para a imagem Palsar, o número equivalente de *looks* encontrado foi 5 e para a imagem Radarsat o número equivalente de *looks* encontrado foi 8.

Figura 5.3 – Imagem TM na composição 5(R)4(G)3(B).



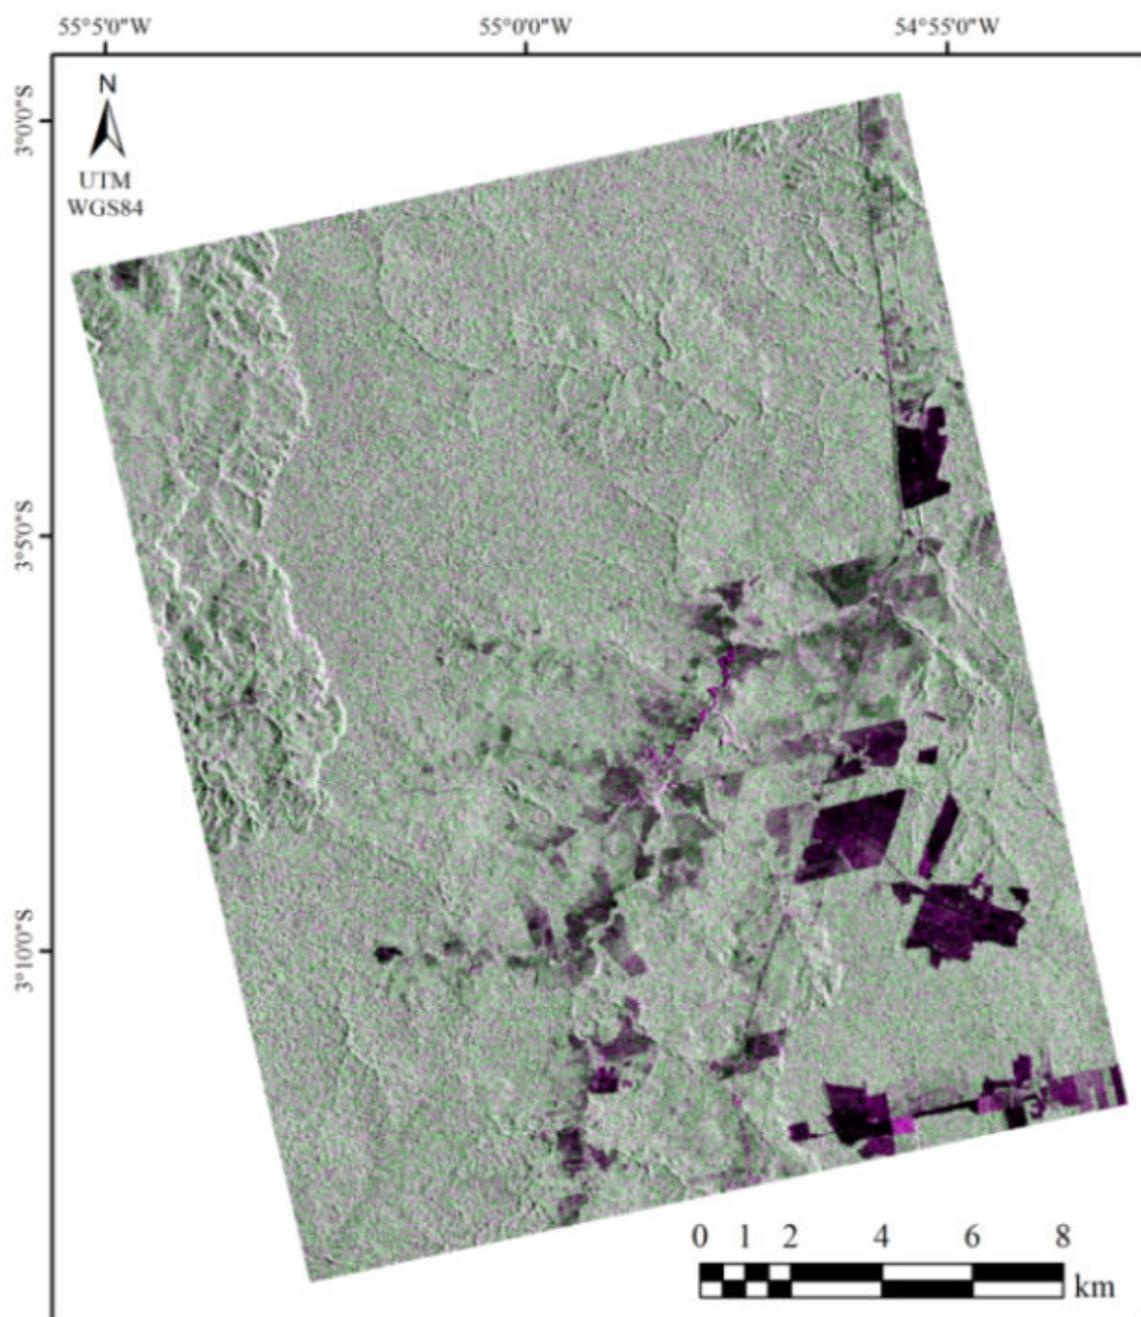
Fonte: Produção do autor.

Figura 5.4 – Imagem Palsar na composição $hh(R)hv(G)hh(B)$.



Fonte: Produção do autor.

Figura 5.5 – Imagem Radarsat na composição $hh(R)hv(G)hh(B)$.



Fonte: Produção do autor.

5.2.2. Segmentação da imagem

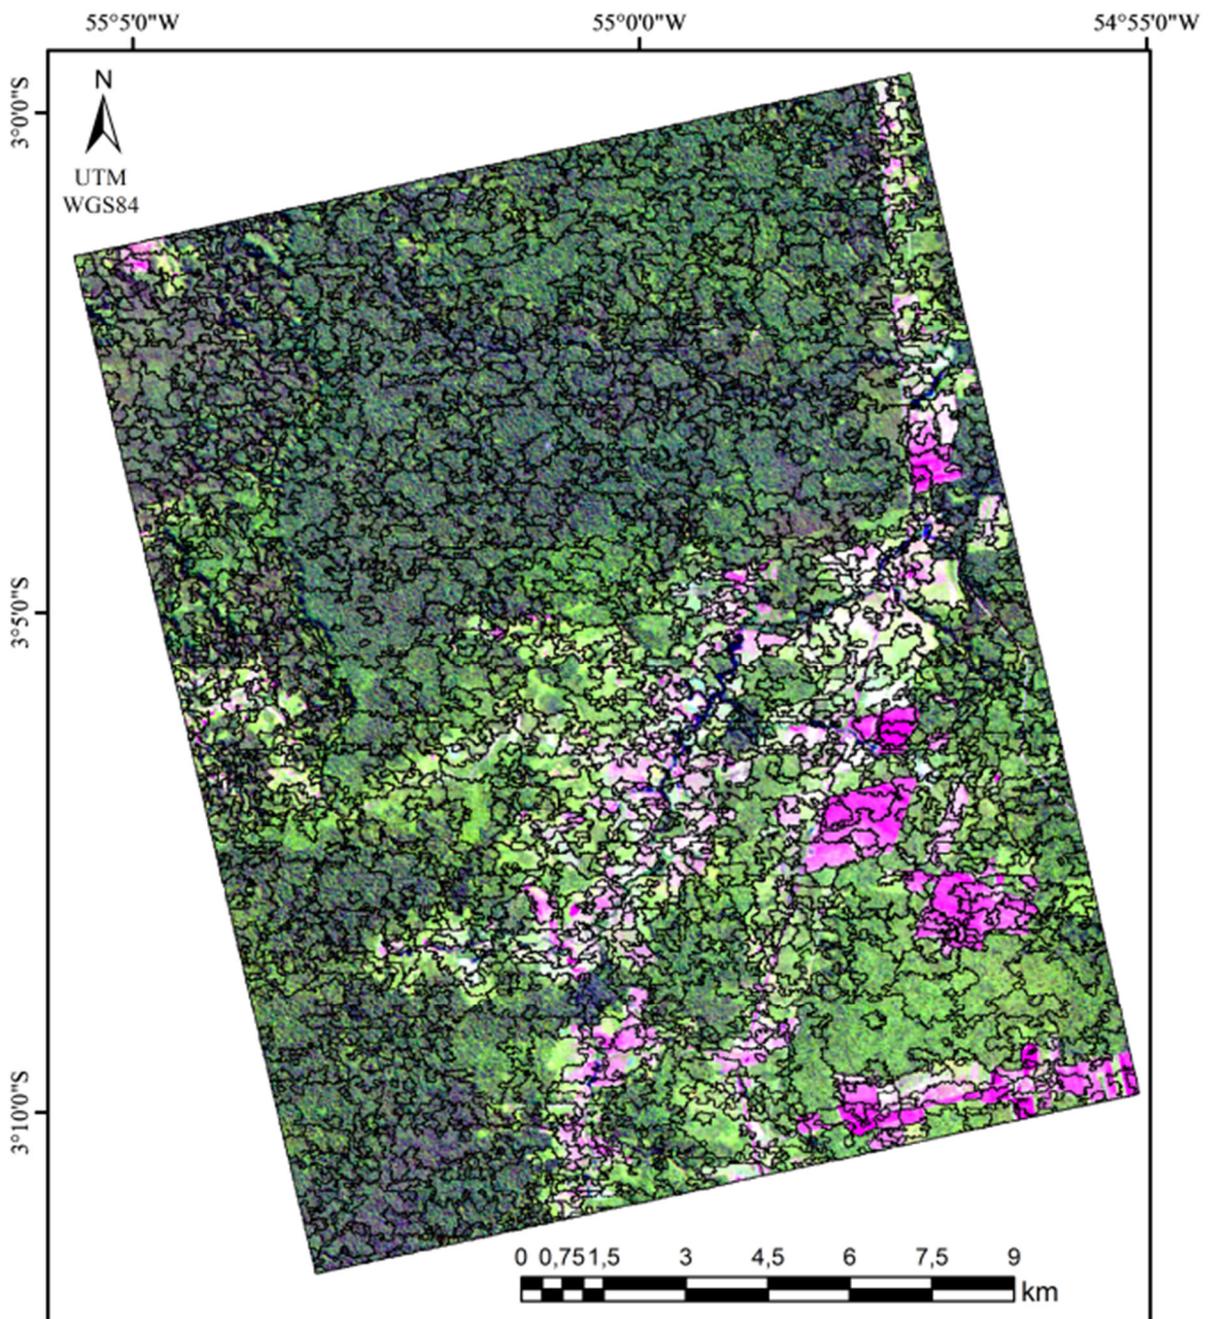
O processo de segmentação consiste em subdividir uma imagem em regiões homogêneas considerando-se alguns de seus atributos, como por exemplo, o nível de cinza dos pixels e a textura, visando caracterizar a representatividade dos objetos da cena (BINS *et al.*, 1996). Um ponto importante e fundamental em todo o processo de classificação multifonte proposto está diretamente relacionado à segmentação utilizada como dado de entrada. Dadas w imagens provenientes de fontes distintas, são geradas w segmentações individuais relativas a cada uma das imagens. Neste trabalho de dissertação, a segmentação é gerada a partir da operação lógica da união das w segmentações das imagens provenientes das fontes distintas. Posteriormente, aplica-se um filtro de áreas mínimas de forma a se determinar o número mínimo de pixels em cada segmento da imagem.

A segmentação de cada uma das imagens foi obtida por meio do *software* SegSAR (SOUSA JR, 2005). Este segmentador de imagens ópticas e de radar utiliza técnicas de agrupamento e crescimento de regiões, detecção de bordas, teste de homogeneidade e teste de área mínima e forma integradas a uma estrutura de compressão piramidal (REIS, 2014). Nele é possível o processamento utilizando-se uma ou mais bandas da imagem além de permitir a escolha entre dois modelos para representação dos dados: manchas e texturas. O primeiro baseia-se na hipótese de que a imagem é formada por regiões uniformes, enquanto o segundo considera que a imagem possa ser formada por regiões com textura.

Para a segmentação das imagens SAR, utilizaram-se as suas respectivas 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 e vv . Para a segmentação da imagem TM, também no SegSAR, todas as bandas foram consideradas e utilizou-se o modelo de manchas em sete níveis, similaridade 16,0db, coeficiente de variação 0,6 e área mínima de 20 pixels.

As segmentações das imagens 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 pode ser vista na Figura 5.6.

Figura 5.6 – Segmentação unificada sobreposta à imagem TM na composição colorida 5(R)4(G)3(B).



Fonte: Produção do autor.

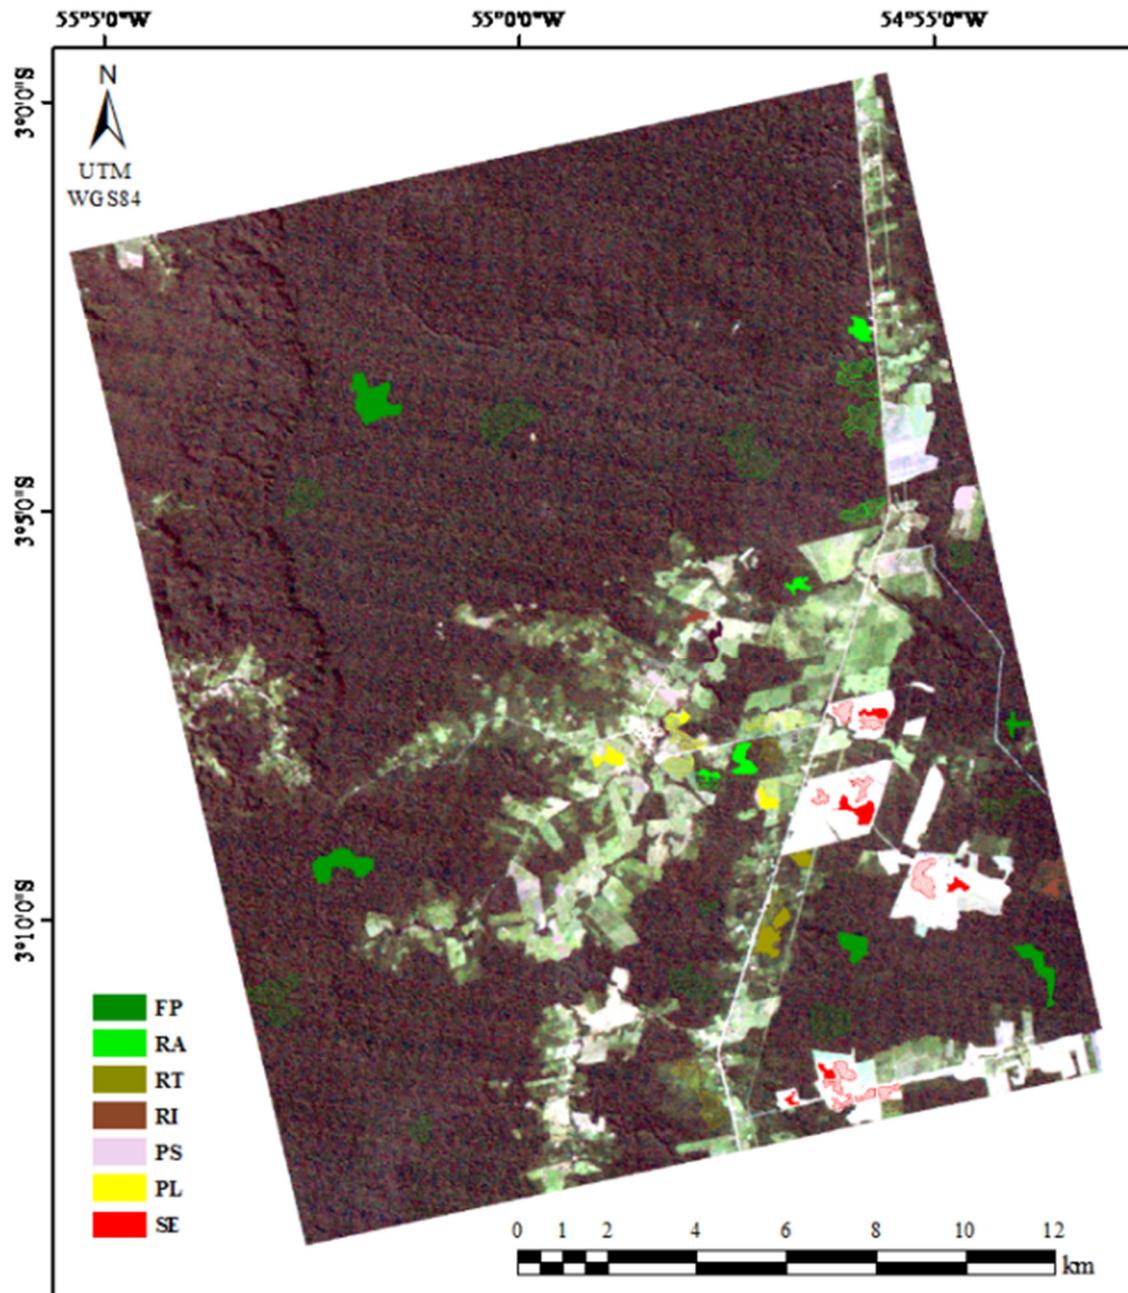
5.2.3. Coleta das amostras de treinamento e teste

A partir de vários trabalhos elaborados nesta área de estudo (GUERRA, 2008; ABOUD NETA, 2009; PEREIRA, 2012; PEREIRA et. al., 2013; REIS, 2014), bem como dos trabalhos de campo já realizados, nota-se que existem diversas classes de uso e cobertura da terra presentes nesta região. Para fins de classificação adotaram-se sete classes de uso e cobertura da terra. São elas: Floresta Primária (FP), Regeneração Antiga (RA), Regeneração Intermediária (RT), Regeneração Inicial (RI), Pasto Sujo (PS), Pasto Limpo (PL) e Solo Exposto (SE). Uma descrição simplificada das classes utilizadas neste trabalho pode ser encontrada, por exemplo, em Reis (2014) e é dada por:

- **Floresta Primária:** floresta em que a ação humana não provocou ações significativas em suas características originais de estrutura e espécies;
- **Regeneração Antiga:** florestas secundárias em avançado estágio de desenvolvimento, com predomínio de árvores geralmente entre 13 e 17 m, mais ocorrência de árvores emergentes e, em menor grau, arbustos e herbáceas;
- **Regeneração Intermediária:** áreas com presença de vegetação secundária com poucas espécies herbáceas e predominância de árvores de pequeno porte e arbustos;
- **Regeneração Inicial:** áreas de vegetação secundária com predominância de herbáceas e arbustos;
- **Pasto Sujo:** áreas com vegetação típica de pastagens, com presença de espécies arbustivas, árvores e espécies invasoras;
- **Pasto Limpo:** áreas com vegetação típica de pastagens, com predomínio de herbáceas;
- **Solo Exposto:** áreas predominantemente de solo sem nenhum tipo de cobertura vegetal.

Para fins de classificação foram selecionadas amostras das 7 classes acima mencionadas. As amostras de treinamento e amostras de teste foram obtidas por meio de dados de campos realizados em 2009 e 2015, com base na imagem LANDSAT5/TM. A localização das amostras coletadas, ao longo da imagem TM é ilustrada na Figura 5.7. Na Tabela 5.5, são mostrados o número de polígonos e o respectivo número de pixels das amostras de treinamento e das amostras de teste de cada classe de interesse.

Figura 5.7 – Localização das amostras de Treinamento (polígonos hachurados) e Teste (polígonos sólidos) sobre imagem TM na composição colorida 1(R)2(G)3(B).



Fonte: Produção do autor.

Tabela 5.5 - Especificações das amostras coletadas.

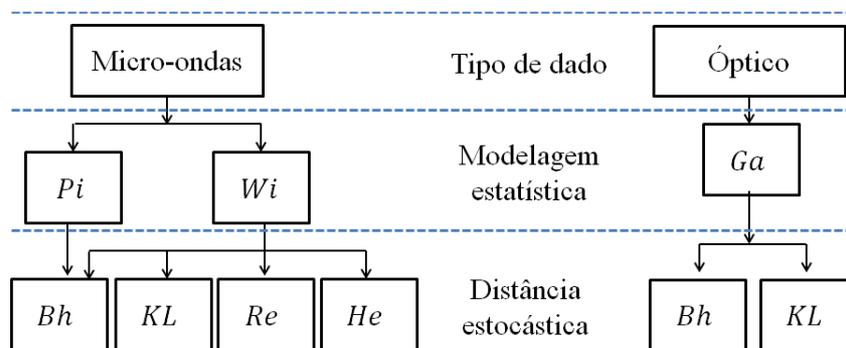
Classes	Amostras de Treinamento	Amostras de Teste
	#Polígonos / #Pixels	#Polígonos / #Pixels
Floresta Primária (FP)	10 / 18789	5 / 9402
Regeneração Antiga (RA)	7 / 4747	4 / 2684
Regeneração Intermediária (RT)	6 / 3478	3 / 2110
Regeneração Inicial (RI)	4 / 1076	2 / 834
Pasto Sujo (PS)	10 / 3518	5 / 1762
Pasto Limpo (PL)	8 / 2996	4 / 1639
Solo Exposto (SE)	10 / 4661	5 / 2345

Fonte: Produção do autor.

5.2.4. Modelagem estatística dos dados e Cenários de classificação

A modelagem das imagens adotadas nesta dissertação e os Cenários de classificação construídos são descritos nesta seção. Na Figura 5.8, apresentam-se os dados utilizados, as diferentes modelagens empregadas para o tratamento de cada um destes dados e as distâncias estocásticas aplicadas a cada uma destas modelagens. As siglas Ga , Pi , Wi correspondem aos modelos de distribuição Gaussiana multivariada, Par de intensidades *multi-look* e *Wishart* complexa escalonada, respectivamente. As abreviaturas Bh , KL , Re , He representam nesta ordem as distâncias de *Bhattacharyya*, *Kullback-Leibler*, *Rényi* de ordem β e *Hellinger*. Seguindo-se a metodologia desenvolvida por Silva (2013), para a distância de *Rényi* considerou-se $\beta=0,9$.

Figura 5.8 – Visão geral da modelagem dos dados.



Fonte: Produção do autor.

Como se pode notar, o dado óptico possui uma única modelagem e duas fórmulas para o cálculo de distâncias enquanto os dados de micro-ondas ora podem ser modelados pela distribuição Par de intensidades *multi-look*, ora pela distribuição *Wishart* complexa escalonada. Para a primeira modelagem dos dados SAR utiliza-se somente a distância de *Bhattacharyya* e para a segunda é possível a aplicação de quatro diferentes distâncias. Portanto, observa-se que é possível formar 2 classificações com modelagens distintas para dados ópticos e 5 para dados de micro-ondas, totalizando 12 classificações, as quais correspondem aos 12 Cenários monofontes distintos para as imagens desta dissertação.

Por intermédio de grupos constituídos por duas ou três imagens, das quais se originam esses Cenários monofontes, constrói-se um total de 95 combinações multifontes, considerando que a distância é a mesma para a combinação de sensor. Entre as combinações possíveis para geração de Cenários multifontes, utilizaram-se neste trabalho as 10 combinações apresentadas na Tabela 5.7. As siglas *P*, *R* e *T* representam as imagens Palsar, Radarsat e TM, respectivamente. A notação utilizada para as combinações t a t entre w imagens é a seguinte: {Imagem 1, Modelagem 1, distância 1;...; Imagem t , Modelagem t , distância t }. Para o caso em que $t = 1$ tem-se uma combinação monofonte, para $1 < t \leq w$ tem-se combinações multifontes.

Para fins de comparação, para cada uma das 12 combinações monofontes presentes na Tabela 5.7, foi criado um Cenário monofonte por intermédio da metodologia descrita na Subseção 2.4.2. Como já mencionado, considera-se um Cenário de classificação um conjunto formado pela classificação da imagem e seus respectivos mapas de confiabilidade (mapa de possibilidade e mapa de probabilidade). Ressalta-se que, as classificações monofontes obtidas são similares às classificações obtidas por intermédio do classificador PolClass, desenvolvido por Silva (2013).

Para origem dos Cenários multifontes, seguiram-se os passos apresentados no Capítulo 4. Neste caso, para cada uma das 10 combinações multifontes exibidas na Tabela 5.7 obtiveram-se os três Cenários multifontes, da soma, dos mínimos e do produto. O Cenário multifonte *Fuzzy*, originado da combinação IV entre as imagens TM e Radarsat, apresenta-se como um Cenário extra e é exibido como um exemplo. Devido a suas particularidades tornou-se inviável a criação deste Cenário para todas as combinações nesta dissertação. Para abordagem deste Cenário, foram geradas vinte e oito classes *Fuzzy*, denominadas por FP_FP, FP_RA, FP_RT, FP_RI, FP_PS, FP_PL, FP_SE, RA_RA,

RA_RT, RA_RI, RA_PS, RA_PL, RA_SE, RT_RT, RT_RI, RT_PS, RT_PL, RT_SE, RI_RI, RI_PS, RI_PL, RI_SE, PS_PS, PS_PL, PS_SE, PL_PL, PL_SE, SE_SE.

Ressalta-se que nas combinações em que a modelagem das imagens SAR deu-se por intermédio da distribuição Par de intensidades *multi-look*, as polarizações *vv* e *hv* foram adotadas para compor o par de intensidades, pois, comparadas às outras combinações (*hh_hv*, *hh_vv*) foi a que obteve os melhores índices de acurácia (coeficiente *Kappa* e acurácia global) para ambas as imagens, Palsar e Radarsat.

Tabela 5.7 – Combinações para construção dos Cenários multifontes.

Combinação	Imagem	Modelagem	Distância estocástica	Multifonte	Monofonte
I	P	Wi	Re	{P, Wi, Re; R, Wi, Re}	{P, Wi, Re}
	R				{R, Wi, Re}
II	P	Wi	Bh	{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh}	{P, Wi, Bh}
	R				
	T	Ga			
III	P	Wi	Bh	{P, Wi, Bh; T, Ga, Bh}	{R, Wi, Bh}
	T	Ga			
IV	R	Wi	Bh	{R, Wi, Bh; T, Ga, Bh}	{T, Ga, Bh}
	T	Ga			
V	P	Wi	Bh	{P, Wi, Bh; R, Wi, Bh}	
	R				
VI	P	Wi	KL	{P, Wi, KL; T, Ga, KL}	{P, Wi, KL}
	T	Ga			
VII	R	Wi	KL	{R, Wi, KL; T, Ga, KL}	{R, Wi, KL}
	T	Ga			
VIII	P	Wi	KL	{P, Wi, KL; R, Wi, KL}	
	R				
IX	P	Pi	Bh	{P, Pi, Bh; R, Pi, Bh}	{P, Pi, Bh}
	R				{R, Pi, Bh}
X	P	Wi	He	{P, Wi, He; R, Wi, He}	{P, Wi, He}
	R				{R, Wi, He}

Fonte: Produção do autor.

No capítulo atual, apresentaram-se os materiais e métodos adotados nesta dissertação. No capítulo a seguir apresentam-se os principais resultados obtidos por intermédio da metodologia de classificação multifonte proposta.

6 RESULTADOS

Neste capítulo, apresentam-se os resultados obtidos assim como suas análises. Os resultados são exibidos em quatro etapas. Na primeira, analisaram-se as classificações monofontes e selecionaram-se aquelas que apresentaram os maiores índices de acurácia. Nesta fase, examinaram-se também a influência da modelagem estatística e da distância estocástica no tratamento de cada uma das imagens. Na segunda etapa, foram construídos e analisados os Cenários multifontes teóricos da soma. Na terceira foram gerados e avaliados os Cenários multifontes empíricos dos mínimos, do produto e *Fuzzy*. Por fim, na última etapa, fez-se um breve estudo acerca da influência de dados SAR bivariados e polarimétricos nos resultados de classificação. As etapas citadas são descritas nas seções a seguir.

6.1. Avaliação dos Cenários monofontes

Inicialmente, para verificação da hipótese de independência entre os sensores, calculou-se a matriz de correlação de Pearson entre as bandas das imagens provenientes dos sensores em questão. Os baixos valores encontrados refletem a ausência de correlação linear entre as bandas das imagens em estudo e possivelmente sugerem independência entre os respectivos sensores. A matriz contendo os resultados calculados pode ser visualizada no Apêndice A. Após a verificação de independência, construíram-se as 12 classificações monofontes descritas na Tabela 5.7. Posteriormente, selecionaram-se aquelas que apresentaram os maiores índices de acurácia da classificação a fim de construírem-se, por intermédio de combinações destas, as classificações multifontes.

Como parte do processo de avaliação, examinaram-se a influência da distribuição utilizada para a modelagem dos dados assim como a intervenção da distância estocástica adotada nos resultados obtidos. Para a validação das classificações, se utilizaram índices de acurácias adquiridos por intermédio da Matriz de confusão, normalmente computada para validação da classificação por meio das amostras de testes. Neste trabalho, esses índices são representados pelo coeficiente *Kappa* e pela acurácia global. Na Tabela 6.1, são exibidos os coeficientes *Kappas*, as variâncias dos *Kappas* e as acurácias globais correspondentes a cada uma das classificações produzidas.

Analisando-se as medidas computadas, observa-se que os índices de acurácia apresentaram valores muito baixos. Entre as possíveis fontes de erros que podem esclarecer os resultados obtidos, citam-se, escolha inadequada da distribuição por meio da qual se modelaram os dados (ou seja, os dados não se comportam como as distribuições supostas), seleção de distâncias pouco “efetivas” entre distribuições, não adoção da *f.d.p.* conjunta que considera a correlação não-linear entre sensores (sensores não independentes), autocorrelação entre os dados (que justifica os baixos valores de variância do *Kappa* obtido), incerteza na coleta das amostras, data de aquisição das imagens e a definição das classes em estudo, que de fato, pode explicar os baixos índices relativos às classificações da imagem Palsar que, diferente das outras imagens, foi adquirida no período em que era maior a presença de áreas agrícolas. Embora os resultados obtidos possam ter sido afetados por tais fatores, ainda assim a metodologia multifonte foi aplicada em busca de possíveis contribuições nas classificações individuais, porém, é importante enfatizar que como consequência, os itens listados também se refletem nos resultados obtidos por meio da metodologia proposta.

Analisando os resultados obtidos na classificação da imagem TM, modelada por meio da distribuição Gaussiana multivariada, nota-se que ao variar as distâncias de *Bhattacharyya* e *Kullback-Leibler*, a acurácia global e coeficiente *Kappa*, nesta ordem, apresentam valores 1,7% e 1% superiores para a distância de *Bhattacharyya*. Tais valores podem ser visualizados na Tabela 6.1.

Tabela 6.1 – Coeficiente *Kappa* e acurácia global relativos às classificações monofontes.

Cenários monofontes	<i>Kappa</i>	Variância do <i>Kappa</i>	Acurácia global (%)
{ <i>T, Ga, Bh</i> }	0,50	$1,31 \times 10^{-5}$	60,58
{ <i>T, Ga, KL</i> }	0,49	$1,34 \times 10^{-5}$	58,88
{ <i>P, Wi, Re</i> }	0,11	$1,05 \times 10^{-5}$	20,52
{ <i>P, Wi, KL</i> }			
{ <i>P, Wi, Bh</i> }	0,14	$1,07 \times 10^{-5}$	22,72
{ <i>P, Wi, He</i> }			
{ <i>P, Pi, Bh</i> }	0,14	$1,12 \times 10^{-5}$	23,09
{ <i>R, Wi, Re</i> }	0,31	$1,31 \times 10^{-5}$	39,46
{ <i>R, Wi, Bh</i> }			
{ <i>R, Wi, KL</i> }			
{ <i>R, Wi, He</i> }			
{ <i>R, Pi, Bh</i> }	0,19	$1,21 \times 10^{-5}$	30,14

Fonte: Produção do autor.

Na Tabela 6.2, é possível analisar a acurácia por classe e erros cometidos ao variarem-se as modelagens e distâncias para cada uma das imagens. Nesta tabela, as maiores acurácias são destacadas assim como os menores erros de comissão e omissão.

Ainda em relação à imagem TM, para as classes Floresta Primária, Pasto Limpo e Pasto Sujo, as acurácias por classe apresentaram valores distintos ao alterarem-se as distâncias enquanto para as outras classes os valores permaneceram idênticos. Independente da distância adotada, as classes Regeneração Antiga e Solo Exposto não sofreram alterações nos valores de erros de comissão e omissão. Para as classes Regeneração Intermediária e Regeneração Inicial, somente os erros de comissão sofreram pequenas variações de acordo com a distância utilizada. Para a classe Floresta Primária, além da acurácia por classe, os erros de omissão foram modificados com a diferente modelagem dos dados. As classes Pasto Sujo e Pasto Limpo sofreram transformações em todos os índices envolvidos.

Para a imagem TM os menores erros de comissão para as classes Pasto Limpo e Pasto Sujo estão presentes nos Cenários baseados na distância de *Kullback-Leibler*. Para as classes Regeneração Intermediária e Regeneração Inicial, os menores erros de comissão ocorrem quando a distância de *Bhattacharyya* é utilizada. Para as outras classes os erros de comissão são superiores ou iguais àqueles apresentados para a distância de *Bhattacharyya*. Os menores erros de omissão ocorrem para as classes Floresta Primária e Pasto Limpo quando adota-se a distância de *Bhattacharyya* e para a classe Pasto Sujo quando adota-se a distância de *Kullback-Leibler*. Para as outras classes os erros são os mesmos para ambas as distâncias. Desta forma, conclui-se que, de modo geral, a modelagem Gaussiana multivariada para a imagem TM apresenta resultados ligeiramente mais favoráveis quando se adota a distância de *Bhattacharyya*.

Fixando-se a distribuição *Wishart* para modelagem da imagem Palsar e variando-se as distâncias, observam-se na Tabela 6.1 os mesmos resultados de acurácia e coeficiente *Kappa* para as classificações monofontes $\{P, Wi, Re\}$ e $\{P, Wi, KL\}$ relativas às distâncias *Rényi* de ordem β e *Kullback-Leibler*, assim como se notam os mesmos valores para estes índices nas classificações monofontes $\{P, Wi, Bh\}$ e $\{P, Wi, He\}$, em que se utilizam as distâncias de *Bhattacharyya* e *Hellinger*. As medidas presentes na Tabela 6.2 também são idênticas para esses pares de imagens.

Tabela 6.2 – Acurácia por classe e erros relativos às classificações monofontes para as classes em estudo.

Cenários monofontes																					
Percentual: acurácia (A), erro de comissão (C) e erro de omissão (O)																					
Classes	FP			RA			RT			RI			PS			PL			SE		
Monofontes	A	C	O	A	C	O	A	C	O	A	C	O	A	C	O	A	C	O	A	C	O
{T, Ga, Bh}	68,10	0,00	31,90	18,11	86,05	81,89	100,00	38,39	0,00	45,08	84,56	54,92	9,31	86,14	90,69	52,35	48,16	47,65	93,39	0,00	6,61
{T, Ga, KL}	62,45	0,00	37,55	18,11	86,05	81,89	100,00	46,66	0,00	45,08	85,03	54,92	23,67	70,96	76,33	47,71	41,03	52,29	93,39	0,00	6,61
{P, Wi, Re}	5,65	41,46	94,35	50,04	81,39	49,96	100,00	23,96	0,00	0,00	100,00	100,00	15,83	83,69	84,17	0,00	100,00	100,00	0,00	0,00	100,00
{P, Wi, KL}	5,65	41,46	94,35	50,04	81,39	49,96	100,00	8,93	0,00	54,92	92,04	45,08	15,83	83,69	84,17	0,00	100,00	100,00	0,00	0,00	100,00
{P, Wi, He}	5,65	41,46	94,35	50,04	81,39	49,96	100,00	8,93	0,00	54,92	92,04	45,08	15,83	83,69	84,17	0,00	100,00	100,00	0,00	0,00	100,00
{P, Pi, Bh}	5,65	41,46	94,35	5,65	41,46	94,35	100,00	8,93	0,00	54,92	89,73	45,08	15,83	82,94	84,17	4,64	97,42	95,36	0,00	0,00	100,00
{R, Wi, Re}	28,27	15,46	71,73	0,00	100,00	100,00	100,00	38,01	0,00	54,92	94,76	45,08	23,67	71,90	76,33	87,37	16,31	12,63	47,89	19,09	52,11
{R, Wi, Bh}	28,27	15,46	71,73	0,00	100,00	100,00	100,00	38,01	0,00	54,92	94,76	45,08	23,67	71,90	76,33	87,37	16,31	12,63	47,89	19,09	52,11
{R, Wi, KL}	28,27	15,46	71,73	0,00	100,00	100,00	100,00	38,01	0,00	54,92	94,76	45,08	23,67	71,90	76,33	87,37	16,31	12,63	47,89	19,09	52,11
{R, Wi, He}	28,27	15,46	71,73	0,00	100,00	100,00	100,00	38,01	0,00	54,92	94,76	45,08	23,67	71,90	76,33	87,37	16,31	12,63	47,89	19,09	52,11
{R, PI, Bh}	33,92	21,18	66,08	0,00	100,00	100,00	24,50	71,45	75,50	54,92	95,99	45,08	0,00	0,00	100,00	87,37	37,28	12,63	28,36	19,78	71,64

Fonte: Produção do autor.

Observa-se que, de forma geral, adotando-se a distribuição *Wishart* complexa escalonada para a modelagem da imagem Palsar, as distâncias entre distribuições que apresentam os maiores índices *Kappas* e as maiores acurácias globais são as distâncias de *Bhattacharyya* e *Hellinger*. Sendo esses valores 3% e 2,2% superiores àqueles apresentados quando se adotam as distâncias *Rényi* de ordem β e *Kullback-Leibler* respectivamente. Comparando os valores presentes na Tabela 6.2 entre si, verifica-se que, para a classe Regeneração Inicial, o maior valor de acurácia e menores erros de omissão e comissão correspondem aos resultados em que se optou pelas distâncias de *Bhattacharyya* e *Hellinger*. Neste caso também ocorreu o menor erro de comissão para a classe Regeneração Intermediária. Os outros resultados são os mesmos que aqueles apresentados pelas outras distâncias.

Ainda para a imagem Palsar, fixando-se a distância de *Bhattacharyya* e variando-se a distribuição para modelagem dos dados (*Wishart* complexa escalonada e Par de intensidades *multi-look*) nota-se que para ambas as modelagens obtêm-se índices *Kappas* iguais e, para a distribuição Par de intensidades *multi-look* a acurácia global é superior em 0,37% (Tabela 6.1). Analisando-se as acurácias por classe descobre-se que para a modelagem através do Par de intensidades *multi-look*, a classe Pasto Limpo possui acurácia superior em 4,64%. Os menores erros de comissão (melhoras inferiores a 2,6%) ocorrem para as classes Regeneração Antiga, Regeneração Inicial, Pasto Sujo e Pasto Limpo. Também ocorre menor erro de omissão para a classe Pasto Limpo nesta modelagem inferior em 4,64% em relação à modelagem *Wishart* complexa escalonada. A modelagem por intermédio da distribuição *Wishart*, apresenta valor de acurácia superior e menor erro de omissão para a classe Regeneração Antiga em relação à modelagem por meio do Par de Intensidades. Para os resultados restantes, os valores foram idênticos, independente da modelagem utilizada.

De maneira geral, observa-se que o tratamento da imagem Palsar por intermédio da modelagem *Wishart* independe das distâncias quando estas são *Rényi* de ordem β e *Kullback-Leibler* ou *Bhattacharyya* e *Hellinger*. Fixada a distância de *Bhattacharyya*, a variação na distribuição adotada não altera significativamente os índices de acurácia. Contudo, recomenda-se uma análise mais criteriosa baseada nos valores de acurácia por classe e erros de omissão e comissão para o caso em que existam interesses em classes específicas.

Para a imagem Radarsat, fixada a modelagem *Wishart* complexa escalonada baseada nas distâncias *Rényi* de ordem β , *Bhattacharyya*, *Kullback-Leibler* e *Hellinger*, nota-se por intermédio das

Tabelas 6.1 e 6.2 que os valores de acurácia global e acurácia por classe são idênticos assim como a porcentagem de erros de omissão e comissão para os Cenários monofontes construídos. Desta forma, conclui-se que, para a imagem Radarsat modelada por meio da distribuição *Wishart* complexa escalonada, o resultado de classificação obtido independe da distância entre distribuições escolhida.

Ainda para a mesma imagem, fixada a distância, no caso, *Bhattacharyya*, nota-se na Tabela 6.2 que, com a mudança da distribuição que modela os dados, obtêm-se resultados distintos. De modo geral, o resultado da acurácia global para a modelagem da imagem Radarsat por intermédio da distribuição *Wishart* possui valor superior à modelagem da mesma imagem por meio da distribuição Par de intensidades *multi-look*. Analisando-se os valores de acurácia global, observa-se uma melhora de 9,32%. Avaliando-se as acurácias por classe, percebe-se que para a classe Floresta Primária, a acurácia é 5,65% maior para a modelagem através do Par de intensidades *multi-look* em relação à modelagem *Wishart* complexa escalonada. Para as outras classes os resultados são iguais ou inferiores aos apresentados pela modelagem *Wishart*. Ainda para a modelagem por meio da distribuição Par de intensidades *multi-look*, o erro de comissão para a classe Pasto Sujo é 71,90% menor que o erro apresentado para a modelagem *Wishart* e o erro de omissão para a classe Floresta Primária é 5,65% menor que o erro apresentado pela modelagem *Wishart* para a classe em questão.

Assim, conclui-se que, os resultados de classificação obtidos para a imagem Radarsat pela modelagem *Wishart* independem das distâncias adotadas neste trabalho. Além disso, para a distância de *Bhattacharyya*, os maiores valores de acurácia ocorrem quando se adota a modelagem *Wishart* para tratamento dos dados. Da mesma forma, neste caso também se recomenda uma análise mais criteriosa quando o objeto em estudo trata-se de uma classe de interesse em específico.

Refletindo acerca de todos os resultados discutidos, chega-se a conclusão que as classificações monofontes mais adequados para construção das classificações multifontes são $\{T, Ga, Bh\}$, $\{P, Wi, Bh\}$ e $\{R, Wi, Bh\}$. Tal decisão baseia-se nos seguintes pontos:

- embora para a imagem TM, ambos o resultados apresentados possuam índices de acurácia muito próximos, devido às pequenas contribuições refletidas nos valores de acurácias por classes e erros de omissão, considerou-se a modelagem envolvendo a distância de *Bhattacharyya* entre distribuições Gaussianas multivariadas;

- para a imagem Palsar, fixada a distância de *Bhattacharyya*, as duas modelagens adotadas apresentam índices *Kappas* iguais e na modelagem *Wishart* complexa escalonada, os maiores resultados são obtidos utilizando-se as distâncias de *Bhattacharyya* ou *Hellinger*;
- para a imagem Radarsat modelada pela distribuição *Wishart* complexa escalonada, os índices de acurácia são superiores aqueles obtidos ao adotar-se a modelagem por meio da distribuição Par de intensidades e os resultados independem da distância escolhida;
- a adoção de tais classificações monofontes permite o estudo de um número maior de combinações entre aquelas apresentadas na Tabela 5.7.

Os Cenários monofontes correspondentes às classificações selecionadas são ilustrados nas Figuras 6.1 a 6.3. Nestas figuras a parte (a) representa a imagem classificada nas 7 classes de uso e cobertura do solo consideradas, na parte (b) apresenta-se o resultado da espacialização da estatística s (mapa de possibilidade ou mapa de incerteza da classificação), e na parte (c) se ilustra a matriz de confusão da classificação (onde o tamanho de cada círculo é proporcional ao valor de porcentagem correspondente). Os Cenários monofontes relativos às outras classificações construídas encontram-se no Apêndice B.

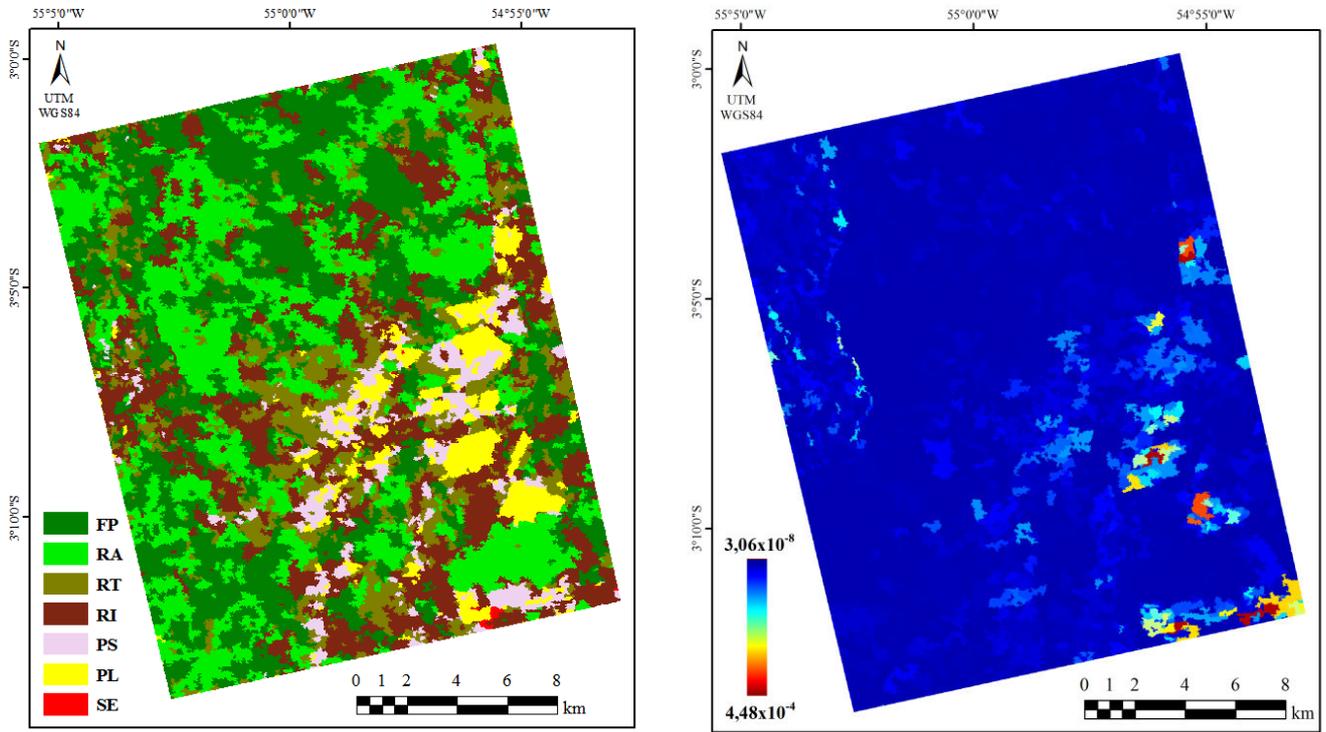
Analisando-se, de maneira geral os resultados de classificação entre os Cenários, verifica-se que, na classificação da imagem Palsar existe confusão na identificação da classe Solo Exposto. O fato ocorre, provavelmente devido à época em que a imagem foi adquirida. Sua data corresponde a épocas em que ocorre o cultivo de grãos em algumas regiões, divergindo da classe Solo Exposto. Como informação adicional, examinando-se a classificação da imagem Palsar relativa ao Cenário monofonte $\{P, Pi, Bh\}$, observou-se menor confusão para a classe Solo Exposto. Neste Cenário, a modelagem da imagem SAR deu-se por intermédio da distribuição Par de intensidades *multi-look*.

Quanto aos mapas de confiabilidade, adotou-se para análise dos resultados de classificação o mapa de possibilidade relativo à incerteza da classificação (quanto maior o valor s obtido, maior a incerteza da classificação). Na escala deste mapa apresentam-se os valores na ordem decrescente para fins de simplificação da interpretação da confiabilidade de classificação, uma vez que, para os mapas de possibilidade, quanto menor o valor s , maior a confiabilidade da classificação, o contrário ocorrendo para os mapas de probabilidade.

Existem vantagens em se ter duas grandezas representativas da confiabilidade da classificação. Para os casos em que os mapas de valores- p (mapas de probabilidade relativos à certeza da classificação) apresentam conteúdos não representativo, utilizam-se os mapas de possibilidade. Para os resultados obtidos neste trabalho, os mapas de probabilidade apresentaram valores nulos ou muito próximos de zero. Tal fato pode ser justificado pela possível existência de autocorrelação espacial entre os dados. Esse é um efeito característico na formação de imagens procedentes de sensores remotos. De acordo com os estudos desenvolvidos por Silva (2013), a autocorrelação espacial pode afetar os resultados de classificação de imagens, acarretando em mapas de valores- p não robustos. Esse efeito também se manifesta nas variâncias dos *Kappas* calculados onde se observam valores baixos uma vez que, os dados são redundantes quando é alta a autocorrelação espacial entre eles.

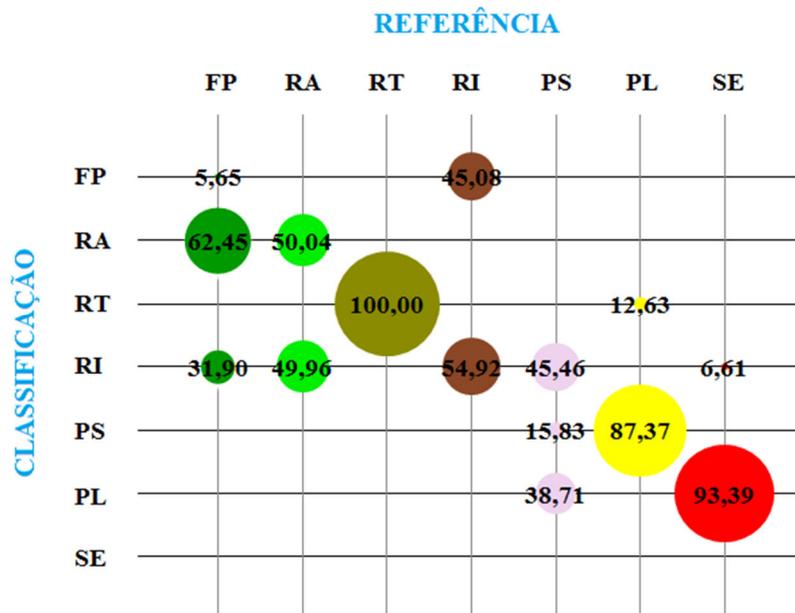
Na próxima seção, são descritas as classificações multifontes construídas por intermédio das classificações monofontes escolhidas nesta seção.

Figura 6.1 – Resultados para o Cenário monofonte $\{P, Wi, Bh\}$.



(a)

(b)

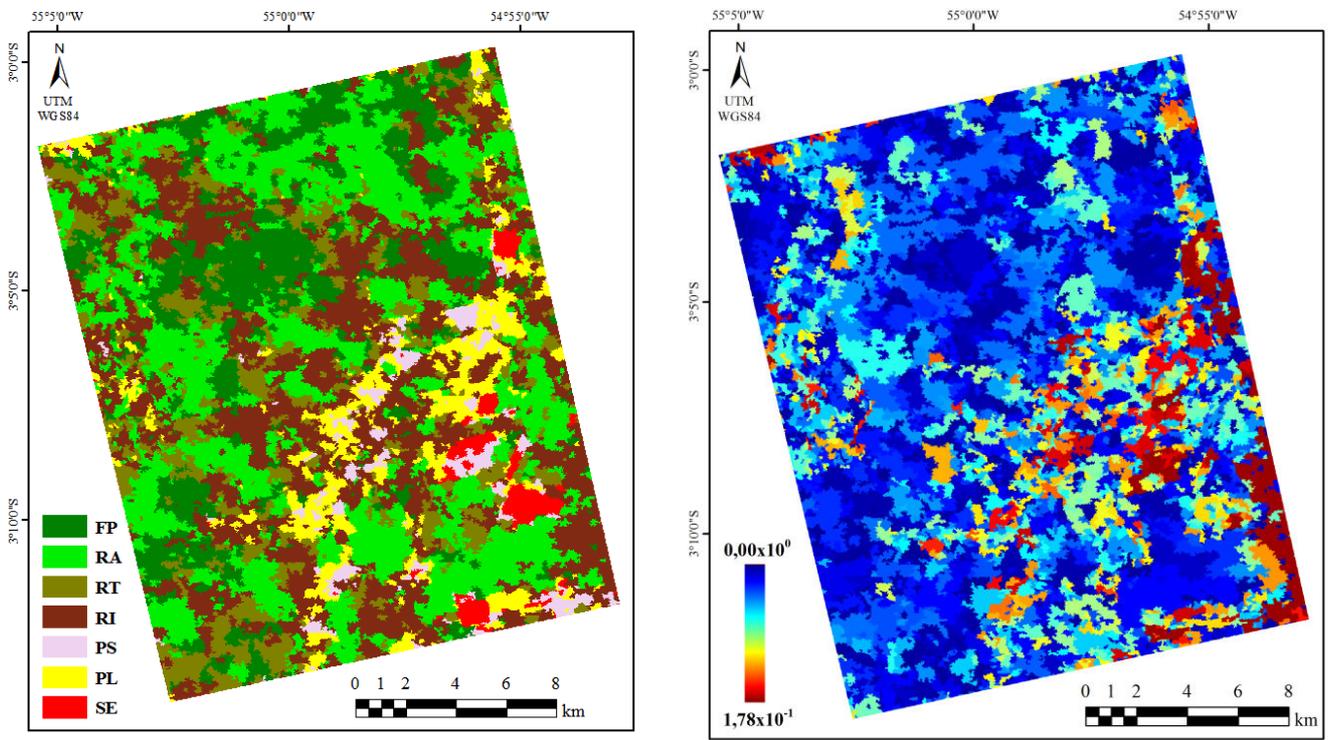


(c)

(a) Classificação; (b) Mapa de possibilidade e (c) Matriz de confusão.

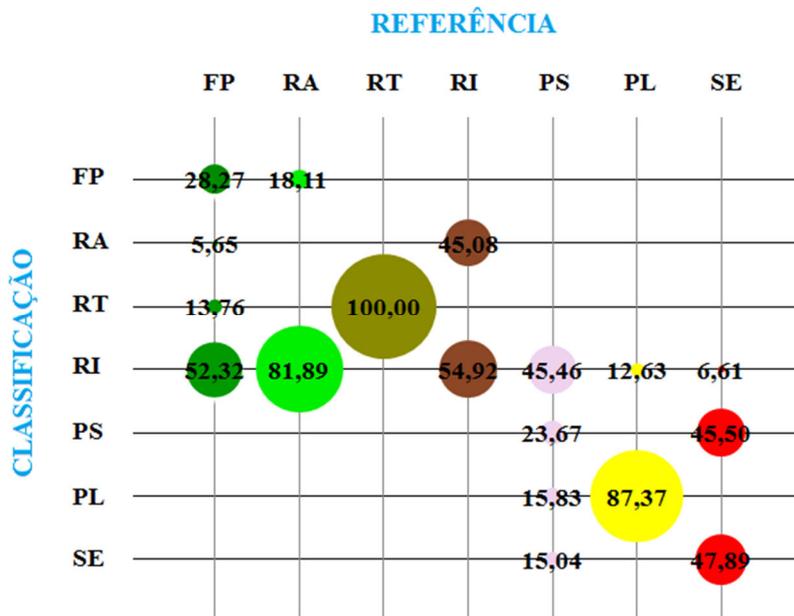
Fonte: Produção do autor.

Figura 6.2 – Resultados para o Cenário monofonte $\{R, Wi, Bh\}$.



(a)

(b)

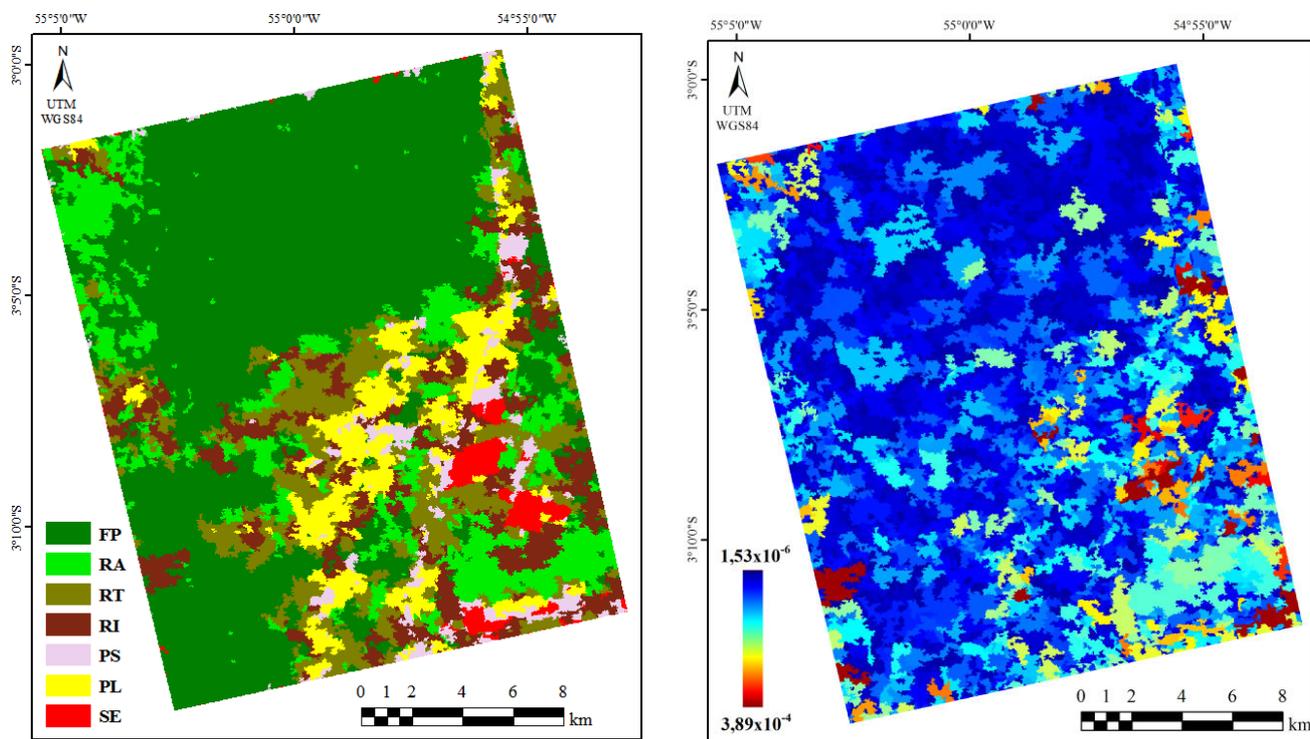


(c)

(a) Classificação; (b) Mapa de possibilidade e (c) Matriz de confusão.

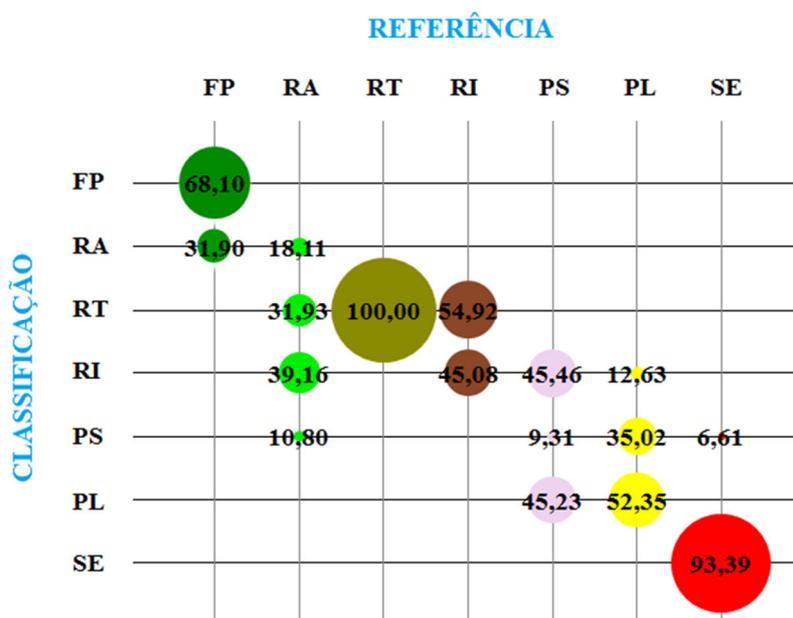
Fonte: Produção do autor.

Figura 6.3 – Resultados para o Cenário monofonte {*T, Ga, Bh*}.



(a)

(b)



(c)

(a) Classificação; (b) Mapa de possibilidade e (c) Matriz de confusão.

Fonte: Produção do autor.

6.2. Avaliação dos Cenários multifontes teóricos

Por intermédio das classificações monofontes selecionadas foram construídas quatro classificações multifontes teóricas da soma por meio das combinações II a V, $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$, $\{P, Wi, Bh; T, Ga, Bh\}$, $\{R, Wi, Bh; T, Ga, Bh\}$ e $\{P, Wi, Bh; R, Wi, Bh\}$. As classificações multifontes correspondentes às outras combinações podem ser visualizadas no Apêndice C. Os índices de acurácias estimados para as classificações multifontes resultantes encontram-se na Tabela 6.3.

Tabela 6.3 – Coeficiente *Kappa*, variância do *Kappa* e acurácia global relativos aos Cenários multifontes da soma.

Combinação	Multifontes	<i>Kappa</i>	Variância <i>Kappa</i>	Acurácia global (%)
II	$\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$	0,53	$1,27 \times 10^{-5}$	62,82
III	$\{P, Wi, Bh; T, Ga, Bh\}$	0,46	$1,34 \times 10^{-5}$	56,58
IV	$\{R, Wi, Bh; T, Ga, Bh\}$	0,51	$1,31 \times 10^{-5}$	60,70
V	$\{P, Wi, Bh; R, Wi, Bh\}$	0,36	$1,29 \times 10^{-5}$	44,27

Fonte: Produção do autor.

Observa-se que os índices de acurácia da classificação multifonte $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$ (combinação II) superaram os valores apresentados pelas três classificações monofontes. Os índices de acurácia relativos à classificação multifonte $\{P, Wi, Bh; T, Ga, Bh\}$ (combinação III) exibiram valores superiores àqueles encontrados na classificação monofonte $\{P, Wi, Bh\}$. Em relação à classificação da imagem TM os valores foram inferiores. Para a classificação multifonte $\{R, Wi, Bh; T, Ga, Bh\}$ (combinação IV), os índices de acurácia também foram superiores aos obtidos nas classificações individuais. Para a classificação multifonte $\{P, Wi, Bh; R, Wi, Bh\}$ (combinação V) os índices foram superiores a ambas as classificações monfontes $\{P, Wi, Bh\}$ e $\{R, Wi, Bh\}$. A partir do índice denominado Melhora Quantitativa da Classificação, do inglês *Quantitative Improvement of Classification (QIC)*:

$$QIC = \frac{k_b - k_a}{1 - k_a} \quad (6.1)$$

é possível avaliar o quanto o resultado de uma classificação (representado por k_b) pode ser melhorado relativamente ao resultado de outra classificação (representado por k_a)

(BRAGA *et al.*, 2015b). Utilizando-se os índices *Kappas* resultantes das classificações para o cálculo do *QIC* obtêm-se os resultados presentes na Tabela 6.4.

Tabela 6.4 – Melhora quantitativa das classificações monofontes em relação às classificações multifontes da soma.

Percentual da Melhora Quantitativa da Classificação			
Combinação / multifontes	Palsar { <i>P, Wi, Bh</i> }	Radarsat { <i>R, Wi, Bh</i> }	TM { <i>T, Ga, Bh</i> }
II / { <i>P, Wi, Bh; R, Wi, Bh; T, Ga, Bh</i> }	45	32	6
III / { <i>P, Wi, Bh; T, Ga, Bh</i> }	37	-	7↓
IV / { <i>R, Wi, Bh; T, Ga, Bh</i> }	-	29	2
V / { <i>P, Wi, Bh; R, Wi, Bh</i> }	26	7	-

Fonte: Produção do autor.

Observa-se que os resultados da classificação correspondente à imagem Palsar são melhorados 45% por meio da classificação multifonte II, 37% por meio da classificação multifonte III e 26% por intermédio da quinta classificação multifonte. Os resultados da classificação monofonte correspondente à imagem Radarsat apresentam melhores de 32% através da classificação multifonte II, 29% por meio da classificação multifonte IV e 7% por meio da classificação multifonte V. Os resultados da classificação monofonte relativa à imagem TM obtêm melhoras de 6% em relação à classificação multifonte II e 2% por meio da classificação multifonte IV. Em relação à classificação multifonte III não houve melhoras para a classificação da imagem TM.

Analisando os resultados, observa-se que os maiores índices de acurácias correspondem às classificações multifontes provenientes das combinações II e IV. Como consequência, tais classificações, apresentaram os maiores percentuais de *QIC* em relação às classificações monofontes. Para estudos específicos, recomenda-se a análise da Tabela 6.5.

Nota-se na Tabela 6.5, por exemplo, que para estudos envolvendo as classes Regeneração Inicial e Floresta Primária, a adoção das combinações II, III ou IV é indiferente para os resultados de classificação assim como, para o estudo das classes Regeneração Intermediária e Regeneração Antiga, a escolha entre as combinações II e III não influencia os mesmos resultados. Em ambos os casos, analisando-se as modelagens adotadas para as imagens em cada uma destas combinações, recomenda-se a utilização da combinação III para os estudos destas classes uma vez que:

- enquanto os resultados de classificação para a combinação IV se mantêm inalterados em relação à 2 classes, para as combinações II e III, estes resultados se mantêm para 4 classes;
- embora as combinações II e III apresentem um número maior de classes em que os resultados de classificação não se alteram, a combinação III envolve apenas duas imagens, Palsar e TM, reduzindo-se assim o custo para aquisição dos dados.

Os Cenários de classificação multifontes correspondentes às combinações II e IV, relativos aos melhores resultados obtidos, encontram-se nas Figuras 6.4 e 6.5. A comparação das acurácias por classe entre as classificações monofontes e multifontes é representada nas Figuras 6.6 e 6.7, em que as siglas CII e CIV representam as combinações II e IV, respectivamente. Nas Figuras 6.8 e 6.9 apresenta-se a relação entre os erros de omissão e comissão calculados para as classificações multifontes e as classificações monofontes. Ao contrário das análises realizadas com os valores de acurácias por classe, no caso dos erros, espera-se que estes sejam reduzidos. Os valores exatos correspondentes a cada um dos gráficos podem ser visualizados na Tabela 6.5. As siglas CP, CR, CT, CCII e CCIV representam os erros de comissão para as classificações monofontes relativas às imagens Palsar, Radarsat, TM e para as classificações multifontes da soma provenientes das combinações II e IV, nesta ordem. As siglas OP, OR, OT, OCII e OCIV referem-se aos erros de omissão para as classificações monofontes relativos às imagens Palsar, Radarsat, TM e para as classificações multifontes da soma provenientes das combinações II e IV, respectivamente.

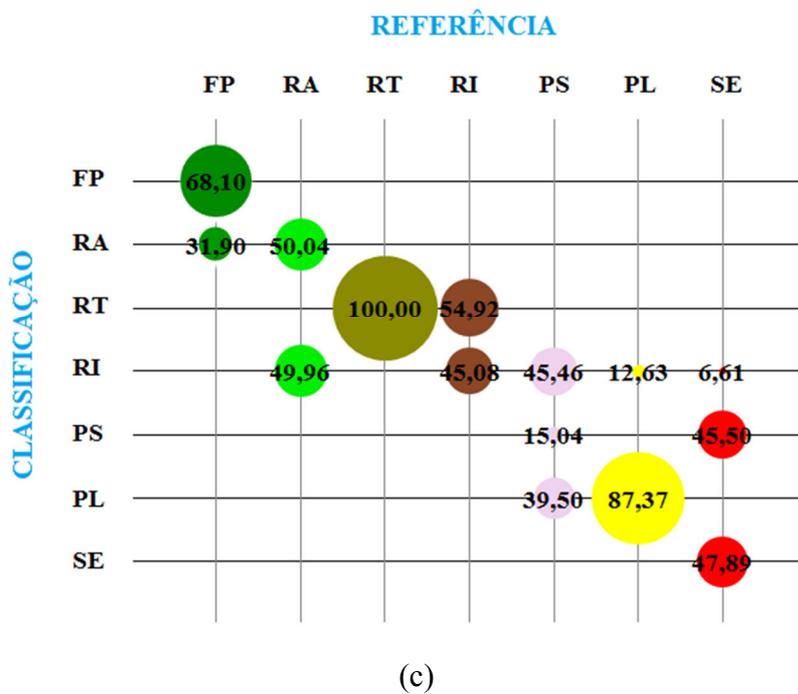
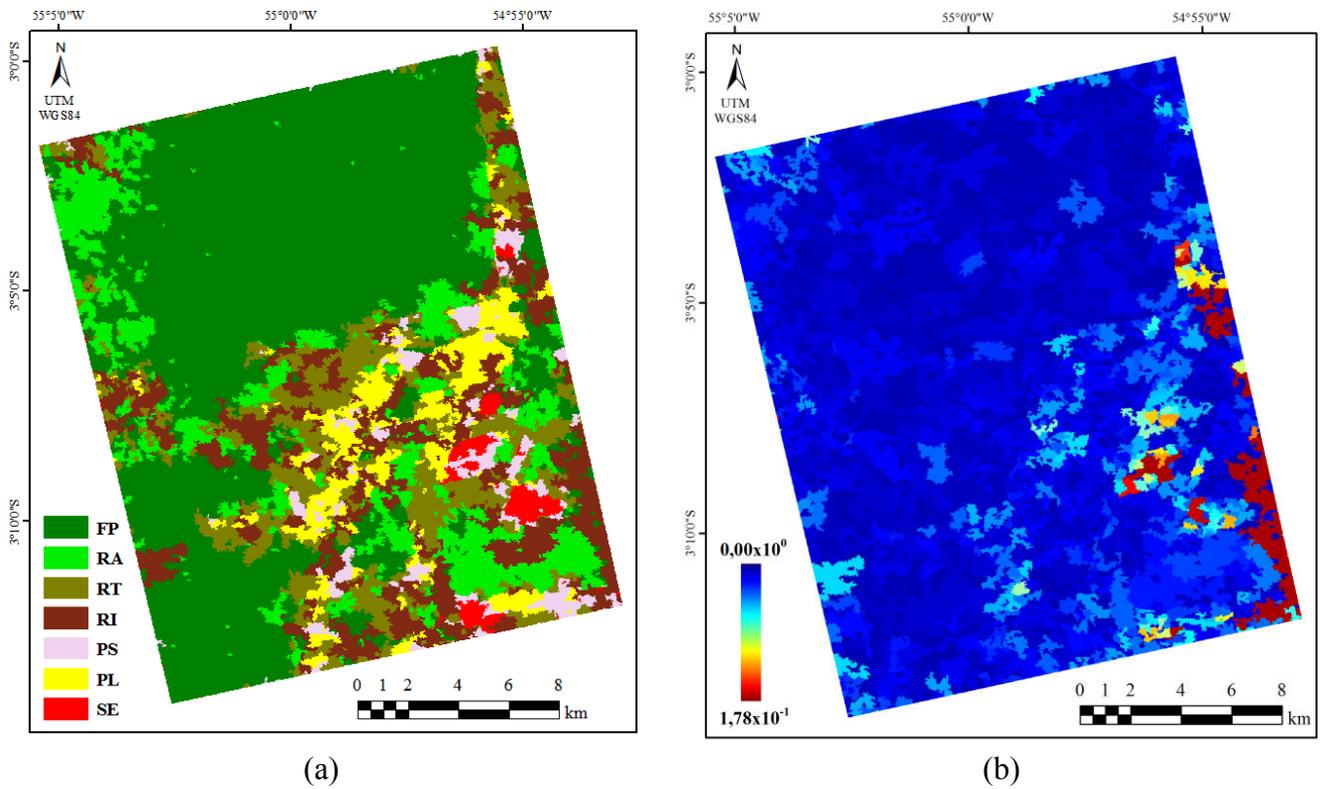
Comparando-se as Figuras 6.3 e 6.4, notam-se grandes semelhanças entre a classificação multifonte da soma $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$ e a classificação monofonte relativa à imagem TM $\{T, Ga, Bh\}$. Embora ambas sejam semelhantes, observam-se também pequenas contribuições provenientes das classificações das imagens SAR principalmente no que diz respeito às classes Pasto Sujo e Solo Exposto. O Cenário multifonte $\{R, Wi, Bh; T, Ga, Bh\}$ também apresenta contribuições provenientes de ambas as classificações monofontes, Radarsat $\{R, Wi, Bh\}$ e TM $\{T, Ga, Bh\}$. A análise da negatividade ou positividade destas contribuições é realizada nos parágrafos seguintes.

Tabela 6.5 - Acurácia por classe e erros relativos as classificações multifontes teóricas para as classes em estudo.

Cenários multifontes																					
Percentual: acurácia (A), erro de comissão (C) e erro de omissão (O)																					
Classes	FP			RA			RT			RI			PS			PL			SE		
Combinação	A	C	O	A	C	O	A	C	O	A	C	O	A	C	O	A	C	O	A	C	O
II	68,10	0,00	31,90	50,04	69,07	49,96	100,00	17,83	0,00	45,08	86,94	54,92	15,04	80,11	84,96	87,37	32,71	12,63	47,89	0,00	52,11
III	68,10	0,00	31,90	50,04	69,07	49,96	100,00	17,83	0,00	45,08	86,94	54,92	0,00	100,00	100,00	52,35	74,34	47,65	28,36	0,00	71,64
IV	68,10	0,00	31,90	18,11	86,05	81,89	100,00	38,39	0,00	45,08	86,94	54,92	38,71	61,01	61,29	87,37	16,31	12,63	47,89	0,00	52,11
V	33,92	0,00	66,08	50,04	21,87	49,96	100,00	8,93	0,00	54,92	94,89	45,08	0,00	100,00	100,00	87,37	32,71	12,63	28,36	28,49	71,64

Fonte: Produção do autor.

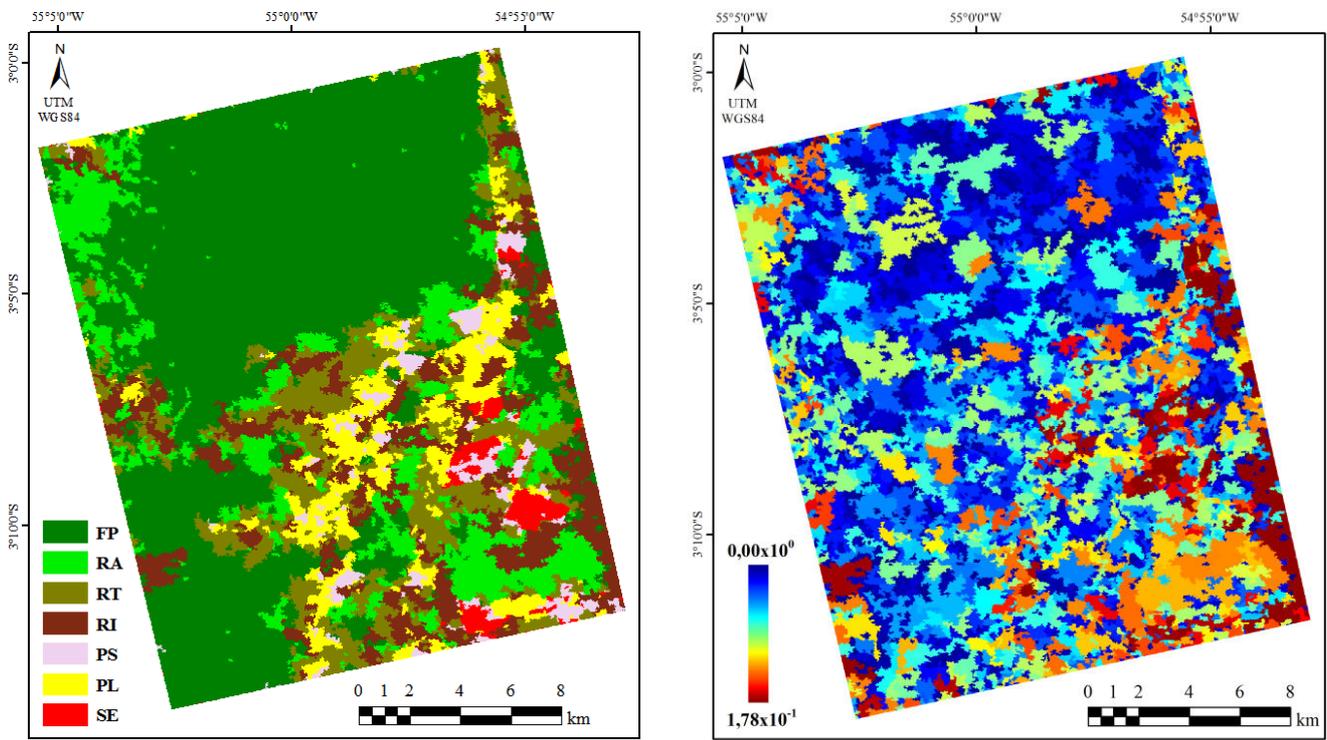
Figura 6.4 – Combinação II: Resultados para a classificação multifonte da soma $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$.



(a) Classificação; (b) Mapa de possibilidade e (c) Matriz de confusão.

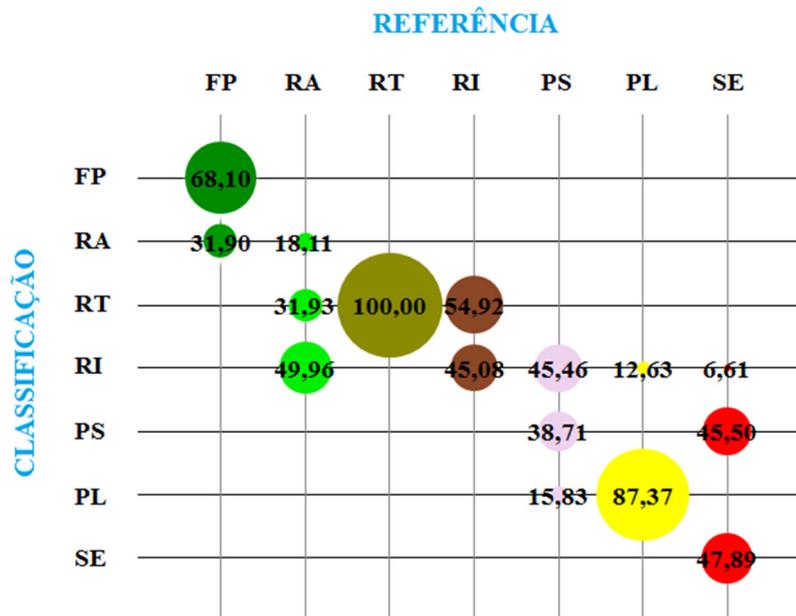
Fonte: Produção do autor.

Figura 6.5 – Combinação IV: Resultados para a classificação multifonte da soma $\{R, Wi, Bh; T, Ga, Bh\}$.



(a)

(b)

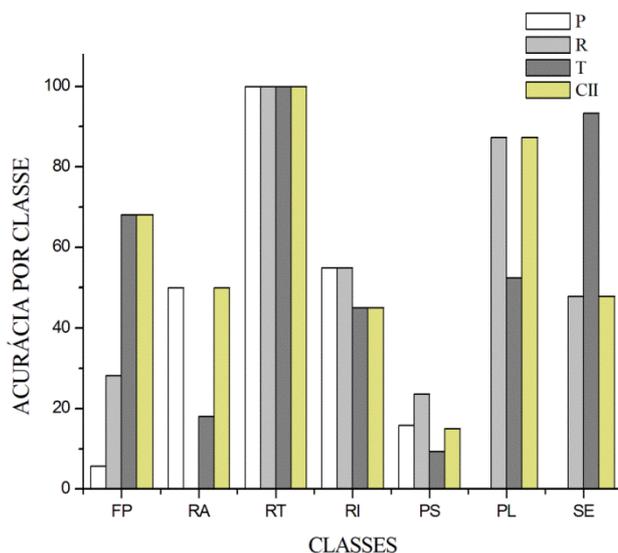


(c)

(a) Classificação; (b) Mapa de possibilidade e (c) Matriz de confusão.

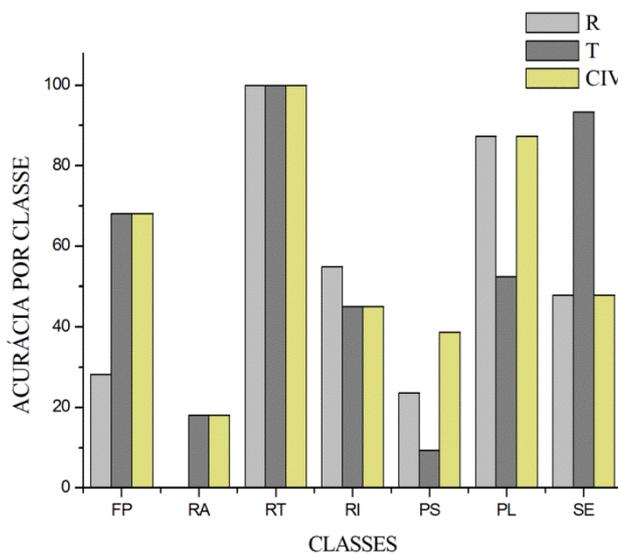
Fonte: Produção do autor.

Figura 6.6 – Relação entre as acurácias por classe para a classificação multifonte da soma resultante da combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$ e as classificações monofontes Palsar, Radarsat e TM.



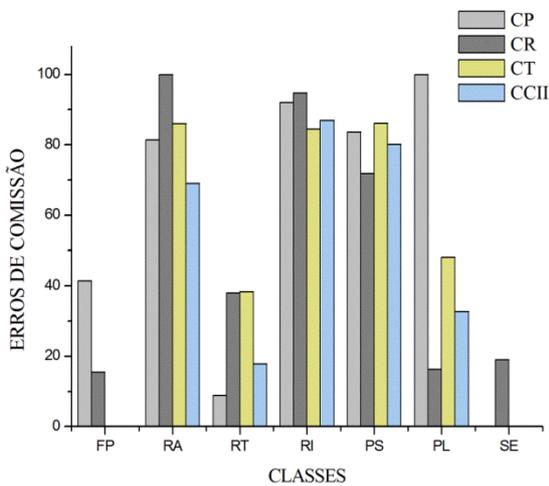
Fonte: Produção do autor.

Figura 6.7 – Relação entre as acurácias por classe para a classificação multifonte da soma resultante da combinação IV $\{R, Wi, Bh; T, Ga, Bh\}$ e as classificações monofontes Radarsat e TM.

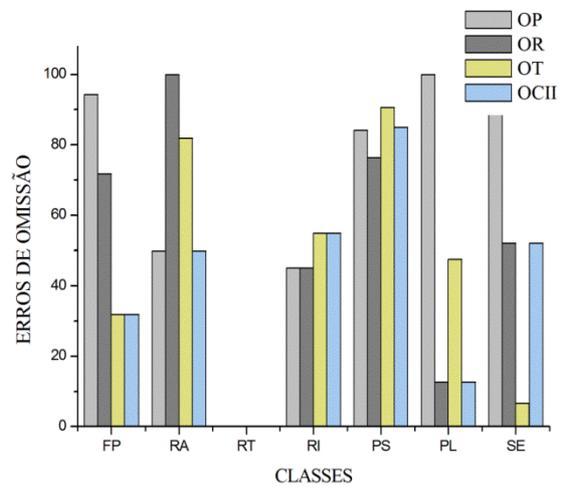


Fonte: Produção do autor.

Figura 6.8 – Relação entre os erros de comissão e omissão por classe para a classificação multifonte da soma resultante da combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$ e as classificações monofontes Palsar, Radarsat e TM.



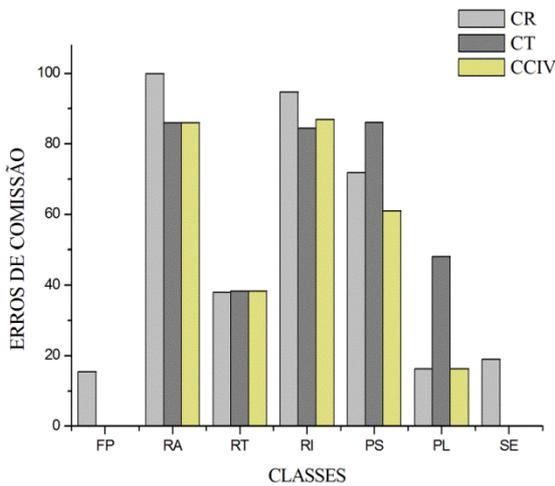
(a) erros de comissão



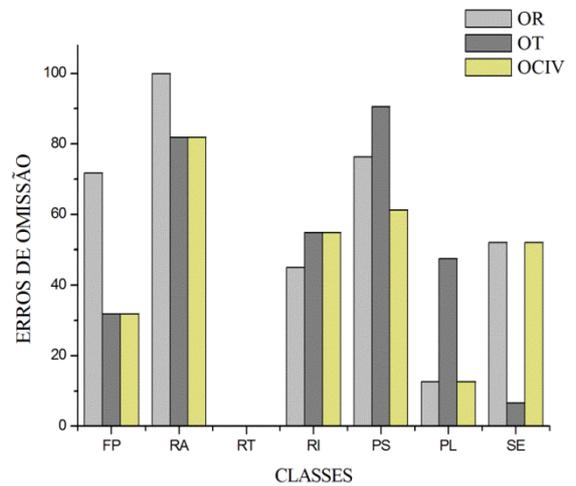
(b) erros de omissão

Fonte: Produção do autor.

Figura 6.9 – Relação entre os erros de comissão e omissão por classe para a classificação multifonte da soma resultante da combinação IV $\{R, Wi, Bh; T, Ga, Bh\}$ e as classificações monofontes Radarsat e TM.



(a) erros de comissão



(b) erros de omissão

Fonte: Produção do autor.

Na Figura 6.6 nota-se que a classificação multifonte da soma $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$, apresentou melhoras de 35%, 6% e 32% em relação à classificação monofonte da imagem TM para as classes Pasto Limpo, Pasto Sujo e Regeneração Antiga, respectivamente. Para as classes Floresta Primária e Regeneração Inicial não houve alterações nos valores de acurácia e para a classe Solo Exposto ocorreu uma queda no valor de 46%. Comparando-se a mesma classificação multifonte com a classificação monofonte da imagem Palsar, observam-se melhorias na acurácia de aproximadamente 62%, 87% e 48% para as classes Floresta Primária, Pasto Limpo e Solo Exposto. Para as classes Regeneração Antiga e Regeneração Intermediária os valores se mantêm e para as classes Pasto Sujo e Regeneração Inicial há uma queda de 0,8% e 10% respectivamente. Em relação à classificação monofonte da imagem Radarsat ocorrem melhoras de 40% e 50% para as classes Floresta Primária e Regeneração Antiga, uma queda de 9% e 10% para as classes Pasto Sujo e Regeneração Inicial e os valores são constantes para as classes Pasto Limpo e Regeneração Intermediária.

Na Figura 6.7 observa-se a relação dos valores de acurácia por classes da classificação multifonte $\{R, Wi, Bh; T, Ga, Bh\}$ e das classificações monofontes das imagens Radarsat e TM. Em relação à imagem Radarsat, ocorre melhora nas classes Floresta Primária, Pasto Sujo e Regeneração Antiga nos valores de 40%, 15% e 18% respectivamente. As classes Pasto Limpo, Regeneração Intermediária e Solo Exposto permanecem inalteradas enquanto a classe Regeneração Inicial é reduzida em 10%.

Em relação à classificação da imagem TM, as classes Floresta Primária, Regeneração Antiga, Regeneração Inicial e Regeneração Intermediária permanecem inalteradas e a classe Solo Exposto sofre redução de 46%. As classes Pasto Limpo e Pasto Sujo aumentam em 35% e 29% respectivamente.

De maneira geral, as classificações multifontes apresentaram pequenas contribuições para as classificações monofontes correspondentes. Nesta seção, foram apresentados os resultados obtidos para Cenários de classificação baseados na metodologia de classificação multifonte teórica. Na próxima seção, exemplificam-se classificações multifontes construídas utilizando-se a abordagem empírica. Neste caso, para fins de comparação, utilizaram-se as combinações relativas aos resultados de classificação com maiores índices de acurácia descritos nesta seção.

6.3. Avaliação dos Cenários multifontes empíricos

Com o intuito de exemplificar classificações multifontes empíricas, considerou-se apenas a combinação II para a construção das classificações multifontes dos mínimos e do produto e, por questão de praticidade, considerou-se a combinação IV para concepção da classificação multifonte *Fuzzy*. Os Cenários dos mínimos e do produto relativos às outras combinações encontram-se no Apêndice D. Na Tabela 6.6 apresentam-se os índices de acurácias obtidos para as classificações multifontes empíricas dos mínimos e do produto para a combinação II.

Tabela 6.6 – Coeficiente *Kappa* e acurácia global relativos aos Cenários multifontes empíricos para a combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$.

Classificação multifonte	<i>Kappa</i>	Variância <i>Kappa</i>	Acurácia global (%)
mínimos	0,22	$1,32 \times 10^{-5}$	30,20
produto	0,39	$1,37 \times 10^{-5}$	47,35

Fonte: Produção do autor.

Comparando os valores da Tabela 6.6 aos valores apresentados na Tabela 6.1, observa-se que, em comparação a classificação da imagem Palsar $\{P, Wi, Bh\}$, ambas as classificações multifontes empíricas obtiveram valores superiores de índice *Kappa* e acurácia global. Para a imagem Radarsat $\{R, Wi, Bh\}$, somente a classificação multifonte do produto apresentou valores superiores para os mesmos índices. Já para a imagem TM $\{T, Ga, Bh\}$, ambas as classificações apresentaram índices inferiores. Por intermédio do *QIC*, observa-se na Tabela 6.7 que os resultados da classificação da Imagem Palsar refletem melhoras de 9% por meio da classificação multifonte dos mínimos e 29% por meio da classificação multifonte do produto. Para a classificação monofonte da imagem Radarsat, ocorre uma melhora de 12% em relação à classificação multifonte do produto.

Dependendo do objeto em estudo, para melhor avaliação da qualidade da classificação, torna-se necessário a análise da acurácia por classe e dos erros registrados, de forma a se retirar a maior quantidade possível de informações da matriz de confusão de cada classificação. Na Tabela 6.8 são exibidos os erros e a acurácia por classe para as classificações multifontes construídas.

Tabela 6.7 – Melhora quantitativa das classificações monofontes em relação às classificações multifontes da empíricas dos mínimos e produto.

Percentual da Melhora Quantitativa da Classificação			
Cenários multifontes	Palsar $\{P, Wi, Bh\}$	Radarsat $\{R, Wi, Bh\}$	TM $\{T, Ga, Bh\}$
mínimos	9	12↓	36↓
produto	29	12	18↓

Fonte: Produção do autor.

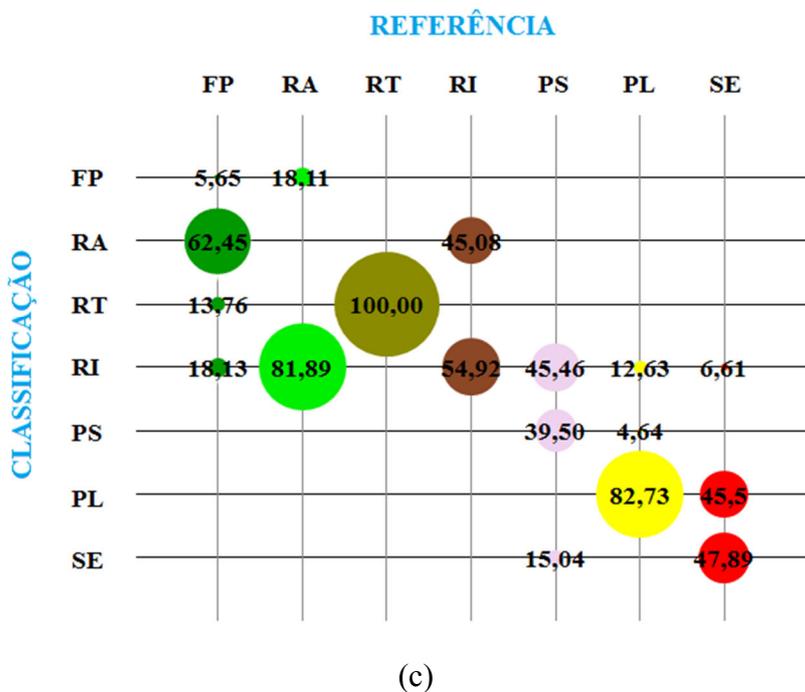
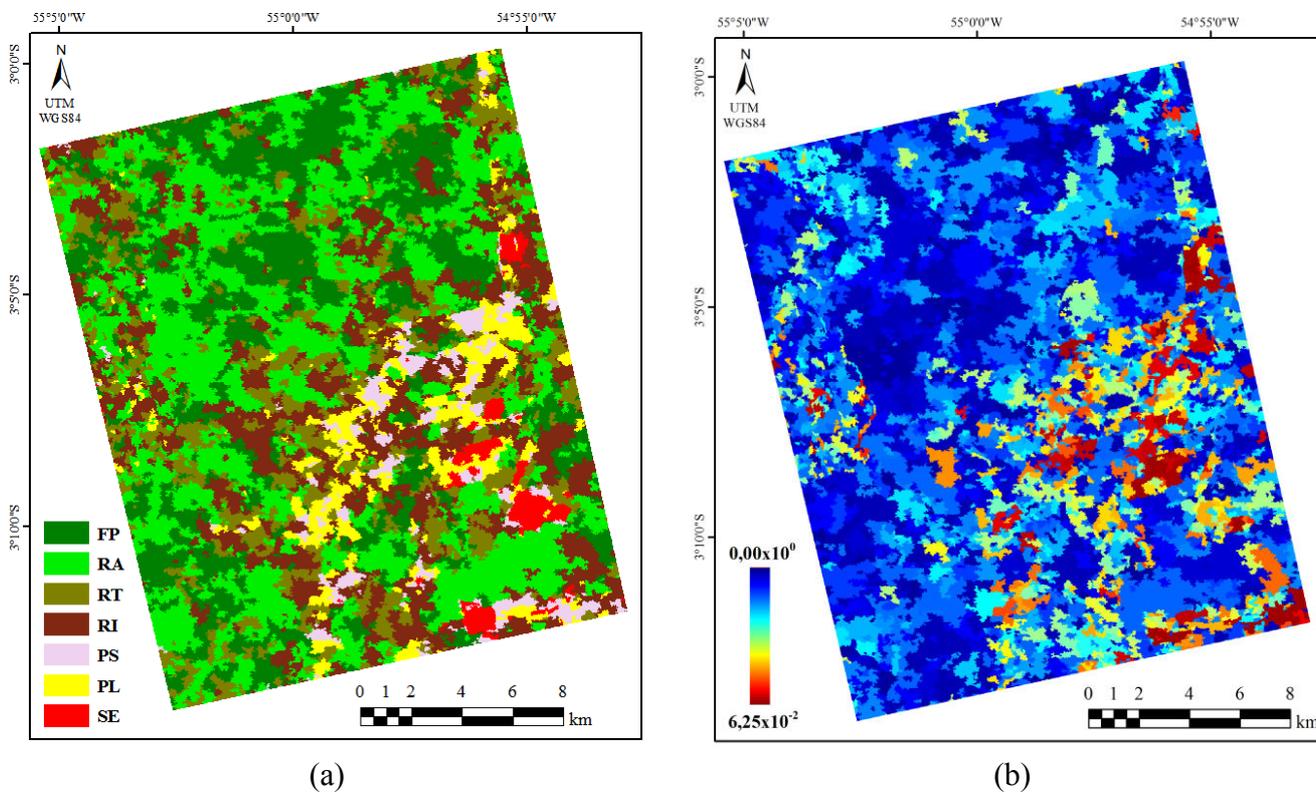
Tabela 6.8 – Erros relativos as classificações multifontes empíricas dos mínimos e do produto para a combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$.

Percentual: Acurácia por classe (A), erro de comissão (C) e erro de omissão (O)						
Classe	Classificação multifonte dos mínimos			Classificação multifonte do produto		
	A	C	O	A	C	O
FP	5,65	47,79	94,35	33,92	0,00	66,08
RA	0,00	100,00	100,00	50,04	70,53	49,96
RT	100,00	38,01	0,00	100,00	17,83	0,00
RI	54,92	91,71	45,08	45,08	93,60	54,92
PS	39,50	9,84	60,50	15,04	80,11	84,96
PL	82,73	44,04	17,27	87,37	32,71	12,63
SE	47,89	19,09	52,11	47,89	0,00	52,11

Fonte: Produção do autor.

Os Cenários multifontes empíricos podem ser visualizados nas Figuras 6.10 e 6.11. As comparações entre as acurácias por classe são exibidas nas Figuras 6.12 e 6.13 e os erros nas Figuras 6.14 e 6.15. As siglas CMIN, CPROD, OMIN, OPROD representam, nesta ordem, os erros de comissão e omissão para os Cenários dos mínimos e produto. Na Figura 6.16 relacionam-se os índices de acurácia das classificações oriundas da combinação II. As classificações monofontes das imagens TM, Palsar e Radarsat, são retratadas por MONOTM, MONOPal e MONORad, respectivamente. Os Cenários multifontes dos mínimos, do produto e da soma são representados por MULTMin, MULTProd e MULTSom nesta ordem.

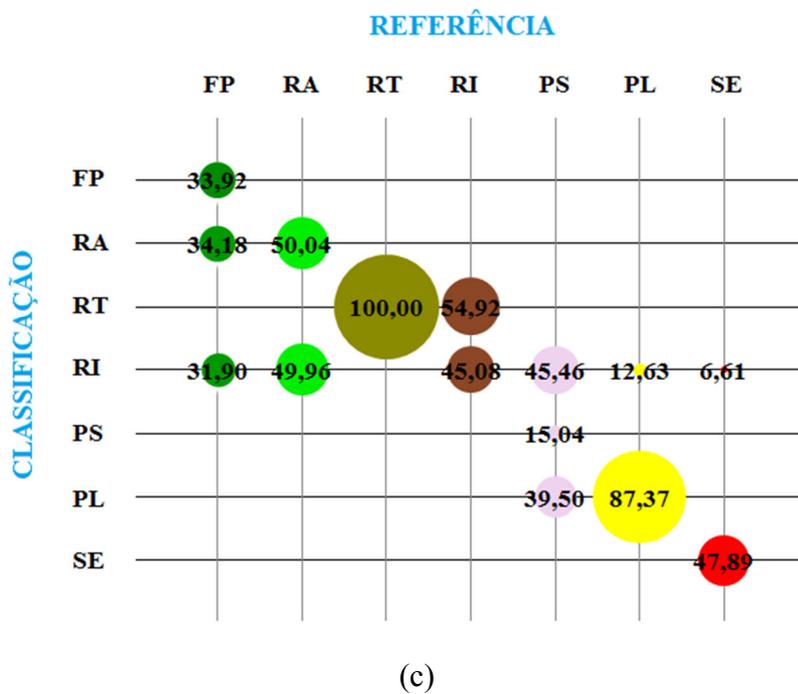
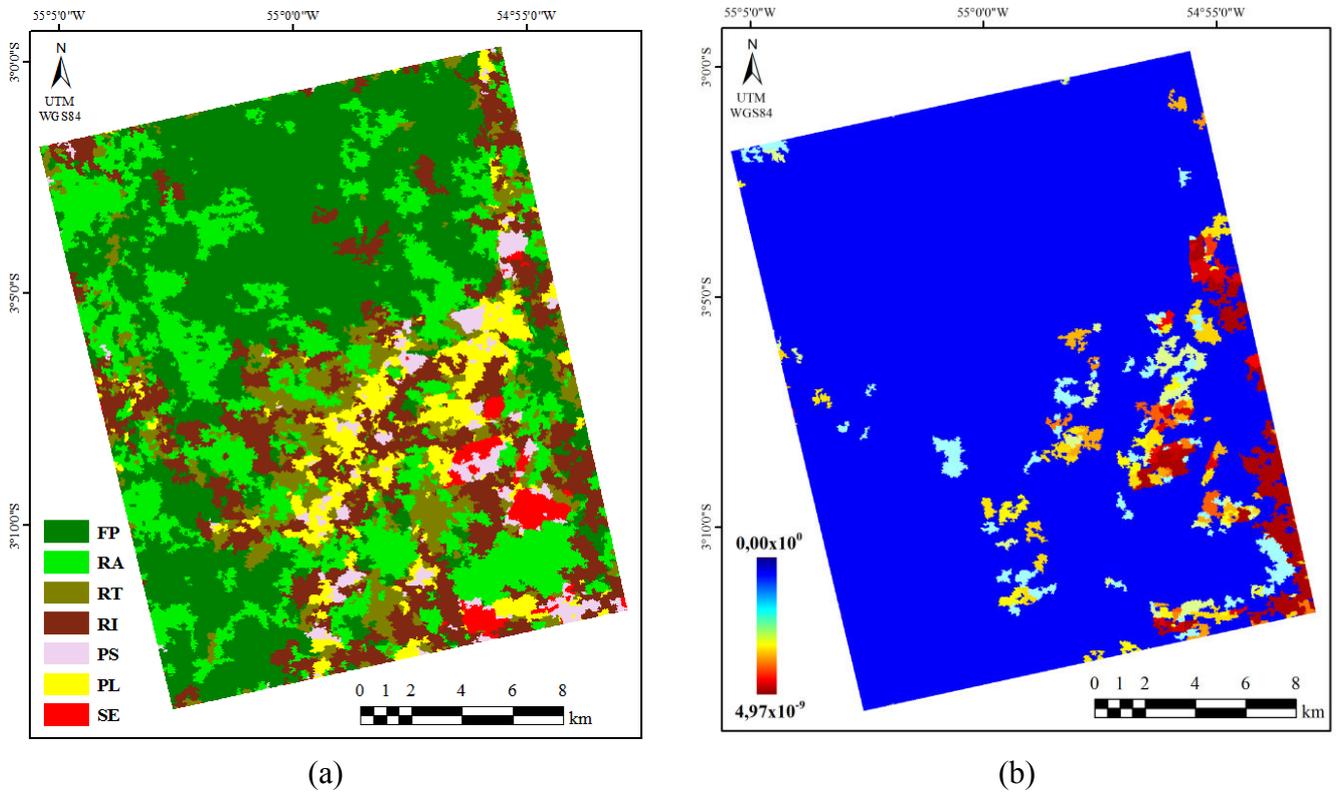
Figura 6.10 – Combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$: Resultados para o Cenário multifonte dos mínimos.



(a) Classificação; (b) Mapa de possibilidade e (c) Matriz de confusão..

Fonte: Produção do autor.

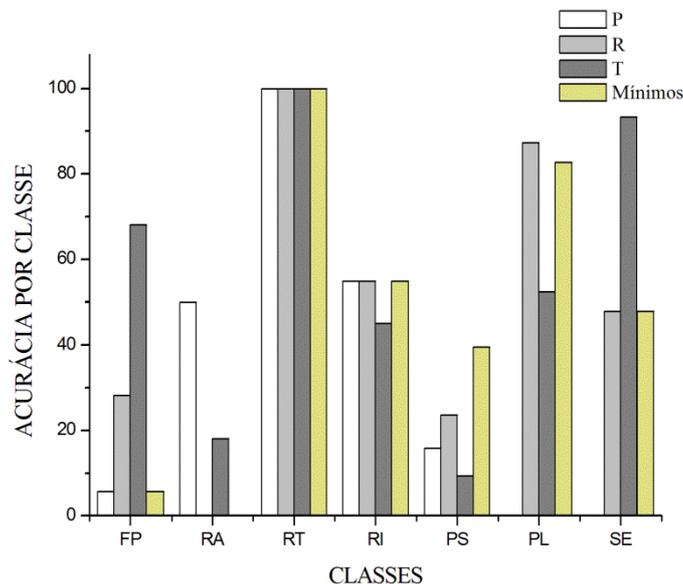
Figura 6.11 – Combinação II {*P, Wi, Bh; R, Wi, Bh; T, Ga, Bh*}: Resultados para o Cenário multifonte do produto.



(a) Classificação; (b) Mapa de possibilidade e (c) Matriz de confusão..

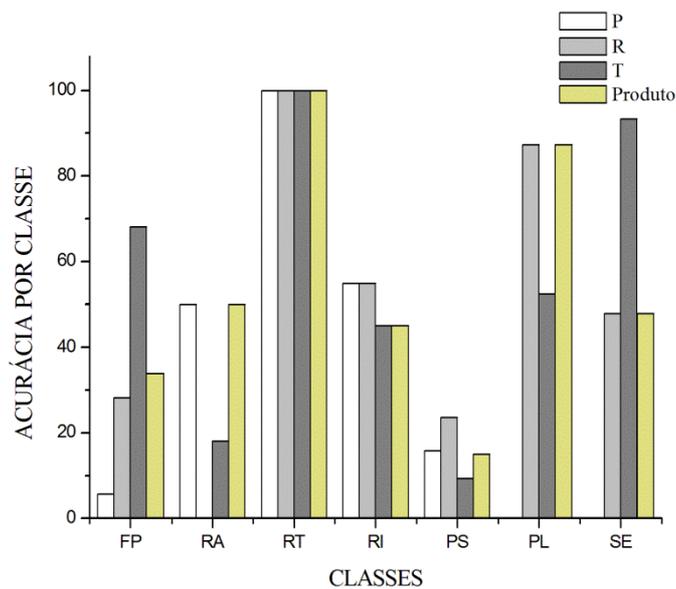
Fonte: Produção do autor.

Figura 6.12 – Relação entre as acurácias por classe para a classificação multifonte dos mínimos resultante da combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$ e as classificações monofontes das imagens Palsar, Radarsat e TM.



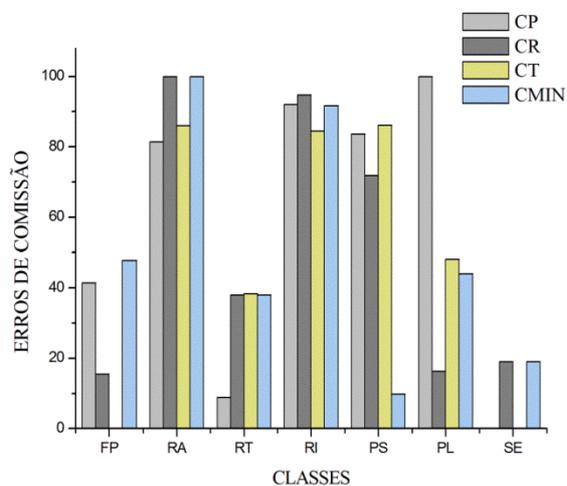
Fonte: Produção do autor.

Figura 6.13 – Relação entre as acurácias por classe para a classificação multifonte do produto resultante da combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$ e as classificações monofontes das imagens Palsar, Radarsat e TM.

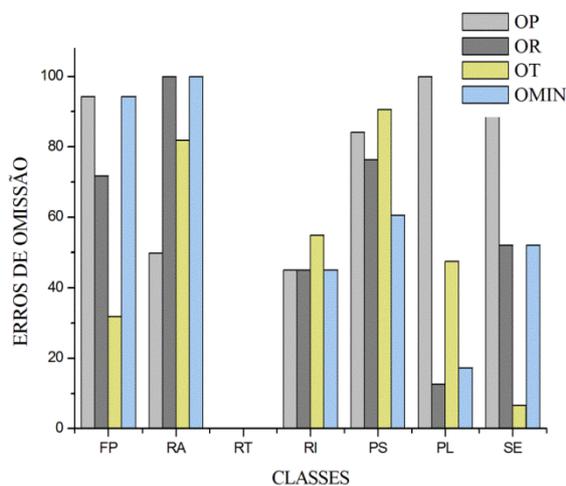


Fonte: Produção do autor.

Figura 6.14 – Relação entre os erros de comissão e omissão por classe para a classificação multifonte dos mínimos resultante da combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$ e as classificações Palsar, Radarsat e TM.



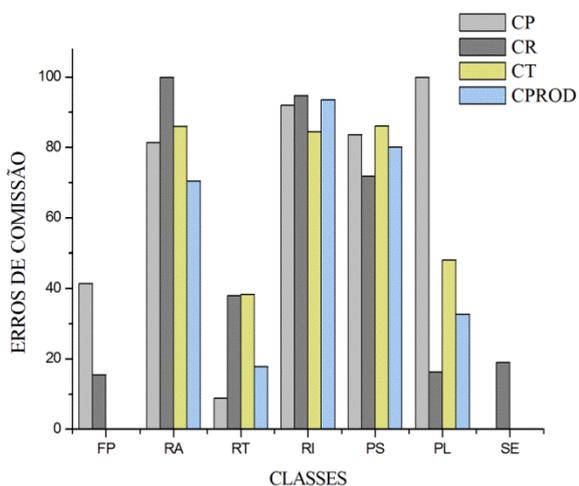
(a) erros de comissão



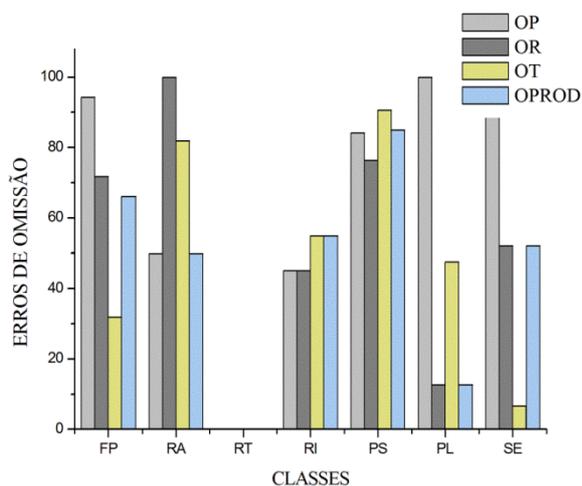
(b) erros de omissão

Fonte: Produção do autor.

Figura 6.15 – Relação entre os erros de comissão e omissão por classe para a classificação multifonte do produto resultante da combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$ e as classificações Palsar, Radarsat e TM.



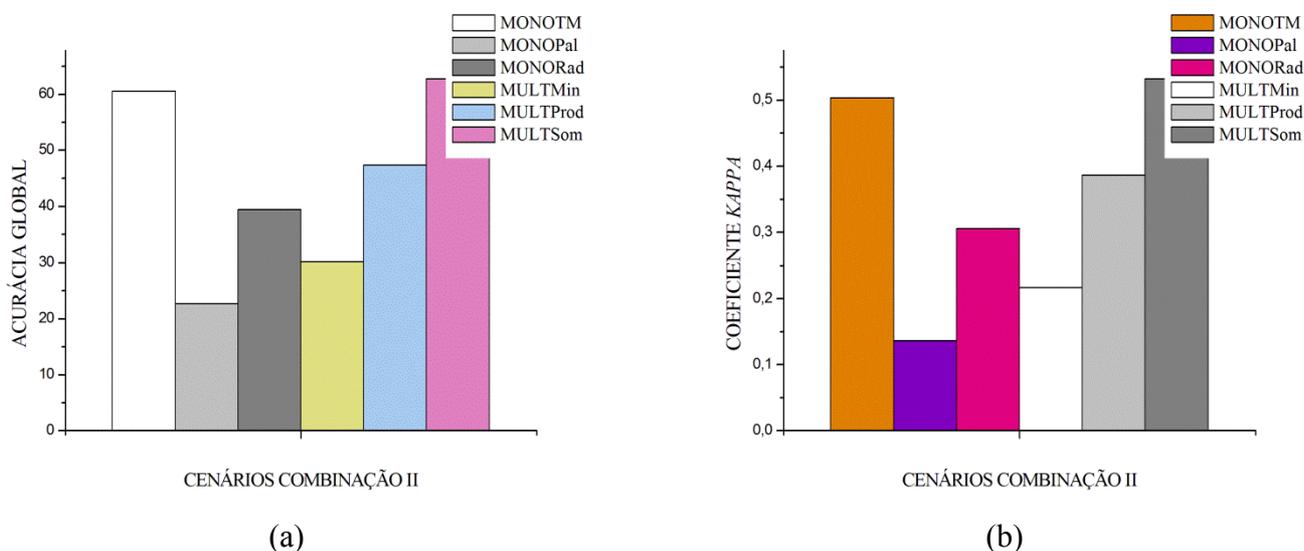
(a) erros de comissão



(b) erros de omissão

Fonte: Produção do autor.

Figura 6.16 – Relações entre os índices de acurácia para as classificações desenvolvidas através da combinação II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$.

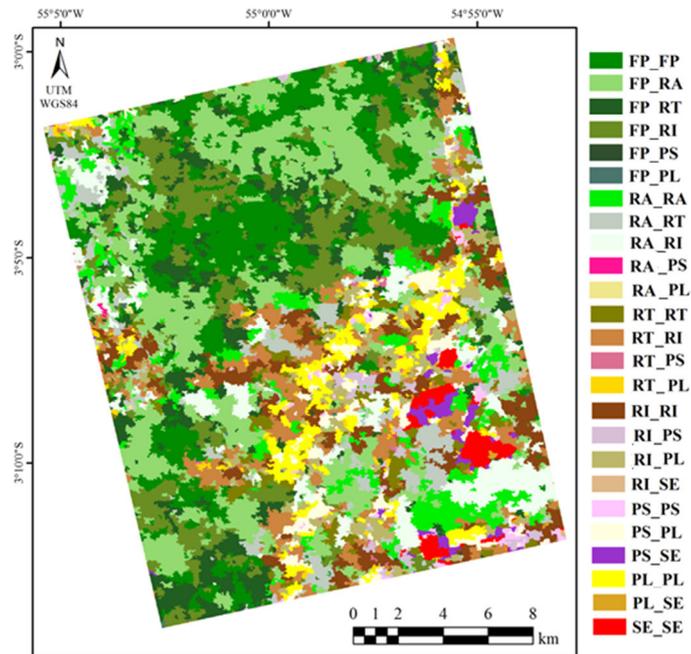


Fonte: Produção do autor.

Comparando as Figuras 6.2a e 6.10a, nota-se que a classificação correspondente ao Cenário dos mínimos, esta próxima da classificação da imagem Radarsat. Já a classificação do Cenário do produto (Figura 6.11a), apresenta valores próximos àqueles exibidos pelas classificações da imagem TM (Figura 6.3a) e Radarsat (Figura 6.2a). A confiabilidade do mapa de possibilidade do Cenário multifonte do produto foi alta, ocorrendo poucas variações nas regiões em que se esperavam confusões por parte do classificador (Figura 6.11c). Observa-se ainda que, o Cenário multifonte dos mínimos para a classe Pasto Sujo, obteve valores de acurácia superiores em relação a todas as classificações monofontes correspondentes as imagens Palsar, Radarsat e TM. Esse valor também foi superior ao apresentado para o Cenário multifonte do produto.

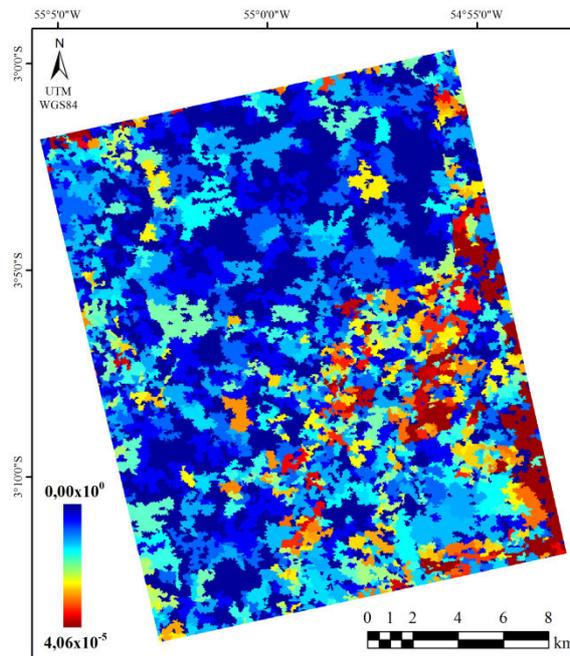
Na Figura 6.17 apresenta-se o resultado de classificação obtido para o Cenário multifonte *Fuzzy* por intermédio da combinação IV. Na Figura 6.18 exhibe-se o mapa de possibilidade para este mesmo Cenário. Observa-se que as classes FP_SE, RA_SE e RT_SE não ocorrem e por isso não aparecem na legenda da classificação *Fuzzy*.

Figura 6.17 – Combinação IV $\{R, Wi, Bh; T, Ga, Bh\}$: Classificação multifonte *Fuzzy*.



Fonte: Produção do autor.

Figura 6.18 – Combinação IV $\{R, Wi, Bh; T, Ga, Bh\}$: Mapa de possibilidade da classificação *Fuzzy*.



(a) Mapa de possibilidade

Fonte: Produção do autor.

A classificação *Fuzzy* exibiu resultados satisfatórios tornando-se assim um fator positivo na metodologia de classificação utilizada, pois permitiu uma classificação em classes mistas com alta confiabilidade e altos valores de acurácia por classe. A matriz de confusão do Cenário de classificação IV não pôde ser gerada como nos casos anteriores uma vez que nas classes *Fuzzy*, aparecem classes que não existem nas amostras de testes das imagens em questão. Ainda assim, conhecendo-se a referência pode-se estimar o quanto de acertos tal Cenário apresentou em relação às classes estudadas. Neste caso, se uma quantidade de pixels foi classificada como PL_SE e pertence à classe Pasto Limpo, tal decisão é considerada válida. Assim como o seria se outra quantidade de pixel fosse classificada como PL_SE e pertencesse à classe Solo Exposto. Utilizando-se esse raciocínio a Tabela 6.9 foi construída para análise do Cenário de classificação *Fuzzy*. Na tabela, o número total de pixels está relacionado aos pixels coletados para composição das amostras de teste.

Analisando a Tabela percebe-se que neste Cenário, em meio aos 9402 pixels pertencentes à classe Floresta Primária, 6403 pixels foram identificados corretamente, correspondendo a um percentual de acertos de 68%. Seguindo tal raciocínio tem-se que o percentual de acertos para a classe Pasto Limpo foi 87%, Pasto Sujo 33% e Regeneração Antiga 18%. Para ambas as classes Regeneração Inicial e Intermediária, o percentual de acertos foi de 100% e para a classe Solo Exposto 93%. Na Tabela 6.10 exibem-se os valores de acurácia por classe para o Cenário *Fuzzy* em relação aos valores apresentados pelos Cenários monofontes correspondentes a combinação IV.

Comparando os valores de acurácia por classe obtidos para a classificação multifonte *Fuzzy* com os valores obtidos nas classificações monofontes das imagens Radarsat e TM, correspondentes a combinação IV, observa-se, em relação à primeira imagem uma melhora de 40% para a classe Floresta Primária, 9% para a classe Pasto Sujo, 45% para a classe Regeneração Inicial e 46% e 18% para a classe Regeneração Antiga. Para a classe Regeneração Intermediária não houve contribuição mantendo-se o valor inicial. Em relação à segunda imagem, TM, notam-se melhorias para as classes Regeneração Inicial, Pasto Sujo e Pasto Limpo nos valores de 55%, 24% e 35% respectivamente. Para as outras classes o valor foi preservado. Em ambos os casos, destacam-se as melhorias para as classes Regeneração Inicial e Pasto Sujo, que foram obtidas em relação às duas imagens.

Tabela 6.9 – Dados para análise da acurácia do Cenário *Fuzzy*.

		Refererência							
		FP	RA	RT	RI	PS	PL	SE	TOTAL
Classes	FP_FP	2658	0	0	0	0	0	0	2658
	FP_RA	531	486	0	0	0	0	0	1017
	FP_RT	0	0	0	0	0	0	0	0
	FP_RI	3214	0	0	0	0	0	0	3214
	FP_PS	0	0	0	0	0	0	0	0
	FP_PL	0	0	0	0	0	0	0	0
	FP_SE	0	0	0	0	0	0	0	0
	RA_RA	0	0	0	0	0	0	0	0
	RA_RT	1294	0	0	0	0	0	0	1294
	RA_RI	1705	0	0	376	0	0	0	2081
	RA_PS	0	0	0	0	0	0	0	0
	RA_PL	0	0	0	0	0	0	0	0
	RA_SE	0	0	0	0	0	0	0	0
	RT_RT	0	0	2110	0	0	0	0	2110
	RT_RI	0	857	0	458	0	0	0	1315
	RT_PS	0	0	0	0	0	0	0	0
	RT_PL	0	0	0	0	0	0	0	0
	RT_SE	0	0	0	0	0	0	0	0
	RI_RI	0	1051	0	0	801	207	0	2059
	RI_PS	0	290	0	0	0	0	155	445
	RI_PL	0	0	0	0	0	0	0	0
	RI_SE	0	0	0	0	0	0	0	0
	PS_PS	0	0	0	0	0	0	0	0
	PS_PL	0	0	0	0	417	574	0	991
	PS_SE	0	0	0	0	164	0	1067	1231
	PL_PL	0	0	0	0	279	858	0	1137
	PL_SE	0	0	0	0	101	0	0	101
	SE_SE	0	0	0	0	0	0	1123	1123
TOTAL	9402	2684	2110	834	1762	1639	2345	20776	

Fonte: Produção do autor.

De forma geral, a classificação *Fuzzy* ou manteve os melhores resultados provenientes das classificações individuais correspondentes ou atingiu índices de acurácias superiores aos resultados obtidos por meio das classificações individuais. Desta forma, observa-se que não houve índices que foram reduzidos como ocorreu em alguns dos casos apresentados.

Tabela 6.10 – Relação da acurácia por classe entre os Cenários monofontes da combinação IV e o Cenário multifonte *Fuzzy*.

Porcentagem da acurácia por classe			
Classe	Radarsat	TM	<i>Fuzzy</i>
FP	28,27	68,10	68,10
RA	0,00	18,11	18,11
RT	100,00	100,00	100,00
RI	54,92	45,08	100,00
PS	23,67	9,31	32,97
PL	87,37	52,35	87,37
SE	47,89	93,39	93,39

Fonte: Produção do autor.

Nesta seção, apresentaram-se as avaliações para três cenários multifontes empíricos, dos mínimos, do produto e *Fuzzy*. Ressalta-se que todos os Cenários apresentados (exceto para o Cenário *Fuzzy*) foram construídos para todas as 10 combinações deste trabalho e as tabelas com os resultados obtidos para cada combinação podem ser visualizadas no Apêndice E. Na próxima seção apresenta-se um breve estudo realizado acerca da influência de dados SAR bivariados e polarimétricos nos resultados de classificação.

6.4. Avaliação entre dados polarimétricos e dados bivariados

Nesta seção, avaliaram-se combinações originárias dos Cenários monofontes listados na Tabela 6.11. Nesta tabela, constata-se que a modelagem estatística para as imagens SAR foram alternadas entre distribuição Par de intensidade *multi-look* (para dados bivariados em amplitude) e *Wishart* complexa escalonada (para dados polarimétricos completos). Uma breve análise foi realizada para as combinações descritas na Tabela 6.12. O objetivo deste exame foi verificar se a utilização de dados polarimétricos acarreta em maiores contribuições nos resultados finais de classificação em comparação aos resultados obtidos por intermédio de dados bivariados. O resultado da análise é relevante para o estudo, uma vez que, a aquisição de dados bivariados é mais acessível devido a seu baixo custo em relação aos dados polarimétricos. O foco desta análise está nos Cenários multifontes da soma, cuja construção é justificada teoricamente.

Nota-se na Tabela 6.11 que a modelagem da imagem Palsar por intermédio da distribuição Par de intensidade *multi-look* ou *Wishart* complexa escalonada, apresentam os mesmos coeficientes *Kappas* e as acurácias diferem em 0,37%. Contudo, analisando-se os valores correspondentes a imagem Radarsat, conclui-se que, para esta, os maiores índices são obtidos quando a modelagem dá-se por meio da distribuição *Wishart* complexa escalonada. Após esse diagnóstico, para todas as combinações multifontes oriundas destas imagens (Tabela 6.12), foram construídos os Cenários multifontes da soma e calcularam-se o coeficiente *Kappa*, a variância do *Kappa* e a acurácia global.

Tabela 6.11 – Índices de acurácia para Cenários monofontes.

Combinação	<i>Kappa</i>	Variância do <i>Kappa</i>	Acurácia global (%)
{ <i>P, Wi, Bh</i> }	0,14	$1,07 \times 10^{-5}$	22,72
{ <i>P, Pi, Bh</i> }	0,14	$1,12 \times 10^{-5}$	23,09
{ <i>R, Wi, Bh</i> }	0,31	$1,31 \times 10^{-5}$	39,46
{ <i>R, Pi, Bh</i> }	0,19	$1,21 \times 10^{-5}$	30,14
{ <i>T, Ga, Bh</i> }	0,50	$1,31 \times 10^{-5}$	60,58

Fonte: Produção do autor.

Observou-se que, para os Cenários multifontes da soma, constituídos pelas três imagens Palsar, Radarsat e TM, os maiores índices de acurácia foram obtidos ao utilizar-se a distribuição *Wishart* complexa escalonada para a modelagem da imagem Radarsat independente da modelagem empregada para a imagem Palsar. Para as combinações de imagens duas a duas, nota-se que para os casos em que se combinam as imagens Palsar e TM, a modelagem da primeira por intermédio da distribuição Par de intensidades aumenta em 0,09 e 7,34% os índices *Kappa* e acurácia global, nesta ordem, em relação à modelagem da imagem Palsar pela distribuição *Wishart*. Quando a combinação envolve as imagens Radarsat e TM, a modelagem da imagem SAR aumenta os índices *Kappa* e Acurácia global em 0,06 e 4,69% ao adotar-se a distribuição *Wishart* no lugar da distribuição Par de intensidade. Para as combinações dois a dois, envolvendo as imagens SAR, tais relações não se mantêm. Os maiores índices de acurácia ocorrem quando se modelam ambas as imagens por meio da distribuição *Wishart* complexa escalonada. Na Tabela 6.13 são exibidos os índices *QIC* cálculos.

Tabela 6.12 – Índices de acurácia de classificação para os Cenários multifontes da soma.

Combinação	Cenário multifonte da soma		
	<i>Kappa</i>	Variância do <i>Kappa</i>	Acurácia global(%)
{ <i>P, Wi, Bh; R, Wi, Bh; T, Ga, Bh</i> }	0,53	1,27×10⁻⁵	62,82
{ <i>P, Pi, Bh; R, Pi, Bh; T, Ga, Bh</i> }	0,49	1,33×10 ⁻⁵	59,34
{ <i>P, Pi, Bh; R, Wi, Bh; T, Ga, Bh</i> }	0,53	1,15×10⁻⁵	62,82
{ <i>P, Wi, Bh; R, Pi, Bh; T, Ga, Bh</i> }	0,49	1,38×10 ⁻⁵	59,34
{ <i>P, Wi, Bh; T, Ga, Bh</i> }	0,46	1,34×10 ⁻⁵	56,58
{ <i>R, Wi, Bh; T, Ga, Bh</i> }	0,51	1,31×10 ⁻⁵	60,70
{ <i>P, Wi, Bh; R, Wi, Bh</i> }	0,36	1,29×10 ⁻⁵	44,27
{ <i>P, Pi, Bh; T, Ga, Bh</i> }	0,55	1,12×10⁻⁵	63,92
{ <i>R, Pi, Bh; T, Ga, Bh</i> }	0,45	1,32×10 ⁻⁵	56,01
{ <i>P, Pi, Bh; R, Pi, Bh</i> }	0,31	1,33×10 ⁻⁵	40,14
{ <i>P, Pi, Bh; R, Wi, Bh</i> }	0,23	1,07×10 ⁻⁵	30,00
{ <i>P, Wi, Bh; R, Pi, Bh</i> }	0,28	1,34×10 ⁻⁵	38,36

Fonte: Produção do autor.

Tabela 6.13 – Melhora quantitativa das classificações monofontes em relação às classificações multifontes.

Percentual da Melhora Quantitativa da Classificação					
Cenários	{ <i>P, Wi, Bh</i> }	{ <i>P, Pi, Bh</i> }	{ <i>R, Wi, Bh</i> }	{ <i>R, Pi, Bh</i> }	{ <i>T, Ga, Bh</i> }
{ <i>P, Wi, Bh; R, Wi, Bh; T, Ga, Bh</i> }	45%	-	32%	-	6%
{ <i>P, Pi, Bh; R, Pi, Bh; T, Ga, Bh</i> }	-	41%	-	37%	2↓
{ <i>P, Pi, Bh; R, Wi, Bh; T, Ga, Bh</i> }	-	41%	32%	-	6%
{ <i>P, Wi, Bh; R, Pi, Bh; T, Ga, Bh</i> }	41%	-	-	37%	2↓
{ <i>P, Wi, Bh; T, Ga, Bh</i> }	37%	-	-	-	7↓
{ <i>R, Wi, Bh; T, Ga, Bh</i> }	-	-	29%	-	2%
{ <i>P, Wi, Bh; R, Wi, Bh</i> }	26%	-	7%	-	-
{ <i>P, Pi, Bh; T, Ga, Bh</i> }	-	48%	-	-	10%
{ <i>R, Pi, Bh; T, Ga, Bh</i> }	-	-	-	32%	9↓
{ <i>P, Pi, Bh; R, Pi, Bh</i> }	-	20%	-	15%	-
{ <i>P, Pi, Bh; R, Wi, Bh</i> }	-	11%	10↓	-	-
{ <i>P, Wi, Bh; R, Pi, Bh</i> }	16%	-	-	11%	-

Fonte: Produção do autor.

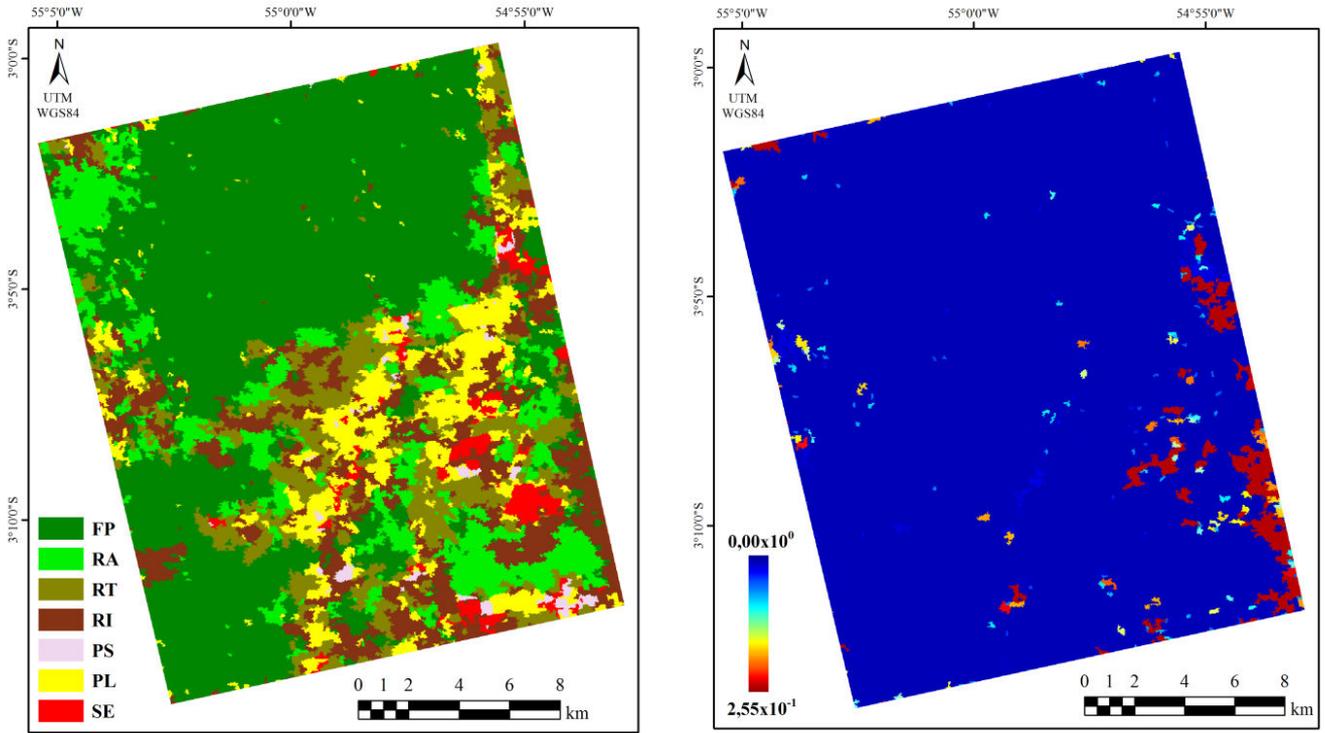
De maneira geral, os maiores índices de acurácia foram obtidos para a combinação {*P, Pi, Bh; T, Ga, Bh*}, superando inclusive os Cenários multifontes que incluem informações das três imagens. O segundo resultado com maiores índices foi obtido por dois Cenários, {*P, Wi, Bh; R, Wi, Bh; T, Ga, Bh*} e {*P, Pi, Bh; R, Wi, Bh; T, Ga, Bh*}, contudo, levando-se em

consideração que a modelagem da imagem Palsar por intermédio da distribuição Par de intensidade possui menor custo, opta-se pelo Cenário $\{P, Pi, Bh; R, Wi, Bh; T, Ga, Bh\}$.

Portanto, conclui-se que, para trabalhos que envolvam imagens Palsar, a aquisição de dados polarimétricos ou bivariados é indiferente principalmente se este for utilizado em conjunto com um dado óptico (no caso, imagem TM). A orientação neste caso é a obtenção de dados bivariados devido a seu baixo custo em relação a dados polarimétricos. Para aplicações que envolvam somente a utilização de imagens SAR (Palsar e Radarsat), opta-se pelo emprego de dados polarimétricos. Para o caso em que se trabalha somente com imagens Radarsat, indica-se a aquisição de dados polarimétricos. Os Cenários multifontes da soma relativos às combinações presentes na Tabela 6.12, ainda não citadas neste trabalho, são ilustrados nas Figuras 6.19 a 6.25.

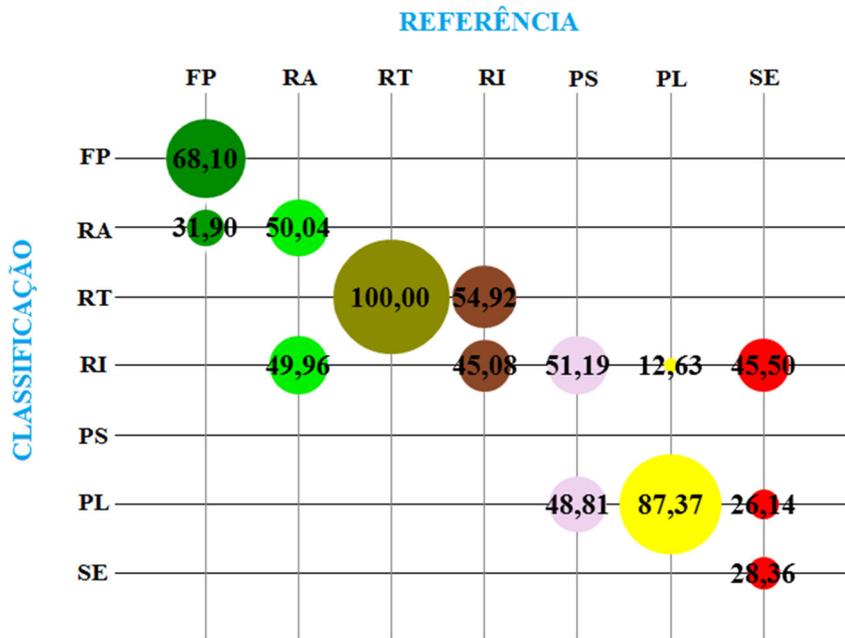
Por fim, em relação a todos os resultados obtidos nas diferentes etapas da análise dos dados, conclui-se que a metodologia é efetiva uma vez que, apesar dos pequenos valores de acurácias obtidos, foi possível alcançar maiores índices por meio das classificações multifontes propostas em grande parte dos resultados. É necessário enfatizar que a importância desta dissertação está na originalidade da metodologia apresentada e, como descrito em parágrafos anteriores, diferentes fontes de erros podem justificar os baixos índices de acurácia. Outros testes em que os índices de acurácia apresentaram valores bem mais elevados foram realizados para validação da metodologia e podem ser encontrados em Braga *et al.* (2015a), Braga *et al.* (2015b) e Braga *et al.* (2015c). De maneira geral, observou-se também que os Cenários multifontes teóricos da soma apresentaram valores superiores àqueles obtidos pelos Cenários multifontes empíricos dos mínimos e produto, como era de se esperar. Outra contribuição relevante diz respeito ao esforço computacional empregado para geração das classificações. Notou-se que, o tempo de execução para obtenção das classificações multifontes é muito menor que o tempo necessário para construção das classificações monofontes.

Figura 6.19 – Resultados para a classificação multifonte da soma $\{P, Pi, Bh; R, Pi, Bh; T, Ga, Bh\}$.



(a)

(b)

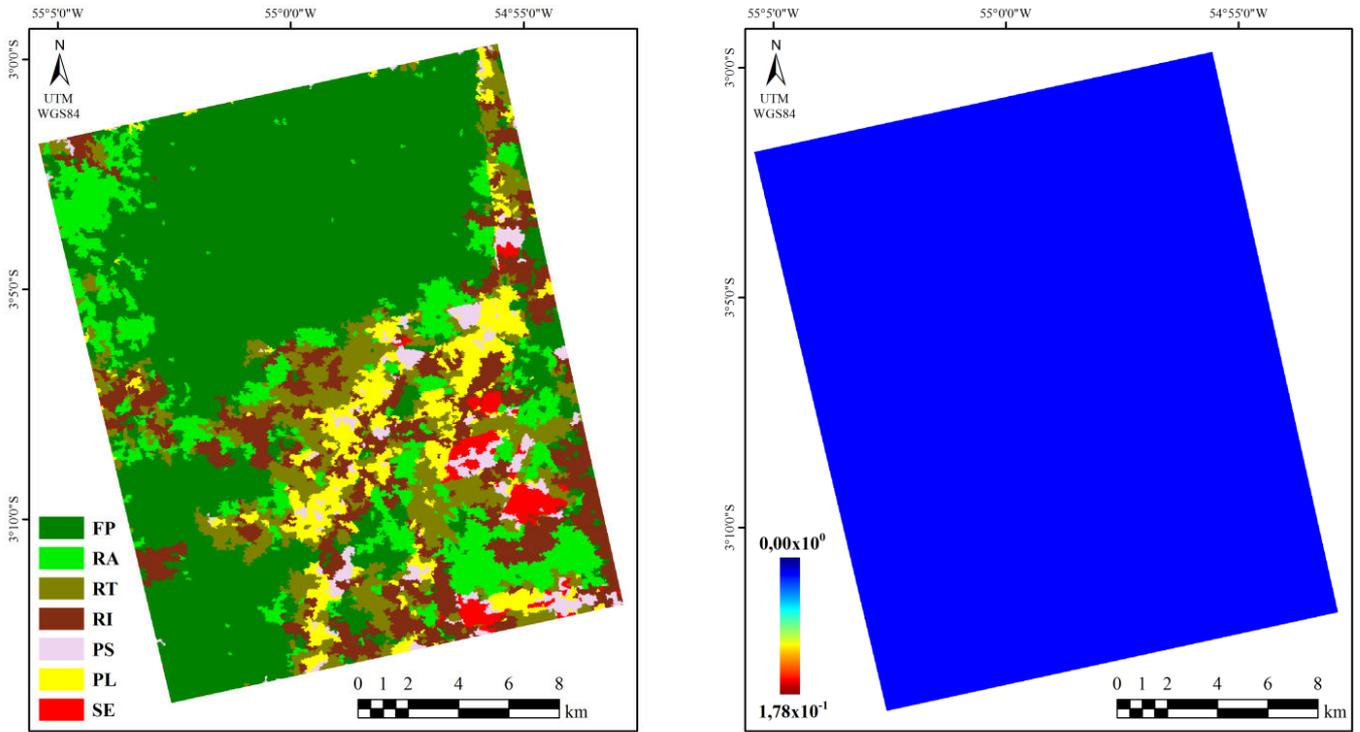


(c)

(a) Classificação; (b) Mapa de possibilidade e (c) Matriz de confusão..

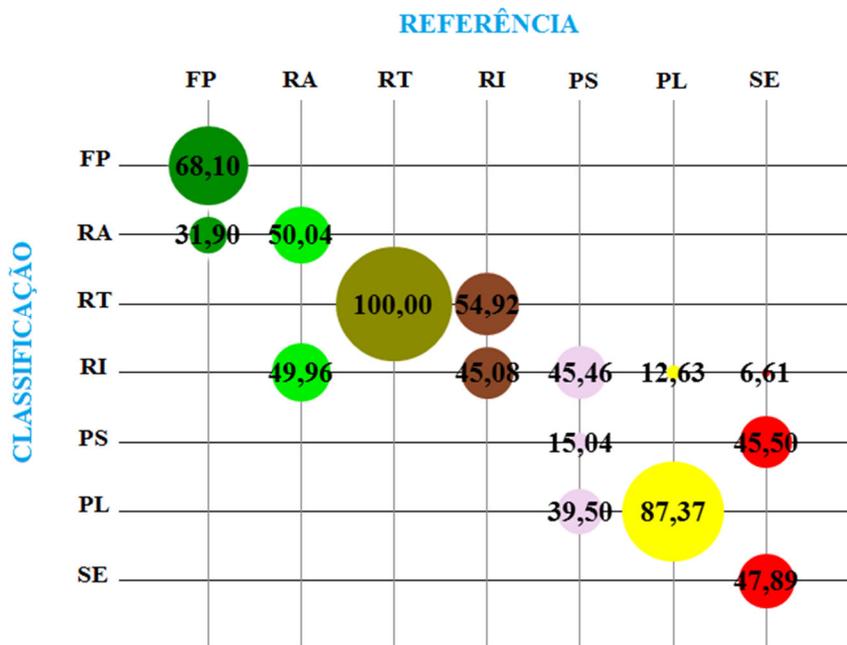
Fonte: Produção do autor.

Figura 6.20 – Resultados para a classificação multifonte da soma $\{P, Pi, Bh; R, Wi, Bh; T, Ga, Bh\}$.



(a)

(b)

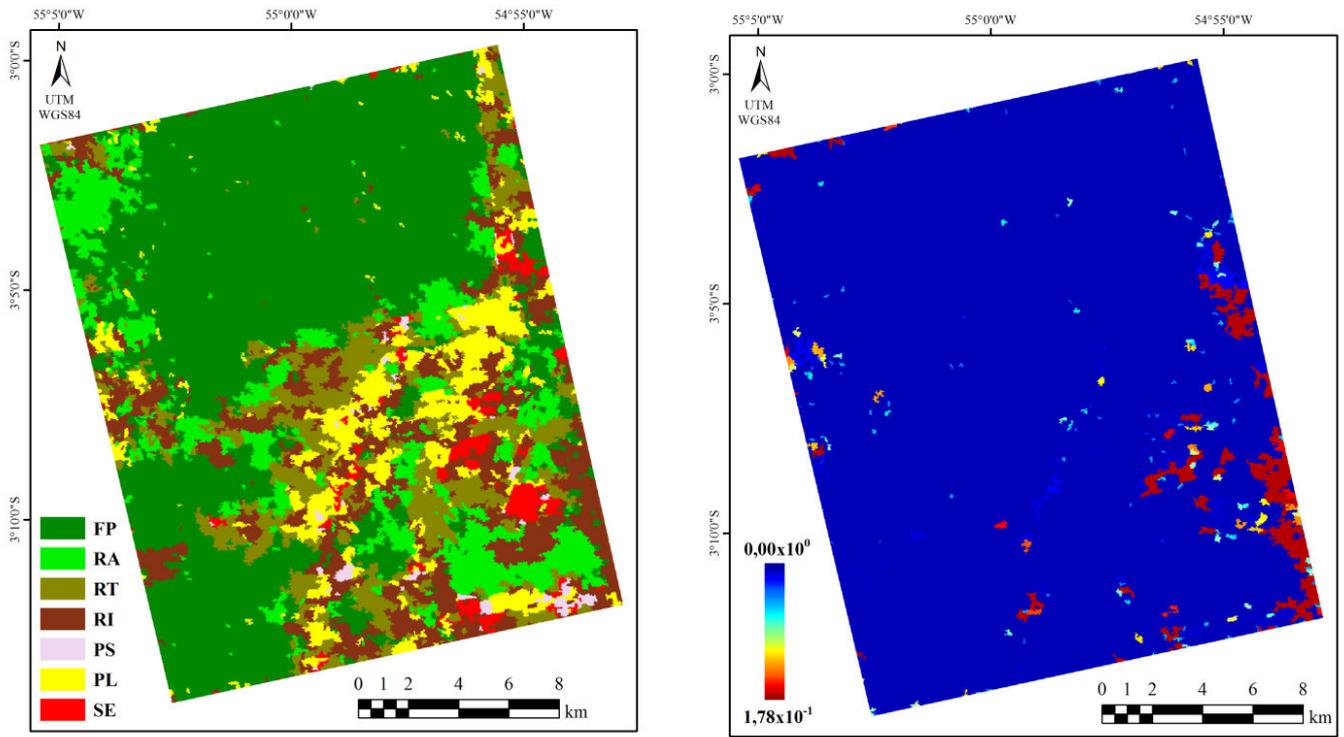


(c)

(a) Classificação; (b) Mapa de possibilidade e (c) Matriz de confusão..

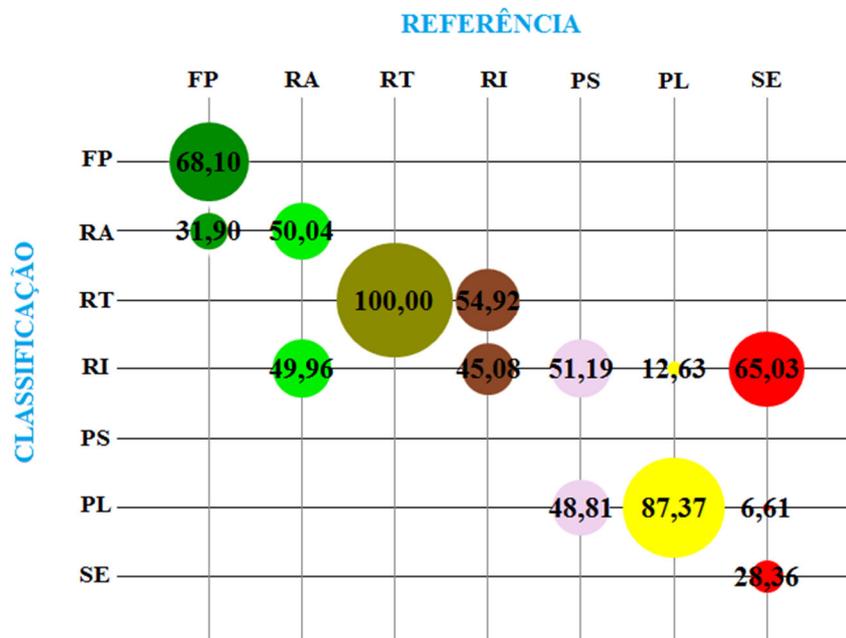
Fonte: Produção do autor.

Figura 6.21 – Resultados para a classificação multifonte da soma $\{P, Wi, Bh; R, Pi, Bh; T, Ga, Bh\}$.



(a)

(b)

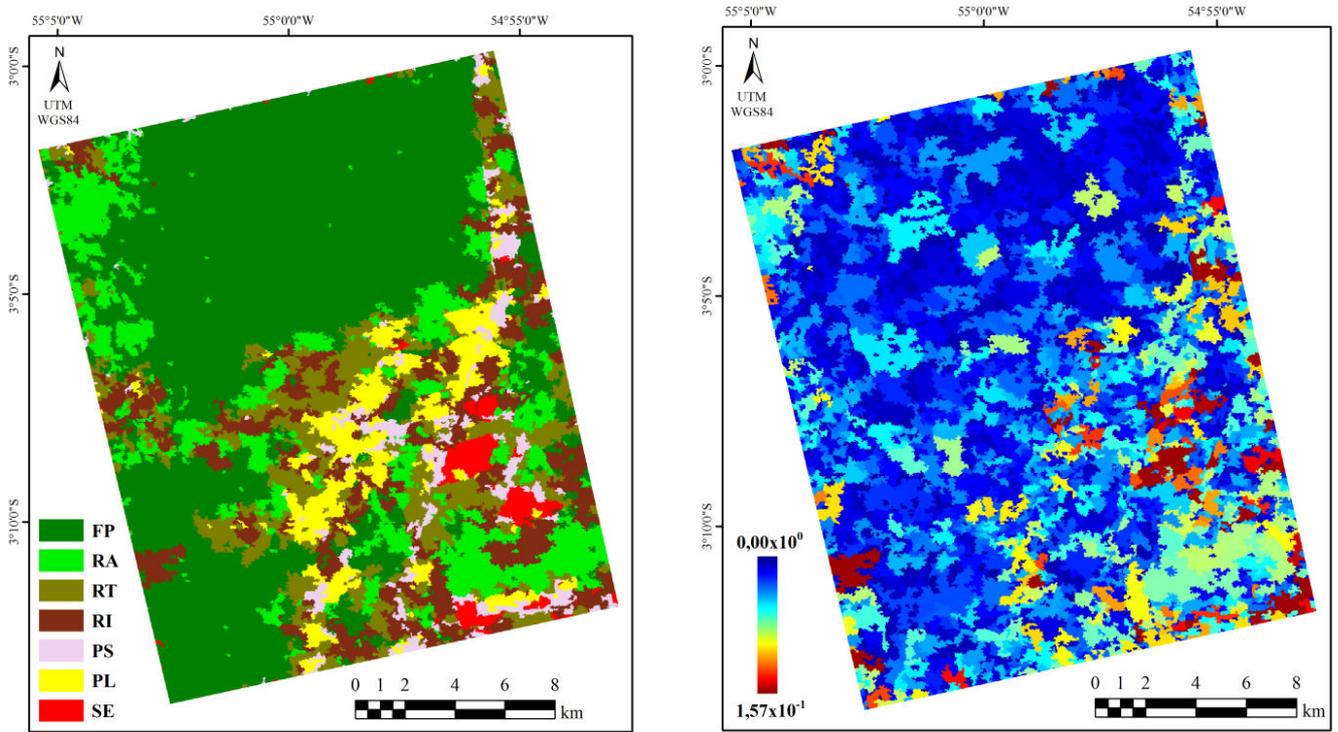


(c)

(a) Classificação; (b) Mapa de possibilidade e (c) Matriz de confusão..

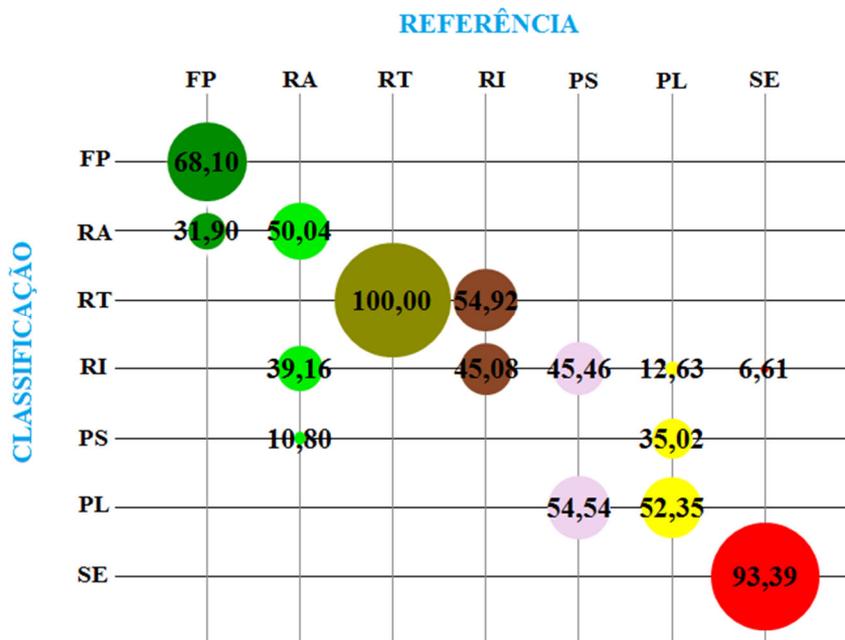
Fonte: Produção do autor.

Figura 6.22 – Resultados para a classificação multifonte da soma $\{P, P_i, B_h; T, G_a, B_h\}$.



(a)

(b)

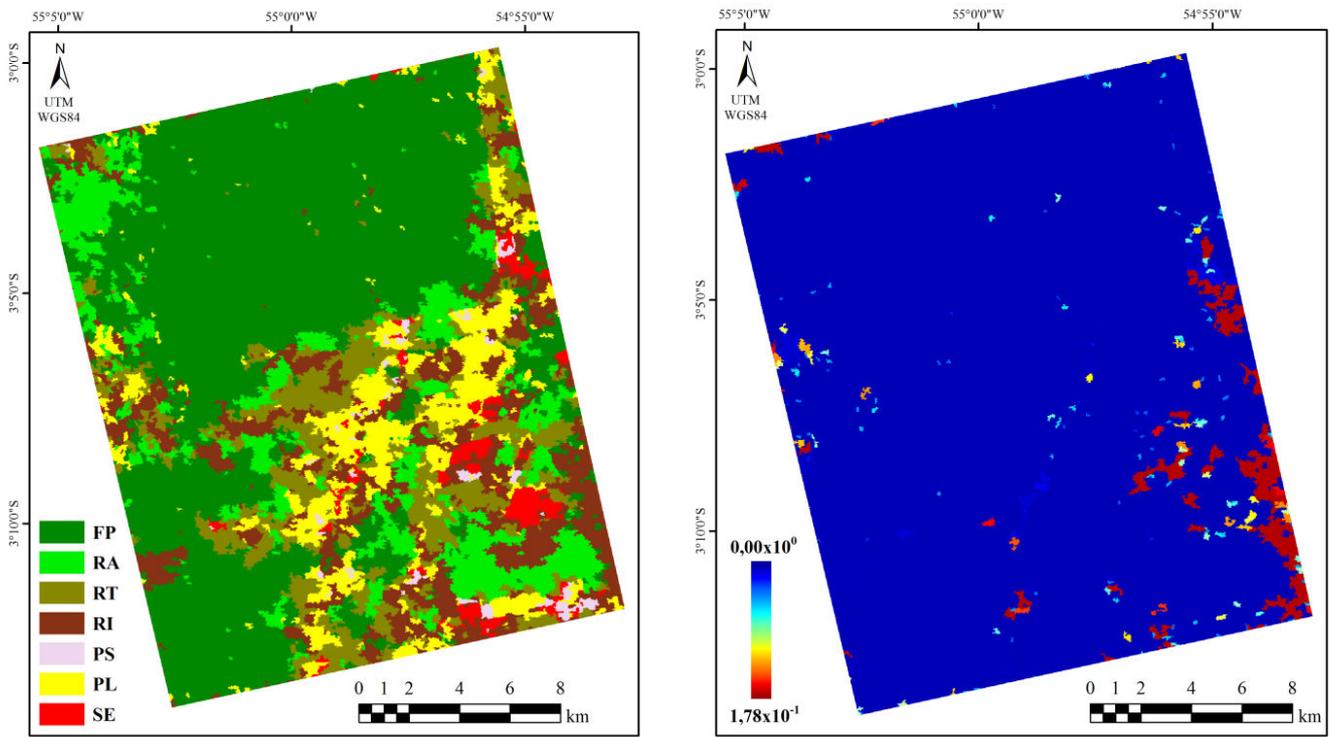


(c)

(a) Classificação; (b) Mapa de possibilidade e (c) Matriz de confusão..

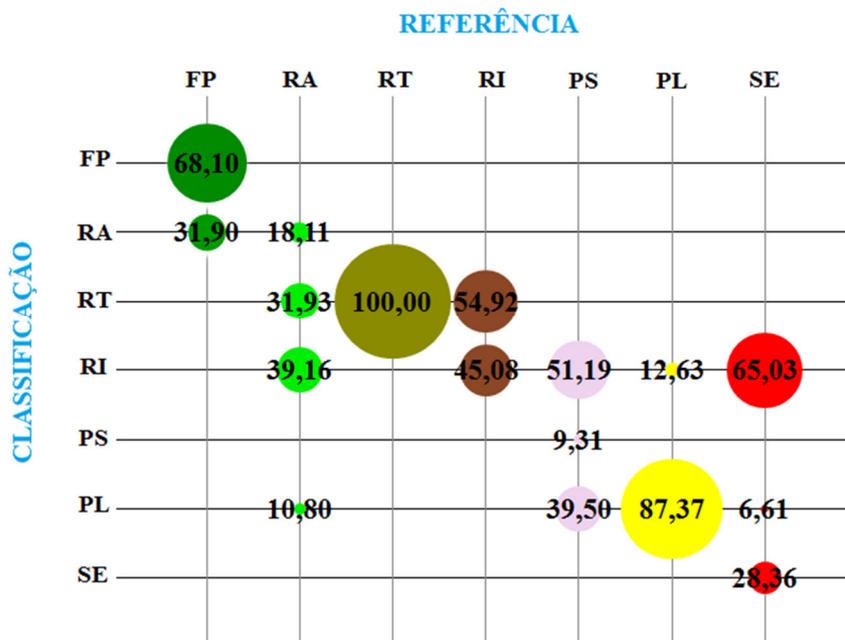
Fonte: Produção do autor.

Figura 6.23 – Resultados para a classificação multifonte da soma $\{R, Pi, Bh; T, Ga, Bh\}$.



(a)

(b)

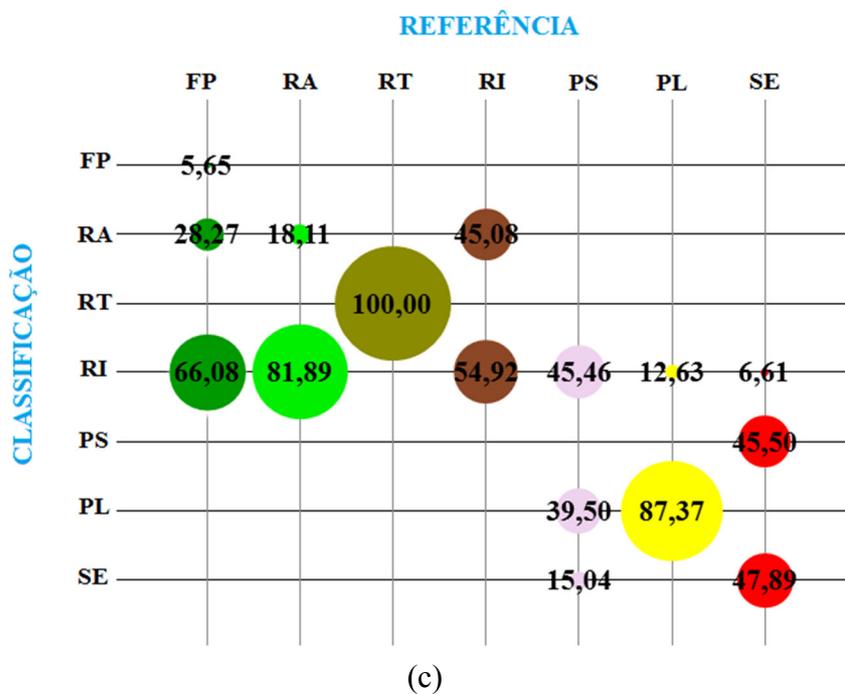
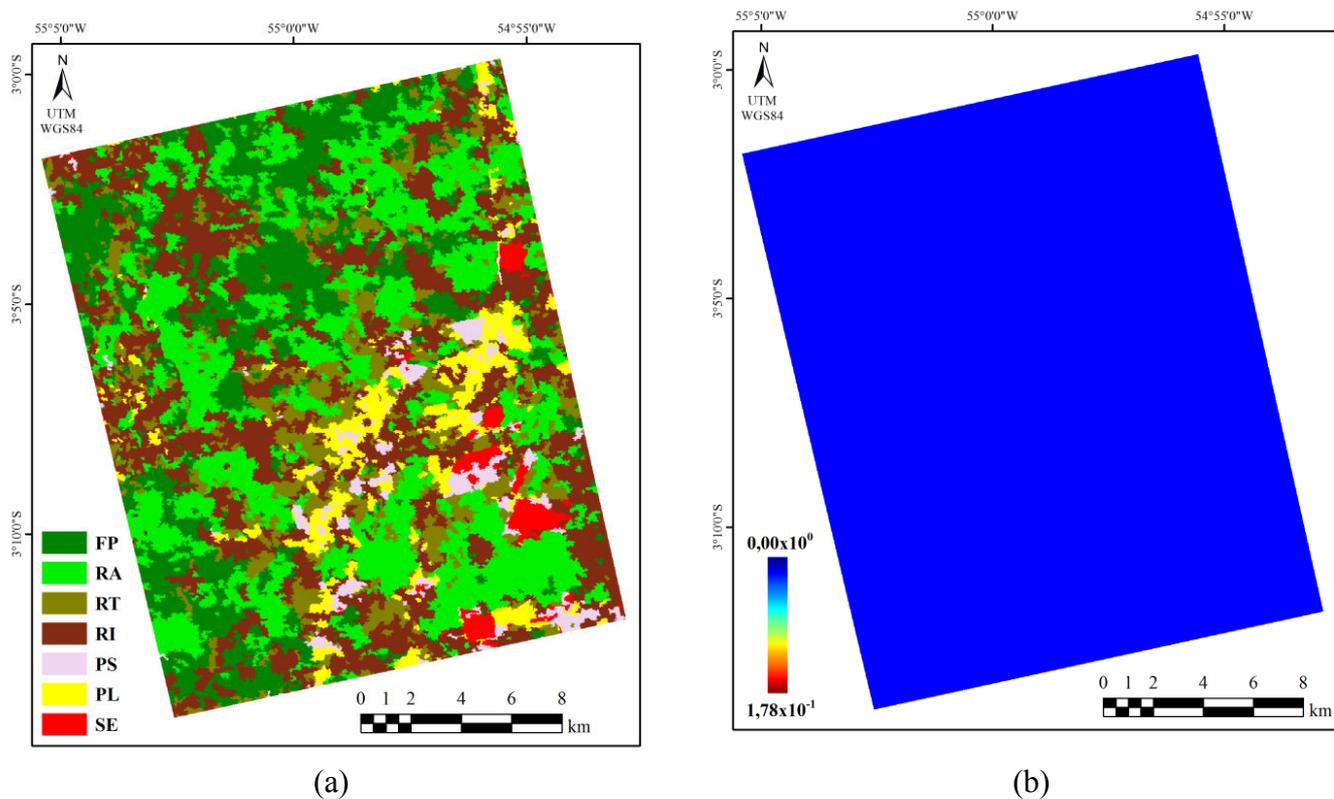


(c)

(a) Classificação; (b) Mapa de possibilidade e (c) Matriz de confusão..

Fonte: Produção do autor.

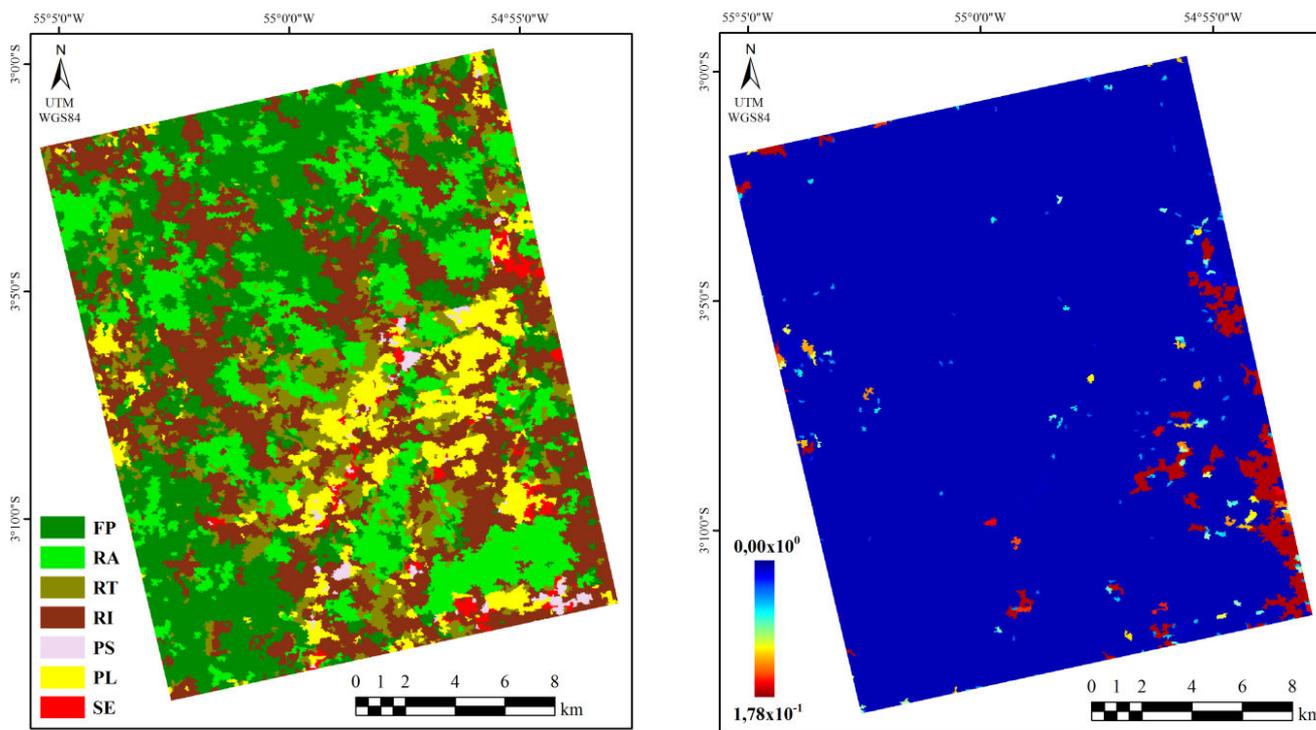
Figura 6.24 – Resultados para a classificação multifonte da soma $\{P, P_i, B_h; R, W_i, B_h\}$.



(a) Classificação; (b) Mapa de possibilidade e (c) Matriz de confusão.

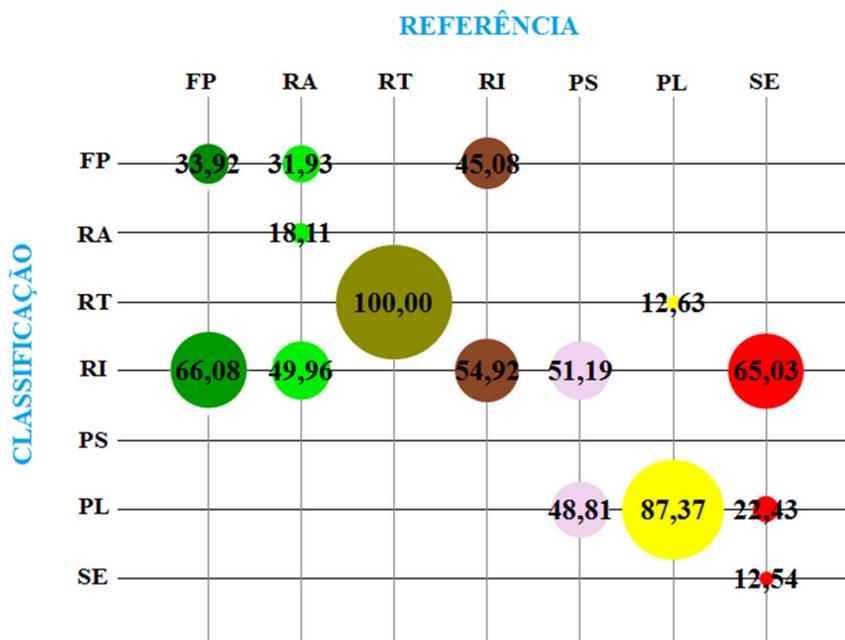
Fonte: Produção do autor.

Figura 6.25 – Resultados para a classificação multifonte da soma $\{P, Wi, Bh; R, Pi, Bh\}$



(a)

(b)



(c)

(a) Classificação; (b) Mapa de possibilidade e (c) Matriz de confusão..

Fonte: Produção do autor.

7 CONCLUSÕES E TRABALHOS FUTUROS

O objetivo central deste trabalho foi a proposição de uma nova metodologia de integração de dados classificados baseada em distâncias estocásticas e testes de hipóteses, denominada "Classificação multifonte". Por intermédio das análises realizadas sobre os resultados de classificação obtidos chegou-se à conclusão de que a metodologia proposta é viável e efetiva, no entanto, maiores estudos devem ser realizados para sua validação.

Os objetivos específicos foram atingidos, uma vez que, no âmbito da pesquisa com distâncias estocásticas e testes de hipótese associados, provou-se matematicamente que é possível desenvolver distâncias estocásticas entre funções densidade de probabilidade conjuntas não conhecidas a partir das distâncias entre as distribuições marginais conhecidas, quando se supõe a independência entre fontes distintas que geraram os dados. Já no contexto da classificação de imagens, demonstrou-se que, por meio de informações provenientes de múltiplas fontes, é possível obter resultados de classificação por regiões com melhores índices de acurácia (coeficiente *Kappa* e acurácia global) do que os apresentados por classificações individuais.

De modo geral, combinações envolvendo somente os dados SAR resultaram, na maior parte, em classificações com maiores índices de acurácia do que aqueles apresentados pelas imagens individualmente. Para combinações envolvendo as imagens SAR e TM os índices foram elevados em algumas situações.

Especificamente observou-se que, os índices de acurácia da classificação da imagem Palsar foi melhorado 45% por meio do Cenário multifonte II $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$, 37% por meio do Cenário multifonte III $\{P, Wi, Bh; T, Ga, Bh\}$, e 26% por intermédio do quinto Cenário $\{P, Wi, Bh; R, Wi, Bh\}$. Os resultados de classificação da imagem Radarsat apresentaram melhoras de 32% através do Cenário multifonte II, 29% por meio do Cenário multifonte IV e 7% por meio do Cenário multifonte V. Os resultados de classificação relativos à imagem TM exibiram melhoras de 6% em relação ao Cenário multifonte I e 2% por meio do Cenário multifonte IV. Em relação ao Cenário III não houve melhoras para os resultados de classificação da imagem TM.

Para os Cenários multifontes empíricos dos mínimos e do produto, observou-se que, em comparação à imagem Palsar, ambos os Cenários obtiveram valores superiores de índice *Kappa* e acurácia global. Para a imagem Radarsat, somente o Cenário multifonte do produto apresentou valores superiores para os mesmos índices. Já para a imagem TM, ambos os Cenários apresentaram índices inferiores. A classificação baseada na lógica *Fuzzy* permitiu uma classificação em classes mistas com alta confiabilidade e altos valores de acurácia por classe. Isto pode ser visto como um fator positivo na metodologia de classificação proposta. Dada a variedade de Cenários multifontes distintos possíveis de serem construídos concluiu-se que é possível melhorar os resultados de classificação utilizando-se a metodologia multifonte proposta.

As análises realizadas neste trabalho permitiram a obtenção de outros resultados também pertinentes ao estudo em questão, tais como:

- para a imagem TM, resultados ligeiramente mais favoráveis são obtidos quando admite-se a distância de *Bhattacharyya* entre distribuições Gaussianas;
- para a imagem Palsar, fixada a distância de *Bhattacharyya*, as duas modelagens adotadas apresentam índices *Kappa* iguais e na modelagem *Wishart* complexa escalonada, os melhores resultados são obtidos utilizando-se as distâncias de *Bhattacharyya* e *Hellinger*;
- os resultados de classificação para a imagem Radarsat pela modelagem *Wishart* independem das distâncias adotadas. Além disso, para a distância de *Bhattacharyya*, os melhores valores ocorrem quando se adota a modelagem *Wishart* para tratamento dos dados;
- a modelagem de imagens SAR pela distribuição Par de intensidades permite maior identificação de porções de solo exposto do que pela modelagem *Wishart*;
- para trabalhos que envolvam imagens Palsar, a aquisição de dados polarimétricos ou bivariados é indiferente principalmente se este for utilizado em conjunto com um dado óptico (no caso, imagem TM);

- para aplicações que envolvam somente a utilização de imagens SAR (Palsar e Radarsat), recomenda-se o emprego de dados polarimétricos;
- para o caso em que se trabalha com imagens Radarsat, indica-se a aquisição de dados polarimétricos.

a partir dos resultados obtidos conclui-se que a metodologia de classificação multifontes é eficaz para a melhora de classificações. Todavia, embora os mapas de possibilidades tenham apresentado resultados coerentes acerca da confiabilidade da classificação, os mapas de probabilidade mostraram-se pouco robustos devido a provável existência de autocorrelação espacial entre os dados utilizados, resultado também obtido por Silva (2013). Os mapas de probabilidade mais representativos ocorreram para as imagens SAR modeladas por intermédio da distribuição Par de intensidades *multi-look*. Como trabalhos futuros, sugerem-se:

- estudos em busca da maior fonte de erros, responsável pelos baixos valores de acurácia encontrados, isto é, ajuste de distribuição incorreto, utilização de distância entre distribuição pouco “efetiva”, não adoção da *f. d. p.* conjunta que considera a correlação não-linear entre sensores, incerteza na definição das classes e problemas na coleta de amostras;
- avaliação dos resultados de classificação para dados simulados;
- análises mais detalhadas acerca do Cenário multifonte *Fuzzy* cuja aplicação pode estender-se ao estudo da mudança de uso e cobertura da terra e neste caso a utilização de dados adquiridos em datas distintos trariam contribuições para os resultados de classificação;
- análise da modelagem de imagens SAR por intermédio da distribuição Par de intensidades, uma vez que, os resultados de classificação das imagens SAR modeladas por essa distribuição exibiram os melhores mapas de probabilidade e permitiram maior identificação de porções da classe solo exposto do que pela modelagem *Wishart*;

- no trabalho em questão, para aplicação da metodologia multifonte, exige-se a utilização da mesma distância estocástica para diferentes distribuições relativas à modelagem dos dados. Um trabalho futuro pertinente refere-se à integração de dados modelados por diferentes distribuições e diferentes distâncias, neste caso a abordagem de classificação adotada deverá ser a abordagem empírica;
- analisando de forma geral, observou-se que o Cenário multifonte dos mínimos para determinadas classes, obteve valores de acurácia superiores em relação a todas as classificações correspondentes às imagens Palsar, Radarsat e TM. Desta forma, uma análise mais detalhada acerca deste Cenário de classificação é pertinente como um trabalho futuro, pois, embora, de maneira geral, o Cenário dos mínimos não tenha superado os valores de acurácia global e coeficientes *Kappa* em relação aos outros Cenários, analisando-se sua contribuição na análise individual das acurácias por classe obtêm-se resultados interessantes;
- sugere-se também, a construção e análise de Cenários multifontes teóricos baseados nos resultados encontrados para a distância de *Hellinger* entre distribuições (Equação 3.8);
- estudo da utilização de diferentes Cenários para a classificação de classes específicas;
- combinação de diferentes Cenários onde obtêm-se classificações por intermédio de diferentes Cenários para posterior construção de uma classificação multifonte baseada nos mapas-*p* correspondentes;
- cálculo das distâncias para cada um dos polígonos das amostras de treinamento para obtenção da média das estatísticas relativas a esses polígonos. Neste caso, a atribuição da classe ao segmento dar-se-á por meio da função mínimo das médias.

REFERÊNCIAS BIBLIOGRÁFICAS

ABOUD NETA, S.R. **Uso de imagens Alos/Palsar multipolarizadas para detecção de incremento de desflorestamento na Amazônia**. 2009. 264p. (INPE-16624-TDI/1598). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009. Disponível em: <<http://urlib.net/8JMKD3MGP7W/36EBT5L>>. Acesso em: 27 jul. 2016.

AMARSAIKHAN, D.; DOUGLAS, T. Data fusion and multisource data classification. **International Journal Remote Sensing**, v. 25, n. 17, p. 3529-3539, sept. 2004.

AMARSAIKHAN, D.; SAANDAR, M.; GANZORING, M.; BLOTEVOGEL, H.; EGSHIGLEN, E.; GATUAL, R.; NERGUI, B.; ENKHJARGAL, D. Comparison of multisource image fusion methods and land cover classification. **International Journal Remote Sensing**, v. 33, n. 8, p. 2532–2550, 2012.

ASCHBACHER, J.; LICHTENEGGER, J. Complementary nature of SAR and optical data: a case study in the Tropics. **Earth Observation Quarterly**, v. 31, p. 4-8, 1990.

BINS, L.S.; FONSECA, L.G.; ERTHAL, G. Satellite Imagery Segmentation: a region growing approach. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8. (SBSR), 1996, Salvador. **Anais...** São José dos Campos: INPE, 1996. p. 677-680. CD-ROM. ISBN 85-17-00014-5. (INPE-6231-PRE/2321). Disponível em: <<http://urlib.net/sid.inpe.br/deise/1999/02.05.09.30>>. Acesso em: 13 abr. 2015.

BRAGA, B.C.; FREITAS, C.C.; SANT'ANNA, S.J.S. Classificação multifontes de imagens de sensoriamento remoto baseada em mapas de incertezas. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17. (SBSR), 2015, João Pessoa. **Anais...** São José dos Campos: INPE, 2015a. p. 4474-4481. ISBN 978-85-17-0076-8. Disponível em: <<http://urlib.net/8JMKD3MGP6W34M/3JM4CQS>>. Acesso em: 19 jan. 2016.

BRAGA, B.C.; FREITAS, C.C.; SANT'ANNA, S.J.S. Multisource classification based on uncertainty maps. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2015, Milão-Itália. (doi: 10.1109/IGARSS.2015.7326097.). **Proceedings...IEEE**, 2015b. p. 1630-1633.

BRAGA, B.C.; FREITAS, C.C.; SANT'ANNA, S.J.S. Distâncias estocásticas e mapas de incertezas aplicados à classificação de dados de múltiplos sensores. **Revista Brasileira de Cartografia (RBC)**, v. 7, n. 67, p. 1391-1411, 2015c.

BRISCO, B.; BROWN, R.J. Multidate SAR/TM synergism for crop classification in Western Canada. **Photogrammetric Engineering and Remote Sensing**, v. 61, n. 8, p. 1009-1014, 1999.

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.

CASELLA, G.; BERGER L.B. **Inferência Estatística**. 2. ed. São Paulo: Cengage Learning, 2010, 612p.. ISBN 978-85-221-0894-7.

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

CORREIA, A.H. **Projeto, desenvolvimento e avaliação de classificadores estatísticos pontuais e contextuais para imagens SAR polarimétricas**. 1998. 271 p. (INPE/7178-TDI/679). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 1998. Disponível em: <<http://urlib.net/6qtX3pFwXQZ4PKzA/isJ7N>>. Acesso em: 27 jul. 2016.

DUSSEUX, P.; CORPETTI, T.; HUBERT-MOY, L.; CORGNE, S. Combined use of multi-temporal optical and radar satellite images for Grassland monitoring. **Remote Sensing**, v.6, p. 6163-6182, 2014.

ESCADA, M.I.S.; AMARAL, S.; RENNÓ, C.D.; PINHEIRO, T.F. Levantamento do uso e cobertura da terra e da rede de infraestrutura no distrito florestal da BR-163. **Distrito florestal sustentável da BR-163: dinâmicas sociais, mudanças ambientais e produção florestal**. Belém: Museu Paraense Emílio Goeldi, 2015. p. 39-65. ISBN 9788561377687.

FORKUOR, G.; CONRAD, C.; THIEL, M.; ULLMANN, T.; ZOUNGRANA, E. Integration of optical and synthetic aperture radar imagery for improving crop mapping in northwestern Benin, west Africa. **Remote Sensing**, n.6, p. 6472-6499, 2014.

FREITAS, C.C.; SANT'ANNA, S.J.S.; RENNÓ, C.D.; CORREIA, A. H. (eds.). **Utilização de imagens de radar de abertura sintética na classificação do uso e ocupação do solo**. São José dos Campos: INPE, 2003. 54p. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m17@80/2007/08.10.18.20>>. Acesso em: 27 jul. 2016.

FREITAS, C.C.; FRERY, A.C.; CORREIA, A.H. The polarimetric G distribution for SAR data analysis. **Environmetrics**, v.16, n.1, p. 13–31, 2005.

FRERY, A.C.; NASCIMENTO, AD.C.; CINTRA, R.J. Analytic expressions for stochastic distances between relaxed Complex *Wishart* Distributions. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n.2, p. 1213-1226, 2010.

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.

FURTADO, L.F.A.; SILVA, T.S.F.; FERNANDES, P.J.F.; NOVO, E.M.L.M. Land cover classification of Lago Grande de Curuai floodplain (Amazon, Brazil) using multi-sensor and image fusion techniques. **Acta Amazonia**, v.45, n.2, p. 195-202, 2015.

GERSTL, S.A.W. Physics concepts of optical and radar reflectance signatures - a summary review. **International Journal of Remote Sensing**, v.11, n.7, p. 1109-1117, 1990.

GONZALEZ, R.C; WOODS, R.E. **Digital image processing**. 2 Ed. New Jersey: Prentice Hall, 2002. 793p. ISBN 0-201-18075-8.

GOODMAN, N.R, Statistical analysis based on a certain complex Gaussian distribution (an introduction). **The Annals of Mathematical Statistics**, v.34, n.1, p. 152-177, 1963.

GUERRA, J.B. **Análise metodológica do tratamento de dados SAR R99B para discriminar incremento de desflorestamento no sudoeste da Amazônia brasileira** 2008. 199 p. (INPE-15677-TDI/1451). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2008. Disponível em: <<http://urlib.net/8JMKD3MGP8W/34PR29L>>. Acesso em: 27 jul. 2016.

HAACK, B.N.; HEROLD N. D.; BECHDOL M.A. Radar and optical data integration for land-use/land-cover mapping. **Photogrammetric Engineering & Remote Sensing**, v.66, n.6, p. 709-716, 2000.

HAACK, B.; BECHDOL, M. Integrating multisensor data and radar texture measures for land cover mapping. **Computers and Geosciences**, v. 26, p. 411-421, 2000.

HAACK, B.; SOLOMON, E.K; BECHDOL, M; HEROLD N.D. Radar and Optical data comparison/integration for urban delineation: A case study. **Photogrammetric Engineering & Remote Sensing**, v. 68, n. 12, p. 1289-1296, 2002.

HUANG, H.; LEGARSKY, J.; OTHMAN, J. Land-cover classification using Radarsat and Landsat imagery for St. Louis, Missouri. **Photogrammetric engineering and remote sensing**. v.73, n.1, p. 37-43, 2007.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Catálogo LANDSAT5**. 2013. Disponível em: <<http://www.dgi.inpe.br>>. Acesso em: 16 out. 2015.

JAMES, B.R. **Probabilidade**: um curso em nível intermediário. 3 ed., Rio de Janeiro: IMPA, 2010. 304 p.

JAPAN AEROSPACE EXPLORATION AGENCY (JAXA). **Alos/Palsar level 1.1/1.5 product format description**. Tokyo: JAXA, 2009. 158 p. (NEB-070062B).

KAILATH, T. The divergence and *Bhattacharyya* distance measures in signal selection. **IEEE Transactions on Communication Technology**, v. 15, p. 52-60, 1967.

KULLBACK, S. Information Theory and Statistics. **Journal of the American Statistical Association**, v.54, n. 288, p 825-827, 1959.

LEE, J.S.; SCHULER, D.L.; LANG, R.H.; RANSON, K.J. K-distribution for multi-look processed polarimetric SAR imagery. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 1994, Pasadena, CA. **Proceedings...IEEE**, 1994. v.4, p.2179-2181.

LEE, J.S.; DU, L.; SCHULER, D.L.; GRUNES, M.R. Statistical analysis and segmentation of multi-look SAR imagery using partial polarimetric data. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 1995, Firenze, Itália. **Proceedings...** IEEE, 1995. v.3, p.1422-1424.

LIMA, E. L. **Espaços métricos**. 4. ed. Rio de Janeiro: IMPA, 2011. 299 p. ISBN 978-85-244-0158-9. (Projeto Euclides).

LU, D.; LI, G.; MORAN, E.; DUTRA, L.; BATISTELLA, M. A comparison of multisensor integration methods for land cover classification in the Brazilian Amazon. **GIScience & Remote Sensing**, v. 48, n. 3, p. 345-370, 2011.

MACDONALD DETTWILER AND ASSOCIATES LTD. **Radarsat-2 product description**. Canadá: MDA, 2011. (RN-SP-52-1238).

MENESES, P.R.; ALMEIDA, T. **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. Brasília: Universidade de Brasília, 2012. 276 p. Disponível em:< <http://www.cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8>>. Acesso em: 15 mar. 2015.

NASCIMENTO, A.D.C.; CINTRA, R.J.; FRERY, A.C. Hypothesis testing in speckled data with stochastic distances. **IEEE Transactions on Geoscience and Remote Sensing**, v. 48, n.1, p. 373-385, 2010.

NASCIMENTO, A.D.C.; HORTA, M.M.; FRERY, A.C. Boundary detection with stochastic distance in polarimetric imagery, In: INTERNATIONAL WORKSHOP ON SCIENCE AND APPLICATIONS OF SAR POLARIMETRY AND POLARIMETRIC INTERFEROMETRY, 5., 2011, Frascati-Itália. **Proceedings...**,Noordwijk: ESA, 2011.

NASCIMENTO, A.D.C. **Teoria Estatística da Informação para Dados de Radar de Abertura Sintética Univariados e Polarimétricos**, 2012. 262 p. Tese (Doutorado em estatística) - Universidade Federal de Pernambuco, Recife, 2012.

NEGRI, R. G. **Avaliação de dados polarimétricos do sensor Alos Palsar para classificação da cobertura da terra da Amazônia**, 2009. 170 p. (INPE-16220-TDI/1541). Dissertação (Mestrado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009. Disponível em: <<http://urlib.net/8JMKD3MGP8W/35AKRR5>>. Acesso em: 27 jul. 2016.

NEUMAN, E. Inequalities involving multivariate convex functions II, **Proceedings of the American Mathematical Society**, v.109, n.4, p. 965–974, 1990.

PARIS, J.E.; KWONG, H.H. Characterization of vegetation with combined Thematic Mapper (TM) and Shuttle Imaging Radar (SIR-B) image data. **Photogrammetric Engineering Remote Sensing**, v. 54, n. 8, p.1187-1193, 1988.

PEREIRA, L.O.; FREITAS, C.C.; SANT'ANNA, S.J.S.; LU, D.; MORAN, E.F. Optical and radar data integration for land use and land cover mapping in the Brazilian Amazon, **GIScience and Remote Sensing**, v.50, p.301-321, 2013.

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, São José dos Campos, 2012. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3CHCSD5>>. Acesso em: 27 jul. 2016.

POHL, C.; VAN GENDEREN, J.L. Multisensor image fusion in remote sensing: concepts, methods and applications. **International Journal of Remote Sensing**, v. 19, n. 5, p. 823-854,1997.

REICHE, J.; SOUZA JR., C.M.; HOEKMAN, D.H.; VERBESSELT, J.; PERSAUD, H.; HEROLD, M. Feature Level fusion of multi-temporal Alos Palsar and Landsat data for mapping and monitoring of tropical deforestation and forest degradation. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing (J-STARS)**, v.6, n.5, p. 2159-2173, 2013.

REIS, M.S. **Detecção de mudanças de uso e Cobertura da Terra utilizando dados óticos e de Micro-ondas em uma região da Amazônia Brasileira**.2014. 331 p. (sid.inpe.br/mtc-m21b/2014/06.30.19.09-TDI). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2014. Disponível em: <<http://urlib.net/8JMKD3MGP5W34M/3GJ7LFB>>. Acesso em: 27 jul. 2016.

SALDANHA, M.F.S. **Um segmentador multinível para imagens SAR polarimétricas baseado na distribuição Wishart**. 2013. 289p. (o.sid.inpe.br/mtc-m19/2014/01.22.12.39-TDI). Tese (Doutorado em Computação Aplicada)- Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3FKAGTL>>. Acesso em: 27 jul. 2016.

SALICRÚ, 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.

SANTOS, C.; MESSINA, J. Multi-sensor data fusion for modeling African Palm in the Ecuadorian Amazon, **Photogrammetric engineering and remote sensing**. v. 74 n. 6, p. 711–724, 2008.

SARABANDI, K. Derivations of phase statistics from the Mueller matrix. **Radio Science**, v.27, n. 5, p. 553–560, 1992.

SARTORI, L. R. **Informação polarimétrica Palsar/Alos aplicada à discriminação de espécies e estimação de parâmetros morfológicos de macrófitas**. 2011. 126 p. Tese (Doutorado em Ciências Cartográficas) - Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia. Presidente Prudente, 2011.

SCHISTAD-SOLBERG, A.H.; JAIN A. K.; TAXT T. Multisource classification of remotely sensed data: fusion of Landsat TM and SAR images. **I.E.E.E. Transactions on Geoscience and Remote Sensing**, v. 32, p. 768 - 778, 1994.

SCHISTAD-SOLBERG, A.H.; JAIN A.K.; TAXT T. A Markov random field model for classification of multisource satellite imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v.34, p. 100 – 112, 1996.

SEGHOUANE, A.K.; AMARI, S.I. The AIC criterion and symmetrizing the *Kullback-Leibler* divergence. **IEEE Transactionson Neural Networks**, v. 18, n. 1, p. 97 - 106, 2007.

SILVA, W.B. **Classificação de regiões de imagens utilizando testes de hipóteses baseados em distâncias estocásticas: aplicações a dados polarimétricos**. 2013. 143p. (sid.inpe.br/mtc-m19/2013/02.20.16-TDI). Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3DJMB48>>. Acesso em: 27 jul. 2016.

SILVA, W.B.; FREITAS, C.C.; SANT'ANNA, S.J.S.; FRERY, A.C. Classification of segments in PolSAR imagery by minimum stochastic distances between *Wishart* distributions. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing (J-STARS)**, v. 6, p. 1263 - 1273, 2013.

SIMONE, G.; FARINA, A.; MORABITO, F. C.; SERPICO, S. B.; BRUZZONE, L. Image fusion techniques for remote sensing application. **Information Fusion Journal**, v. 3, n. 1, p. 3 - 15, 2002.

SOUSA JR, M. **Segmentação multi-níveis e multi-modelos para imagens radar e ópticas**. 2005. 131 p. (INPE - 14466-TDI/1147). Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005. Disponível em: <<http://urlib.net/sid.inpe.br/jeferson/2005/06.01.18.47>>. Acesso em: 27 jul. 2016.

TORRES, L.J.T.M. **Um novo algoritmo para filtragem de *Speckle* em imagens SAR de intensidade baseado em distâncias estocásticas**. 2012. 74 p. Dissertação (Mestrado em Modelagem Computacional de Conhecimento)- Universidade Federal de Alagoas, Instituto de Computação. Maceió, 2012.

ULABY, F.T.; ELACHI, C. **Radar Polarimetry for Geoscience Applications**. Norwood: Artech House Remote Sensing Library, 1990. 388 p. ISBN-10 0890064067.

YANASSE, C.C.F.; FRERY, A.C.; SANT'ANNA, S.J.S.; FILHO, P.H.; DUTRA, L.V. Statistical Analysis of SAREX data over the Tapajós- Brazil. In: International workshop on South American Radar Experiment (SAREX-92), 1993, Paris, França. **Proceedings...** ESA Headquarters, 1993. P. 6-8.

APÊNDICE A –VERIFICAÇÃO DA INDEPENDÊNCIA ENTRE OS SENSORES

A.1 – Análise da correlação linear entre as bandas das imagens TM, Palsar e Radarsat.

Tabela A.1 – Matriz de correlação linear de Pearson entre as bandas das imagens TM (T), Palsar (P) e Radarsat (R).

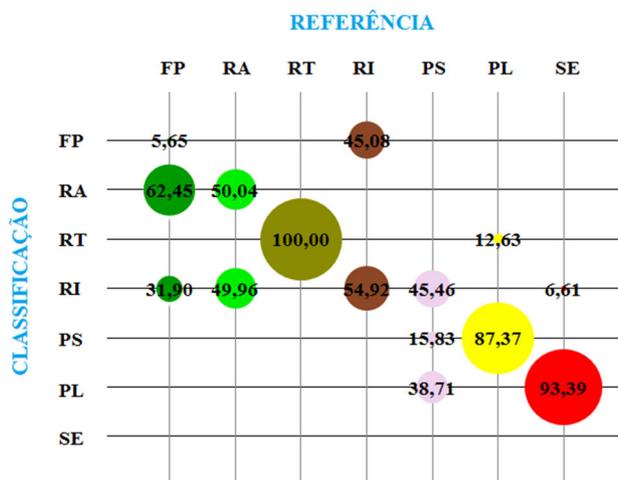
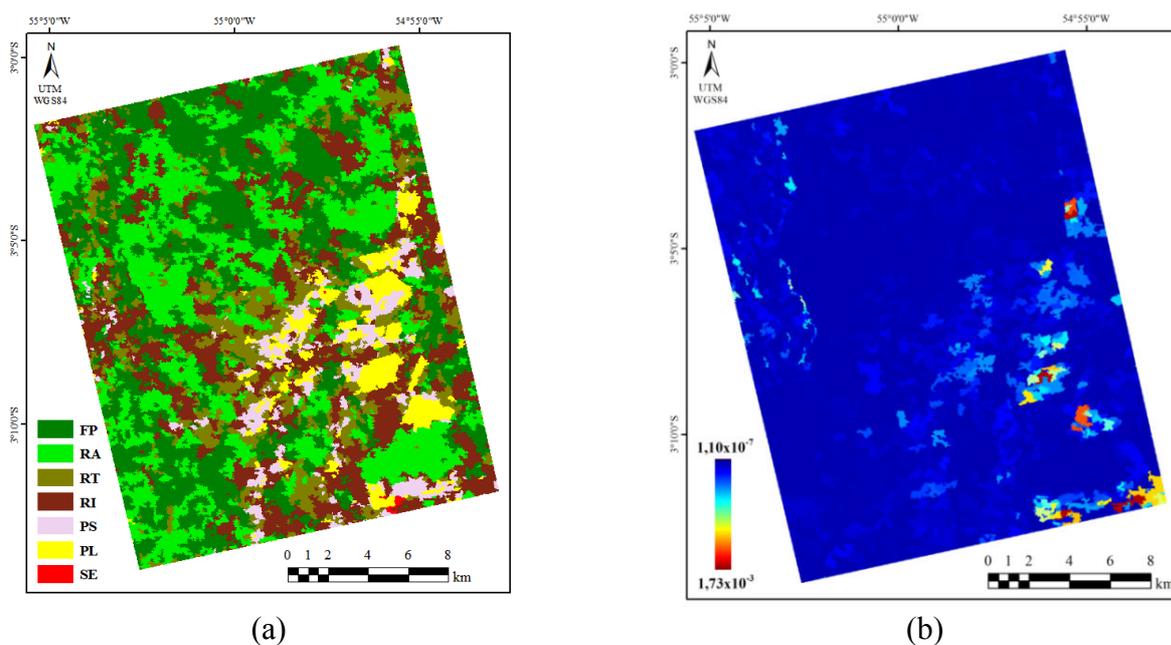
	T_B1	T_B2	T_B3	T_B4	T_B5	T_B6	P_HH	P_HV	P_VV	R_HH	R_HV	R_VV
T_B1	1,000	0,909	0,927	0,145	0,880	0,898	0,056	-0,169	0,004	-0,161	-0,169	-0,181
T_B2	0,909	1,000	0,940	0,294	0,910	0,898	0,053	-0,194	0,002	-0,178	-0,187	-0,204
T_B3	0,927	0,940	1,000	0,094	0,905	0,944	0,060	-0,174	0,003	-0,167	-0,176	-0,186
T_B4	0,145	0,294	0,094	1,000	0,335	0,142	-0,011	-0,092	-0,006	-0,070	-0,055	-0,085
T_B5	0,880	0,910	0,905	0,335	1,000	0,957	0,037	-0,184	0,001	-0,175	-0,177	-0,194
T_B6	0,898	0,898	0,944	0,142	0,957	1,000	0,043	-0,171	0,002	-0,165	-0,172	-0,183
P_HH	0,056	0,053	0,060	-0,011	0,037	0,043	1,000	0,047	0,550	0,016	-0,001	0,006
P_HV	-0,169	-0,194	-0,174	-0,092	-0,184	-0,171	0,047	1,000	0,062	0,079	0,081	0,086
P_VV	0,004	0,002	0,003	-0,006	0,001	0,002	0,550	0,062	1,000	0,023	0,007	0,010
R_HH	-0,161	-0,178	-0,167	-0,070	-0,175	-0,165	0,016	0,079	0,023	1,000	0,402	0,558
R_HV	-0,169	-0,187	-0,176	-0,055	-0,177	-0,172	-0,001	0,081	0,007	0,402	1,000	0,413
R_VV	-0,181	-0,204	-0,186	-0,085	-0,194	-0,183	0,006	0,086	0,010	0,558	0,413	1,000

Fonte: Produção do autor.

APÊNDICE B – CENÁRIOS MONOFONTES

B.1 - Cenário monofonte da imagem Palsar correspondente às combinações I, VI e VIII.

Figura B.1 – Resultados para os Cenários monofontes $\{P, Wi, Re\}$ e $\{P, Wi, KL\}$.

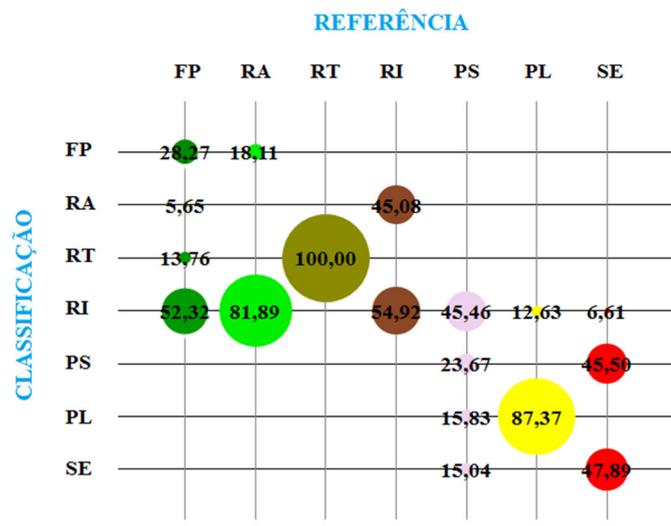
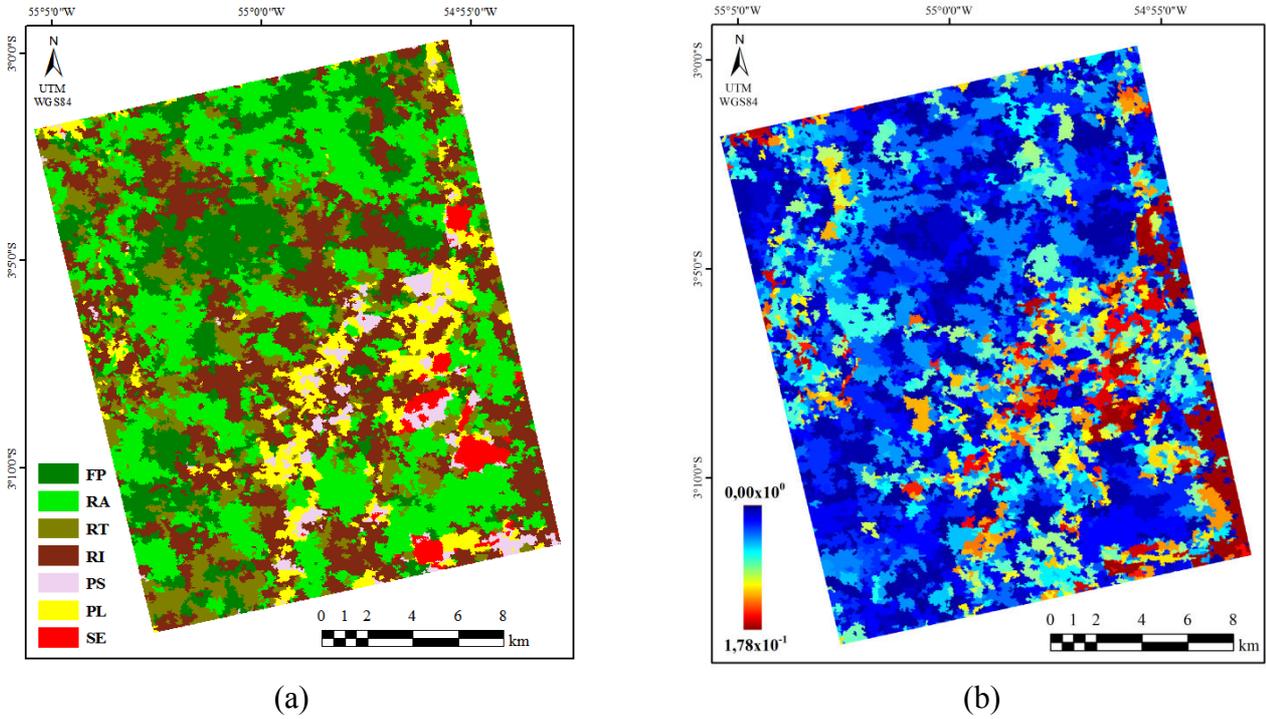


(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

B.2 - Cenário monofonte da imagem Radarsat correspondente às combinações I, II, IV, V, VII, VIII e X.

Figura B.2 – Resultados para os Cenários monofontes $\{R, Wi, Re\}$, $\{R, Wi, Bh\}$, $\{R, Wi, KL\}$ e $\{R, Wi, He\}$.

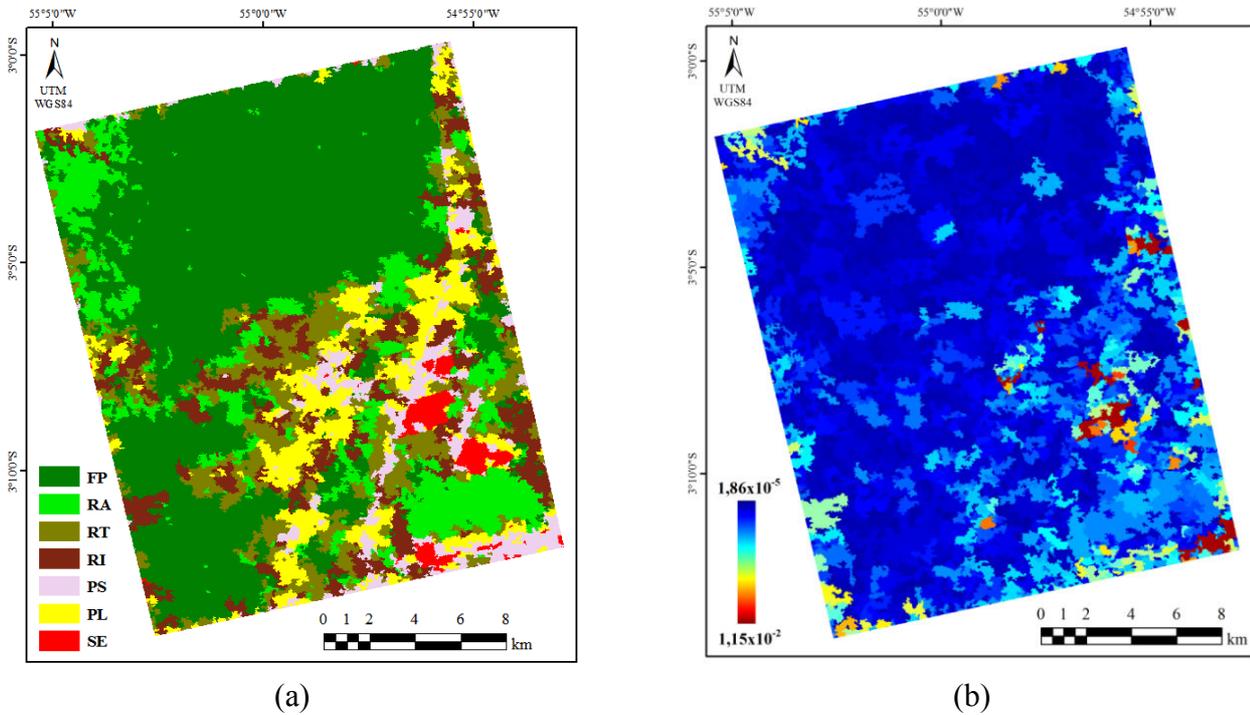


(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

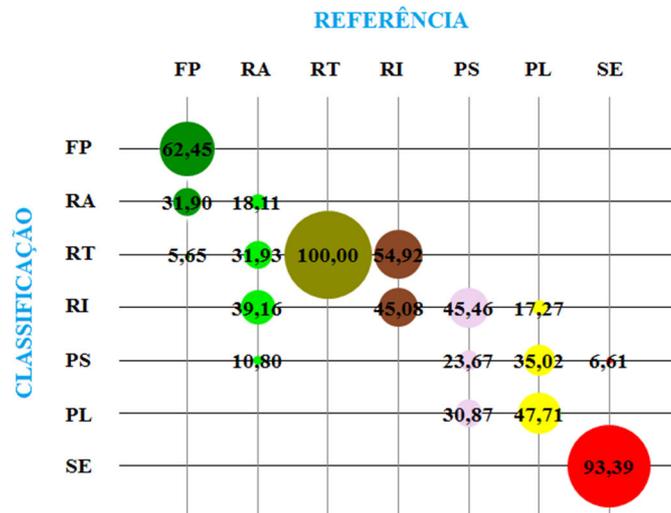
B.3 - Cenário monofonte da imagem TM correspondente às combinações VI e VII.

Figura B.3 – Resultados para o Cenário monofonte $\{T, Ga, KL\}$.



(a)

(b)



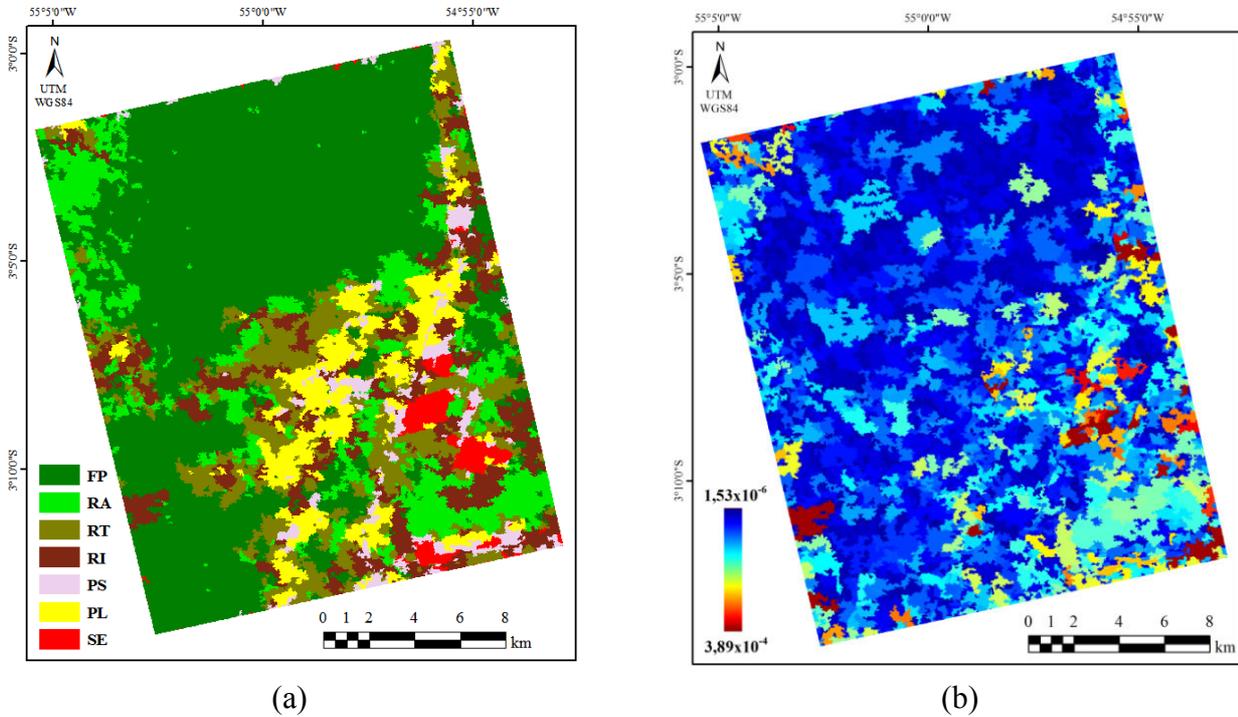
(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

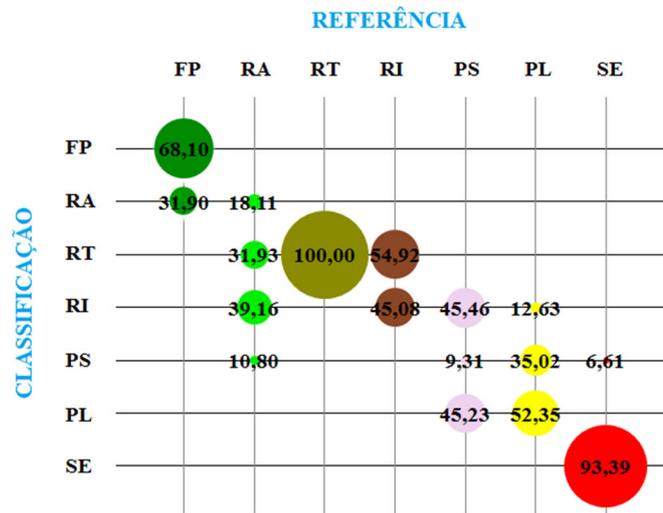
B.4 - Cenário monofonte da imagem TM correspondente às combinações II a IV.

Figura B.4 – Resultados para o Cenário monofonte $\{T, Ga, Bh\}$.



(a)

(b)



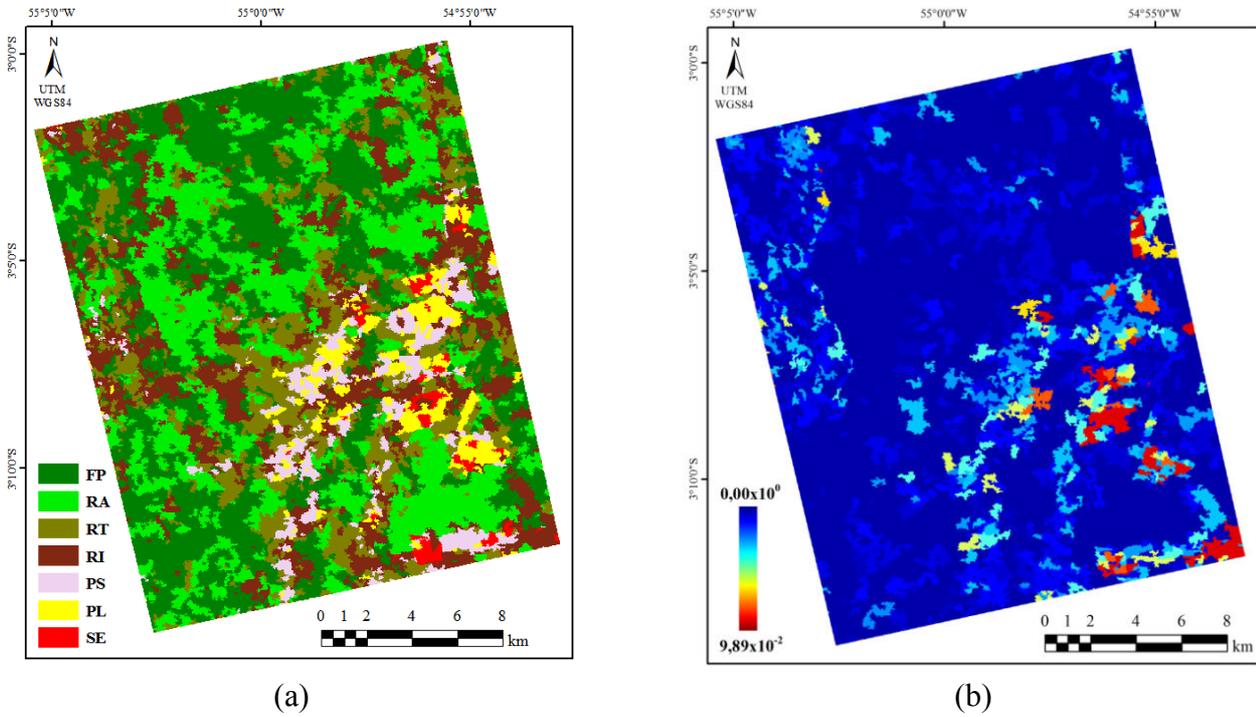
(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

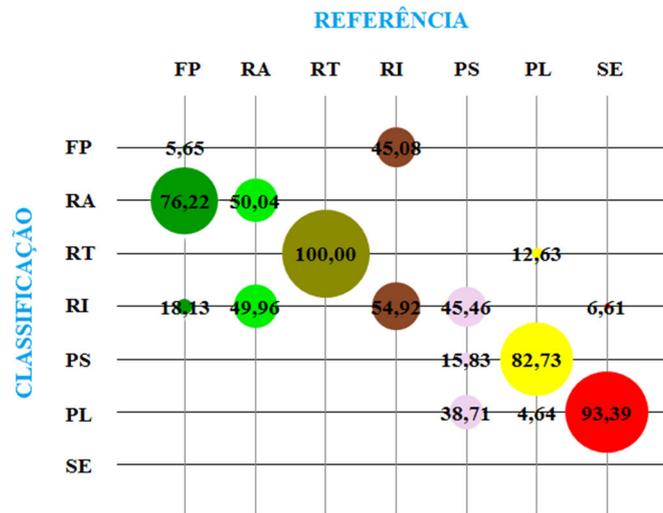
B.5 - Cenário monofonte da imagem Palsar correspondente à combinação IX

Figura B.5 – Resultados para o Cenário monofonte $\{P, Pi, Bh\}$.



(a)

(b)



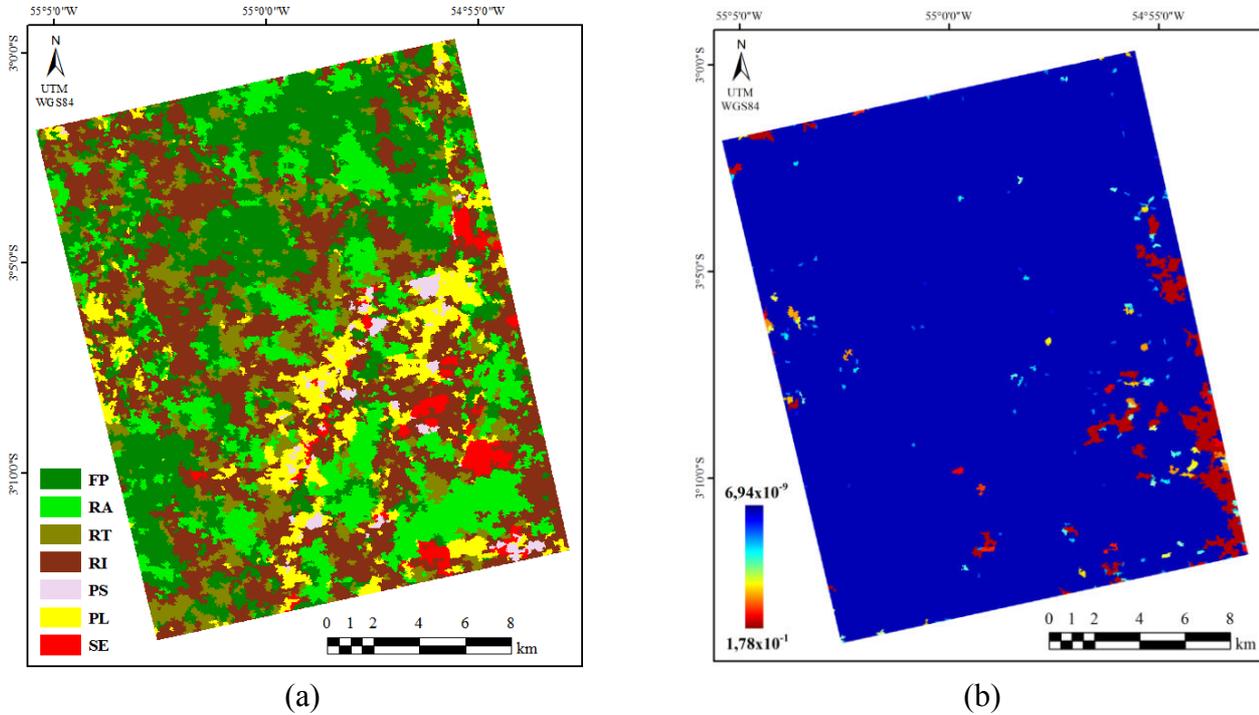
(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

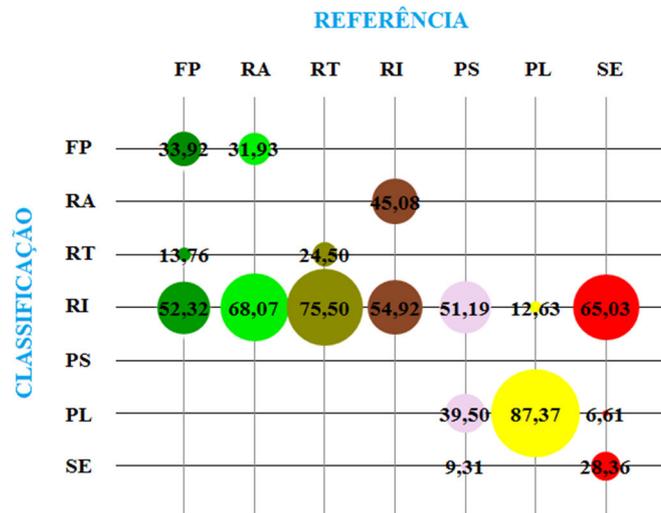
B.6 - Cenário monofonte da imagem Radarsat correspondente à combinação IX

Figura B.6 – Resultados para o Cenário monofonte $\{R, Pi, Bh\}$.



(a)

(b)



(c)

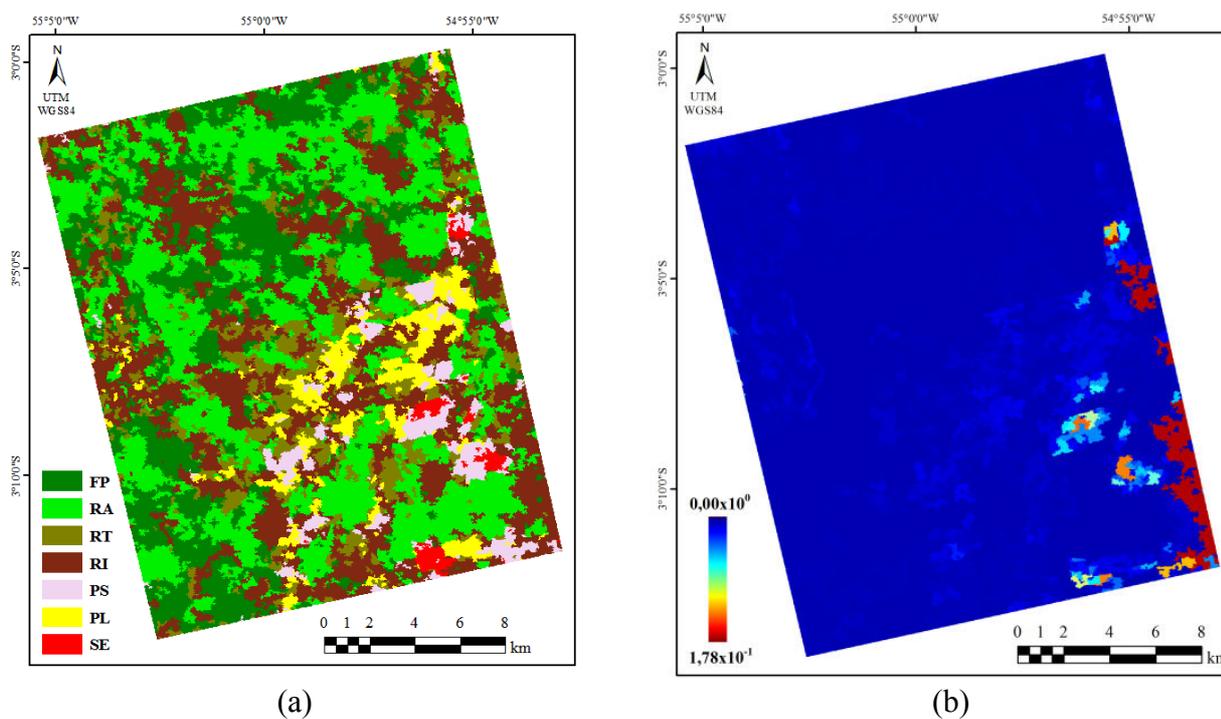
(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

APÊNDICE C – CENÁRIOS MULTIFONTES DA SOMA

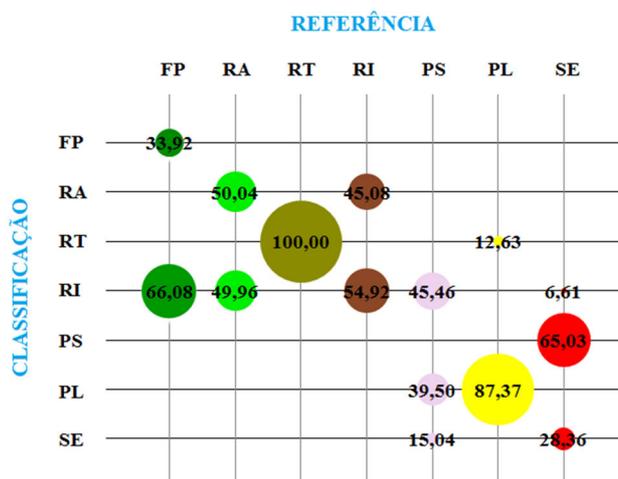
C.1 - Cenário da soma para combinação I

Figura C.1 – Combinação I: resultados para a classificação multifonte da soma $\{P, Wi, Re; R, Wi, Re\}$.



(a)

(b)



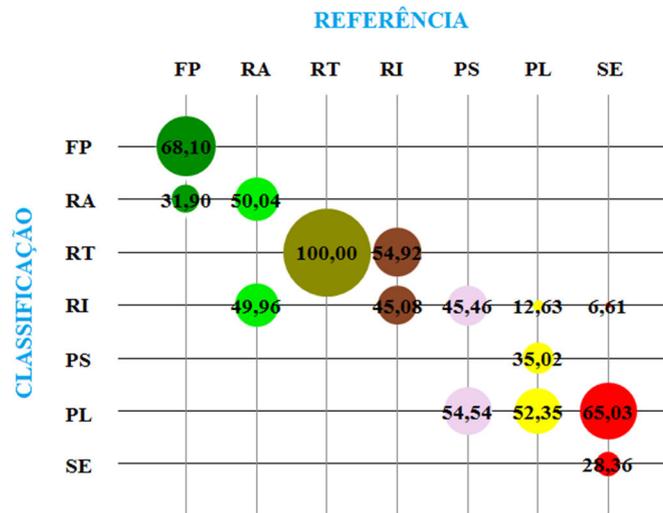
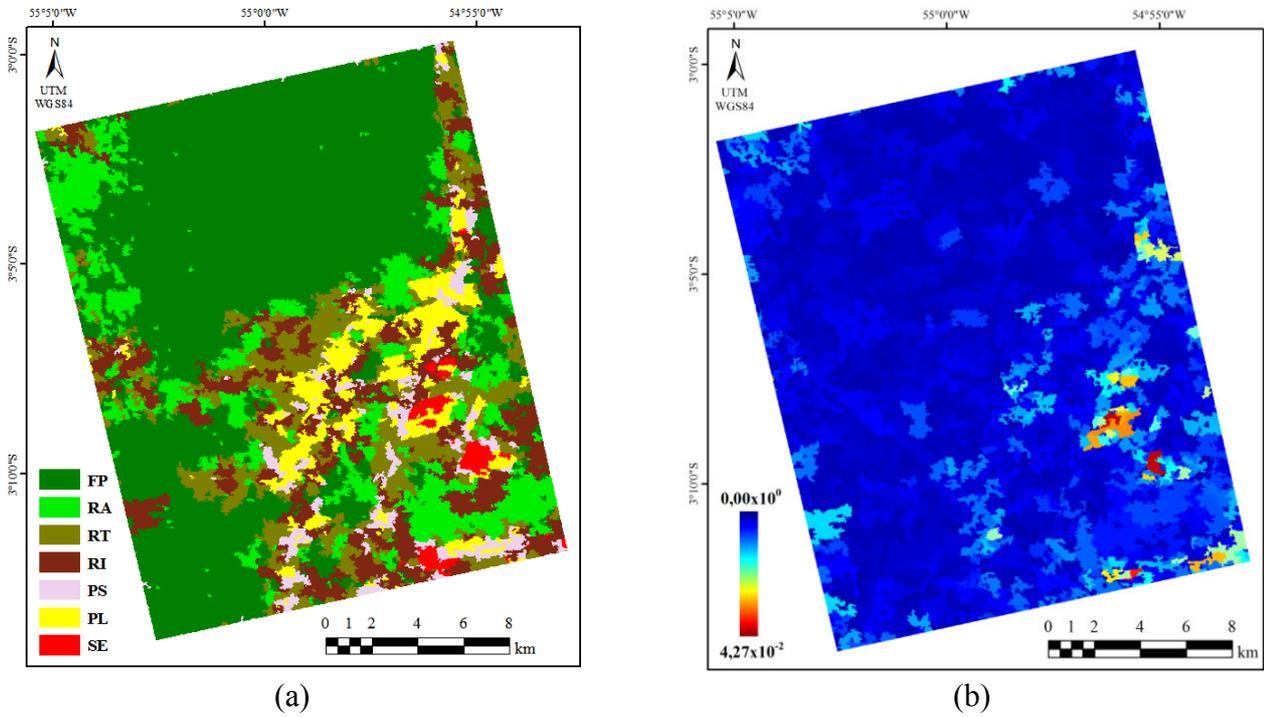
(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

C.2 - Cenário da soma para combinação III

Figura C.2 – Combinação III: resultados para a classificação multifonte da soma $\{P, Wi, Bh; T, Ga, Bh\}$



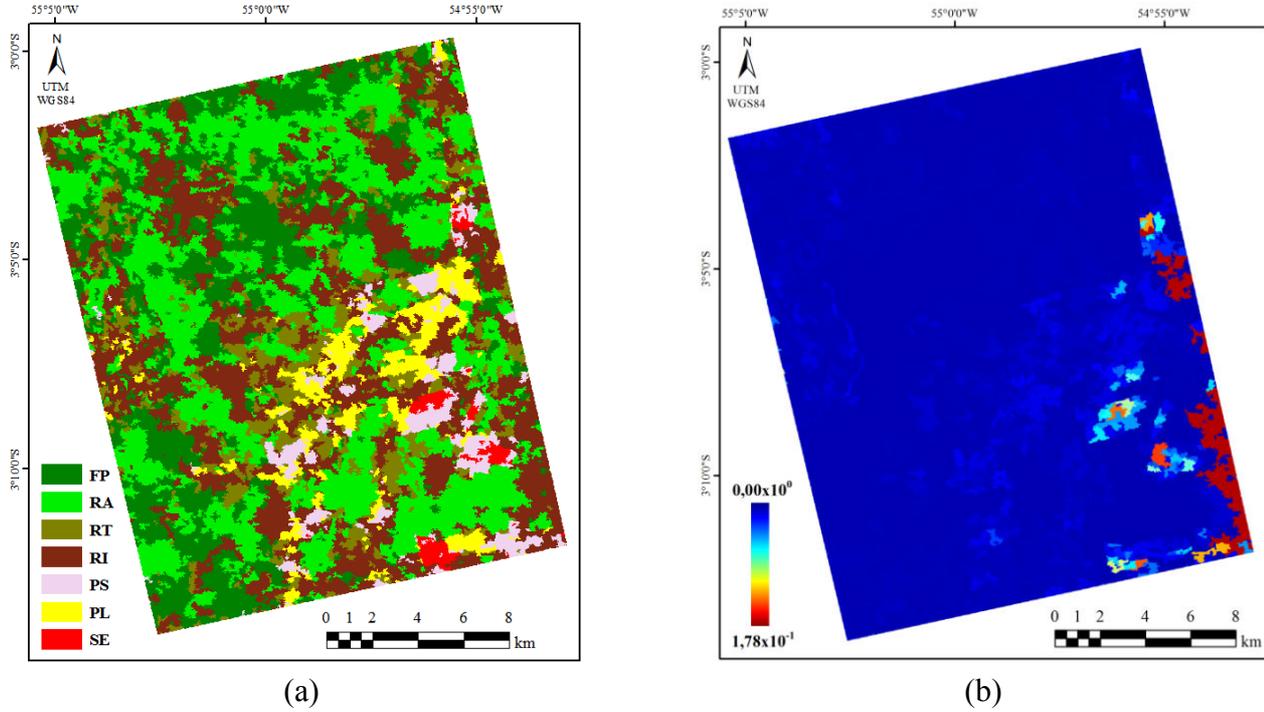
(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

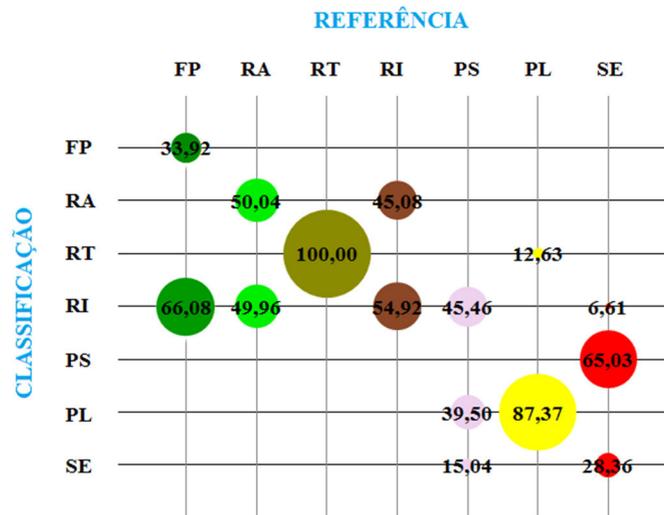
C.3 - Cenário da soma para combinação V

Figura C.3 – Combinação V: resultados para a classificação multifonte da soma $\{P, Wi, Bh; R, Wi, Bh\}$.



(a)

(b)



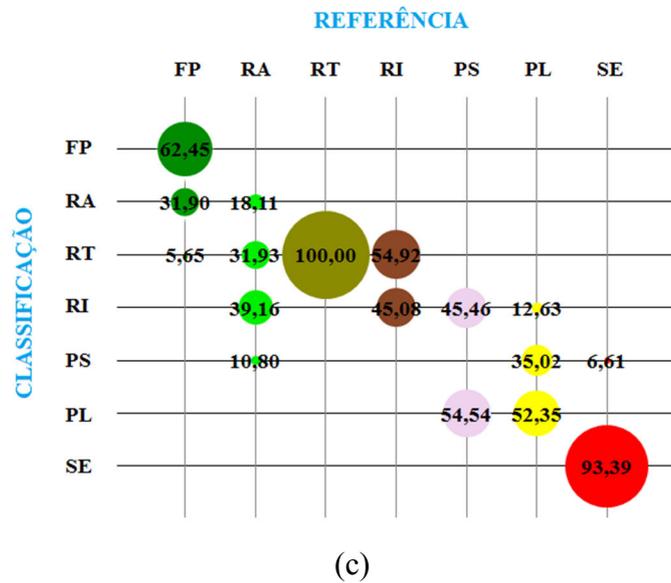
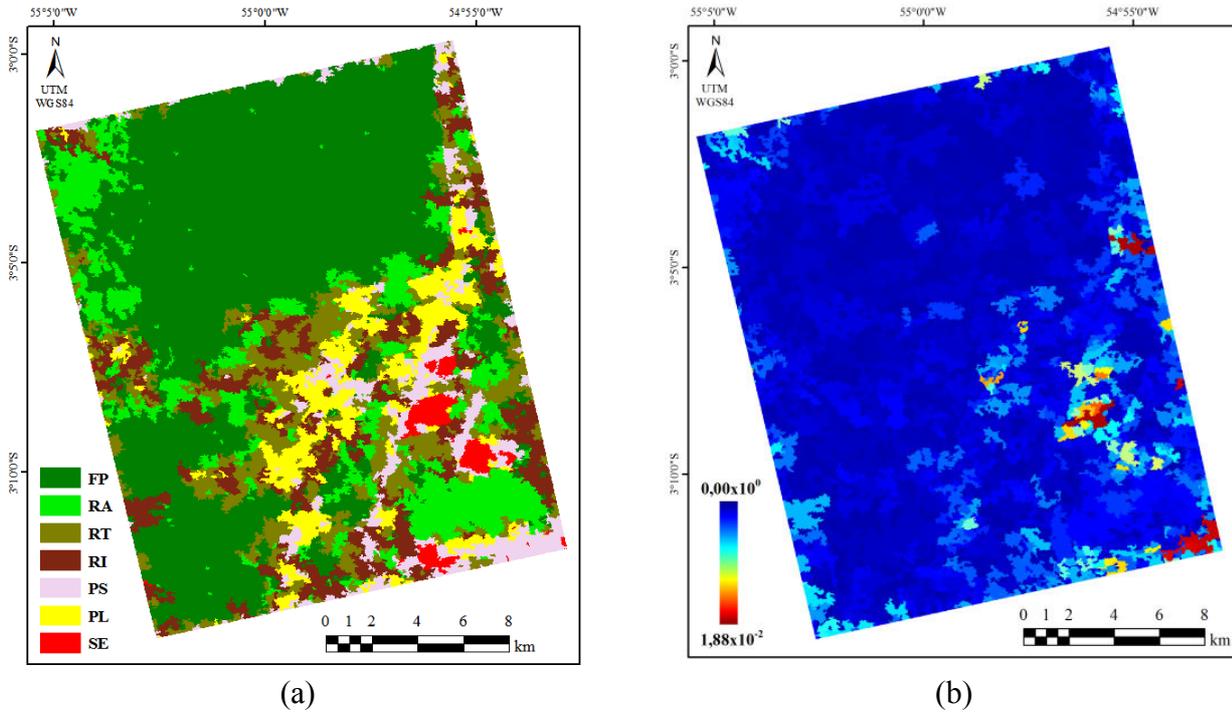
(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

C.4 - Cenário da soma para combinação VI

Figura C.4 – Combinação VI: resultados para a classificação multifonte da soma $\{P, Wi, KL; T, Ga, KL\}$.

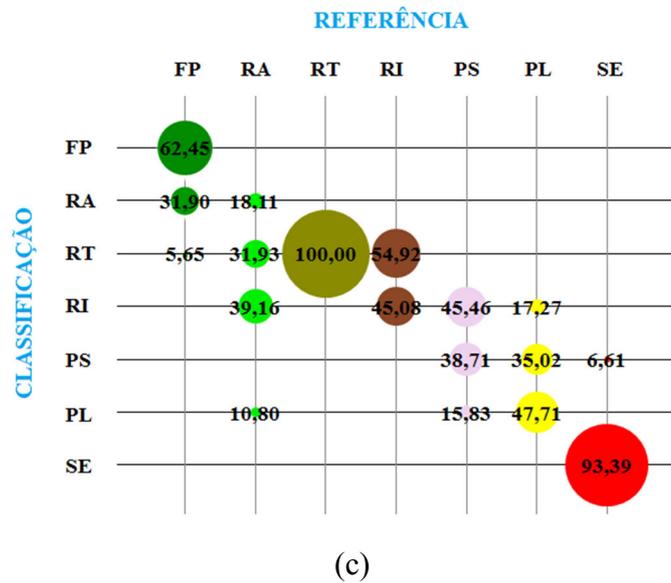
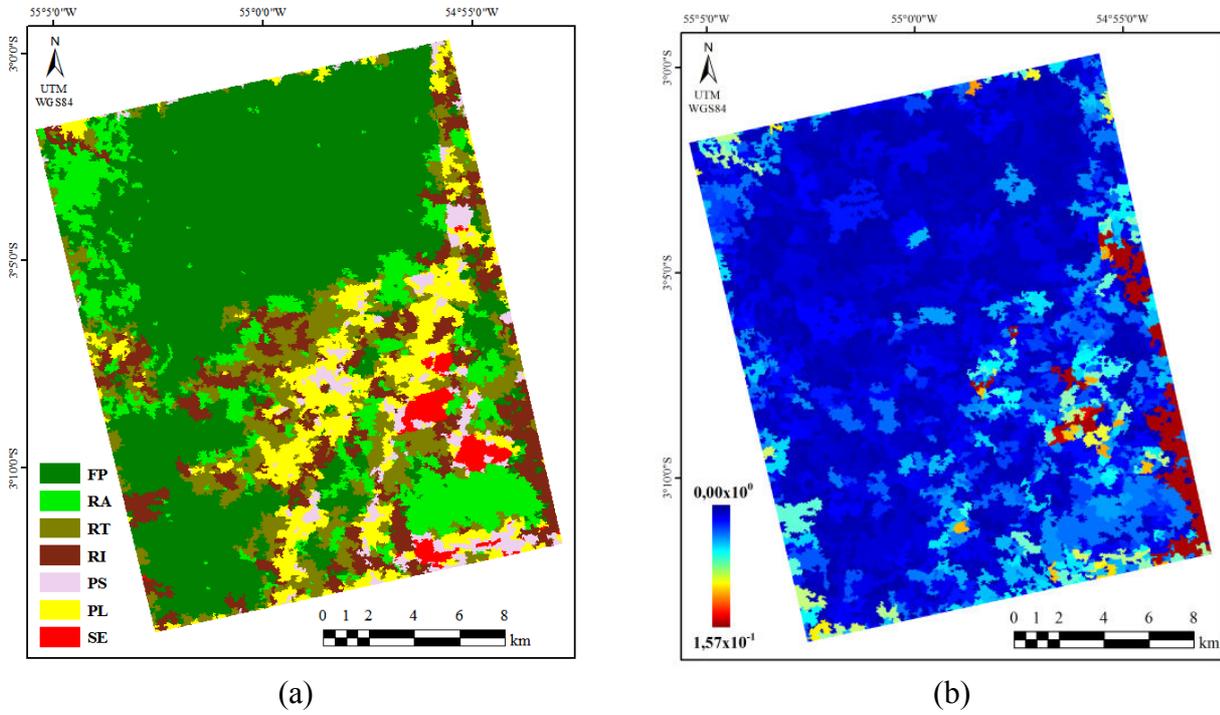


(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

C.5 - Cenário da soma para combinação VII

Figura C.5 – Combinação VII: resultados para a classificação multifonte da soma $\{R, Wi, KL; T, Ga, KL\}$.

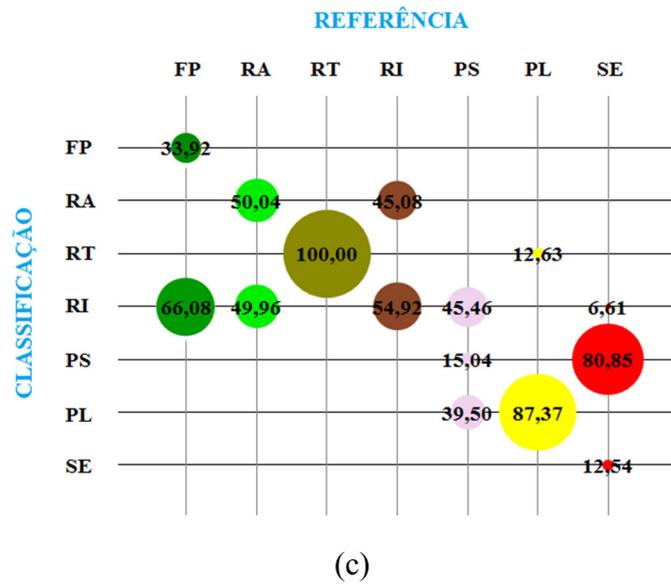
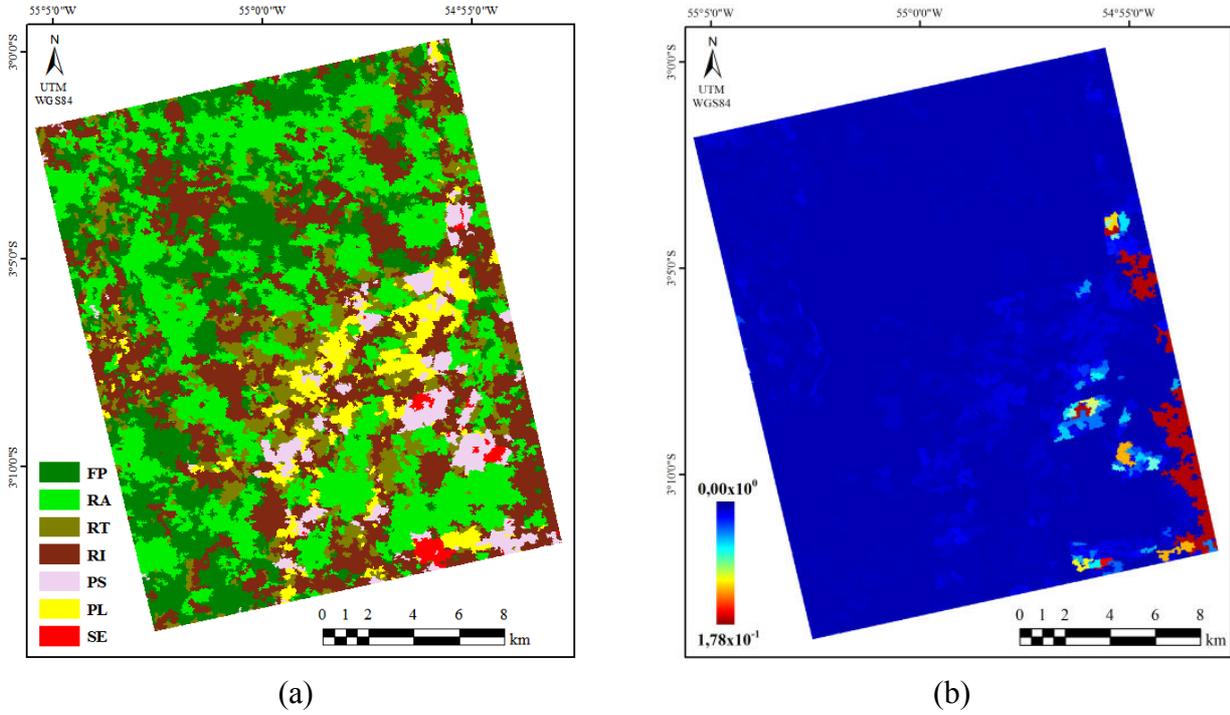


(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

C.6 - Cenário da soma para combinação VIII

Figura C.6 – Combinação VIII: resultados para a classificação multifonte da soma $\{P, Wi, KL; R, Wi, KL\}$.

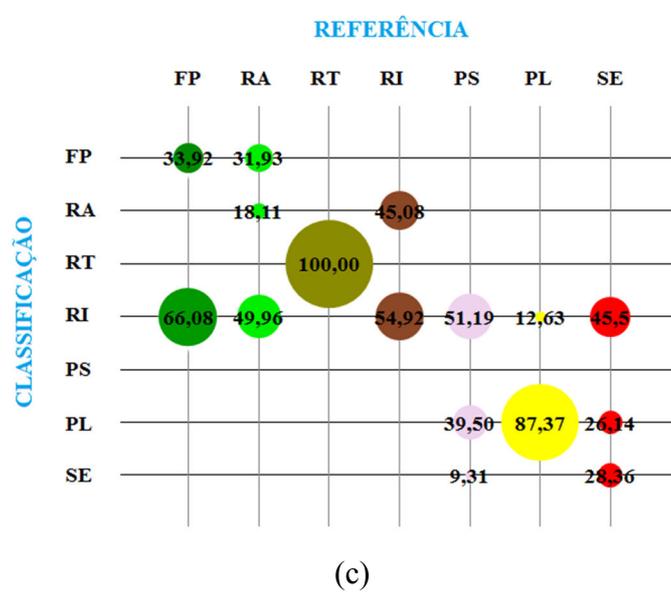
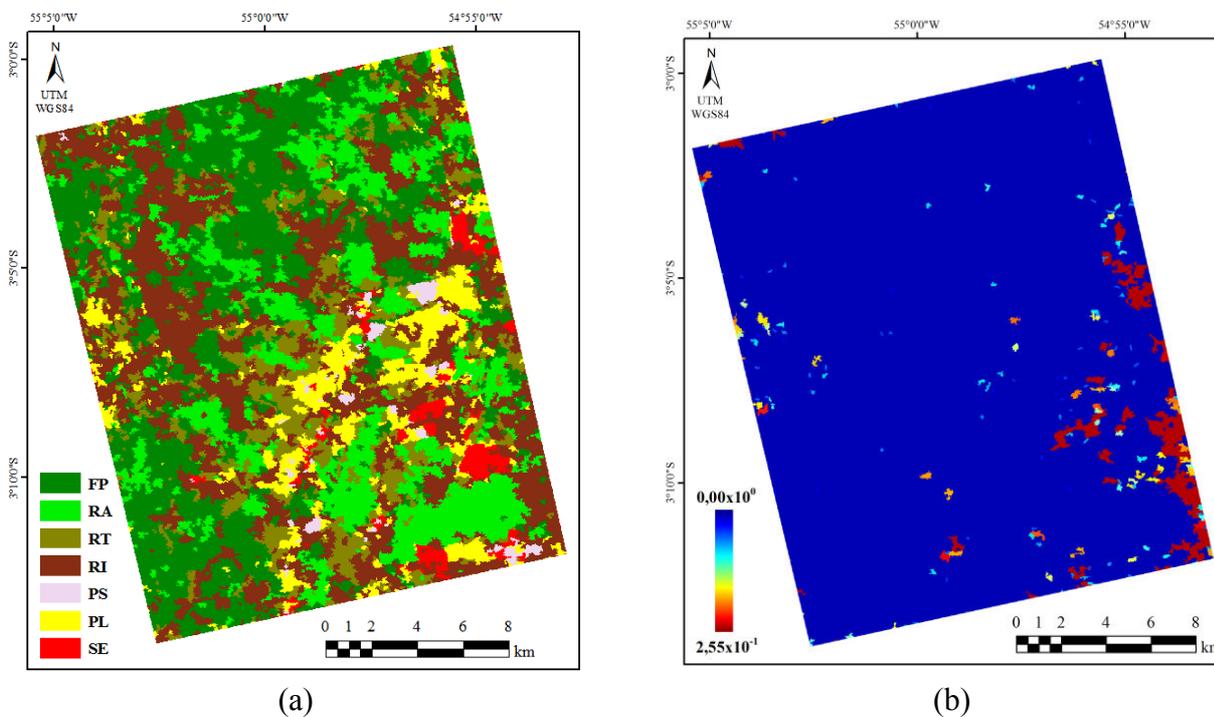


(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

C.7 - Cenário da soma para combinação IX

Figura C.7 – Combinação IX: resultados para a classificação multifonte da soma $\{P, PI, Bh; R, PI, Bh\}$.

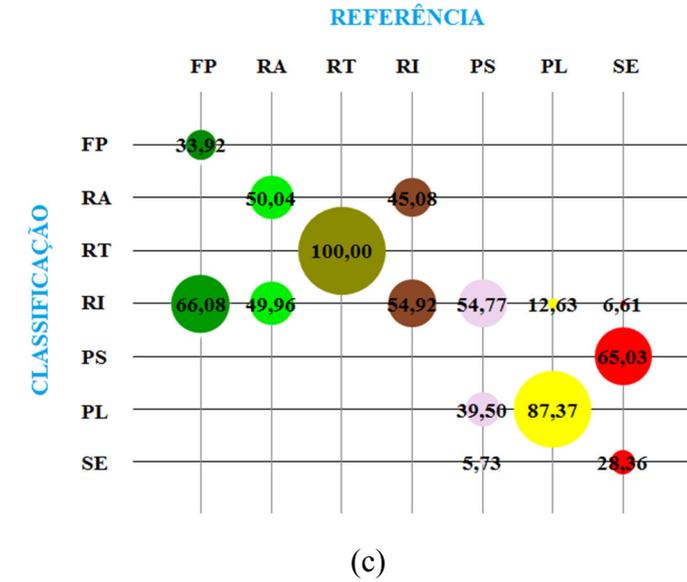
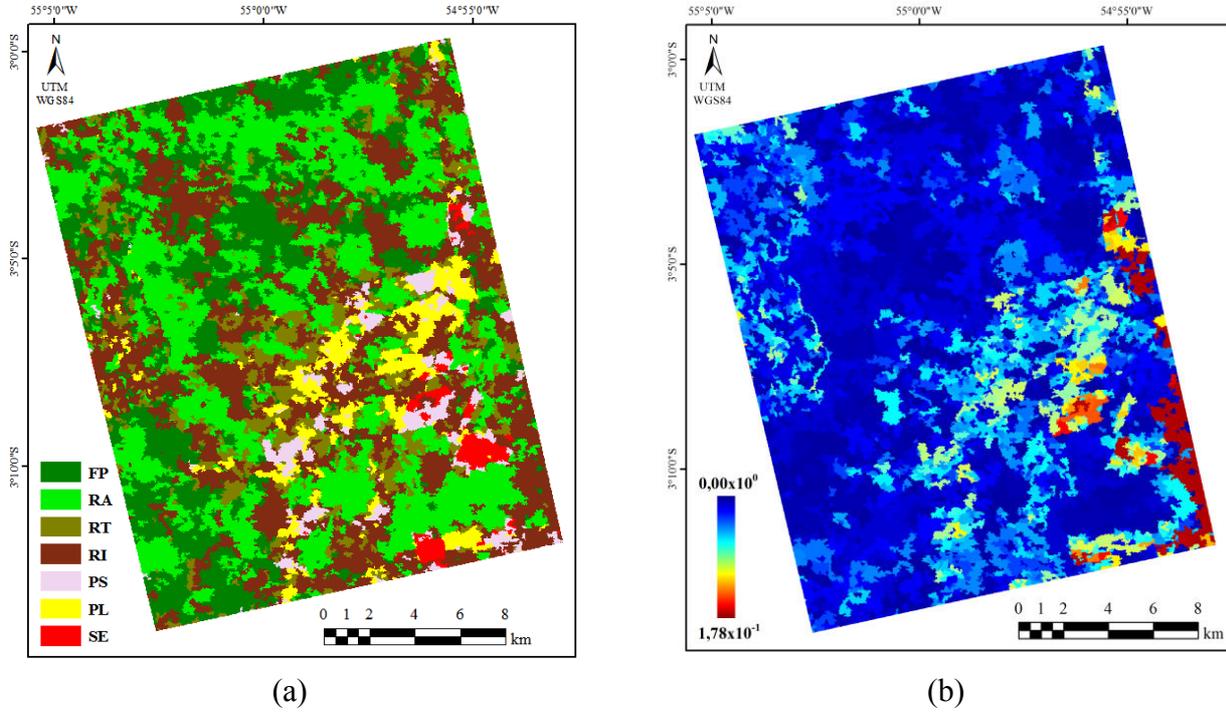


(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

C.8 - Cenário da soma para combinação X

Figura C.8 – Combinação I: resultados para a classificação multifonte da soma $\{P, Wi, He; R, Wi, He\}$.



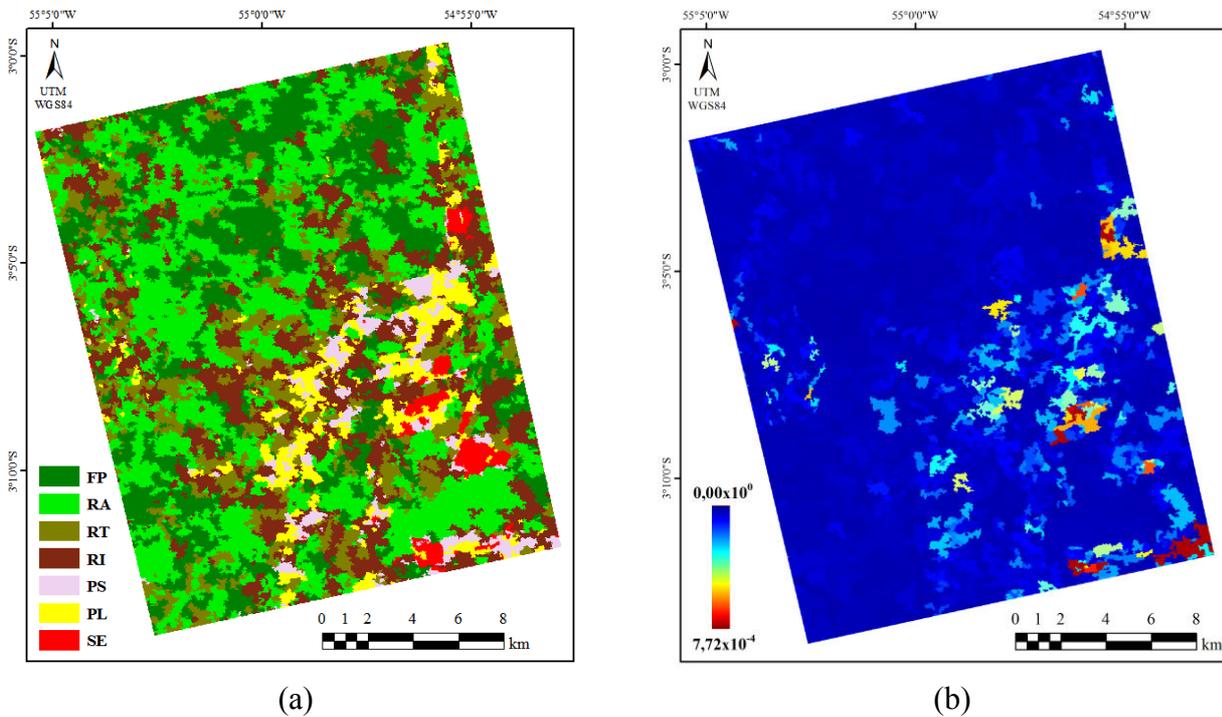
(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

APÊNDICE D – CENÁRIOS MULTIFONTES EMPÍRICOS.

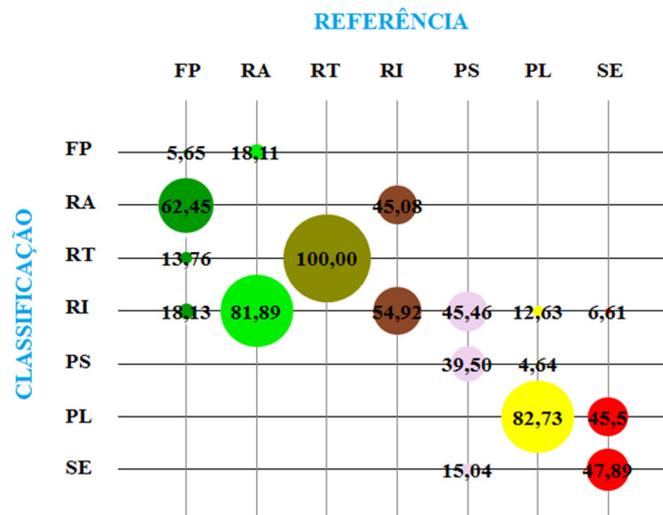
D.1 - Cenário dos mínimos para a combinação I

Figura D.1 – Combinação I: classificação multifonte dos mínimos $\{P, Wi, Re; R, Wi, Re\}$.



(a)

(b)



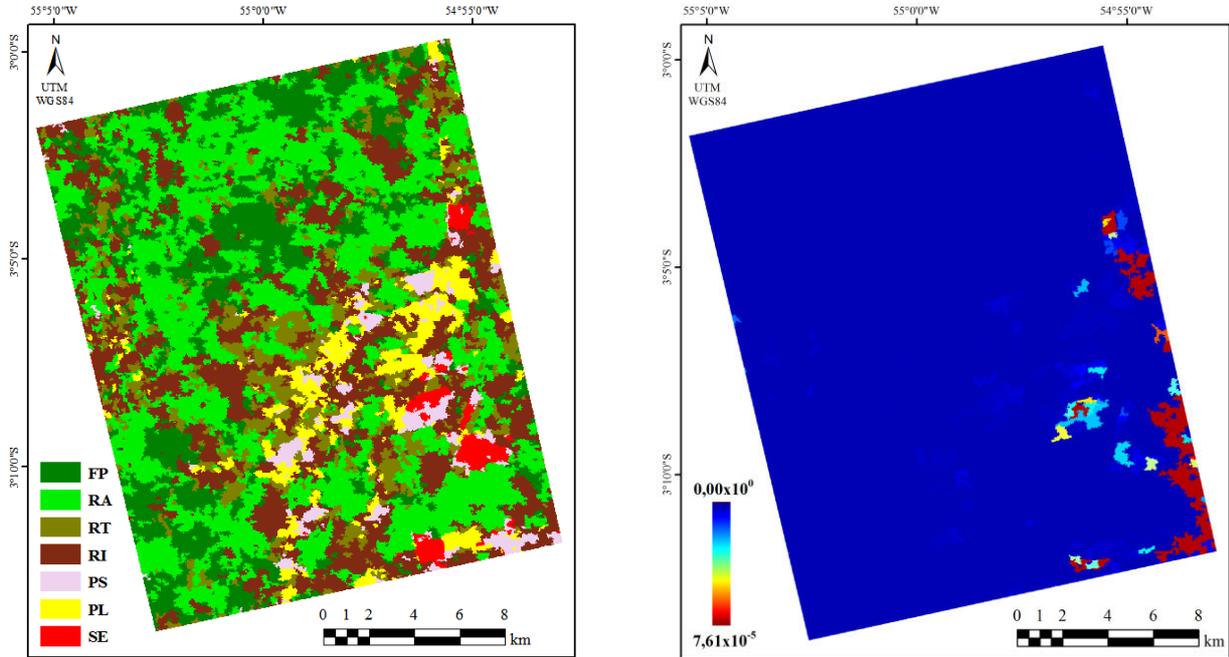
(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

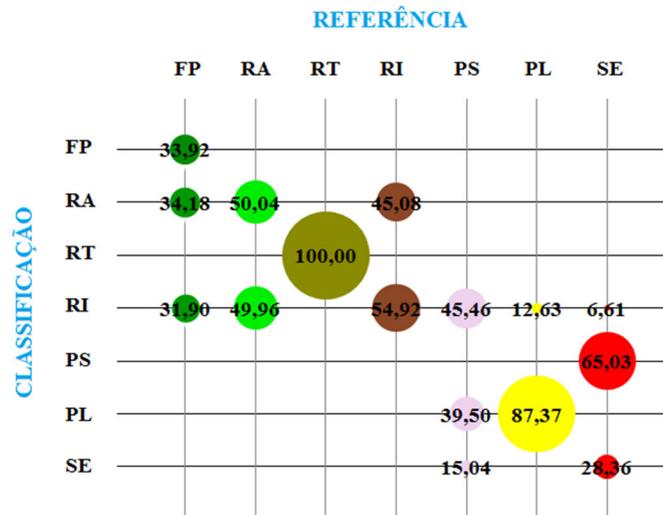
D.2 - Cenário do produto para a combinação I

Figura D.2 – Combinação I: classificação multifonte do produto $\{P, Wi, Re; R, Wi, Re\}$.



(a)

(b)



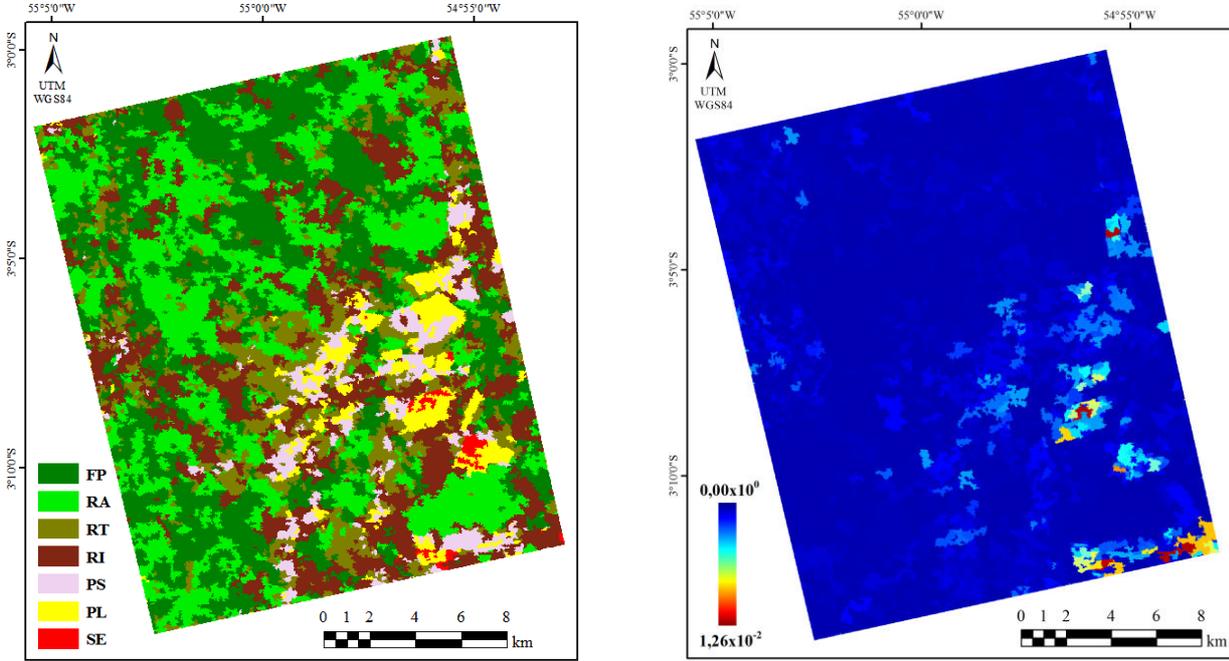
(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

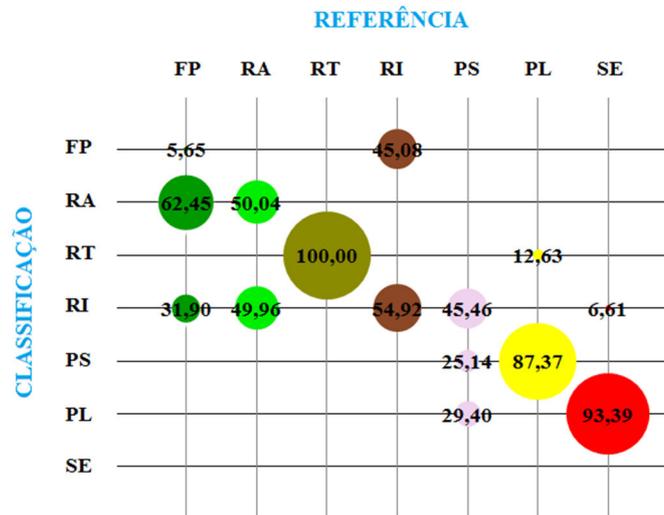
D.3 - Cenário dos mínimos para a combinação III

Figura D.3 – Combinação III: classificação multifonte dos mínimos $\{P, Wi, Bh; T, Ga, Bh\}$.



(a)

(b)



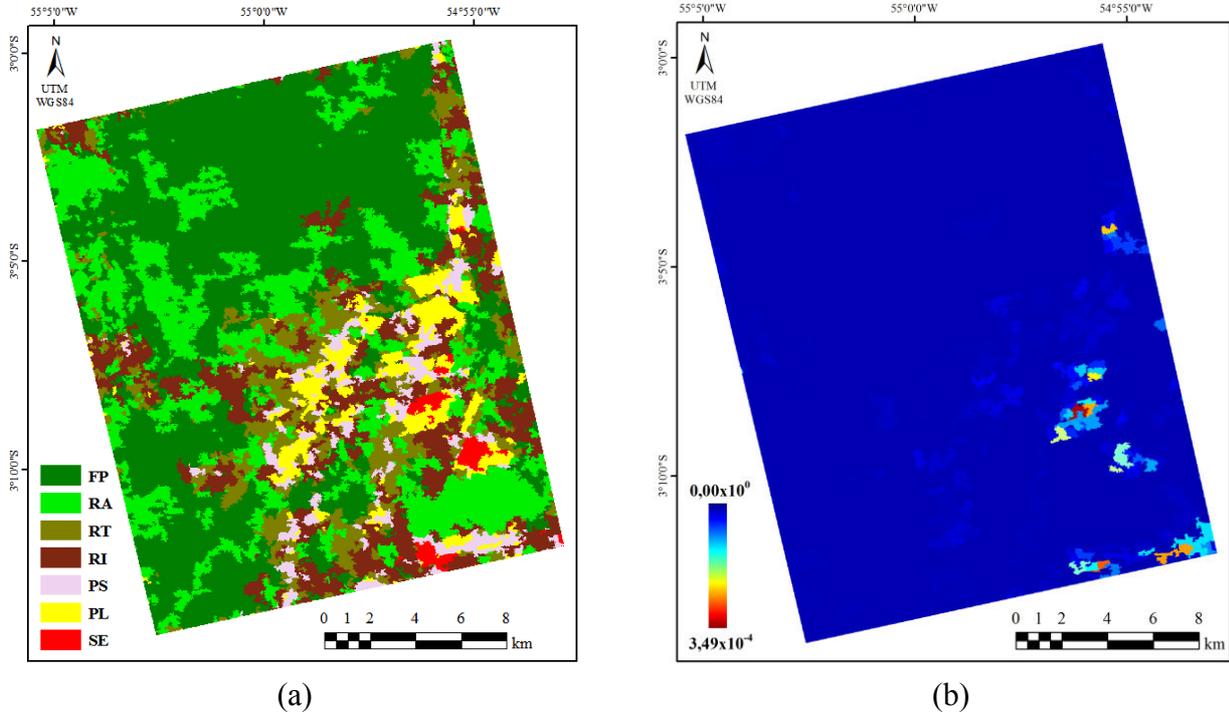
(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

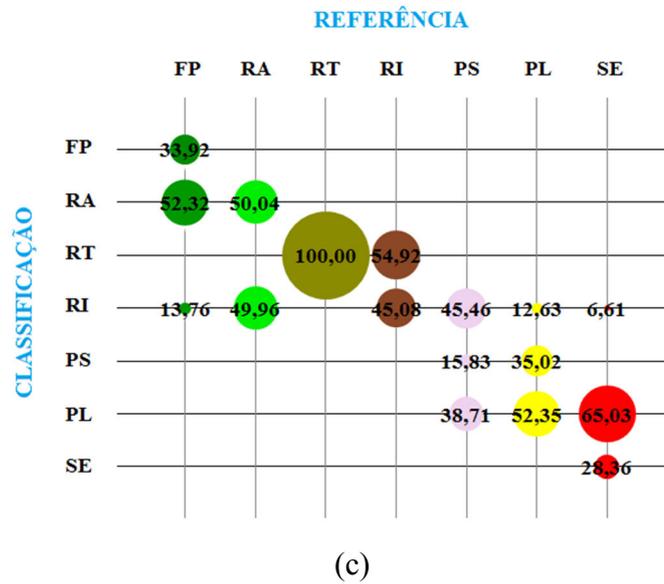
D.4 - Cenário do produto para a combinação III

Figura D.4 – Combinação III: classificação multifonte do produto {*P, Wi, Bh; T, Ga, Bh*}.



(a)

(b)



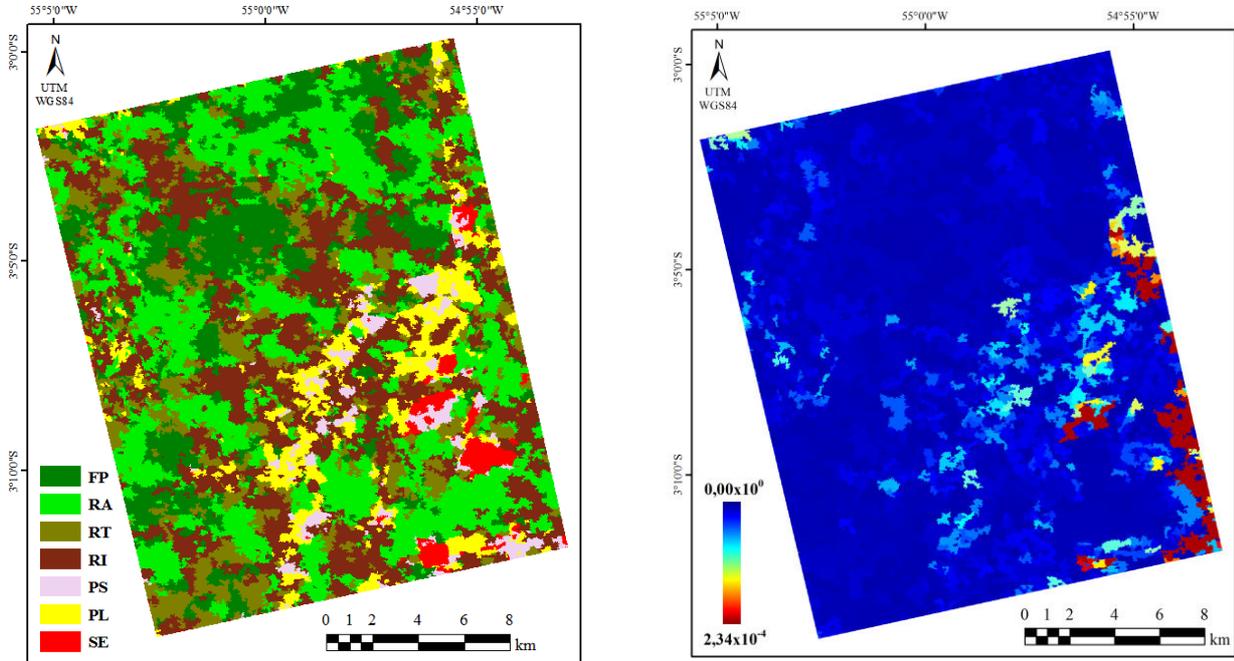
(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

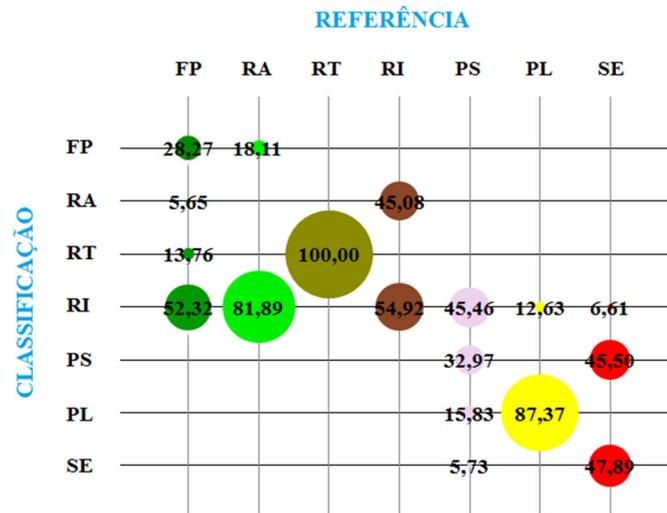
D.5 - Cenário dos mínimos para a combinação IV

Figura D.5 – Combinação IV: classificação multifonte dos mínimos $\{R, Wi, Bh; T, Ga, Bh\}$.



(a)

(b)



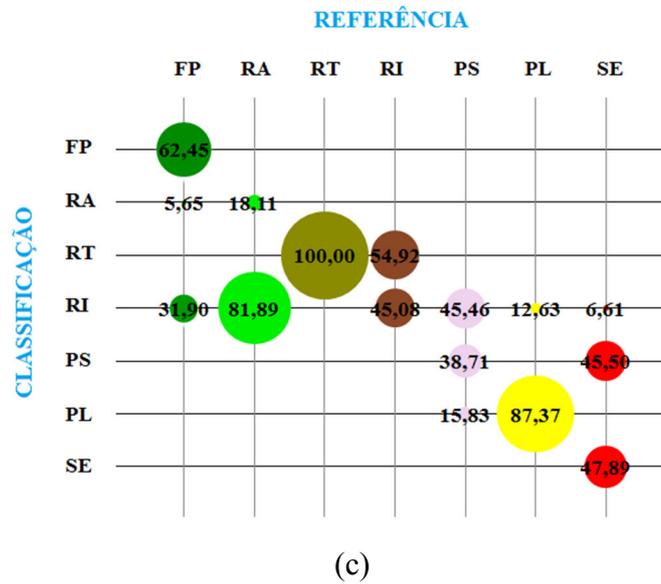
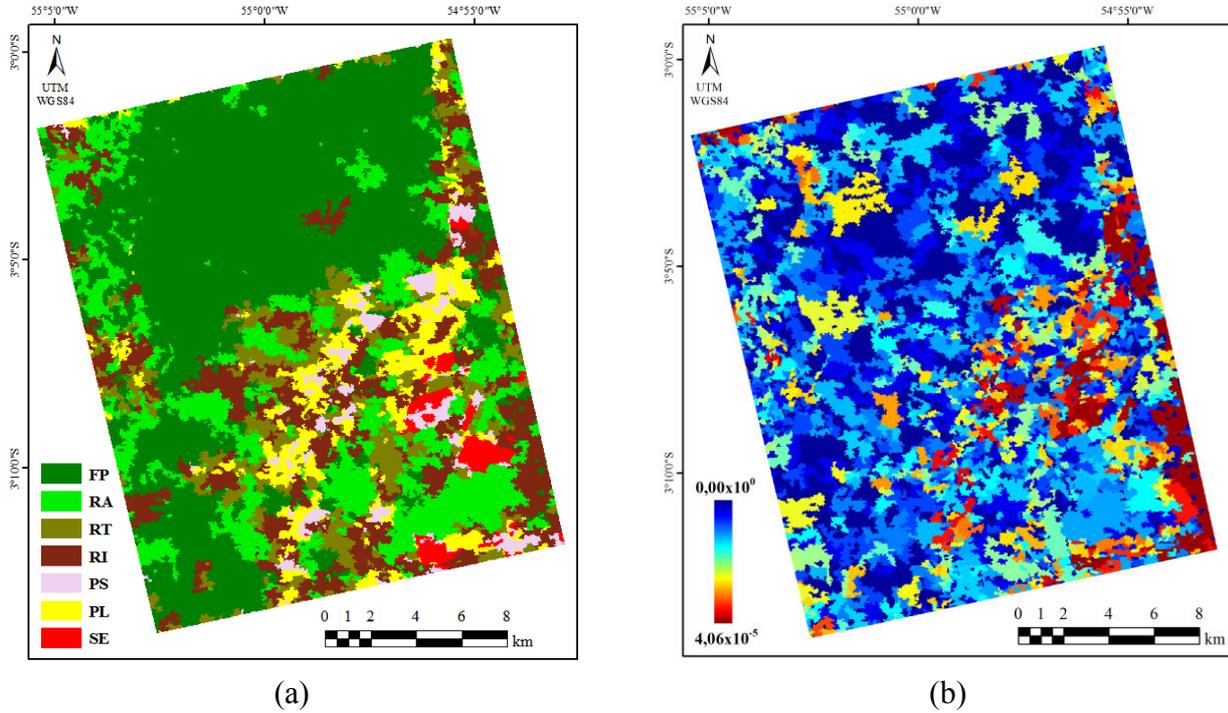
(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

D.6 - Cenário do produto para a combinação IV

Figura D.6 – Combinação IV: classificação multifonte do produto $\{R, Wi, Bh; T, Ga, Bh\}$.

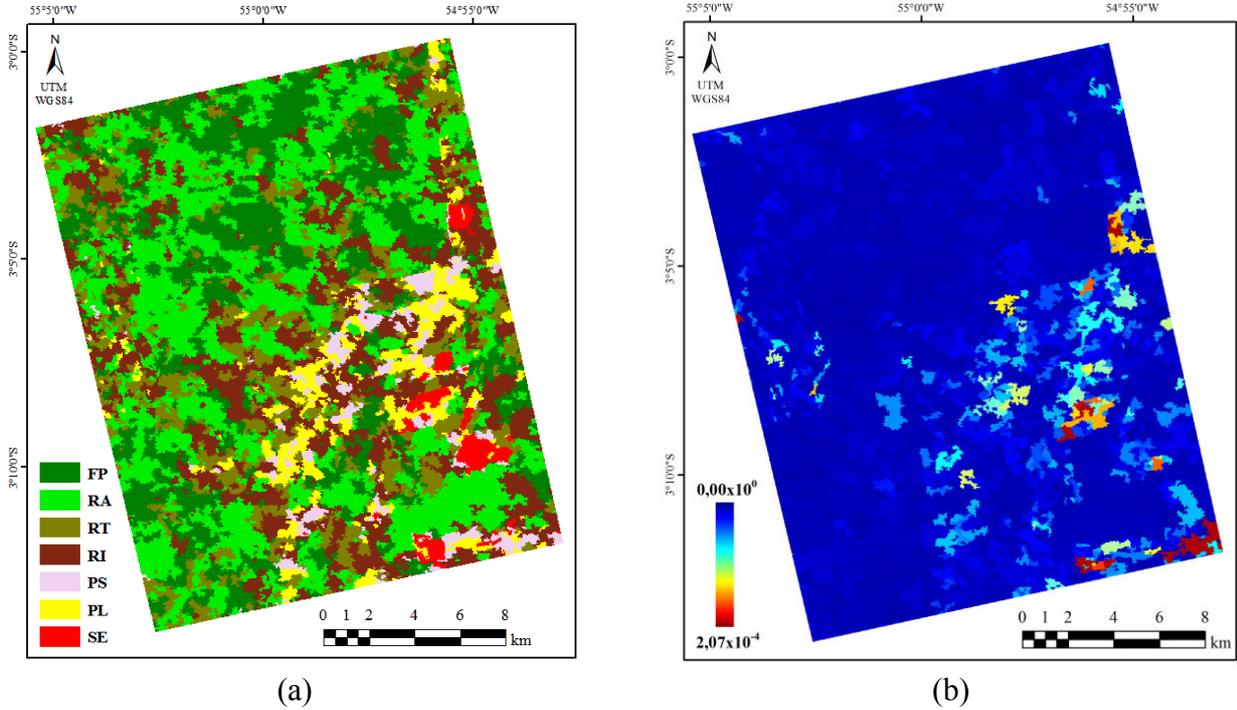


(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

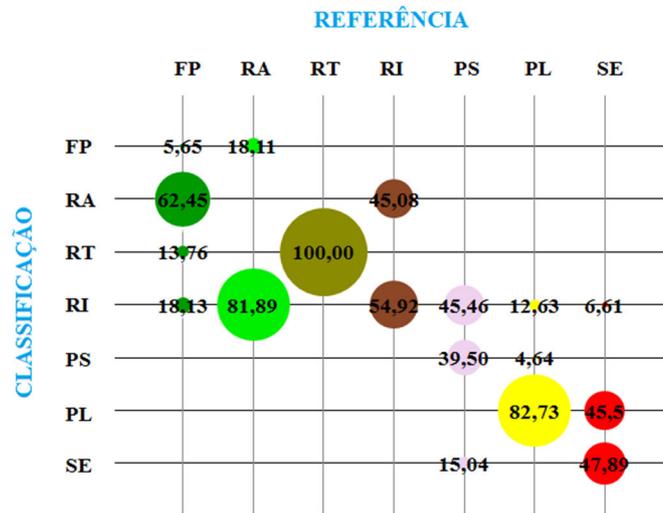
D.7 - Cenário dos mínimos para a combinação V

Figura D.7 – Combinação V: classificação multifonte dos mínimos $\{P, Wi, Bh; R, Wi, Bh\}$



(a)

(b)



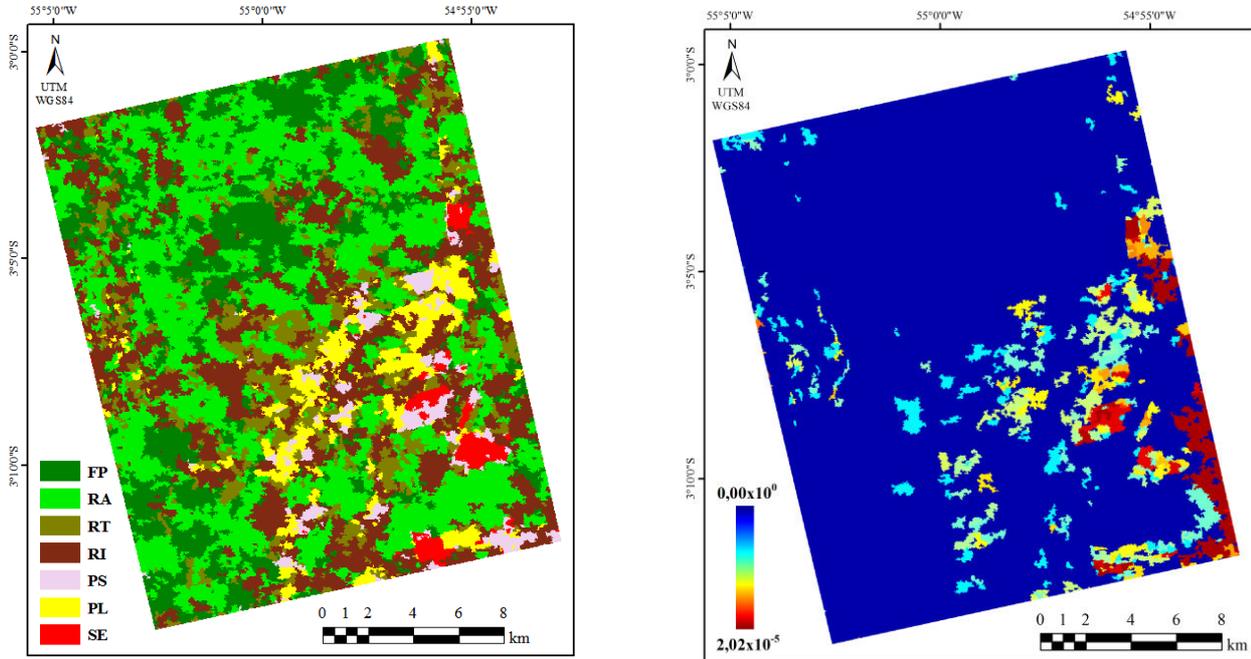
(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

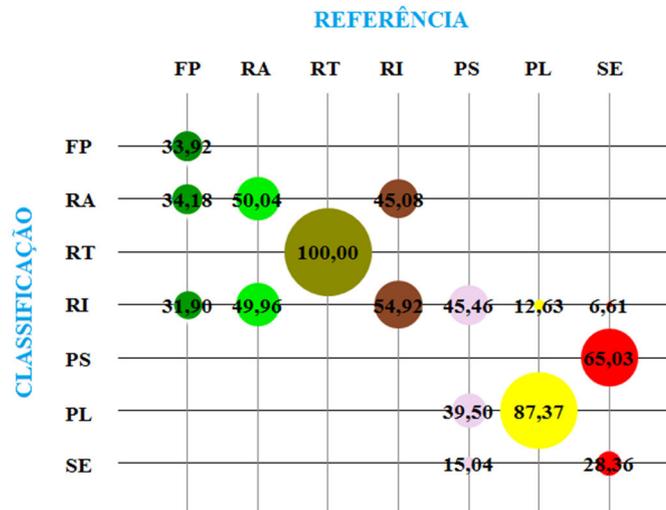
D.8 - Cenário do produto para a combinação V

Figura D.8 – Combinação V: classificação multifonte do produto $\{P, Wi, Bh; R, Wi, Bh\}$.



(a)

(b)



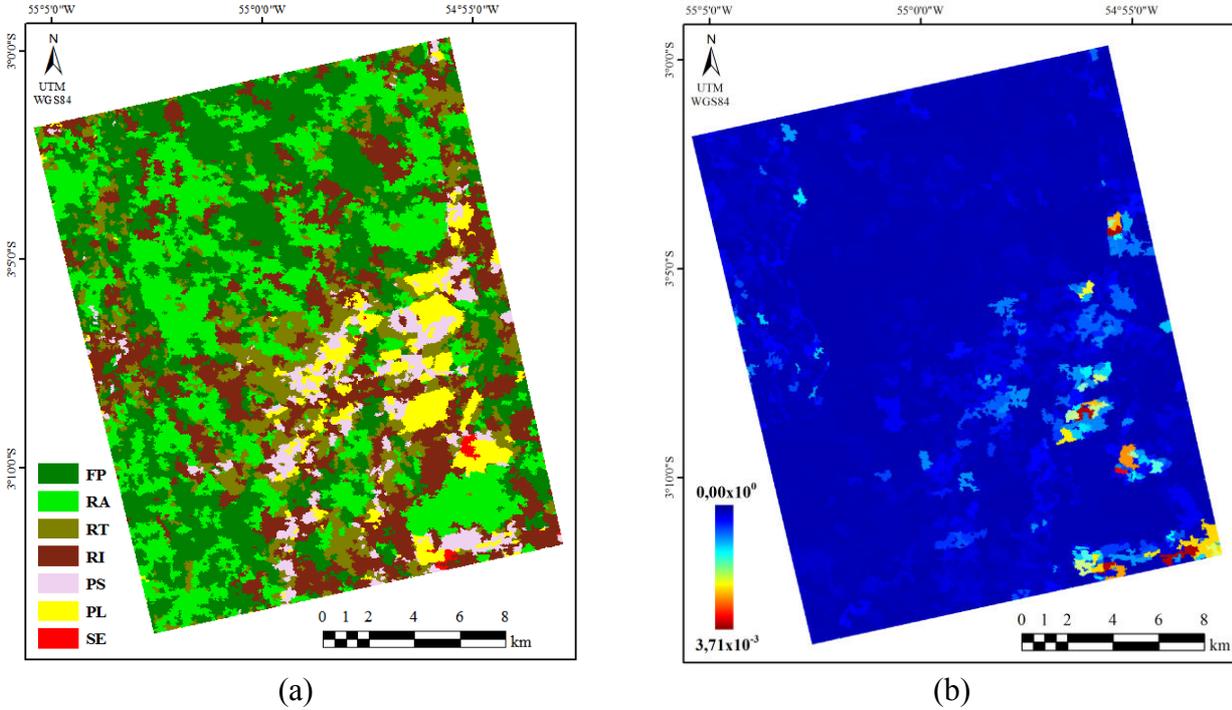
(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

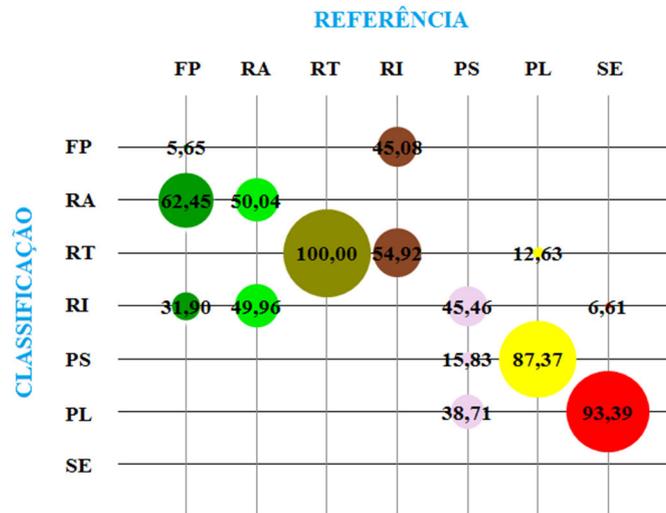
D.9 - Cenário dos mínimos para a combinação VI

Figura D.9 – Combinação VI: classificação multifonte dos mínimos $\{P, Wi, KL; T, Ga, KL\}$.



(a)

(b)



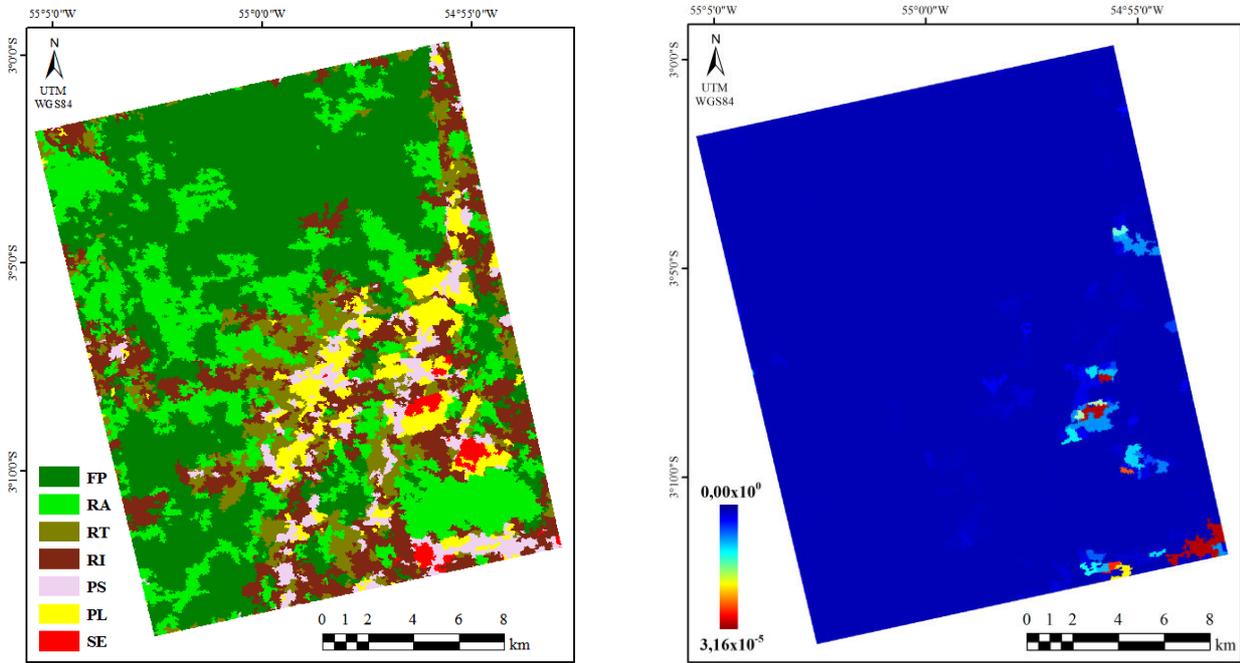
(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

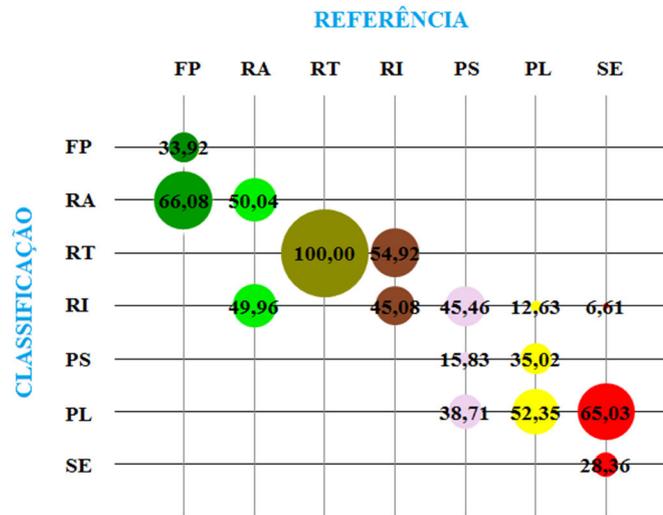
D.10 - Cenário do produto para a combinação VI

Figura D.10 – Combinação VI: classificação multifonte do produto {*P, Wi, KL; T, Ga, KL*}.



(a)

(b)



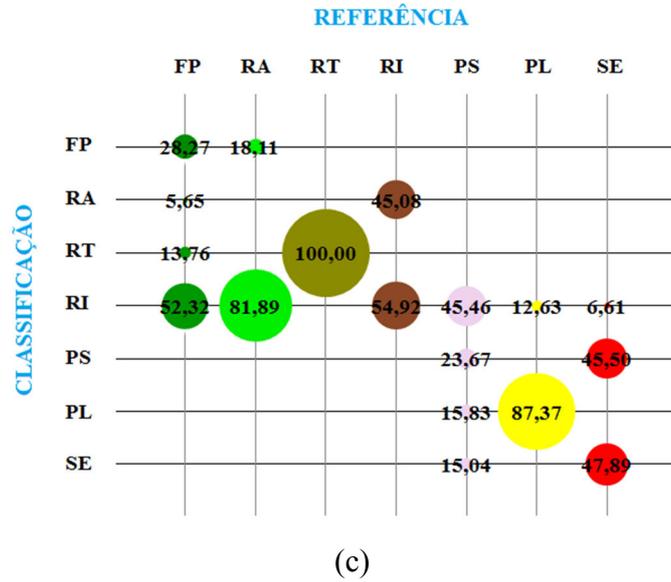
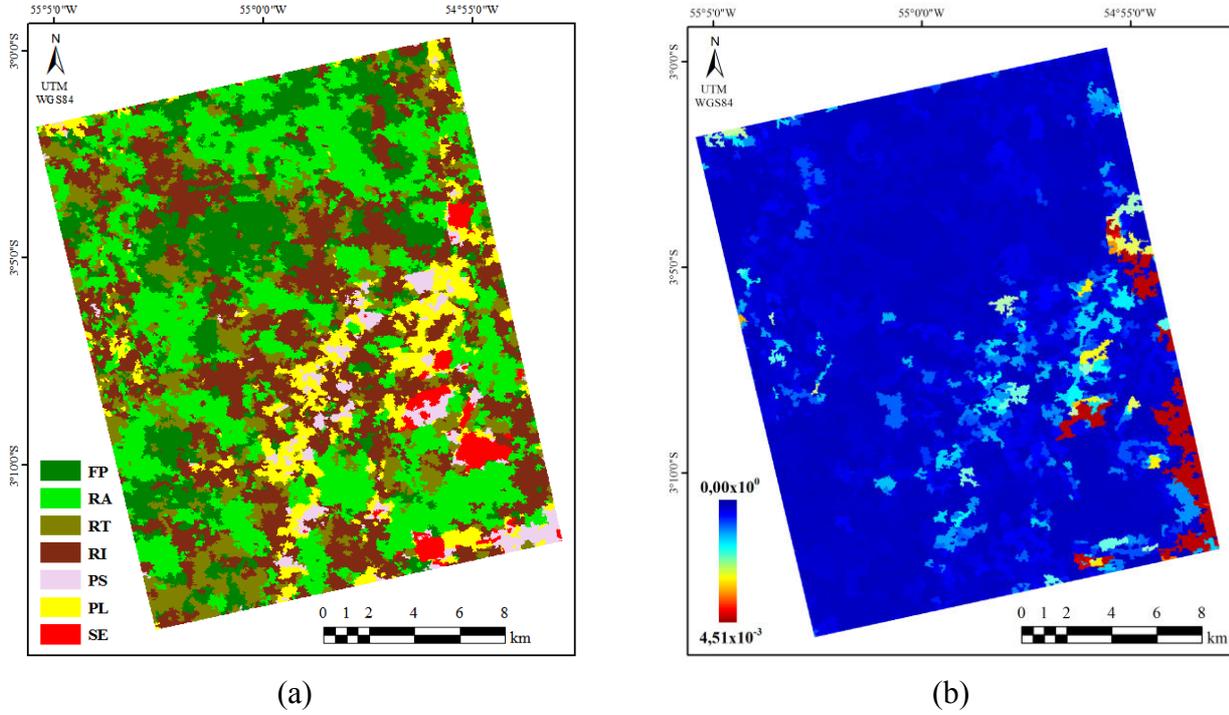
(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

D.11 - Cenário dos mínimos para a combinação VII

Figura D.11 – Combinação VII: classificação multifonte dos mínimos {*R, Wi, KL; T, Ga, KL*}.

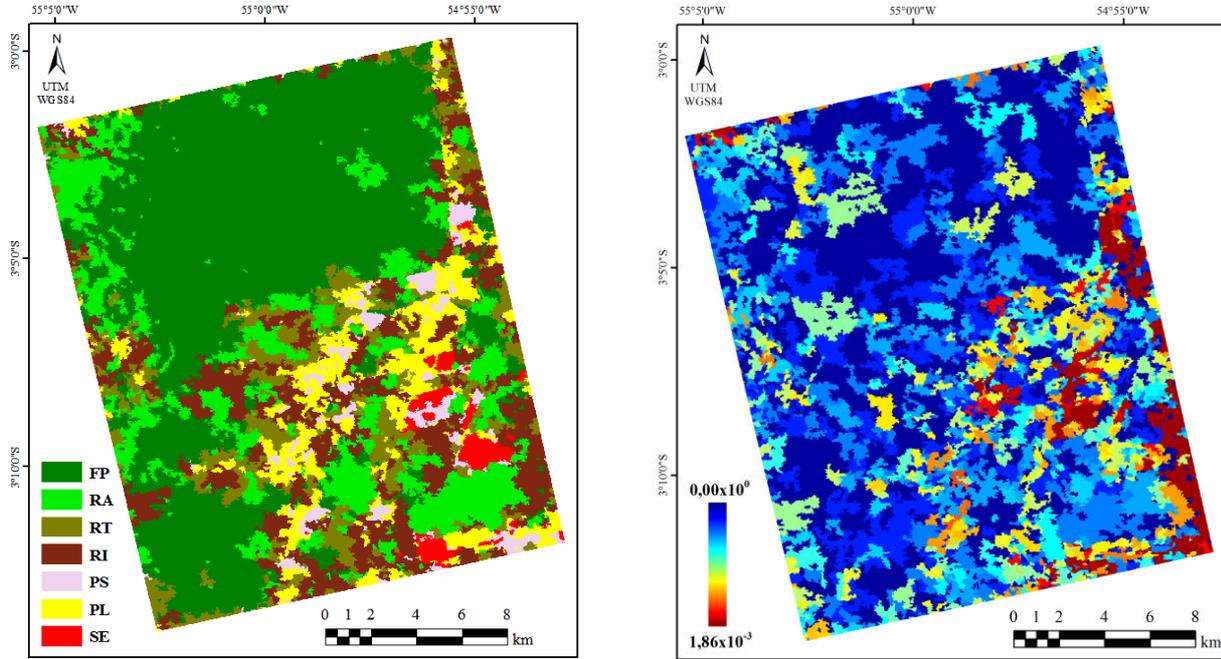


(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

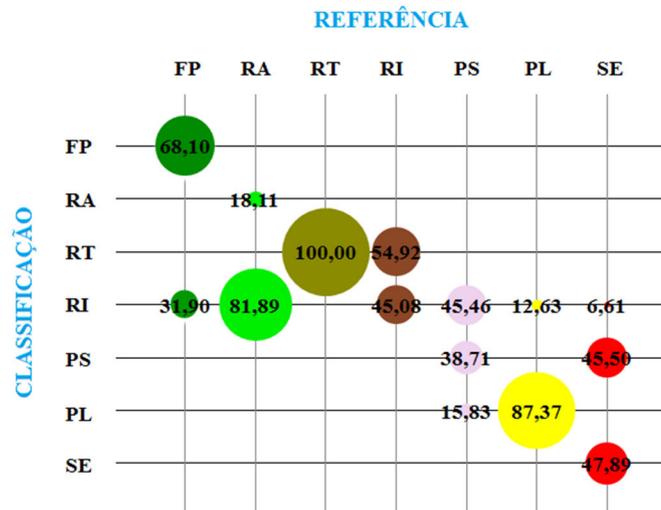
D.12 - Cenário do produto para a combinação VII

Figura D.12 – Combinação VII: classificação multifonte do produto $\{R, Wi, KL; T, Ga, KL\}$.



(a)

(b)



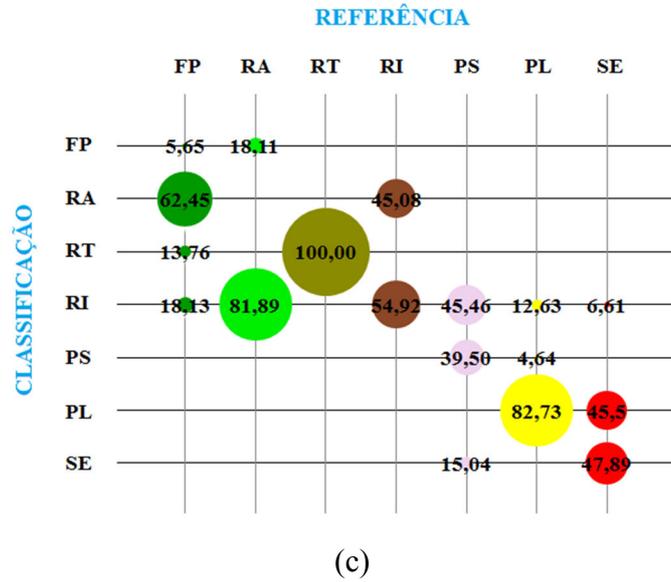
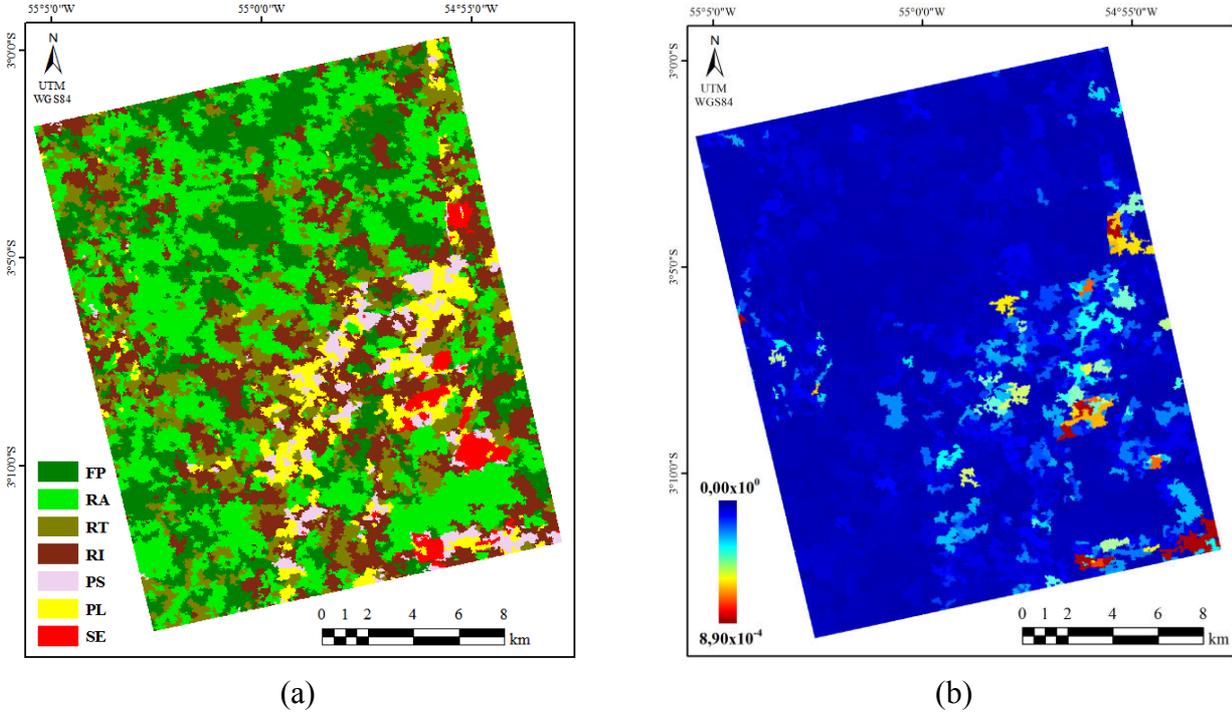
(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

D.13 Cenário dos mínimos para a combinação VIII

Figura D.13 – Combinação VIII: classificação multifonte dos mínimos $\{P, Wi, KL; R, Wi, KL\}$.

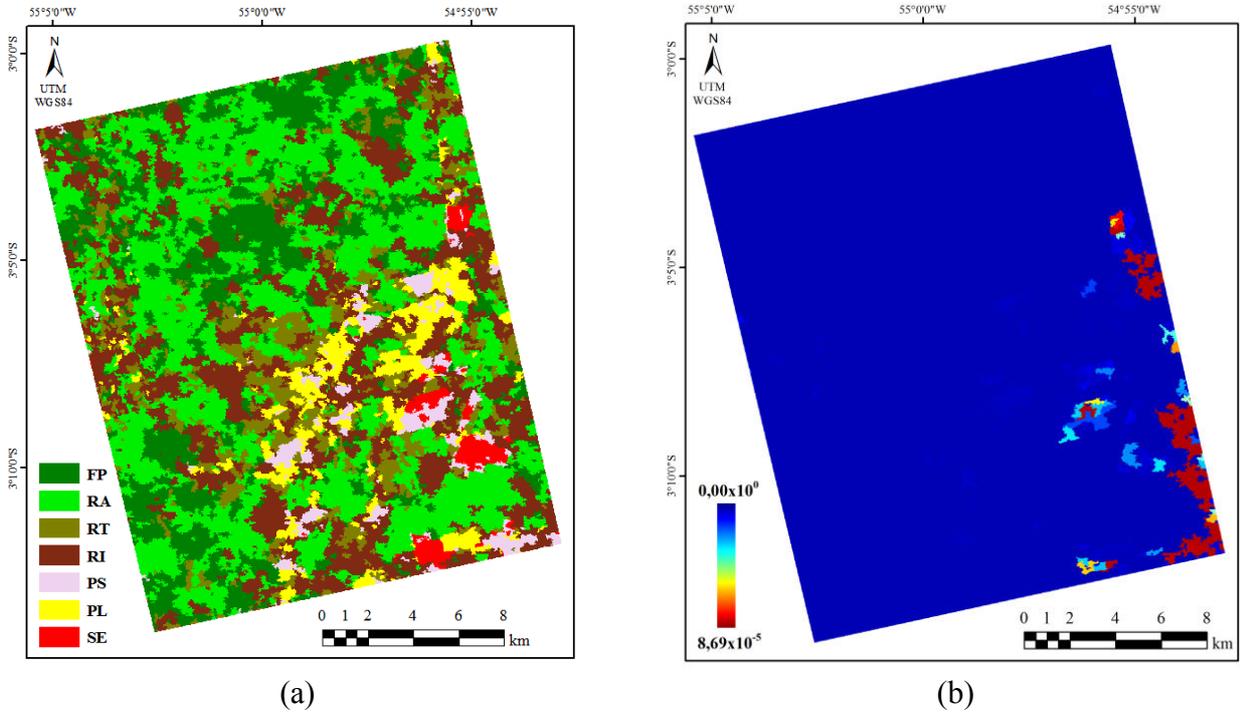


(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

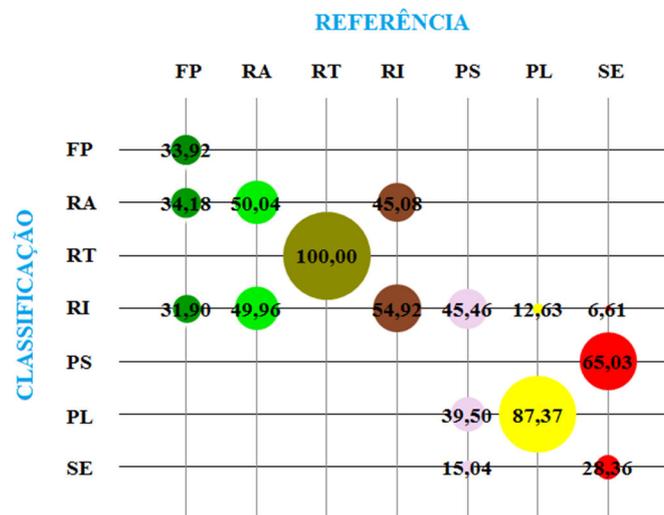
D.14 - Cenário do produto para a combinação VIII

Figura D.14 – Combinação VIII: classificação multifonte do produto $\{P, Wi, KL; R, Wi, KL\}$.



(a)

(b)



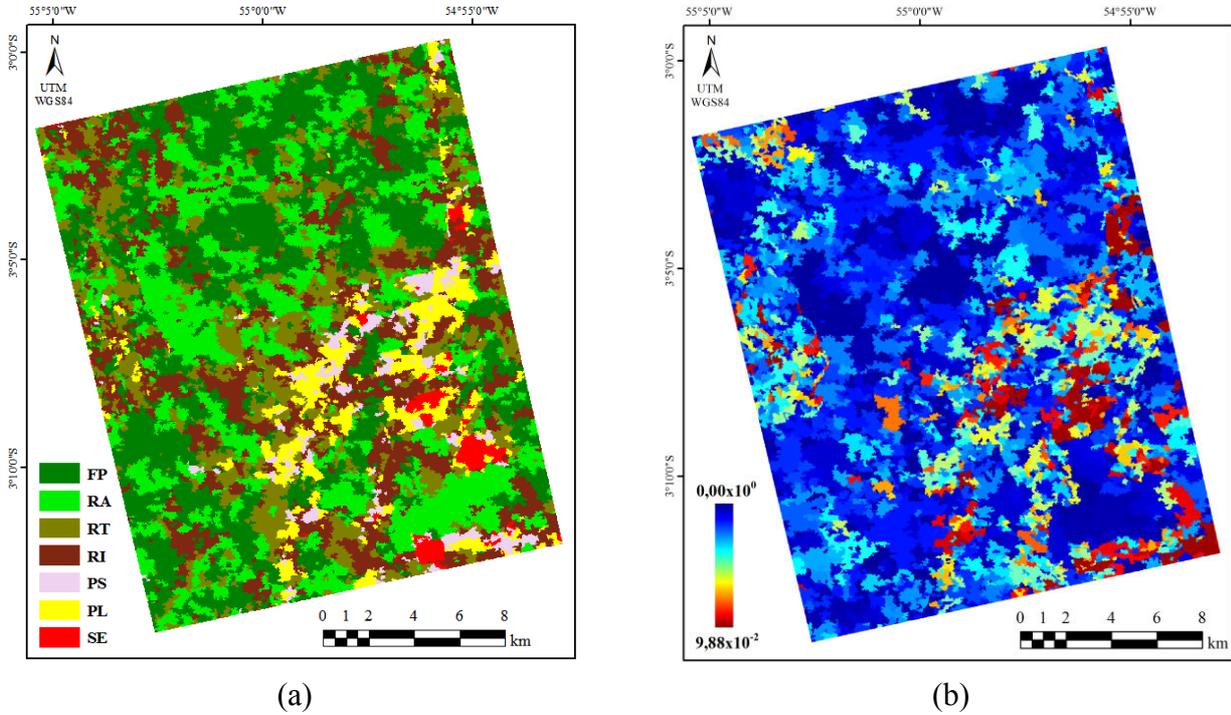
(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

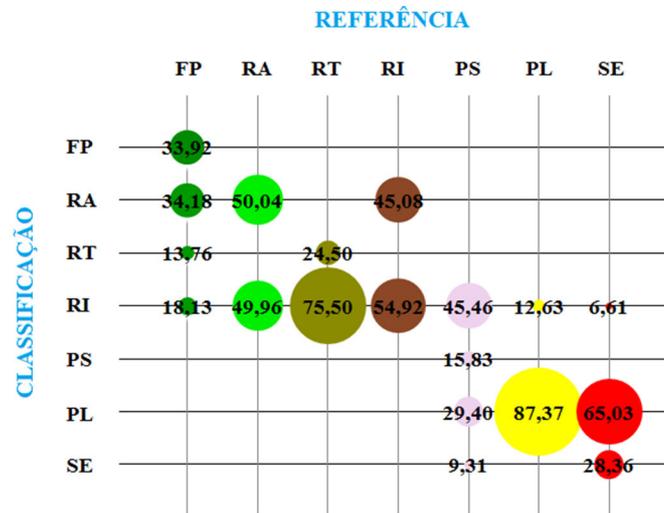
D.15 - Cenário dos mínimos para a combinação IX

Figura D.15 – Combinação IX: classificação multifonte dos mínimos {*P, PI, Bh; R, PI, Bh*}.



(a)

(b)



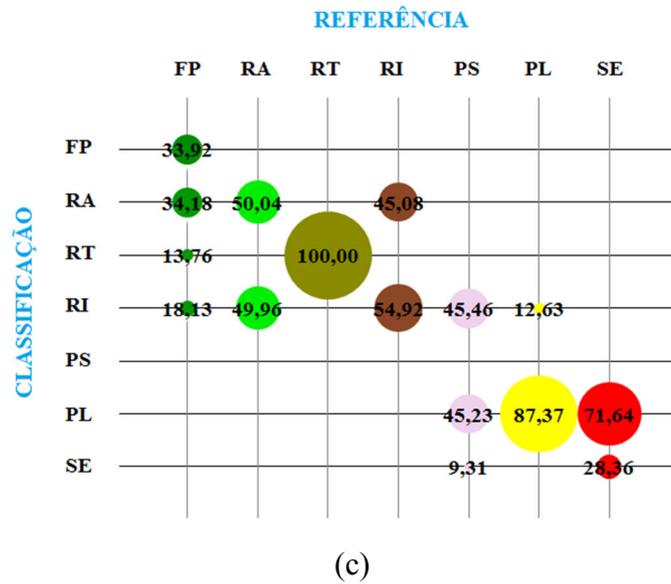
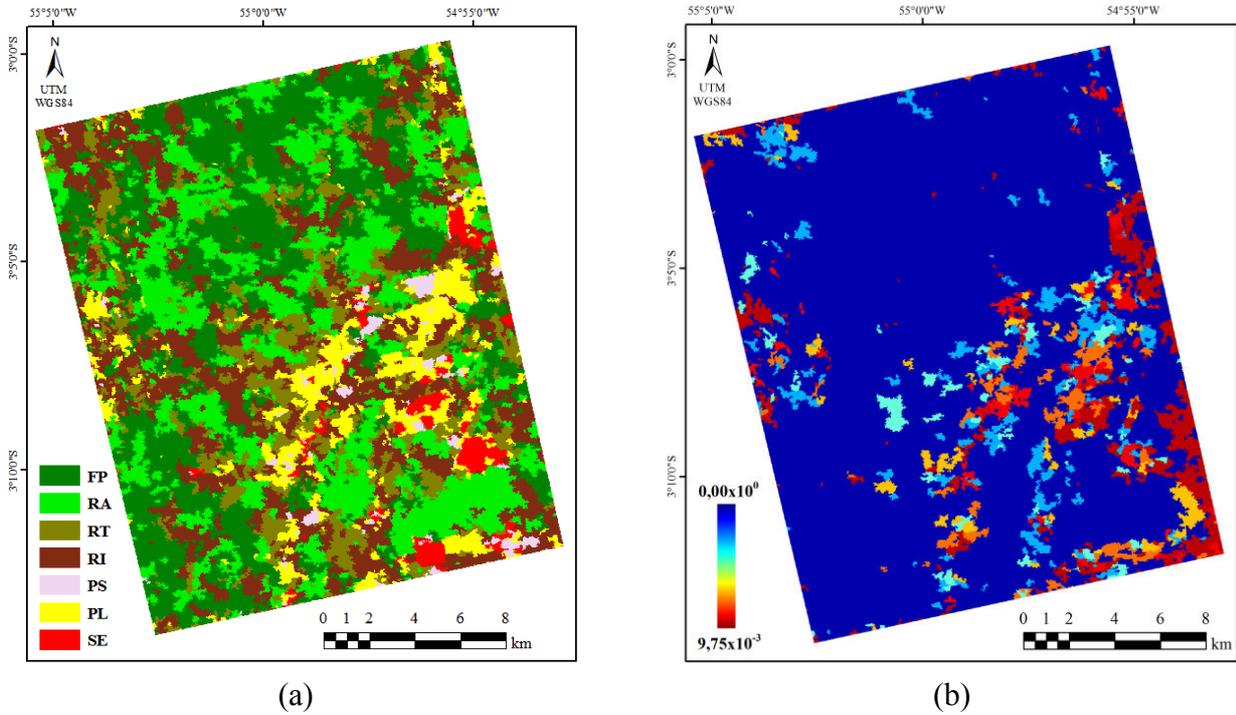
(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

D.16 - Cenário do produto para a combinação IX

Figura D.16 – Combinação IX: classificação multifonte do produto {*P, PI, Bh; R, PI, Bh* }

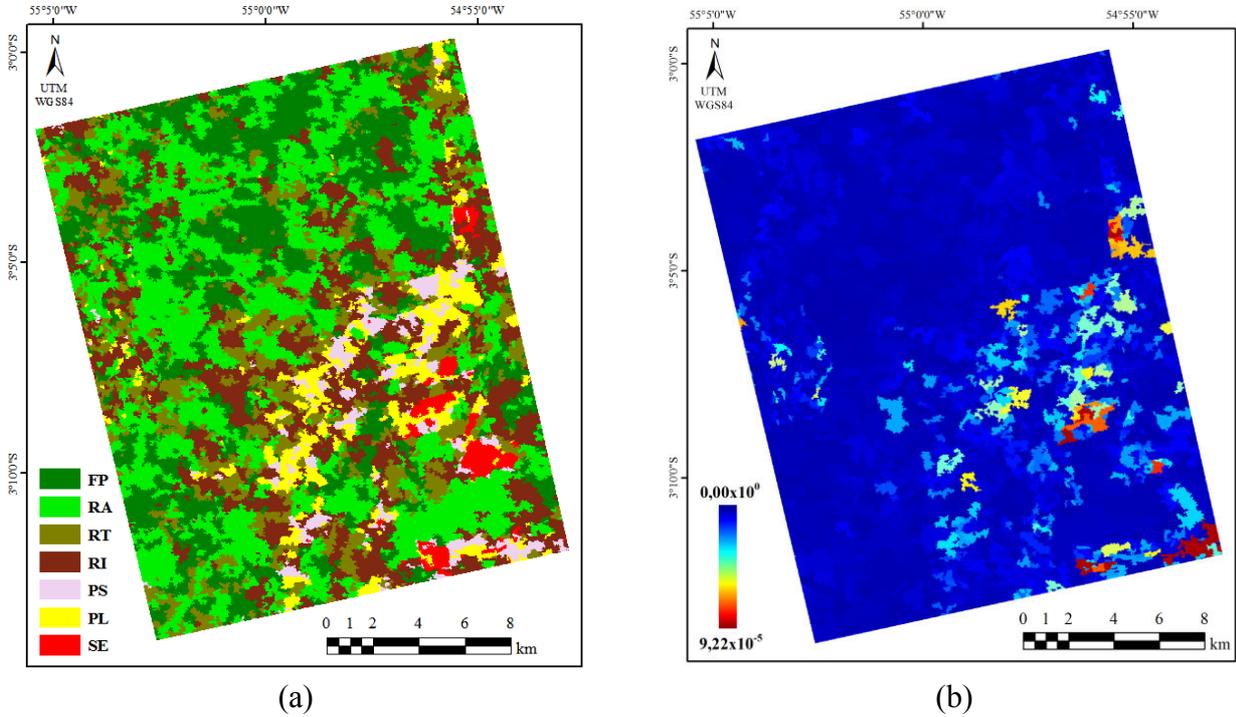


(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

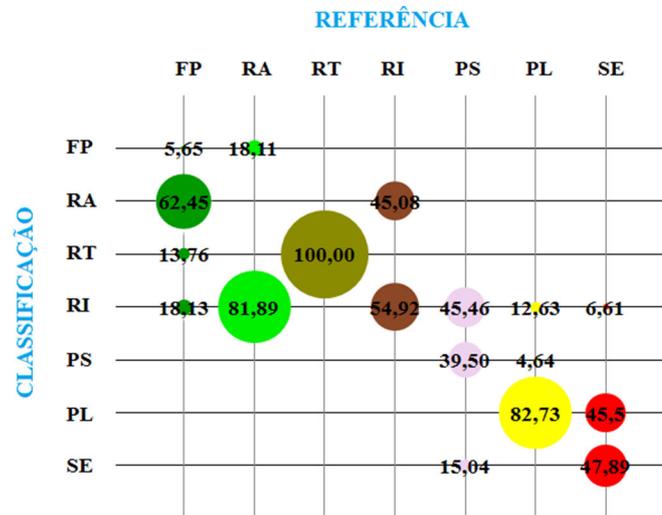
D.17 - Cenário dos mínimos para a combinação X

Figura D.17 – Combinação X: classificação multifonte dos mínimos $\{P, Wi, He; R, Wi, He\}$.



(a)

(b)



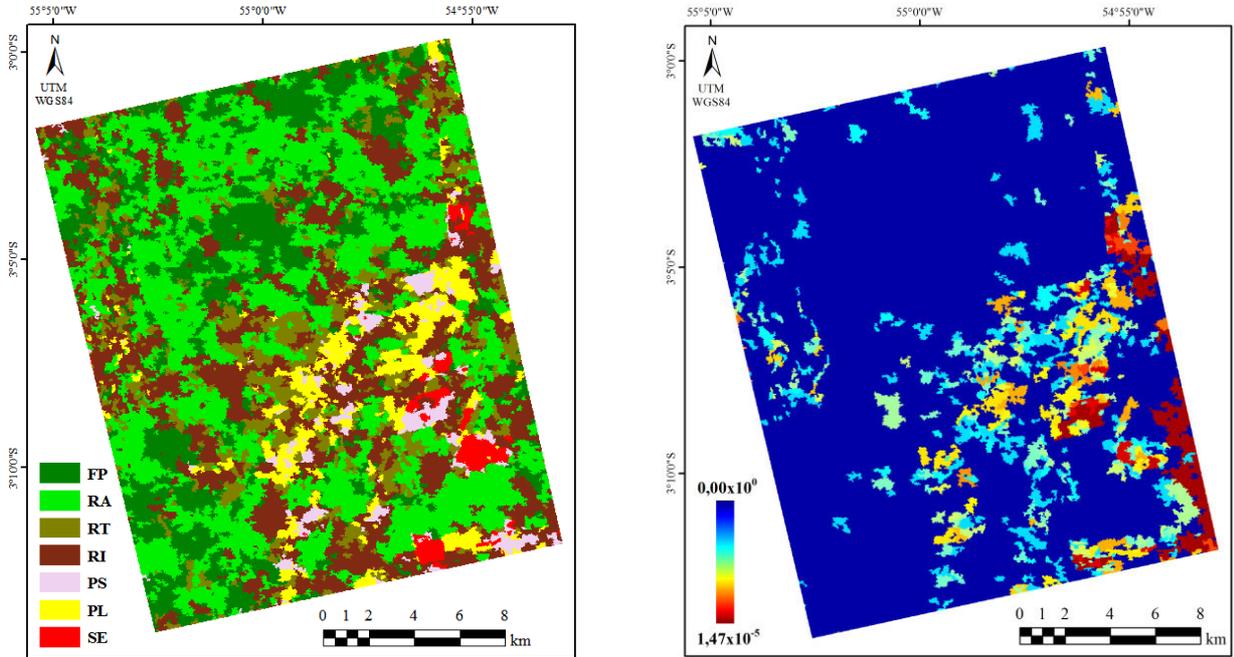
(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

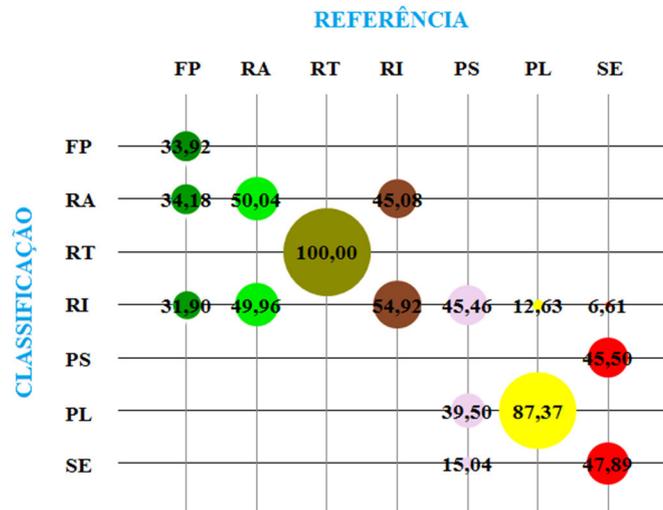
D.18 - Cenário do produto para a combinação X

Figura D.18 – Combinação X: classificação multifonte do produto $\{P, Wi, He; R, Wi, He\}$.



(a)

(b)



(c)

(a) Classificação; (b) Mapa de possibilidade e (C) Matriz de confusão.

Fonte: Produção do autor.

APÊNDICE E – ACURÁCIA GLOBAL (AG), ACURÁCIA POR CLASSE E COEFICIENTE *KAPPA* (K) PARA AS COMBINAÇÕES.

E.1 – Resultados correspondentes aos Cenários para a combinação I

Tabela E.1 – Relação da acurácia por classe entre os Cenários resultantes da combinação I (CI) $\{P, Wi, Re; R, Wi, Re\}$.

Percentual de acurácias por classe CI					
	Palsar	Radarsat	Mínimos	Produto	Soma
FP	5,65	28,27	5,65	33,92	33,92
RA	50,04	0,00	0,00	50,04	50,04
RT	100,00	100,00	100,00	100,00	100,00
RI	0,00	54,92	54,92	54,92	54,92
PS	15,83	23,67	39,5	0,00	0,00
PL	0,00	87,37	82,73	87,37	87,37
SE	0,00	47,89	47,89	28,36	28,36
AG	20,52	39,46	30,20	44,27	44,27
K	0,11	0,31	0,22	0,35	0,36

Fonte: Produção do autor

D.2 – Resultados correspondentes aos Cenários para a combinação II

Tabela E.2 – Relação da acurácia por classe entre os Cenários resultantes da combinação II (CII) $\{P, Wi, Bh; R, Wi, Bh; T, Ga, Bh\}$.

Percentual de acurácias por classe CII						
	TM	Palsar	Radarsat	Mínimos	Produto	Soma
FP	68,1	5,65	28,27	5,65	33,92	68,10
RA	18,11	50,04	0,00	0,00	50,04	50,04
RT	100,00	100,00	100,00	100,00	100,00	100,00
RI	45,08	54,92	54,92	54,92	45,08	45,08
PS	9,31	15,83	23,67	39,5	15,04	15,04
PL	52,35	0,00	87,37	82,73	87,37	87,37
SE	93,39	0,00	47,89	47,89	47,89	47,89
AG	60,58	22,72	39,46	30,20	47,35	62,82
K	0,50	0,14	0,31	0,22	0,39	0,53

Fonte: Produção do autor.

E.3 – Resultados correspondentes aos Cenários para a combinação III

Tabela E.3 – Relação da acurácia por classe entre os Cenários resultantes da combinação III (CIII) {*P, Wi, Bh; T, Ga, Bh*}.

	Percentual de acurácias por classe CIII				
	Palsar	TM	Mínimos	Produto	Soma
FP	5,65	68,1	5,65	33,92	68,10
RA	50,04	18,11	50,04	50,04	50,04
RT	100,00	100,00	100,00	100,00	100,00
RI	54,92	45,08	54,92	45,08	45,08
PS	15,83	9,31	25,14	15,83	0,00
PL	0,00	52,35	0,00	52,35	52,35
SE	0,000	93,39	0,00	28,36	28,36
AG	22,72	60,58	23,51	42,4528	56,5797
K	0,14	0,50	0,15	0,3248	0,455

Fonte: Produção do autor.

E.4 – Resultados correspondentes aos Cenários para a combinação IV

Tabela E.4 – Relação da acurácia por classe entre os Cenários resultantes da combinação IV (CIV){*R, Wi, Bh; T, Ga, Bh*}.

	Percentual de acurácias por classe CIV				
	Radarsat	TM	Mínimos	Produto	Soma
FP	28,27	68,1	28,27	62,45	68,10
RA	0,00	18,11	0,00	18,11	18,11
RT	100,00	100,00	100,00	100,00	100,00
RI	54,92	45,08	54,92	45,08	45,08
PS	23,67	9,31	32,97	38,71	38,71
PL	87,37	52,35	87,37	87,37	87,37
SE	47,89	93,39	47,89	47,89	47,89
AG	39,46	60,58	40,25	58,15	60,70
K	0,31	0,50	0,32	0,49	0,51

Fonte: produção do autor.

E.5 – Resultados correspondentes aos Cenários para a combinação V

Tabela E.5 – Relação da acurácia por classe entre os Cenários resultantes da combinação V (CV) {*P, Wi, Bh; R, Wi, Bh*}.

	Percentual de acurácias por classe CV				
	Palsar	Radarsat	Mínimos	Produto	Soma
FP	5,65	28,27	5,65	33,92	33,92
RA	50,04	0,00	0,00	50,04	50,04
RT	100,00	100,00	100,00	100,00	100,00
RI	54,92	54,92	54,92	54,92	54,92
PS	15,83	23,67	39,5	0,00	0,00
PL	0,00	87,37	82,73	87,37	87,37
SE	0,00	47,89	47,89	28,36	28,36
AG	22,72	39,46	30,20	44,27	44,27
K	0,14	0,31	0,22	0,35	0,36

Fonte: Produção do autor.

E.6 – Resultados correspondentes aos Cenários para a combinação VI

Tabela E.6 – Relação da acurácia por classe entre os Cenários resultantes da combinação VI (CVI) {*P, Wi, KL; T, Ga, KL*}.

	Percentual de acurácias por classe CVI				
	Palsar	TM	Mínimos	Produto	Soma
FP	5,65	62,45	5,65	33,92	62,45
RA	50,04	18,11	50,04	50,04	18,11
RT	100,00	100,00	100,00	100,00	100,00
RI	0,00	45,08	0,00	45,08	45,08
PS	15,83	23,67	15,83	15,83	0,00
PL	0,00	47,71	0,00	52,35	52,35
SE	0,00	93,39	0,00	28,36	93,39
AG	20,52	58,88	20,52	42,45	57,24
K	0,11	0,49	0,11	0,32	0,47

Fonte: Produção do autor.

E.7 – Resultados correspondentes aos Cenários para a combinação VII

Tabela E.7 – Relação da acurácia por classe entre os Cenários resultantes da combinação VII (CVII) {*R, Wi, KL; T, Ga, KL*}.

	Percentual de acurácias por classe CVII				
	Radarsat	TM	Mínimos	Produto	Soma
FP	28,27	62,45	28,27	68,1	62,45
RA	0,00	18,11	0,00	18,11	18,11
RT	100,00	100,00	100,00	100,00	100,00
RI	54,92	45,08	54,92	45,08	45,08
PS	23,67	23,67	23,67	38,71	38,71
PL	87,37	47,71	87,37	87,37	47,71
SE	47,89	93,39	47,89	47,89	93,39
AG	39,46	58,88	39,46	60,70	60,16
K	0,31	0,49	0,31	0,52	0,50

Fonte: Produção do autor.

E.8 – Resultados correspondentes aos Cenários para a combinação VIII

Tabela E.8 – Relação da acurácia por classe entre os Cenários resultantes da combinação VIII (CVIII) {*P, Wi, KL; R, Wi, KL*}.

	Percentual de acurácias por classe CVIII				
	Palsar	Radarsat	Mínimos	Produto	Soma
FP	5,65	28,27	5,65	32,92	33,92
RA	50,04	0,00	0,00	50,04	50,04
RT	100,00	100,00	100,00	100,00	100,00
RI	0,00	54,92	54,92	54,92	54,92
PS	15,83	23,67	39,5	0,00	15,04
PL	0,00	87,37	82,73	87,37	87,37
SE	0,00	47,89	47,89	28,36	12,54
AG	20,52	39,46	30,20	44,27	43,76
K	0,11	0,31	0,22	0,35	0,36

Fonte: Produção do autor.

E.9 – Resultados correspondentes aos Cenários para a combinação IX

Tabela E.9 – Relação da acurácia por classe entre os Cenários resultantes da combinação IX (CIX) {*P, PI, Bh; R, PI, Bh*}.

	Percentual de acurácias por classe CIX				
	Palsar	Radarsat	Mínimos	Produto	Soma
FP	5,65	33,92	33,92	33,92	33,92
RA	50,04	0,00	50,04	50,04	18,11
RT	100,00	24,50	24,50	100,00	100,00
RI	54,92	54,92	54,92	54,92	54,92
PS	15,83	0,00	15,83	0,00	0,00
PL	4,64	87,37	87,37	87,37	87,37
SE	0	28,36	28,36	28,36	28,36
AG	23,09	30,14	37,94	44,27	40,14
K	0,14	0,19	0,28	0,35	0,31

Fonte: Produção do autor.

E.10 – Resultados correspondentes aos Cenários para a combinação X

Tabela E.10 – Relação da acurácia por classe entre os Cenários resultantes da combinação X (CX) {*P, PI, Bh; R, PI, Bh*}.

	Percentual de acurácias por classe X				
	Palsar	Radarsat	Mínimos	Produto	Soma
FP	5,65	28,27	5,65	33,92	33,92
RA	50,04	0,00	0,00	50,04	50,04
RT	100,00	100,00	100,00	100,00	100,00
RI	54,92	54,92	54,92	54,92	54,92
PS	15,83	23,67	39,5	0,00	0,00
PL	0,00	87,37	82,73	87,37	87,37
SE	0,00	47,89	47,89	47,89	28,36
AG	22,72	39,46	30,20	46,47	44,27
K	0,14	0,31	0,22	0,38	0,36

Fonte: Produção do autor.

