



Ministério da  
**Ciência, Tecnologia  
e Inovação**



sid.inpe.br/mtc-m19/2012/08.30.12.50-TDI

**AVALIAÇÃO DE MÉTODOS DE INTEGRAÇÃO DE  
IMAGENS ÓPTICAS E DE RADAR PARA A  
CLASSIFICAÇÃO DO USO E COBERTURA DA TERRA  
NA REGIÃO AMAZÔNICA**

Luciana de Oliveira Pereira

Dissertação de Mestrado do Curso  
de Pós-Graduação em Sensoria-  
mento Remoto, orientada pelos  
Drs. Corina Costa Freitas, e Sidnei  
João Siqueira Sant'Anna, aprovada  
em 27 de agosto de 2012.

URL do documento original:

<<http://urlib.net/8JMKD3MGP7W/3CHCSD5>>

INPE  
São José dos Campos  
2012

## **PUBLICADO POR:**

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

Fax: (012) 3208-6919

E-mail: pubtc@sid.inpe.br

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

### **Presidente:**

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

### **Membros:**

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

Dr<sup>a</sup> Inez Staciarini Batista - Coordenação Ciências Espaciais e Atmosféricas (CEA)

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

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

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

Dr<sup>a</sup> Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação

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

### **BIBLIOTECA DIGITAL:**

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

### **REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

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

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

### **EDITORAÇÃO ELETRÔNICA:**

Ivone Martins - Serviço de Informação e Documentação (SID)



Ministério da  
**Ciência, Tecnologia  
e Inovação**



sid.inpe.br/mtc-m19/2012/08.30.12.50-TDI

**AVALIAÇÃO DE MÉTODOS DE INTEGRAÇÃO DE  
IMAGENS ÓPTICAS E DE RADAR PARA A  
CLASSIFICAÇÃO DO USO E COBERTURA DA TERRA  
NA REGIÃO AMAZÔNICA**

Luciana de Oliveira Pereira

Dissertação de Mestrado do Curso  
de Pós-Graduação em Sensoria-  
mento Remoto, orientada pelos  
Drs. Corina Costa Freitas, e Sidnei  
João Siqueira Sant'Anna, aprovada  
em 27 de agosto de 2012.

URL do documento original:

<<http://urlib.net/8JMKD3MGP7W/3CHCSD5>>

INPE  
São José dos Campos  
2012

Dados Internacionais de Catalogação na Publicação (CIP)

---

Pereira, Luciana de Oliveira.

P414a Avaliação de métodos de integração de imagens ópticas e de Radar para a classificação do uso e cobertura da terra na Região Amazônica / Luciana de Oliveira Pereira. – São José dos Campos : INPE, 2012.

xxviii+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, 2007.

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

1. fusão de imagens. 2. uso e cobertura da terra. 3. Amazônia Brasileira. 4. Santarém-Pará. I. Título.

CDU 528.8.044.2(811.5)

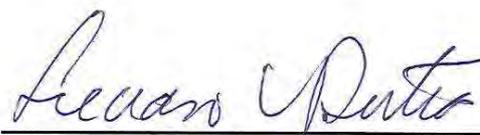
---

Copyright © 2012 do MCT/INPE. Nenhuma parte desta publicação pode ser reproduzida, armazenada em um sistema de recuperação, ou transmitida sob qualquer forma ou por qualquer meio, eletrônico, mecânico, fotográfico, reprográfico, de microfilmagem ou outros, sem a permissão escrita do INPE, com exceção de qualquer material fornecido especificamente com o propósito de ser entrado e executado num sistema computacional, para o uso exclusivo do leitor da obra.

Copyright © 2012 by MCT/INPE. No part of this publication may be reproduced, stored in a retrieval system, or transmitted in any form or by any means, electronic, mechanical, photocopying, recording, microfilming, or otherwise, without written permission from INPE, with the exception of any material supplied specifically for the purpose of being entered and executed on a computer system, for exclusive use of the reader of the work.

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

Dr. Luciano Vieira Dutra



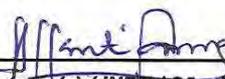
Presidente / INPE / SJCampos - SP

Dra. Corina da Costa Freitas



Orientador(a) / INPE / SJCampos - SP

Dr. Sidnei João Siqueira Sant'Anna



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

Dr. Yosio Edemir Shimabukuro



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

Dr. Aylton Pagamisse



Convidado(a) UNESP/PP / Presidente Prudente - SP

Este trabalho foi aprovado por:

maioria simples

unanimidade

Aluno (a): **Luciana de Oliveira Pereira**

São José dos Campos, 27 de Agosto de 2012



*“Os sonhos não determinam o lugar onde você vai chegar, mas produzem a força necessária para tirá-lo do lugar onde esta”*

(Augusto Cury)



## AGRADECIMENTOS

A meus pais, Norma e Joaquim e a minha irmã Renata por todo o amor, carinho, auxílio, confiança e incentivo não só aos estudos, mas em todas as partes da minha vida.

Ao Dr. César Hérique Barra Rocha pelo incentivo à continuação profissional no meio acadêmico.

A meu namorado Marcelo e a minha cachorra Cacau, pelo companheirismo, compreensão e muitas alegrias durante esses anos.

A todos os familiares, irmãos e amigos que de certa forma contribuíram para que esta dissertação se tornasse uma realidade. Em especial aos amigos de Juiz de Fora que moram no meu coração.

Aos meus orientadores Dra. Corina Costa Freitas e Dr. Sidnei João Siqueira Sant'Anna pela confiança, incentivo e total apoio no desenvolvimento do trabalho.

Aos Dr. Cleber Gonzales de Oliveira e aos futuros doutores Gabriel Pereira, Francielle da Silva Cardoso e Rogério Galante Negri pelas valiosas contribuições e auxílios durante o desenvolvimento deste trabalho.

Aos amigos da senzala e de turma pelo apoio e incentivo ao desenvolvimento deste trabalho.

Ao Instituto Nacional de Pesquisas Espaciais, por ceder as suas instalações para a realização do mestrado.

À Coordenação de Aperfeiçoamento Pessoal de Nível Superior (CAPES), pela concessão da bolsa durante os anos de 2010 a 2012.



## RESUMO

Esta dissertação tem como objetivo principal avaliar diferentes formas de integrar dados (fusões e combinações) de diferentes sensores imageadores (SAR e ópticos) visando identificar a mais adequada para o mapeamento do uso e cobertura da terra de uma região de fronteira agrícola da Amazônia brasileira. Como objetivos específicos pode-se listar a identificação das classes que serão melhores discriminadas com a utilização conjunta dos dados ópticos e SAR e de seus respectivos métodos de integração, e também avaliar um modo de integrar a informação contida em imagens SAR multipolarizadas antes dos processos de fusões utilizando a primeira componente principal (PC) destes dados. Para tanto, foram realizadas 90 classificações com imagens distintas, sendo 2 imagens originais (LANDSAT5/TM e ALOS/PALSAR), 2 imagens formadas pelos atributos extraídos das imagens originais, 6 imagens combinadas e 80 imagens fusionadas por diferentes métodos. Várias classificações resultantes das imagens fusionadas ou combinadas apresentaram valores dos índices *Kappas* estatisticamente superiores ao da imagem LANDSAT5/TM. Neste cenário destacaram-se os métodos de fusões *Ehlers*, *Wavelet á trous*, IHS e SPC (*Selective principal component analysis*). Entretanto, estes três últimos métodos de fusões apresentaram bons resultados somente quando as fusões foram processadas utilizando a primeira componente principal das bandas da imagem ALOS/PALSAR ou dos três atributos SAR selecionados, mostrando assim a aplicabilidade do método proposto de integrar informações dos dados SAR. Baseado nas análises dos índices *Kappas* por classes conclui-se que o uso conjunto dos dados ópticos com SAR melhora a classificação de todas as classes definidas neste estudo. Entretanto, os métodos que melhor discriminam uma determinada classe ou um conjunto de classes são distintos. No geral, as classes florestadas foram melhores discriminadas pelo método de fusão *Ehlers* em que pelo menos a banda HV da imagem ALOS/PALSAR está envolvida no processo. As classes de regeneração intermediária e inicial foram melhor discriminadas pelo método de fusão SPC utilizando a primeira componente das bandas da imagem ALOS/PALSAR. As classes de solo exposto, soja pronta para colheita, pasto limpo e pasto sujo foram melhores discriminadas pela classificação da imagem fusionada pelo método IHS utilizando os atributos ópticos e primeira PC das bandas da imagem ALOS/PALSAR. A classe de soja com aproximadamente 40 dias de semeadura foi melhor discriminada pela classificação da imagem ALOS/PALSAR. Concluiu-se também que a banda HV contém informações importantes na discriminação das classes, pois está presente na maioria dos métodos de fusões que aumentaram acurácia das classificações.



## EVALUATION OF OPTICAL AND RADAR IMAGES INTEGRATION METHODS FOR LAND USE AND LAND COVER CLASSIFICATION ON AMAZON REGION

### ABSTRACT

This study aims to assess different ways for data integration (fusions and combinations) of different imagery sensor (SAR and optical) in order to identify the most appropriate for mapping land use and land cover in an agricultural frontier region of the Brazilian Amazon. The secondary goals are to identify the classes that are better discriminated with the use of SAR and optical data together and also to evaluate the procedure of integrating the information of multipolarized SAR data before the fusion process, using the first principal component (PC) of these data. To achieve these goals 90 distinct image classifications were performed: 2 original images (LANDSAT5/TM and ALOS/PALSAR), 2 images composed by the attributes extracted from the original images, 6 combined images and 80 fused images by different methods. Several classifications of fused and combined images presented statistically higher *Kappa* values than that of LANDSAT5/TM classification. The fusion methods to be highlighted were *Ehlers*, *Wavelet á trous*, IHS e SPC (Selective principal component analysis). However the latter three methods showed good results only when the fusion process where performed using the first principal component of ALOS/PALSAR image bands, or of the three attributes extracted from radar images, showing the applicability of the proposed method of integrating information from SAR data. Based on the analysis of the *Kappa* coefficients per class it was concluded that the use of optical and SAR data together improves the classification results for all classes. However, the methods that best discriminate one single class were different for each class. In general, the forested classes were better discriminated by the *Ehlers* fusion method in which at least the HV band of ALOS/PALSAR image was involved in the fusion process. The intermediate and initial regeneration classes were better discriminated by the SPC fusion method using the first PC of ALOS/PALSAR image bands. The bare soil, soybeans ready for harvest, clean pasture and dirty pasture classes were better discriminated by the IHS fusion method using the optical attributes and the first PC of ALOS/PALSAR image bands. The class of soybean with 40 days of seeding was better discriminated by the classification using only the ALOS/PALSAR image. It was also concluded that the HV band contains valuable information to improve the discrimination of classes, because this band was present in most of the fusion methods with high values of classification accuracies.



## LISTA DE FIGURAS

Figura 2.1.	Níveis de fusão de imagens em sensoriamento remoto.....	9
Figura 2.2.	Técnica IHS de fusão de imagem óptica/SAR.....	14
Figura 2.4.	Técnica por PC de fusão de imagem óptica/SAR.....	15
Figura 2.3.	Método de fusão através da SPC-SAR.....	16
Figura 2.5.	Método de fusão de imagens TW decimada.....	17
Figura 2.6.	Decomposição da TWT não decimada isotrópico: a) imagem pancromática, b) imagem de baixa frequência, e c) imagem de alta frequência.....	19
Figura 2.7.	Método de fusão TW e IHS.....	21
Figura 2.8.	Método de fusão TW e PCA.....	22
Figura 2.9.	Exemplo de fusão <i>Ehlers</i> com 3 bandas multiespectrais e 1 imagem de melhor resolução (AR).....	24
Figura 3.1.	Localização da área de estudo. Composição colorida da imagem LANDSAT5/TM R5G4B3.....	27
Figura 3.2.	Imagens SAR e óptica utilizada nesta dissertação.....	30
Figura 4.1.	Fluxograma metodológico.....	31
Figura 4.2.	Precipitação diária.....	34
Figura 4.3.	Exemplo de Região homogênea na imagem ALOS/PALSAR:(a) HV e (b) HH.....	35
Figura 4.4.	Segmentação das imagens: (a) ALOS/PALSAR, (b) LANDSAT5/TM e (c) combinação das segmentações anteriores.....	38
Figura 5.1.	Localização das amostras das classes de interesse na imagem ALOS/PALSAR.....	59
Figura 5.2.	Fotografias que representam as 13 classes de interesse: a) FP, b) FPE, c) FD, d) RA, e) Rint, f) RI, g) PS, h) AP7/24, i) PL, j) PLBI, k) SP, l) S100 e m) S40.....	60
Figura 5.3.	Valores estimados para a relação sinal/ruído da banda HH para diferentes tamanhos de janelas de vizinhança.....	62
Figura 5.4.	Valores estimados para a relação sinal/ruído da banda HV para diferentes tamanhos de janelas de vizinhança.....	63
Figura 5.5.	Medidas de texturas selecionadas em ordem crescente da distância JM média.....	64
Figura 5.6.	Áreas das bandas de textura Média e do Coeficiente de Variação: a) MED_7_HV, b) MED_9_HH, c) CV_19_HV e d) CV_19_HH.....	66

Figura 5.7.	Área das bandas dos atributos ópticos: a) PC <sub>1</sub> , b) IMF_VEG, c) IMF_SM, d) IMF_SL, e) NDVI e f) GEMI. ....	67
Figura 5.8.	Valores da distância JM média para os atributos SAR. ....	69
Figura 5.9.	Valores da distância JM média para os atributos ópticos.....	69
Figura 5.10.	Seleção de um subconjunto ótimo de atributos SAR. ....	71
Figura 5.11.	Atributos SAR para uma parte da área de estudo e respectivos gráficos da média e desvio padrão das classes de interesse: a) CV_19_HH, b) COR_11_HV e c) COR_9_HH. ....	73
Figura 5.12.	Atributos SAR selecionados para análises e processamentos futuros com os respectivos gráficos de média e desvio padrão das classes em estudo: a) MED_7_HV, b) HOM_15_HH e c) DIS_15_HH. ....	74
Figura 5.13.	Gráficos de média e desvio padrão das classes em estudo para os atributos ópticos: a) B1, b) B2, c) B3, d) B7, e) IMF_SL e f) IMF_SM. ..	76
Figura 5.14.	Gráficos de média e desvio padrão das classes em estudo para os atributos SAR: a) HV_SIG, b) MED_7_HH, c) PC <sub>1</sub> HH_HV e d) PC <sub>1</sub> SAR <sub>3</sub> .....	78
Figura 5.15.	Gráficos de média e desvio padrão das classes de interesse para os atributos ópticos: a) B5 e b) IMF_SM. ....	79
Figura 5.16.	Gráficos de média e desvio padrão dos pares de atributos: a) DIS_15_HH e IMF_VEG, b) HOM_15_HH e IMF_VEG, c) DIS_15_HH e HOM_15_HH.....	80
Figura 5.17.	Gráficos de média e desvio padrão dos pares de atributos: a) DIS_15_HH e MED_7_HV, b) HOM_15_HH e MED_7_HV.....	80
Figura 5.18.	Gráficos de média e desvio padrão dos pares de atributos: a) DIS_15_HH e IMF_SM, b) HOM_15_HH e IMF_SM, c) MED_7_HV e IMF_SM, d) DIS_15_HH e B5, e) HOM_15_HH e B5 f) MED_7_HV e B5, g) MED_7_HV e IMF_VEG. ....	82
Figura 5.19.	Gráficos de média e desvio padrão dos pares de atributos: a) IMF_SM e IMF_VEG, b) B5 e IMF_VEG c) B5 e IMF_SM.....	83
Figura 5.20.	Árvore de decisão do aplicativo para o agrupamento das 13 classes de interesse.....	84
Figura 5.21.	Valores dos índices <i>Kappas</i> . ....	88
Figura 5.22.	Classificações das imagens: a) LANDSAT5/TM, b) OPT <sub>3</sub> , c) ALOS/PALSAR e d) SAR <sub>3</sub> .....	89
Figura 5.23.	Visualização da classificação SAR <sub>3</sub> em uma região de agricultura selecionada na imagem.....	90
Figura 5.24.	Gráfico dos <i>Kappas</i> por classe das classificações das imagens originais LANDSAT5/TM, ALOS/PALSAR, OPT <sub>3</sub> e SAR <sub>3</sub> . ....	91

Figura 5.25. Resultado das classificações das imagens combinadas e comparação com o resultado de classificação da imagem LANDSAT5/TM.....	93
Figura 5.26. Valores dos índices <i>Kappa</i> das 90 classificações e comparação estatística com o resultado de classificação da imagem LANDSAT5/TM.....	95
Figura 5.27. Fusões cujas classificações apresentaram valores dos índices <i>Kappas</i> estatisticamente superiores ao <i>Kappa</i> da classificação da imagem LANDSAT5/TM (0,652). .....	99
Figura 5.28. Exemplo de imagens fusionadas compostas no espaço RGB: a) Imagem LANDSAT5/TM, b) <i>Ehlers_HH_HV</i> , c) <i>WA_SAR<sub>3</sub></i> , d) <i>IHS_OPT<sub>3</sub>HH_HV</i> e e) <i>SPC_SAR<sub>3</sub></i> .....	100
Figura 5.29. Valores dos índices <i>Kappas</i> das classificações selecionadas.....	101
Figura 5.30. Classificações das imagens selecionadas: a) <i>WA_SAR<sub>3</sub></i> , b) <i>SPC_HH_HV</i> , c) <i>IHS_OPT<sub>3</sub>HH_HV</i> , d) <i>IHS_OPT<sub>3</sub>SAR<sub>3</sub></i> , e) <i>SPC_SAR<sub>3</sub></i> , f) <i>Ehlers_HV</i> , g) <i>Ehlers_HH_HV</i> e h) <i>TM_SAR<sub>3</sub></i> . .....	107
Figura 5.31. Visualização da classificação <i>TM_SAR<sub>3</sub></i> em uma região de agricultura selecionada na imagem.....	108
Figura 5.32. Gráfico dos <i>Kappas</i> por classe das classificações das imagens selecionadas com o resultado do teste de hipótese.....	110
Figura 5.33. Valores dos índices <i>Kappas</i> das classificações realizadas com 6 classes de interesse. ....	117
Figura 5.34. Classificações das imagens: a) <i>ALOS/PALSAR</i> , b) <i>SAR<sub>3</sub></i> , c) <i>LANDSAT5/TM</i> e d) <i>TM_SAR<sub>3</sub></i> .....	119
Figura 5.35. Classificações das imagens fusionadas: a) <i>Ehlers_HH_HV</i> , b) <i>Ehlers_HV</i> , c) <i>SPC_HH_HV</i> , d) <i>WA_SAR<sub>3</sub></i> , e) <i>SPC_SAR<sub>3</sub></i> , f) <i>IHS_OPT<sub>3</sub>HH_HV</i> , g) <i>IHS_OPT<sub>3</sub> SAR<sub>3</sub></i> .....	121
Figura 5.36. Visualização das classificações em uma região de agricultura selecionada na imagem: a) <i>SAR<sub>3</sub></i> e c) <i>TM_SAR<sub>3</sub></i> .....	122
Figura 5.37. <i>Kappa</i> por classe das imagens classificadas selecionadas. ....	123
Figura 5.38. Matriz de confusão da classificação da imagem <i>Ehlers_HH_HV</i> com 8 classes.....	126
Figura 5.39. Matriz de confusão da classificação da imagem <i>Ehlers_HH_HV</i> com 6 classes.....	129



## LISTA DE TABELAS

	Pág.
Tabela 3.1. Principais características da imagem ALOS/PALSAR FBD 1.5.....	29
Tabela 3.2. Principais características da imagem LANDSAT5/TM.....	30
Tabela 4.1. Atributos dos dados ópticos e SAR.....	46
Tabela 4.2. Métodos de fusão.....	49
Tabela 5.1. Descrição das imagens, combinações e fusões que serão classificadas e avaliadas.....	54
Tabela 5.2. Descrição das classes selecionadas e número de amostras coletadas.....	58
Tabela 5.3. Valores estimados para a relação sinal/ruído.....	62
Tabela 5.4. Medidas de texturas selecionadas.....	64
Tabela 5.5. Seleção de um subconjunto ótimo de atributos SAR.....	72
Tabela 5.6. Classes de interesse selecionadas e número de amostras coletadas.....	86
Tabela 5.7. Testes de hipótese z entre os pares de Kappas.....	102
Tabela 5.8. Número de atributos utilizados nas fusões selecionadas.....	108
Tabela 5.9. Maiores acréscimos percentuais nos valores dos índices Kappas por classe.....	113
Tabela 5.10. Descrição do novo conjunto de classes e número de amostras coletadas.....	115
Tabela 5.11. Testes de hipótese z entre os pares de Kappas.....	118
Tabela 5.12. Maiores acréscimos percentuais nos valores dos índices Kappas por classe com 6 classes.....	124



## LISTA DE SIGLAS E ABREVIATURAS

AAr	Imagem <i>Wavelet</i> de alta frequência
ABr	Imagem <i>Wavelet</i> de alta frequência (linha) e baixa frequência (coluna)
AD	Árvore de Decisão
ALOS	<i>Advanced Land Observing System</i>
ANA	Agência Nacional de Águas
AR	Imagem de melhor resolução ou SAR
BAr	Imagem <i>Wavelet</i> de baixa frequência (linha) e alta frequência (coluna)
BBr	Imagem <i>Wavelet</i> de baixa frequência
DN	Valor do nível de cinza do pixel
ENL	Número Equivalente de Visadas ( <i>Equivalent Number of Looks</i> )
ERS-2	<i>European Remote Sensing 2</i>
ESA	<i>European Space Agency Information On Alos Palsar Products For Aden Users</i>
ETM+	<i>Enhanced Thematic Mapper Plus</i>
FDB	<i>Fine Beam Dual</i>
FPS	Filtro passa-alta
FPB	Filtro passa-baixa
GEMI	Índice de monitoramento ambiental Global ( <i>Global Environmental Monitoring Index</i> )
GPS	Sistema de Posicionamento Global ( <i>Global Positioning System</i> )
IBGE	Instituto Brasileiro de Geografia e Estatística.
ICM	Modas condicionais Interativas ( <i>Iterated Conditional Modes</i> )
IDL	<i>Interactive Data Language</i>
IHS	Intensidade, Matriz e Saturação ( <i>Intensity, Hue e Saturation</i> )
IMF_SL	Imagem fração solo
IMF_SM	Imagem fração sombra
IMF_VEG	Imagem fração vegetação
INPE	Instituto Nacional de Pesquisas Espaciais
IPEA	Instituto de Pesquisa Econômica e Aplicada

JAXA	<i>Japan Aerospace Exploration Agency</i>
JM	<i>Jeffries-Matusita</i>
LIA	<i>Ângulo de Incidência Local (Local Incidence Angle)</i>
MAXVER	<i>Máxima Verossimilhança</i>
MLME	<i>Modelo linear de mistura espectral</i>
NDVI	<i>Índice de vegetação por diferença normalizada (Normalized Difference Vegetation Index)</i>
NIR	<i>Infravermelho Próximo (Near Infrared)</i>
OIF	<i>Fator de Índice Ótimo (Optimum Index Factor)</i>
PALSAR	<i>Phase Array L-Band Synthetic Aperture Radar</i>
PCA	<i>Análise por Componentes Principais (Principal Component Analysis)</i>
PC	<i>Componente Principal (Principal Component)</i>
PC <sub>1</sub>	<i>Primeira componente principal</i>
PRODES	<i>Projeto de Monitoramento do Desflorestamento na Amazônia Legal</i>
RADAR	<i>Radio Detection And Range</i>
REM	<i>Radiação Eletromagnética</i>
ROI	<i>Região de interesse (Region of Interest)</i>
SAR	<i>Radar de Abertura Sintética (Synthetic Aperture Radar)</i>
SNR	<i>Relação Sinal Ruído (Signal to Noise Ratio)</i>
SPC-SAR	<i>Análise por componentes principais seletivos (Selective principal component analysis)</i>
SPOT-4	<i>Satellite Pour l'Observation de la Terre 4</i>
SRTM	<i>Shuttle Radar Topography Mission</i>
SVM	<i>Máquina de Vetor Suporte (Support Vector Machine)</i>
SWIR	<i>Infravermelho de Ondas Curtas (Shortwave Infrared)</i>
TB	<i>Transformação de Brovey</i>
TF	<i>Transformada de Fourier</i>
TIR	<i>Infravermelho Termal (Thermal Infrared)</i>
TM	<i>Thematic Mapper</i>
TW	<i>Transformada Wavelet</i>
TWI	<i>Transformada Wavelet Inversa</i>

TWA	Transformada <i>Wavelet</i> “ <i>á trous</i> ”
6s	Modelo <i>Second Simulation of the Satellite Signal in the Solar Spectrum</i>



## LISTA DE SÍMBOLOS

$K$	Estimador do índice de concordância <i>Kappa</i>
$x_{ii}$	Valor observado na linha e coluna, respectivamente
$B_i$	$i$ -ésima banda óptica
$\sigma_{Im}$	Desvio padrão da imagem
$\mu_{Im}$	Média da imagem
$\sigma_k$	Desvio padrão da imagem
$\mu_k$	Vetor de média
$\sigma_\tau$	Desvio padrão dos níveis de cinza da banda $\tau$
$Im\ SAR$	Imagem SAR
$\mu$	Média amostral dos níveis de cinza da imagem
$\sigma$	Desvio padrão amostral dos níveis de cinza
$Im$	Imagem
$\tau$	Transformação
$\zeta$	Processo de substituição
$\tau^{-1}$	Transformação inversa
$\mu_i$	Vetores de média para a classe $i$
$B_{ki}$	Distância de <i>Bhattacharyya</i> entre as funções de densidade de probabilidade estimadas para as classes $k$ e $i$
$\sigma^0$	Sigma zero
$ \rho_{\alpha\beta} $	Módulo do coeficiente de correlação entre bandas $\alpha$ e $\beta$



## SUMÁRIO

	<u>Pág.</u>
<b>1. INTRODUÇÃO .....</b>	<b>1</b>
<b>2. FUNDAMENTAÇÃO TEÓRICA.....</b>	<b>7</b>
2.1. Pré-processamento.....	9
2.2. Métodos de fusão de imagens ópticas com SAR.....	11
2.2.1. Fator de Índice Ótimo (OIF).....	12
2.2.2. Transformação de Brovey (TB).....	13
2.2.3. Transformação de cores IHS .....	13
2.2.4. Análise por componentes principais (PCA) .....	14
2.2.5. Análise por componentes principais seletivos (SPC-SAR).....	15
2.2.6. Transformada Wavelet (TW).....	16
2.2.7. Métodos Híbridos de fusão.....	20
2.2.8. TW e PCA .....	21
2.2.9. Método de fusão Ehlers .....	23
2.3. Tendências dos métodos de fusão de dados ópticos com SAR .....	25
<b>3. ÁREA DE ESTUDO E IMAGENS UTILIZADAS .....</b>	<b>27</b>
3. 1. Área de estudo .....	27
3.2. Imagens utilizadas .....	28
<b>4. METODOLOGIA.....</b>	<b>31</b>
4.1. Avaliação planimétrica da imagem ALOS/PALSAR FBD 1.5 Geocoded .....	32
4.2. Pré – processamento .....	32
4.2.1. Influência da precipitação e umidade no restroespalhamento das bandas da imagem ALOS/PALSAR.....	32
4.2.2. Redução do ruído speckle.....	34
4.3. Método de classificação .....	36
4.4. Seleção das amostras das classes de interesses .....	37
4.5. Extração de atributos SAR e ópticos .....	39
4.5.1. Extração dos atributos SAR.....	39
4.5.1.1. Razão de bandas .....	39
4.5.1.2. Imagem ALOS/PALSAR em Sigma zero ( $\sigma^0$ ).....	40
4.5.1.3. Primeira componente das bandas da imagem ALOS/PALSAR.....	40

4.5.1.4. Atributos de textura e seleção dos respectivos tamanhos de janela .....	40
4.5.2. Extração dos atributos ópticos .....	43
4.5.2.1. Modelo linear de mistura espectral (MLME) .....	43
4.5.2.2. Índice de vegetação por diferença normalizada .....	44
4.5.2.3. Índice de Monitoramento Ambiental Global .....	45
4.6. Seleção de um subconjunto ótimo de atributos SAR e ópticos .....	46
4.7. Análise exploratória dos atributos selecionados .....	48
4.8. Agrupamento de classes .....	48
4.9. Métodos de fusão .....	49
4.10. Método de avaliação .....	50
<b>5. RESULTADOS E DISCUSSÕES .....</b>	<b>53</b>
5.1. Fusões e combinações que foram processadas e avaliadas .....	53
5.2. Definição das classes de interesse .....	58
5.3. Resultados da avaliação planimétrica da imagem ALOS/PALSAR .....	60
5.4. Pré-processamento .....	61
5.5. Seleção do tamanho da janela de vizinhança do filtro de speckle Gama .....	61
5.6. Extração de atributos SAR e ópticos .....	63
5.6.1. Extração dos atributos SAR .....	63
5.6.2. Seleção dos tamanhos das janelas de vizinhança das bandas de texturas .....	63
5.6.3. Atributos ópticos .....	66
5.7.1. Seleção de atributos SAR .....	70
5.7.2. Seleção de atributos ópticos .....	75
5.8. Análise exploratória dos dados que participaram dos processos de fusão .....	77
5.9. Agrupamento das 13 classes de interesse .....	84
5.10. Análise das classificações .....	87
5.10.1 Imagens originais LANDSAT5/TM, ALOS/PALSAR e seus atributos .....	87
5.10.2. Imagens combinadas .....	93
5.10.3. Imagens fusionadas .....	94
5.10.4. Análise das classificações selecionadas .....	99
5.10.5. Análise das classificações das imagens originais e das melhores classificações com 6 classes .....	116
<b>6. CONCLUSÕES E RECOMENDAÇÕES .....</b>	<b>131</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>139</b>

APÊNDICE A - AVALIAÇÃO PLANIMÉTRICA DE IMAGENS ALOS/PALSAR, MODO FINE BEAM DUAL (FBD), PARA UMA ÁREA DA AMAZÔNIA BRASILEIRA .....	153
A.1. INTRODUÇÃO.....	154
A.2. MATERIAL E MÉTODOS .....	157
A.2.1. Área de estudo .....	157
A.2.2. Abordagem metodológica.....	159
A.3. RESULTADOS E DISCUSSÃO.....	161
A.4. CONCLUSÃO E CONSIDERAÇÕES FINAIS .....	168
APÊNDICE B - SELEÇÃO DOS TAMANHOS DAS JANELAS DAS MEDIDAS DE TEXTURAS .....	171
APÊNDICE C - MATRIZ DE CORRELAÇÃO DOS ATRIBUTOS ÓPTICOS .....	191
<u>  </u> E SAR .....	191
APÊNDICE D – GRÁFICOS DE MÉDIA E DESVIO PADRÃO DOS ATRIBUTOS SAR E ÓPTICOS.....	193
D.1. Gráfico de média e desvio padrão dos atributos SAR.....	193
D.2. Gráfico de média e desvio padrão dos atributos ópticos .....	206
APÊNDICE E – GRÁFICOS UTILIZADOS NA ANÁLISE EXPLORATÓRIA DOS ATRIBUTOS.....	213
APÊNDICE F – TESTES DE HIPÓTESE Z ENTRE OS PARES DE KAPPAS DAS IMAGENS CLASSIFICADAS. ....	229
APÊNDICE G - REPRESENTAÇÃO DAS MATRIZES DE CONFUSÃO DAS CLASSIFICAÇÕES COM 8 CLASSES DE INTERESSE.....	231
APÊNDICE H - REPRESENTAÇÃO DAS MATRIZES DE CONFUSÃO DAS CLASSIFICAÇÕES COM 6 CLASSES DE INTERESSE.....	237



## 1. INTRODUÇÃO

As imagens adquiridas por sensoriamento remoto têm mostrado grande potencial para fornecer dados sobre diferentes variáveis ambientais, uma vez que é possível utilizar diferentes sensores para registrar a radiação eletromagnética (REM), refletida ou emitida, pelos objetos terrestres em diferentes resoluções espaciais, espectrais, radiométricas e temporais (JENSEN, 2009). Além disso, estas imagens permitem uma visão sinóptica e repetitiva dos alvos terrestres (HUANG et al., 2010). Em relação ao mapeamento e monitoramento dos ecossistemas e dos recursos terrestres, estes dados vêm sendo amplamente utilizados. No entanto, na maioria das vezes, a utilização de um único tipo de sensor (óptico ou de micro-ondas) não fornece informações satisfatórias sobre os fenômenos e/ou objetos em estudo (FATONE et al., 2001). É importante comentar que os sensores de micro-ondas (radar) e os sensores ópticos apresentam diferenças quanto à região do espectro eletromagnético que registram a REM. Os sensores de Radar de Abertura Sintética (*Synthetic Aperture Radar-SAR*) registram a REM na região do espectro eletromagnético conhecido como micro-ondas (1 cm e 1 m). Já os ópticos registram a REM nas regiões do espectro eletromagnético que compreendem o visível (VIR), infravermelho-próximo (*Near-Infrared-NIR*), infravermelho-médio (*Shortwave-Infrared-SWIR*), infravermelho-termal (*Thermal Infrared-TIR*). Os sensores SAR são também chamados de sensores imageadores ativos, pois emitem a própria fonte de energia. Enquanto que os sensores ópticos são conhecidos como sensores passivos, pois dependem da iluminação solar (JENSEN, 2009).

Os sensores ópticos imageadores fornecem informações importantes sobre as características biofísicas dos alvos, em especial para estudos dos ecossistemas aquáticos, terrestres e no monitoramento de mudanças no uso e cobertura da terra (JENSEN, 2009). As imagens ópticas proporcionam maior facilidade na interpretação visual das feições, sendo as mais utilizadas nos estudos ambientais. Em alguns países, dentre eles cita-se o Brasil, estas imagens são disponibilizadas gratuitamente por instituições como o Instituto Nacional de Pesquisas Espaciais (INPE). Já as imagens

SAR raramente são disponibilizadas gratuitamente, à exceção das imagens do *Shuttle Radar Topography Mission* (SRTM).

No entanto, alguns fatores devem ser considerados quando se utilizam dados apenas de sensores ópticos. Estes sensores apresentam algumas limitações quanto à influência das condições atmosféricas, em especial à presença de nuvens, material particulado e intensidade da radiação solar. Enquanto que os dados registrados pelos sensores SAR apresentam grande dependência dos parâmetros do sensor, como a geometria de iluminação entre o sensor e o terreno (ângulo de incidência) (PARADELLA et al., 2001), comprimento de onda emitido e a polarização dos sinais emitido e recebido. Estas imagens são, em geral, de difícil interpretação visual e exigem do usuário maior conhecimento operacional e conceitual sobre sensores remotos SAR. Uma das principais vantagens destes sensores é a capacidade de adquirir dados sob condições atmosféricas adversas e independentemente da iluminação solar. Outra vantagem destes sensores é a capacidade que o sinal tem de penetrar em alguns alvos ampliando assim as áreas de aplicações dos mesmos (POHL; VAN GENDEREN, 1998).

Os dados ópticos relacionam-se com as características químicas, físicas e biológicas dos alvos, enquanto que os dados de micro-ondas com a forma, textura, estrutura, propriedades dielétricas dos alvos. Além disto, pelo fato dos sensores SAR emitirem sinais de ondas longas, estes sinais podem penetrar em alguns alvos, proporcionando assim, o registro de dados e a extração de informações de subsuperfícies. Sendo assim, pode-se notar que os dados ópticos e de micro-ondas são complementares e, portanto, a integração dos mesmos pode resultar em melhorias na extração de informações a cerca dos alvos imageados, tendo como consequência a melhora na qualidade das classificações de feições de interesse (HUANG et al., 2010).

Dentre as técnicas de processamento de imagens, a fusão é uma das principais formas de integração de dados de diferentes sensores. Ela pode ser utilizada para diversas finalidades, tais como detectar alterações no uso e cobertura da terra, melhorar a

resolução espacial, temporal, espectral e conseqüentemente a discriminação de alvos (BWANGOY et al., 2010; ZHU et al., 2010). A extração de informações a partir de dados fusionados pode ser vantajosa na classificação do uso e cobertura da terra, em especial na região da Amazônia. Esta região possui áreas que apresentam uma interferência antrópica crescente (notavelmente áreas de expansão agrícola e pecuária), e como conseqüência, uma vegetação diversificada com diferentes estágios sucessionais, o que resulta em uma grande diversidade de uso e cobertura da terra. A composição deste cenário teve grande impulso a partir da década de 1970 quando o governo implementou uma política de ocupação, desenvolvimento e colonização da Amazônia brasileira. Esta política trouxe como conseqüência a intensificação do processo de desmatamento e a conversão de áreas de floresta densa em áreas de agricultura e pastagens. O processo de conversão persiste até os dias atuais, embora os atores econômicos, sociais e as características espaciais das conversões sejam diferentes (MACHADO, 2005). Este tipo de conversão costuma alterar o ciclo bioquímico local repercutindo, na maioria das vezes negativamente, nas características da área como fertilidade do solo, qualidade da água, biodiversidade e na quantidade de biomassa.

Além disto, a retirada da vegetação nativa altera o albedo da superfície e conseqüentemente o balanço de energia (calor) entre o solo e o ar, o que pode resultar no aumento de temperatura local. Estes fatores acumulados, em última escala, podem contribuir para as alterações climáticas globais (HOUGHTON, 1991; NOBRE et al., 1991). Por outro lado, alguns estudos afirmam que parte das áreas desflorestadas a partir da década de 70 foi abandonada e atualmente encontra-se em diversos estágios de regeneração, tornando-se áreas propensas ao sequestro de carbono, além de apresentarem importantes funções ecológicas no ecossistema amazônico atual. Esta importância está atrelada ao suporte que estas áreas apresentam na recuperação da composição e da estrutura vegetal propiciando a expansão e a dispersão da fauna e flora comuns às florestas primárias (UHL et al., 1988; MORAN et al., 2000; CARDILLE; FOLEY, 2003).

Portanto, a classificação e quantificação mais acurada do uso e cobertura da terra em biomas como a Amazônia são de suma importância para diversos estudos científicos, pois são a base e os dados de entrada para muitas aplicações e temas de pesquisas, tais como, modelagens e análises ambientais (PIERCE et al., 2002; CASTAÑEDA; GABER et al., 2009; DUCROT, 2009; LAURILA et al., 2010), estudos sobre o ciclo do carbono (LIU et al., 2003), mudanças globais, regionais e climáticas (REZULLO et al., 2008), análises multitemporais (MCNAIRN et al., 2009), dentre outros. Esta importância se estende também aos setores políticos e econômicos. No contexto político destacam-se as metas estabelecidas de redução de emissão de carbono previstas para 2020. Esta política tem como meta a redução na emissão de 1.404 milhões de toneladas de CO<sub>2</sub> no setor de mudanças do uso da terra, sendo que deste montante 68% devem ser reduzidos no bioma da Amazônia. Para tanto, são previstos medidas de redução do desmatamento, recuperação de áreas de pastagens degradadas e plantio de florestas (Instituto de Pesquisa Econômica Aplicada - IPEA, 2011). Para que estes objetivos possam ser alcançados certamente serão necessários mapeamentos e monitoramentos acurados das áreas envolvidas nos processos de redução do desmatamento.

No contexto econômico destacam-se o mercado de carbono e o fundo da Amazônia, que tem em comum o objetivo de tornar interessante e viável do ponto de vista econômico a conservação das florestas nativas (IPEA, 2011). Neste contexto, o mapeamento mais acurado das florestas primárias, controle do desmatamento, bem como a quantificação e monitoramento dos mesmos são igualmente importantes.

Assim, muitos esforços e progressos têm sido realizados para melhorar o desempenho dos métodos de extração de informação com finalidade de melhorar a capacidade discriminatória das classes e conseqüentemente a acurácia no mapeamento do uso e cobertura da terra (LU et al., 2007). Entretanto, não há um consenso na comunidade científica sobre o melhor método de se integrar dados ópticos com SAR para fins de classificação, especialmente em ambientes de florestas tropicais úmidas como o bioma Amazônico. Aliado a isto, são poucos os trabalhos que abordam esta temática na

Amazônia, dentre os quais pode-se citar os trabalhos de Walfir e Paradella, (2005); Lu et al. (2007); Gonçalves et al. (2009); Lu et al. (2011); Rodrigues e Souza-Filho,(2011).

As pesquisas com fusão de imagens (óptico/SAR) vêm se intensificando nos últimos anos, com progressos significativos nos métodos, técnicas e análises das fusões (DONG et al., 2009). Atualmente, alguns radares imageadores permitem a aquisição de informações multipolarizadas. Este tipo de imagem fornece informação em diferentes polarizações e, por este motivo, pode ser útil na discriminação de classes de uso e cobertura da terra. Alguns estudos abordam a fusão ou combinação com imagens SAR multipolarizadas. Dentre estes pode-se citar Walker et al. (2007); Waske e Benediktsson, (2007); Waske e Linden, (2008); McNairn et al. (2009); Wijaya e Gloaguen, (2009); Huang et al. (2010); Laurila et al. (2010); Lucas et al. (2010); Lu et al. (2011); Pouteau e Stoll, (2011); Silva et al. (2011); Walker et al. (2011); Wolter e Townsend, 2011. Entretanto, apenas os estudos de Lu et al. (2011); Silva et al. (2011) e Walker et al. (2011) abordam esta temática em regiões da Amazônia.

Baseado no exposto, o objetivo geral desta dissertação é avaliar diferentes formas de integrar dados de diferentes sensores imageadores (óptico com micro-ondas) com a finalidade de identificar a mais adequada para o mapeamento do uso e cobertura da terra de uma região da Amazônia brasileira. Como objetivos específicos podem-se listar:

- A identificação das classes que serão melhores discriminadas com a utilização conjunta dos dados ópticos e SAR e de seus respectivos métodos de integração.
- Avaliar um modo de integrar a informação contida em imagens SAR multipolarizadas antes dos processos de fusões.

Este trabalho foi organizado em seções, as quais são descritas a seguir. A fundamentação teórica é apresentada na seção 2. A área de estudo e as imagens utilizadas nesta dissertação são apresentadas na seção 3. As metodologias empregadas

no desenvolvimento deste estudo são descritas detalhadamente na seção 4. Na seção 5 são apresentados e discutidos os resultados e finalmente na seção 6 são realizadas as considerações finais e as conclusões dos resultados obtidos.

## 2. FUNDAMENTAÇÃO TEÓRICA

A fusão de imagens pode ser utilizada para diversas finalidades, como detectar alterações no uso e cobertura da terra (POHL; VAN GENDEREN, 1998), e melhorar a resolução espacial, temporal, espectral e por consequência a discriminação de alvos (BWANGOY et al., 2010; ZHU et al., 2010). Desde o final do século passado muitas pesquisas e artigos científicos sobre fusão de imagens têm sido publicados com a finalidade de melhorar a qualidade das imagens fusionadas e apresentar novas áreas de aplicação (DONG et al., 2009 ; HUANG et al., 2010).

A definição dos termos “fusão de dados ou de imagens” é amplamente debatida no meio científico, pois são usados em várias áreas do conhecimento, dentre elas o sensoriamento remoto. Uma revisão destas definições pode ser encontrada em Wald (1999). Segundo este autor existem definições abrangentes como a que considera fusão de imagens como um conjunto de meios e técnicas que usam dados provenientes de várias fontes, muitas das vezes, de diferente natureza para aumentar a qualidade e a precisão das informações. Neste contexto, não somente dados de imagens adquiridas por sensoriamento remoto podem ser fusionadas, mas também, dados auxiliares como informações sobre a topografia e dados de Sistema de Posicionamento Global (*Global Positioning System-GPS*). Em Vijayaraj et al. (2006) fusão de imagens é definido como a combinação de duas ou mais imagens que integra as informações contidas nas imagens iniciais, resultando em uma imagem composta. A imagem integrada deve conter mais informação se comparado com as imagens individuais. Pohl e Van Genderen (1998) concebem fusão de imagens de forma similar aos autores anteriores, como “a combinação de duas ou mais diferentes imagens para formar uma nova imagem usando determinado algoritmo”. Wald (1999) também afirma que a definição de fusão não pode se restringir apenas ao método, e concebe fusão de dados como “um quadro conceitual formal, o qual abrange os meios e as ferramentas que proporcionam a junção de dados originários de diferentes fontes, sendo que a fusão de dados visa à obtenção de informações e à melhora da qualidade dos dados”.

Alguns autores usam como sinônimos de fusão de dados e/ou imagens os termos “dados complementares” ou “integração de dados” (AMARSAIKHAN et al., 2007; LU et al., 2007; MCNAIRN et al., 2009). Porém, estes termos possuem significados amplos e podem abrir espaço para várias interpretações (WALD, 1999). Outros autores concebem a fusão de imagens de acordo com o nível de processamento em que são realizadas como mostrado na Figura 2.1. A fusão em nível de sinal significa que o processo de fusão foi realizado no menor nível, ou seja, com os sinais dos sensores, que são combinados para criar um novo sinal com uma maior relação sinal/ruído do que os sinais originais (DONG et al., 2009). A fusão da imagem em nível de *pixel* refere-se à fusão dos níveis de cinza dos alvos em análise. A fusão em nível de atributos requer a extração de características reconhecidas nas várias fontes de dados como, por exemplo, bordas, texturas, regiões e parâmetros. Posteriormente estes dados são fusionados em um ou mais mapas de características. Já na fusão em nível de decisão, as imagens são processadas individualmente e as feições extraídas são tabuladas e identificadas; na maioria das vezes, são fusionadas em uma única imagem o resultado de vários algoritmos de classificação, ou do mesmo algoritmo, porém aplicado em diferentes imagens (ZHANG, 2010). O critério de fusão pode se basear em regras de decisão como lógica *Fuzzy* ou critérios estatísticos.

Neste trabalho integração de dados ópticos e SAR se refere à combinação e a fusão dos mesmos. Considerar-se-á fusão de dados ou de imagens como qualquer método que integre duas ou mais imagens com o intuito de se formar uma nova imagem, a qual conterá informações das imagens originais. A combinação de imagens não forma uma nova imagem e, portanto não utiliza processos de fusões. Espera-se que os resultados das combinações e das imagens provenientes de fusões possuam mais informações que as imagens originais em separado.

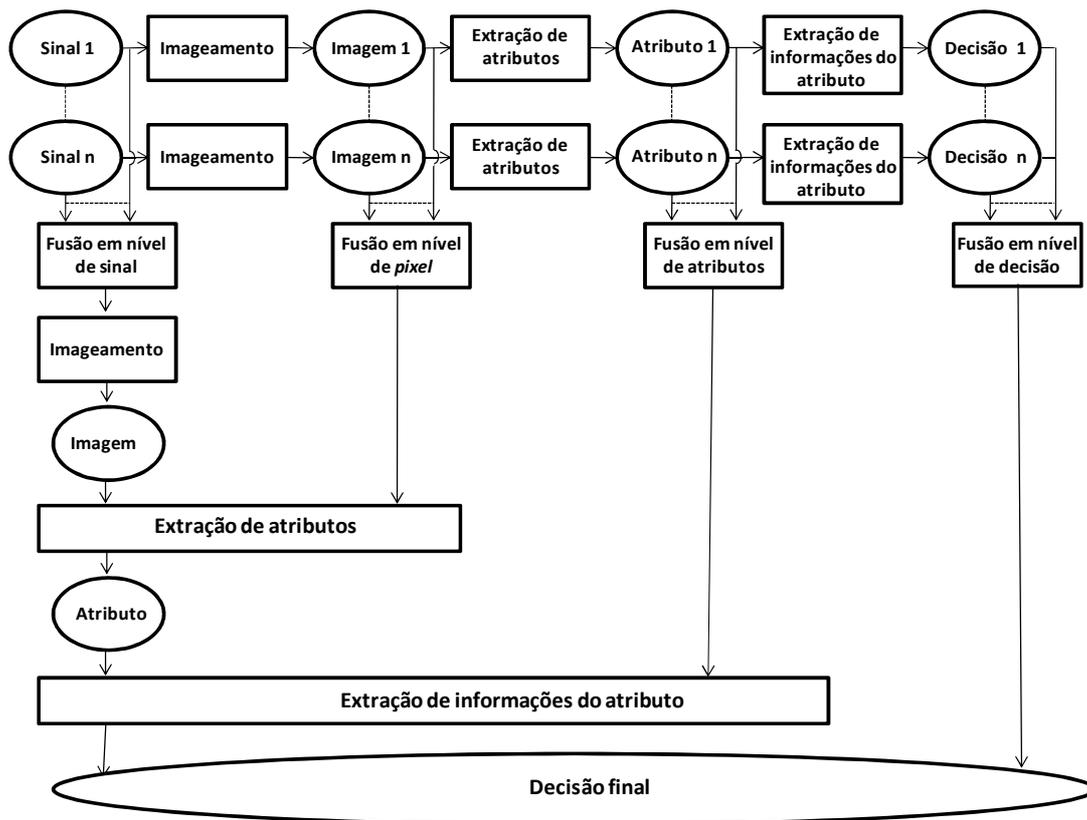


Figura 2.1. Níveis de fusão de imagens em sensoriamento remoto.

Fonte: Adaptado de Dong et al. (2009).

Nas seções que se seguem são abordados alguns aspectos importantes sobre integrações de imagens ópticas com SAR como pré-processamento das imagens originais e os métodos de fusões que serão abordados desta dissertação.

## 2.1. Pré-processamento

Para que as fusões e/ou combinações dos dados ópticos com SAR sejam processadas de forma satisfatória, deve-se definir previamente os objetivos do estudo, pois tanto a seleção como os pré-processamentos das imagens originais dependem dos objetivos do estudo (POHL; VAN GENDEREN, 1998). Pode-se exemplificar esta afirmação no que diz respeito à data de aquisição das imagens. Quando se deseja realizar fusões ou combinações com a finalidade de se realizar mapeamentos, classificações do uso e cobertura da terra e/ou para melhorar a visualização de feições, a proximidade das datas de aquisição das imagens SAR e ópticas é um quesito importante. Esta importância está relacionada aos níveis de cinza

das imagens que devem representar estruturas, geometrias e parâmetros biofísicos dos mesmos objetos.

Nos pré-processamentos dos dados ópticos devem-se considerar correções atmosféricas, geométricas, radiométricas, dentre outros. Entretanto, quando a fusão e a combinação são realizadas para fins de classificação é dispensável a correção atmosférica. Nos pré-processamentos dos dados SAR devem-se considerar as correções radiométricas e geométricas, sendo que este último processamento tem destaque neste cenário, pois cada sistema de aquisição de dados geográficos e/ou de imagens (SAR ou óptico) possui seus próprios erros e distorções geométricas. Se estes erros e distorções não forem corrigidos ou minimizados, os diferentes dados podem não ter correspondência espacial, e conseqüentemente os processamentos e as informações extraídas dos mesmos podem ser imprecisos e até mesmo inválidos (TOUTIN, 2004).

Para minimizar este tipo de problema é usual que nos métodos de fusão ou combinação, sejam utilizadas imagens que estejam corregradas em nível de *subpixel*. Para tanto, também é imprescindível a padronização das imagens ópticas e SAR no que diz respeito à projeção e ao sistema de coordenadas geográficas.

Outro processamento que normalmente é realizado é o ajuste de histograma das imagens de forma que apresentem os mesmos valores de média e desvio padrão. Este processamento evita maiores distorções espectrais nas imagens fusionadas e é dado por:

$$Im_{padronizada} = \left\{ \frac{\sigma_k}{\sigma_{Im}} (Im - \mu_{Im}) \right\} + \mu_k \quad (2.1)$$

onde  $\mu_k$  e  $\sigma_k$  são respectivamente, a média e o desvio padrão da imagem a ser substituída (no caso a imagem  $k$ );  $Im$  é a imagem que será padronizada para substituir a imagem  $k$ ;  $\mu_{Im}$  e  $\sigma_{Im}$  são respectivamente a média e o desvio padrão da imagem que substituirá a imagem  $k$ .

Nota-se que em todo processamento de fusão de imagens SAR e ópticas ocorre uma substituição de uma componente óptica, por uma componente SAR, ou informações da componente SAR são integradas às componentes ópticas. Especialmente no primeiro caso o ajuste dos histogramas das imagens é indispensável. Observe que o ajuste dos histogramas deve ser realizado após a redução do ruído *speckle*, proporcionando assim menor perda de informação da imagem SAR original (DONG et al., 2009).

Nas seções a seguir serão abordados alguns métodos de fusões, sendo que a maioria será abordada nesta dissertação.

## **2.2. Métodos de fusão de imagens ópticas com SAR**

Os métodos de fusão podem ser agrupados em três grandes classes. A primeira corresponde à composição em três bandas no espaço de cores RGB, bem como a Transformação de cores Intensidade, Matiz e Saturação (*Intensity, Hue e Saturation-IHS*). A segunda compreende abordagens numéricas e estatísticas. As abordagens estatísticas são desenvolvidas com base nos parâmetros e/ou atributos estatísticos das bandas das imagens, como por exemplo, a Análise por Componentes Principais (*Principal Component Analysis-PCA*). Já as abordagens numéricas estão relacionadas com as operações aritméticas entre as bandas das imagens (razão, subtração e adição); dentre elas a mais usada é a transformação de *Brovey* (TB) (POHL; VAN GENDEREN, 1998). A terceira corresponde aos métodos de fusões híbridos. São agrupados nesta classe os métodos que utilizam em seu processamento dois ou mais métodos de fusões para gerar uma nova imagem fusionada.

Dentre os vários métodos de fusão de imagens, os mais populares incluem a IHS, combinação aritmética entre bandas como a TB e os métodos estatísticos como a PCA. A composição de bandas em RGB não foi citada neste grupo, porque alguns autores não a consideram uma fusão de dados, e sim uma combinação de dados associados às cores para a sua melhor visualização (WALD, 1999). Dentre os métodos de fusão relativamente recentes destacam-se o de *Ehlers* e a Transformada *Wavelet* (TW), sendo

que este último método pode ser aplicado em conjunto com métodos tradicionais como a transformação IHS ou PCA (DONG et al., 2009). O método TW associado aos métodos IHS ou PCA constitui-se método híbrido de fusão, pois utilizam mais de um método de fusão para a formação de uma imagem fusionada. Baseado neste critério a fusão *Ehlers* também é um método de fusão híbrido.

### 2.2.1. Fator de Índice Ótimo (OIF)

O Fator de Índice Ótimo (*Optimum Index Factor-OIF*), embora citado por alguns autores como um método de fusão de imagens, não se enquadra na definição de fusão de dados utilizada neste trabalho. Este índice foi desenvolvido por Chávez et al. (1982), e tem por finalidade selecionar um determinado número de bandas que utilizadas em conjunto apresentem maior quantidade de informação. Se o objetivo for, por exemplo, a formação de uma composição colorida, o OIF é utilizado para selecionar a combinação ótima de 3 bandas, e neste caso é calculado por:

$$OIF = \frac{\sigma_i + \sigma_j + \sigma_k}{|\rho_{ij}| + |\rho_{ik}| + |\rho_{jk}|} \quad (2.2)$$

onde  $\sigma_\tau$  é o desvio padrão dos níveis de cinza da banda  $\tau$  (com  $\tau \in \{i, j, k\}$ ) e  $|\rho_{\alpha\beta}|$  é o módulo do coeficiente de correlação entre bandas  $\alpha$  e  $\beta$  (com  $\alpha \in \{i, j\}$  e  $\beta \in \{j, k\}$ ). Assim teoricamente, quanto maior o valor do OIF mais informação pode ser extraída do conjunto de bandas (CUNHA, 2002), uma vez que se busca o conjunto contendo o maior contraste entre elas. Isto é, busca-se o conjunto que possui as maiores variâncias e menores correlações entre as bandas envolvidas.

Feingersh et al. (2001) mostraram a aplicabilidade do OIF na classificação do uso e cobertura da terra em áreas de agricultura de trigo, cevada e outros cereais no norte ocidental da Alemanha. Estes autores avaliaram a combinação das imagens do *Satellite Pour l'Observation de la Terre* (SPOT-4) com a imagem do *European Remote Sensing*

(ERS-2) SAR. A composição das bandas selecionadas com o auxílio deste índice mostrou melhor acurácia global nas classificações do que as fusões pelas técnicas tradicionais.

### 2.2.2. Transformação de Brovey (TB)

Neste método de fusão normalizam-se as bandas multiespectrais (ópticas) para a exibição das mesmas em RGB e posteriormente multiplicam-se as bandas normalizadas por outra imagem, neste caso a imagem SAR, para adicionar a componente de rugosidade na imagem (Equação 2.3). A vantagem desta técnica é que as bordas entre as feições, por exemplo, transição entre solo e corpos d'água são bem definidas nas imagens fusionadas (POHL; VAN GENDEREN, 1998).

$$\begin{bmatrix} R_{new} \\ G_{new} \\ B_{new} \end{bmatrix} = \lambda \begin{bmatrix} R \\ G \\ B \end{bmatrix} \text{ com } \lambda = \frac{3SAR}{R + G + B} \quad (2.3)$$

### 2.2.3. Transformação de cores IHS

A transformação de cores IHS está relacionada aos parâmetros da percepção humana de cor e permite a fusão de apenas quatro tipos de bandas. Nesta transformada, “I” refere-se à intensidade ou o brilho da imagem, “H” representa matiz ou cor e “S” saturação ou a pureza da cor.

A fusão de dados ópticos com SAR se processa transformando três bandas ópticas, previamente selecionadas de acordo com o objetivo do estudo, do espaço de cores RGB para o espaço IHS. Neste espaço os aspectos de cor do brilho (intensidade) são separados. A intensidade que corresponde à rugosidade da superfície é substituída pela imagem de melhor resolução espacial (SOARES et al.,1996). No presente estudo a imagem SAR é usada como a imagem de melhor resolução espacial. A transformação inversa de IHS para RGB converte os dados para o espaço original da imagem. A técnica de fusão pela transformação IHS é representada na Figura 2.2.

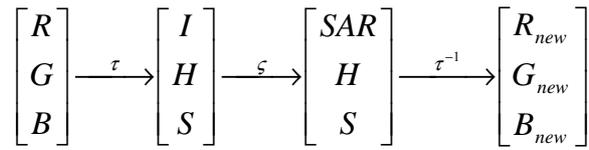


Figura 2.2. Técnica IHS de fusão de imagem óptica/SAR.

Na Figura 2.2  $\tau$  representa a transformação do espaço RGB para o IHS;  $\zeta$  é o processo de substituição da componente intensidade pela imagem SAR; e  $\tau^{-1}$  transformação inversa do espaço IHS para o espaço RGB.

Atualmente a fusão IHS é um dos métodos tradicionais de fusão que melhor separa os aspectos de cor ou espectral (H e S) da informação espacial, a intensidade (KLONUS; EHLERS, 2007). Alguns trabalhos como de Saroglu et al. (2004) reforçam esta afirmativa. Estes autores classificaram por Máxima Verossimilhança (MAXVER) a imagem óptica e as imagens fusionadas (ópticas com SAR) pelos métodos tradicionais de fusão IHS, PC, TB em uma área urbana. O objetivo de classificar estas imagens é de avaliar quantitativamente (através da matriz de confusão) a colaboração na discriminação das feições das imagens fusionadas. O resultado deste trabalho mostrou que a fusão IHS apresentou melhores resultados e maior capacidade discriminatória se comparado com os demais métodos de fusão ou com a imagem óptica original em separado. As transformações IHS podem ser processadas utilizando-se diferentes representações matemáticas. Estas representações diferem entre si do que diz respeito ao sistema de coordenadas de transformação entre o espaço RGB/IHS e vice-versa (GONZALEZ; WOODS, 2002).

#### 2.2.4. Análise por componentes principais (PCA)

O método de fusão por PC consiste em um procedimento estatístico que realiza transformação linear em um conjunto de dados multivariados com informações correlacionadas. A transformação linear consiste na rotação e na translação destes dados dentro de um novo sistema de referência, a fim de maximizar as variâncias dos dados originais (SHAMSHAD et al., 2004). Este processo resulta em um novo conjunto de

dados não correlacionados, no qual a primeira PC possui a maior porcentagem do total da variância e, por isso, contém a maior quantidade de informação das bandas envolvidas no processo (VEGA, 2005). A transformada inversa das PCs retorna os dados para o espaço de atributos original das imagens (DONG et al., 2009).

Este método foi criado inicialmente para auxiliar estudos e processamento de imagens com muitos dados, reduzindo a dimensionalidade dos mesmos, sendo também utilizado na seleção de variáveis. Posteriormente, foi aplicado na fusão de dados ópticos com SAR. A PC permite a integração dos dados SAR com ópticos através da substituição de uma das componentes principais geradas a partir dos dados ópticos pelos dados SAR. A Figura 2.4 exemplifica esta integração, onde  $B_1, \dots, B_n$  representam as  $n$  bandas ópticas,  $\tau$  representa a transformação por PC,  $\zeta$  é o processo de substituição de uma PC pela imagem SAR e  $\tau^{-1}$  é a transformação inversa da PC. Pode-se, também, aplicar a PC diretamente no conjunto formado pelas imagens SAR e ópticas. Nesta técnica os dados SAR influenciam significativamente na aparência das feições (CRÓSTA, 1992).

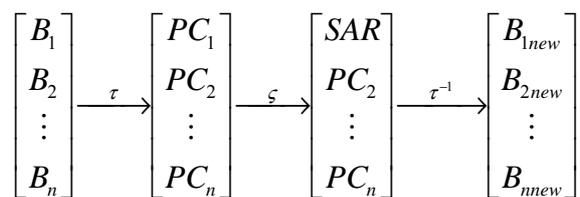


Figura 2.3. Técnica por PC de fusão de imagem óptica/SAR.

### 2.2.5. Análise por componentes principais seletivos (SPC-SAR)

Este método foi idealizado por Chavez Jr. et al. (1984 citado por PARADELLA et al., 2001) e adaptado por Paradella et al. (1999 citado por PARADELLA et al., 2001) para integrar as imagens SAR e ópticas. Seu processamento consiste em descorrelacionar as bandas ópticas que estão localizadas em faixas específicas do espectro eletromagnético. Para tanto, é aplicada a técnica PC nestas bandas, e como a primeira PC é a que contém a maior parte das informações descorrelacionada, estas são as bandas que serão compostas no espaço RGB. Esta composição é realizada da seguinte forma R(PC<sub>1</sub> das bandas 1,2 e 3) G (4) B (PC<sub>1</sub> das bandas 5 e 7). Posteriormente é aplicada nestes dados a transformação de cores IHS (GONÇALVES et al., 2009). A imagem SAR é então

introduzida na componente intensidade e assim processa-se a transformada IHS inversa. Para a exemplificação deste método, na Figura 2.3 é esquematizada uma fusão de uma imagem LANDSAT5/ *Thematic Mapper* (TM) e uma imagem SAR.

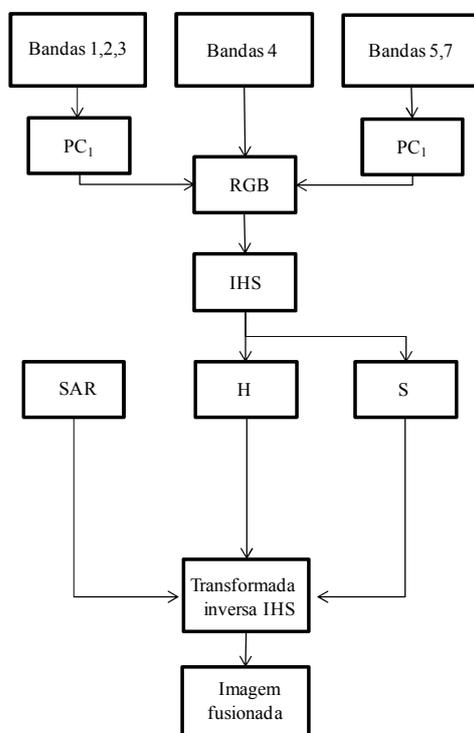


Figura 2.4. Método de fusão através da SPC-SAR.

### 2.2.6. Transformada *Wavelet* (TW)

A TW vem sendo usada no âmbito do sensoriamento remoto, principalmente na fusão de imagens. Esta técnica possibilita a extração de informações de detalhes de uma imagem e a integração desta informação em outras imagens. A informação de detalhe em uma imagem é representada pelos sinais de altas frequências. A TW apresenta similaridades com a transformada de *Fourier*, porém as posições e os valores dos coeficientes da TW estão diretamente relacionados com a posição e valores dos níveis de cinza da imagem (GONZALEZ; WOODS, 2002). A TW também possibilita a discriminação das diferentes frequências nas imagens, porque apresenta a capacidade de representar pequenas variações no sinal (LU et al., 2007). Assim, o processo de aplicação da TW pode ser representado como um banco de filtros, e cada vez que estes filtros são aplicados, a imagem é decomposta em um nível. Isto significa dizer que o

sinal da imagem é dividido em componentes de altas frequências e baixas frequências. Estas componentes são representadas visualmente por uma imagem de detalhes e outra mais homogênea (AMOLINS et al., 2007).

Existem vários algoritmos *Wavelets* e vários métodos de fusões que utilizam estes algoritmos. Entretanto, uma das formas mais usuais de realizar a fusão de imagens é decompor a imagem SAR (ou de melhor resolução espacial) até que a componente de baixa frequência tenha o espaçamento dos *pixels* igual ao da imagem de pior resolução espacial. Posteriormente substitui-se a componente de baixa frequência pela imagem de pior resolução espacial e assim se processa a Transformada *Wavelet* Inversa (TWI). O resultado é uma imagem óptica com as informações de detalhe da imagem SAR. Estes métodos de fusões de imagens TW(s) são denominadas decimadas ou multiresolução. A Figura 2.5 exemplifica este processo de fusão por TW sendo que AAr é a imagem *Wavelet* de alta frequência; ABr é a imagem *Wavelet* de alta frequência (linha) e baixa frequência (coluna); BAr é a imagem *Wavelet* de baixa frequência (linha) e alta frequência (coluna); BBr é a imagem *Wavelet* de baixa frequência; C/2 é a metade do número de colunas da imagem anterior; e L/2 é a metade do número de linhas da imagem anterior.

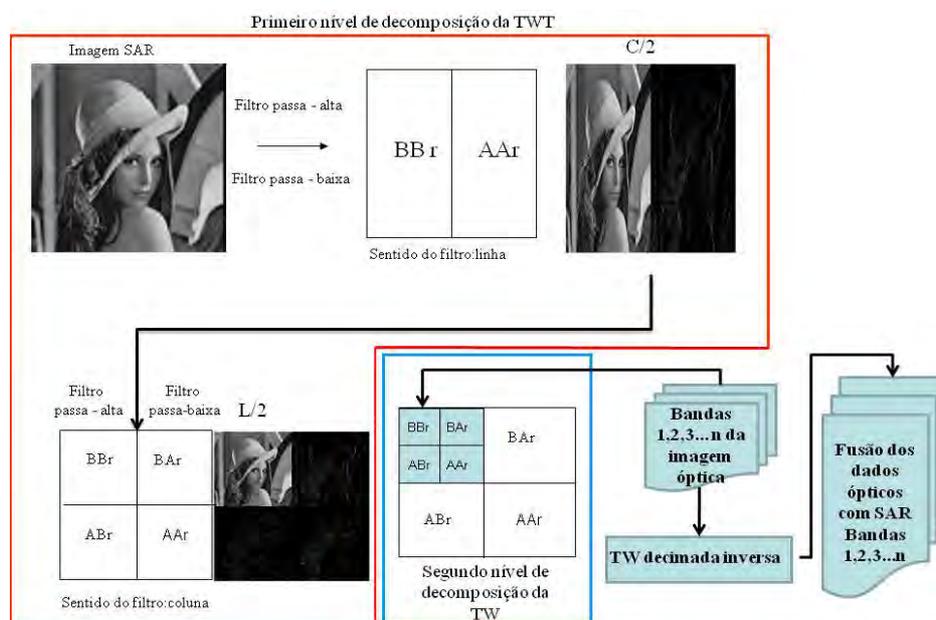


Figura 2.5. Método de fusão de imagens TW decimada.  
Fonte: Adaptado de Acharya e Tsai (2005).

Neste cenário cabe comentar que é bastante usual a utilização de métodos de fusões TW(s) que realizam apenas um nível de decomposição, o que resulta em uma imagem de alta frequência e outra de baixa frequência (AMOLINS et al., 2007). Estas TW(s) são denominadas não decimadas.

Apesar dos métodos de fusões que utilizam a TW(s) apresentarem algumas diferenças, em geral, estes métodos possuem a vantagem de propiciar menores distorções espectrais dos dados ópticos (CHEN; PETER HO, 2008). As limitações estão associadas à complexidade computacional e à possibilidade de perda do conteúdo espectral de feições de interesse, principalmente as representadas com pequenas dimensões nas imagens originais. Outro possível problema é a possibilidade de acréscimo de informações (detalhes) falso nos objetos, visto que ruídos são representados nas imagens de sensoriamento remoto como sinais de alta frequência (AMOLINS et al., 2007).

A TW “*à trous*” (WA) isotrópica é um método de fusão não decimado, e seu processamento pode ser entendido basicamente como a aplicação de um filtro passa-baixa o que resulta em uma imagem de baixa frequência. A imagem de alta frequência é obtida pelo resultado da diferença entre a imagem original e a imagem de baixa frequência. Outra característica desta TW é que o tamanho das imagens que correspondem às componentes de alta e baixa frequência não é alterado, ou seja, o número de linhas e colunas destas imagens permanece o mesmo da imagem original. Para a ilustração da maioria dos processos de fusão que serão descritos a seguir considerar-se-á a TWT não decimada. Esta TW está exemplificada na Figura 2.6.

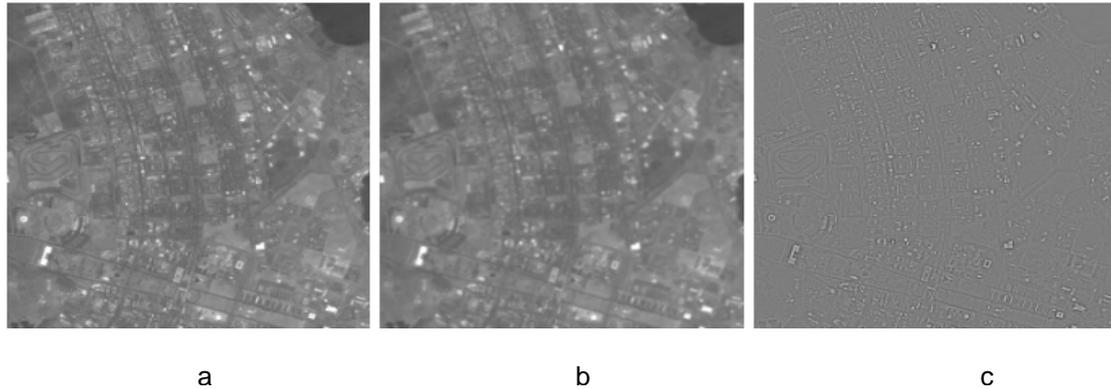


Figura 2.6. Decomposição da TWT não decimada isotrópico: a) imagem pancromática, b) imagem de baixa frequência, e c) imagem de alta frequência.

Fonte: Adaptado de Silva (2009).

No pré-processamento das imagens originais que serão fusionadas por métodos de fusões TW não decimados as resoluções espaciais da imagem de melhor resolução (e.g., SAR) e a de pior resolução (e.g., óptica) deve seguir a seguinte relação:

$$r' = r * 2^h \text{ sendo que } h \in N^* \quad (2.4)$$

onde  $r$  e  $r'$  são as resoluções espaciais da imagem de melhor e pior resolução, respectivamente .

Entretanto, nem sempre a resolução das imagens a serem fusionadas é compatível com a relação supracitada. Neste caso, basta fazer uma reamostragem dos *pixels* da imagem de entrada com pior resolução espacial para o dobro do espaçamento dos *pixels* da imagem de melhor resolução espacial (SILVA, 2009).

A TW pode ser combinada com os métodos tradicionais de fusão PC ou IHS. A principal vantagem de se utilizar estas técnicas em conjunto é que a imagem fusionada geralmente apresenta menores distorções espectrais se comparada com aquelas geradas através dos métodos tradicionais de fusão (AMOLINS et al., 2007). Estes métodos híbridos de fusão são descritos na próxima subseção.

## **2.2.7. Métodos Híbridos de fusão**

### **2.2.7.1. TW e IHS**

A fusão por transformação IHS resulta em distorções espectrais na imagem fusionada. Porém, quando se utiliza a TW não decimada, as distorções espectrais diminuem, pois a componente intensidade não é retirada do processo; pelo contrario, é nesta banda que são integradas as informações dos detalhes da imagem SAR (CHIBANI, 2006). Neste caso, também pode ser processada a TW decimada. Sendo assim, a imagem (no caso SAR) pode ser decomposta em vários níveis. Esta decomposição pode ser realizada até o nível de detalhamento desejado, ou até a imagem de baixa frequência atingir o espaçamento dos *pixels* compatível com o espaçamento de *pixels* da componente intensidade. O próximo passo é injetar a componente intensidade no lugar da imagem de baixa frequência, e assim processa-se TW decimada inversa. O resultado são as informações da componente intensidade e as informações de detalhes da imagem SAR integradas às 3 bandas multiespectrais envolvidas no processo (AMOLINS et al., 2007). A Figura 2.7 ilustra o método de fusão TW e IHS não decimado.

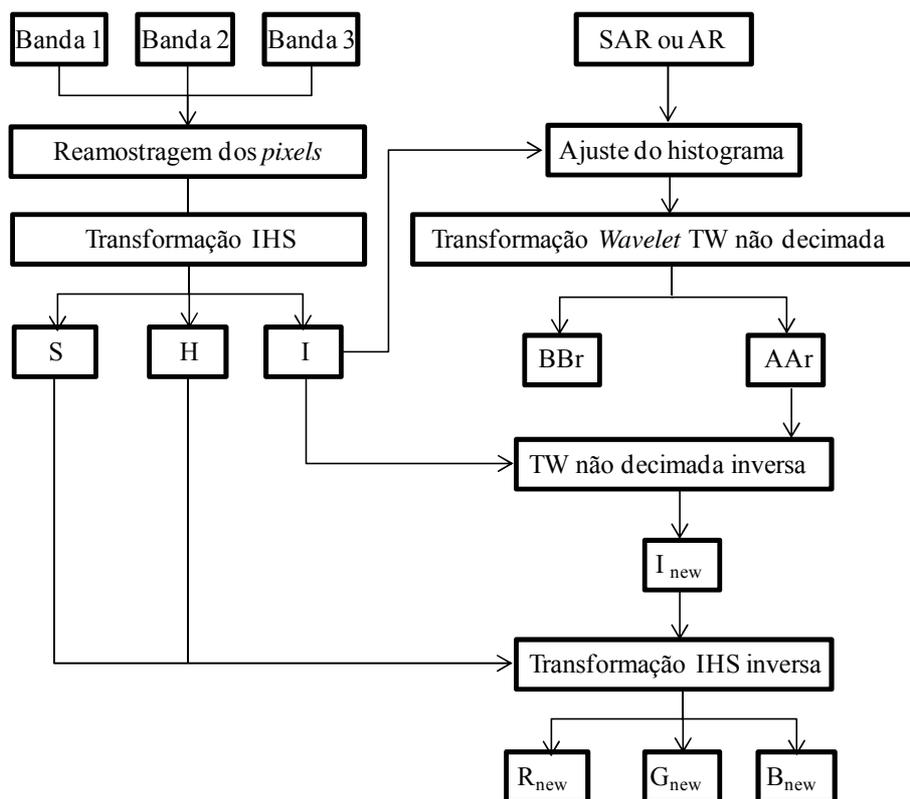


Figura 2.7. Método de fusão TW e IHS.  
 Fonte: Adaptado de Silva (2009).

Na Figura 2.7, AR é a imagem de melhor resolução ou SAR; BBr é a imagem *Wavelet* de baixa frequência; AAr é a imagem *Wavelet* de alta frequência; e  $R_{new}$   $G_{new}$   $B_{new}$  representam três novas bandas fusionadas que irão compor uma imagem no espaço RGB a qual irá conter informações de detalhes da imagem SAR ou AR.

### 2.2.8. TW e PCA

A fusão utilizando a TW e PCA é efetuada de uma maneira análoga à fusão com TW e IHS. A Figura 2.8 exemplifica este método de fusão.

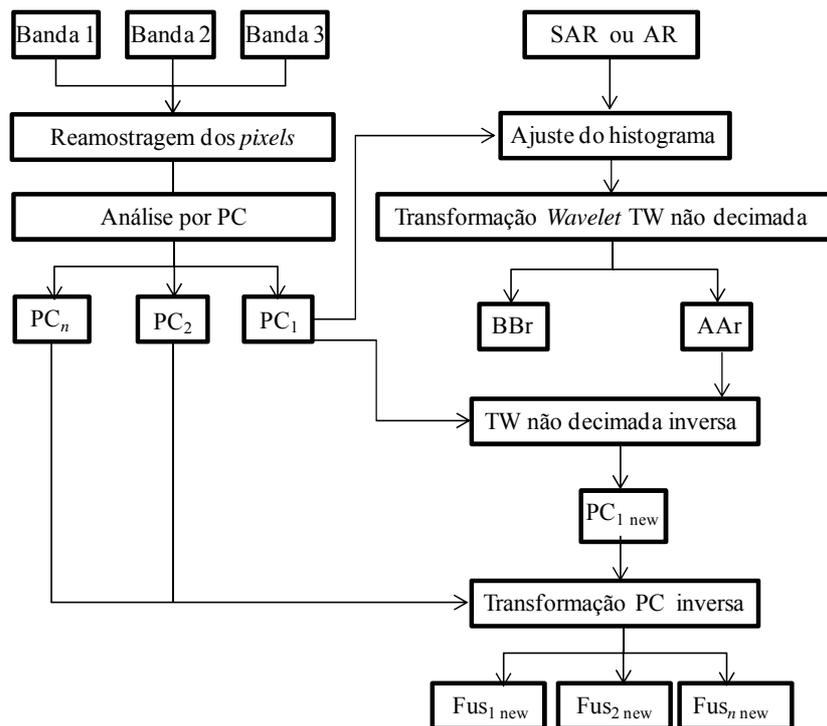


Figura 2.8. Método de fusão TW e PCA.  
 Fonte: Adaptado de Silva (2009).

Na Figura 2.8, AR é a imagem de melhor resolução ou SAR; BBr é a imagem *Wavelet* de baixa frequência; AAr é a imagem *Wavelet* de alta frequência; e  $Fus_{1new}$   $Fus_{2new}$   $Fus_{nnew}$  representam o novo conjunto de bandas no que comporão uma imagem com informações de detalhes da imagem AR.

Nota-se que o resultado da TW é uma nova PC ( $PC_{1new}$ ) com informações de detalhes da imagem SAR. Esta imagem é que, juntamente com as outras PC(s), participará do próximo processo de transformação inversa da PC.

Lu et al. (2007) aplicaram em seu trabalho a TW e PCA para integrar as informações espaciais e espectrais das bandas pancromática ou Radarsat (banda C, polarização HH) às bandas multiespectrais (1, 2, 3, 4, 5 e 7) do LANDSAT/7 *Enhanced Thematic Mapper Plus* (ETM+). Para tanto foi processada a PC da imagem LANDSAT/7 ETM+. Na primeira componente foram integradas as informações de detalhes da imagem Radarsat e pancromática. Posteriormente foi realizada a TW inversa o que resultou em duas

imagens fusionadas, sendo que uma delas tinham informações de detalhes das imagem Radarsat e a outra da imagem pancromática. Este trabalho concluiu que as imagens LANDSAT/7 ETM+ fusionadas, tanto com os dados SAR quanto com a imagem pancromática, não melhorou de forma significativa a acurácia da classificação. Neste cenário tem destaque as combinações da imagem óptica com as medidas de texturas extraídas da imagem SAR, pois estas classificações resultaram em valores dos índices *kappas* superiores ao da classificação da imagem óptica em questão.

### **2.2.9. Método de fusão Ehlers**

A motivação para o desenvolvimento deste método de fusão está atrelada à dificuldade de se encontrar métodos de fusões que apresentem bons resultados quando são fusionadas imagens de diferentes sensores (e.g., ópticos e SAR). Segundo seus idealizadores Klonus e Ehlers, (2009), este método tem mostrado bons resultados por preservar as informações espectrais das bandas multiespectrais, ao mesmo tempo em que introduz informações espaciais minimizando a introdução de ruídos nas imagens fusionadas (e.g., detalhes falsos). Entretanto, apresenta como desvantagem o alto custo computacional (KLONUS; EHLERS, 2009).

Este método de fusão utiliza a transformação IHS em conjunto com filtros adaptativos no domínio de *Fourier*. Embora os métodos tradicionais de fusões IHS implementados em aplicativos livres e comerciais possuam a limitação de permitir a fusão de apenas 4 bandas, o método de fusão *Ehlers* foi modificado para realizar fusões com mais de 4 bandas usando múltiplas transformações IHS. Esta transformação foi selecionada para compor este método porque segundo Klonus e Ehlers, (2007) é a que melhor separa os aspectos da cor (espectrais) dos aspectos espaciais. Já a transformada de *Fourier* foi selecionada por permitir a manipulação eficiente da componente intensidade e da imagem com melhor resolução espacial. Esta manipulação é realizada através da aplicação de filtros adaptativos no domínio da frequência. Este método híbrido de fusão está ilustrado na Figura 2.9, onde TF é a transformada de *Fourier*, FPA e FPB representam, respectivamente, filtro passa-alta e o filtro passa-baixa,  $I_{new}$  é a

componente intensidade com informações de detalhes e  $TF^{-1}$  e  $IHS^{-1}$  são respectivamente, as transformações inversas de *Fourier* e *IHS*.

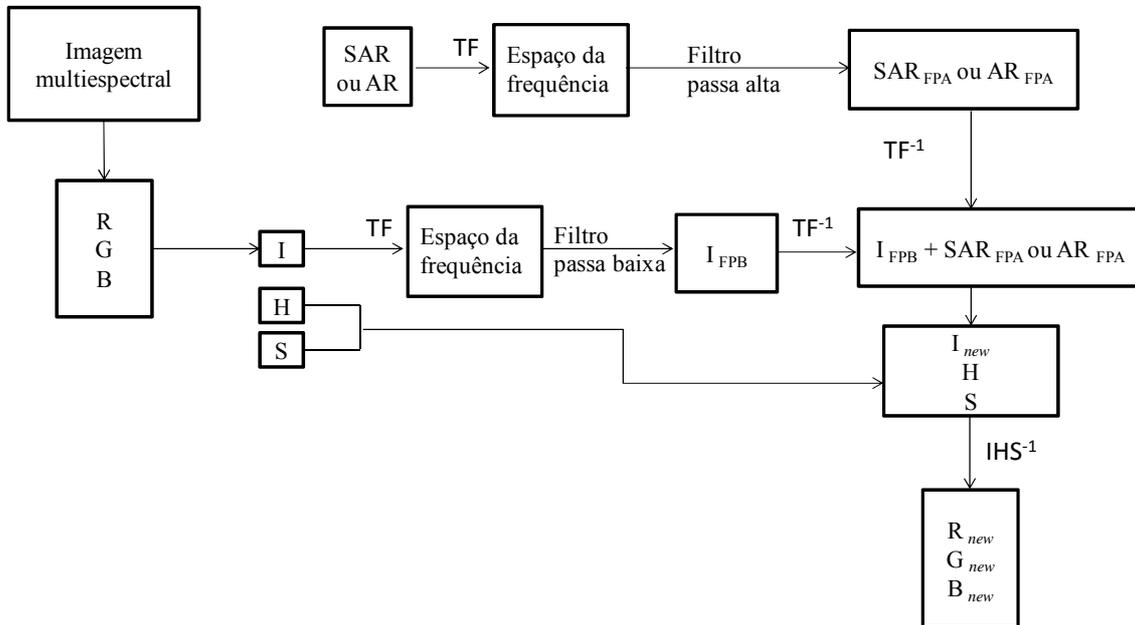


Figura 2.9. Exemplo de fusão *Ehlers* com 3 bandas multiespectrais e 1 imagem de melhor resolução (AR).

Fonte: Adaptado de Klonus e Ehlers, (2007).

Nota-se que de se iniciar o processo de fusão a imagem AR ou SAR deve ser normalizada em relação a componente intensidade. Como pode ser observada, após a transformação IHS (única ou múltipla), a componente intensidade e a imagem de melhor resolução espacial ou SAR são passadas para o espaço da frequência (TF). Na imagem intensidade é aplicado um filtro passa-baixa, e na imagem de melhor resolução é aplicado um filtro passa-alta. As características destes filtros, como o tamanho da janela de vizinhança e o limiar da frequência que os definem, são determinadas de acordo com as características da área (e.g., urbano, rural e outros). Após as filtragens as imagens retornam para o espaço original através da transformação inversa de *Fourier* ( $FT^{-1}$ ) e são adicionadas formando uma nova imagem intensidade de tal forma que a imagem de baixa frequência da componente intensidade estará fusionada com a imagem de alta frequência da imagem de melhor resolução ou SAR. Esta componente intensidade com informações de detalhes é

adicionada às demais componentes H e S originais formando um novo conjunto IHS, o qual é transformado para o espaço RGB.

### **2.3. Tendências dos métodos de fusão de dados ópticos com SAR**

Uma propriedade indesejável nas aplicações dos métodos de fusão em nível de sinal e *subpixel* é que tanto as características espectrais das imagens ópticas e/ou informação de retroespalhamento dos dados SAR podem ser degradados. Portanto, é necessário desenvolver técnicas e/ou métodos de fusão, concebidos especificamente para dados SAR/ópticos, que possuam a capacidade de integrar plenamente esses dois tipos de imagens (ZHANG, 2010).

Assim, a tendência dos métodos e técnicas de fusão de dados ópticos com SAR é a utilização da fusão em nível de atributos ou de decisão, ou seja, fusão em alto nível. Nestes níveis os dados de textura e estrutura das imagens SAR e os conteúdos espectrais das imagens ópticas são preservados. Sendo assim, pode-se inferir que esta abordagem é interessante para classificação do uso e ocupação da terra na Amazônia (ZHANG, 2010).

Nesta dissertação serão classificados e avaliados combinações e métodos de fusões de imagens SAR e óptica de uma área de interesse na Amazônia brasileira. Esta área bem como as imagens ópticas e SAR que serão utilizadas para se processar as combinações e as fusões são descritas na próxima seção.



### 3. ÁREA DE ESTUDO E IMAGENS UTILIZADAS

#### 3.1. Área de estudo

A área de estudo está localizada na Amazônia brasileira e abrange parte do município de Belterra, no estado do Pará, mesorregião do Baixo Amazonas, entre as coordenadas  $3^{\circ}22'37''\text{S}$  e  $55^{\circ}03'15''\text{W}$ ;  $2^{\circ}51'44''\text{S}$  e  $54^{\circ}49'01''\text{W}$ , com aproximadamente  $1.117 \text{ km}^2$  esta área é ilustrada na Figura 3.1, juntamente com uma imagem óptica do sensor TM na composição colorida R(5)G(4)B(3). A área é caracterizada por um clima quente e úmido e predominância de floresta tropical úmida. Quanto à geomorfologia a área é considerada plana e tem uma altitude média de 138 m.

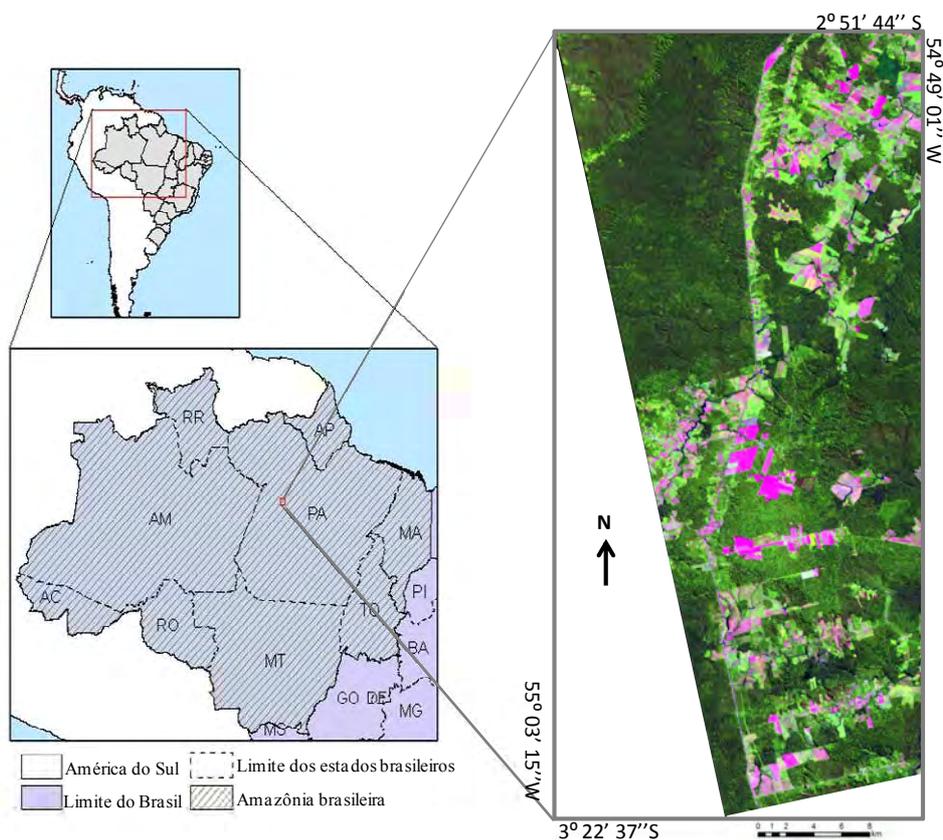


Figura 3.1. Localização da área de estudo. Composição colorida da imagem LANDSAT5/TM R5G4B3.

A ocupação desta área teve início por volta de 1970 quando o governo iniciou uma política de incentivo a ocupação da Amazônia brasileira. Para tanto, o governo financiou a construção da rodovia BR-163(Cuiabá-Santarém), o que intensificou a ocupação da área. Esta rodovia pode ser visualizada ao longo da imagem LANDSAT5/TM da Figura 3.1. Associado a este investimento também foi intensificado o desmatamento e as atividades articuladas a este processo, tais como a extração de madeira, abertura de áreas agrícolas e de pastagens. Os dados do Programa de Cálculo do Desflorestamento da Amazônia (PRODES, 2011), mostram que até 2009 cerca de 34% da área de estudo tinha sido desflorestada.

Atualmente, a área apresenta uma grande diversidade quanto ao uso e ocupação da terra sendo possível observar atividades como a pecuária extensiva e cultivo de grãos (soja, arroz, milho, sorgo e feijão). O calendário agrícola começa em dezembro, no início da estação chuvosa, com uma ou duas atividades de plantio durante o ano, sendo as colheitas realizadas, respectivamente, nos meses de março/abril e de julho/agosto (ESCADA et al., 2009). No contexto político a área está incluída em um dos pólos de expansão do plantio comercial da soja, sendo que este processo é incentivado pelo governo do estado do Pará. No contexto social, nota-se o aumento de evidências que mostram importantes mudanças na estrutura e desempenho da economia, bem como na renda e modo de vida da população local desta região. Muitas destas alterações estão associadas à introdução de novas tecnologias e métodos de culturas no campo, cujos efeitos afetam o meio ambiente e conseqüentemente o uso e ocupação da terra via desmatamento, erosão, poluição hídrica, entre outros (Instituto Brasileiro de Geografia e Estatística-IBGE, 2011). Devido a esta dinâmica política, social e espacial torna-se importante que estudos sobre o mapeamento do uso e cobertura da terra sejam realizados, tema deste trabalho de pesquisa.

### **3.2. Imagens utilizadas**

Para a elaboração desta dissertação foram utilizados dados de radar do satélite *Advanced Land Observing System* (ALOS) mais especificamente do sensor *Phase Array L-Band*

*Synthetic Aperture Radar* (PALSAR) e de dados ópticos do satélite LANDSAT5 do sensor *Thematic Mapper* (TM). O satélite ALOS foi lançado em 24 de janeiro de 2006 pela *Japan Aerospace Exploration Agency* (JAXA), levando a bordo três sensores dentre eles o PALSAR que opera na banda L. Através do sensor PALSAR pode-se obter imagens nos modos FBS (*Fine-Beam Single*) polarização (HH ou VV), FBD (*Fine-Beam Dual*) com polarizações (HH, HV ou VV, VH), ou polarimétrico (HH, HV, VH, VV) (ROSENQVIST et al., 2004). A imagem SAR que será utilizada neste trabalho é a ALOS/PALSAR FBD 1.5 (bandas HH e HV) adquirida no dia 21/06/2010, com nível de correção 1.5 no formato *Geocoded*. Na Figura 3.2 é mostrada a imagem do ALOS/PALSAR na composição colorida R(HH), G(HV), B(HH). As principais características desta imagem estão resumidas na Tabela 3.1.

Tabela 3.1. Principais características da imagem ALOS/PALSAR FBD 1.5.

Características	Imagem ALOS/PALSAR FBD 1.5
Data de aquisição	21/06/2010
Comprimento de onda	(aprox. 23 cm) Band L
Modo de operação	<i>Fine Beam Dual</i> (FBD)
Polarizações	HH/HV
Ângulo de incidência	34,3°
Espaçamento entre os <i>pixels</i>	12,5 m x 12,5 m
Resolução	19 m em range x 10 m em azimute
Número de visadas	4
Faixa imageada	70 km
Número de linhas e colunas	4560 x 2112
Resolução radiométrica	16 bits
Nível de correção	1.5 <i>Geocoded</i>
Órbita	Ascendente

Fonte: JAXA, (2008); ESA, (2007).

A imagem óptica multiespectral utilizada neste trabalho foi a LANDSAT5/TM bandas 1(B1), 2(B2), 3(B3), 4(B4), 5(B5) e 7(B7), adquirida em 29/06/2010, também ilustrado na Figura 3.2 na composição R(5)G(4)B(3). As principais características desta imagem são apresentadas na Tabela 3.2.

Tabela 3.2. Principais características da imagem LANDSAT5/TM.

Características	Imagem LANDSAT5/TM
Resolução espacial	30 m
Resolução radiométrica	8 bits
Resolução espectral	7 bandas: 3 no visível, 1 no NIR, 2 no SWIR e 1 no TIR
Resolução temporal	16 dias
Faixa imageada	185 km

Fonte: Jensen, (2009).

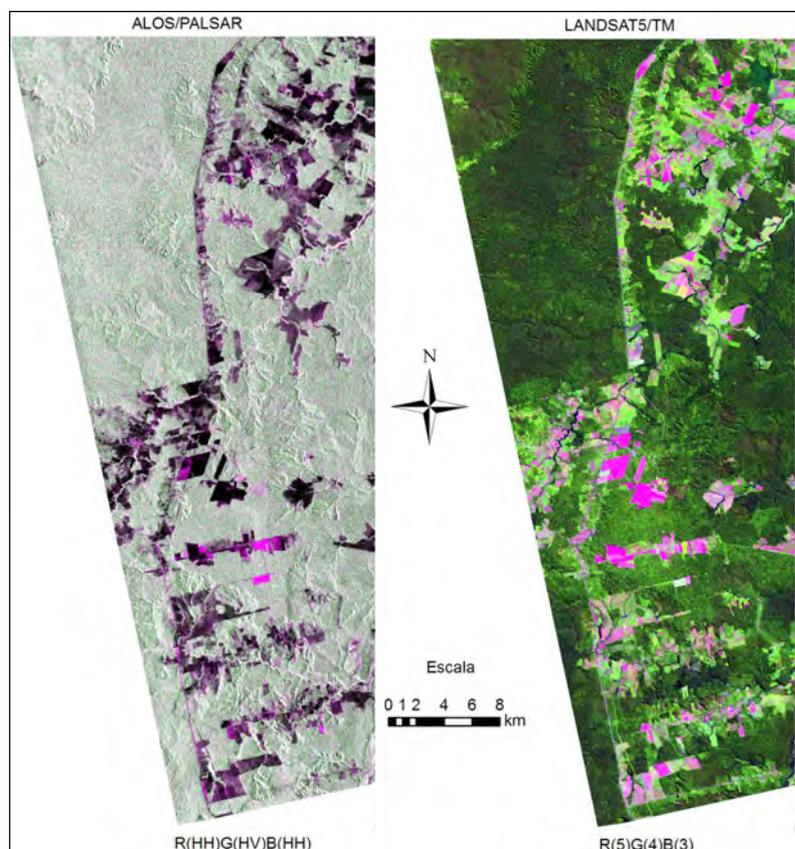


Figura 3.2. Imagens SAR e óptica utilizada nesta dissertação.

#### 4. METODOLOGIA

O objetivo da dissertação é estudar e avaliar as diferentes formas de integração de dados ópticos e de radar ou micro-ondas para o mapeamento do uso e cobertura da terra em uma região na Amazônia. Para atingir este objetivo foram realizadas as seguintes etapas: 1) Avaliação planimétrica da imagem ALOS/PALSAR *Geocoded*; 2) Remoção das tendências identificadas na imagem; 3) Aplicação dos pré-processamentos necessários nas imagens SAR e óptica; 4) Definição do classificador a ser aplicado nas imagens originais, combinadas e fusionadas; 5) Definição das classes e de suas respectivas amostras de treinamento e teste; 6) Processamento e extração de atributos de ambas as imagens originais; 7) Seleção e análise dos subconjuntos ótimos de atributos (SAR e ópticos); 8) Análise de separabilidade das classes de interesse, agrupamento e seleção das amostras de treinamento e teste; 9) Definição dos métodos de fusão, bem como das imagens que foram classificadas e 10) Avaliação das imagens classificadas. A Figura 4.1 mostra o fluxograma metodológico, a qual é descrito, mais detalhadamente nas próximas seções.

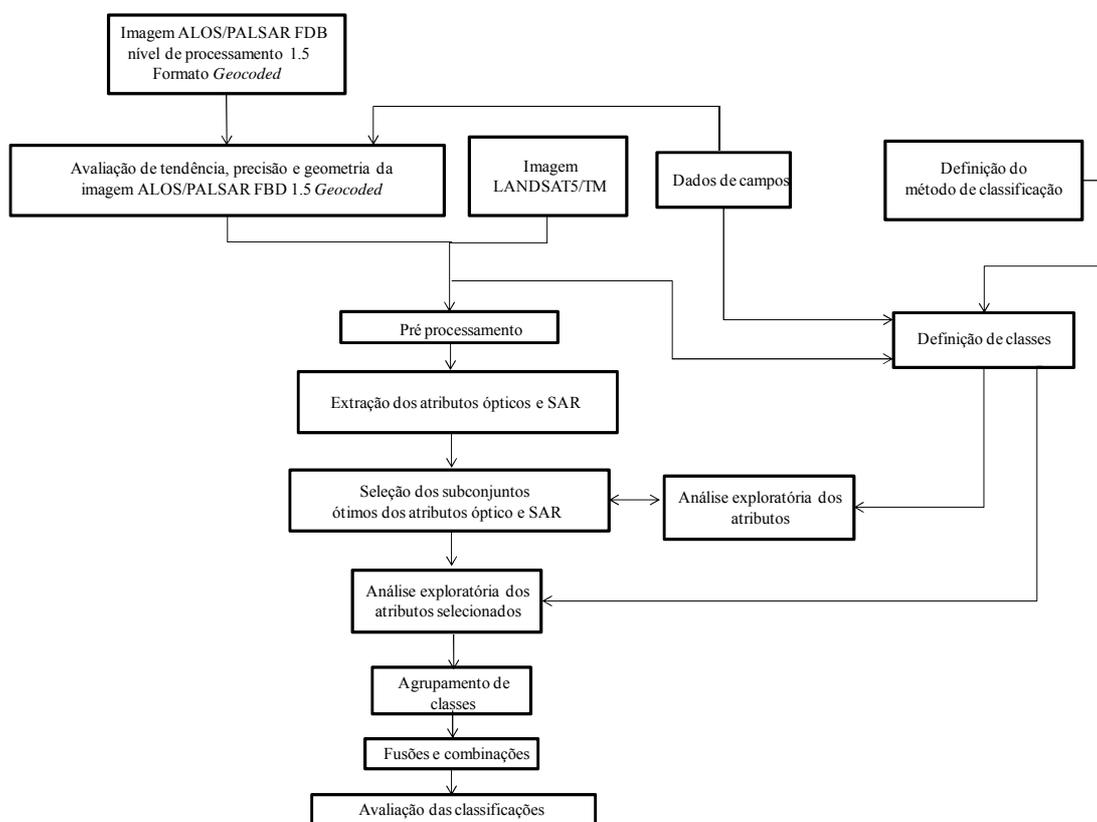


Figura 4.1. Fluxograma metodológico.

#### **4.1. Avaliação planimétrica da imagem ALOS/PALSAR FBD 1.5 *Geocoded***

Para o desenvolvimento deste trabalho foi necessária a avaliação planimétrica da imagem ALOS/PALSAR FBD 1.5 *geocoded* para verificar se a mesma enquadra-se no padrão de exatidão cartográfica classe “A” para a escala de mapeamento 1:100.000. Foi definida esta escala como limiar, pois caso a imagem apresentasse um erro planimétrico superior à da referida escala (30 m) as anotações realizadas em campo com GPS de navegação, que possui um erro planimétrico de aproximadamente 15 m, poderiam não ser correspondentes às feições identificadas nas imagens LANDSAT5/TM e ALOS/PALSAR. Assim, a precisão planimétrica das amostras de treinamento do classificador e a validação das classificações ficariam comprometidas. Nota-se que nenhuma feição de interesse possuía a área menor do que 4 *pixels* da imagem ALOS/PALSAR. Para as avaliações e comparações dos dados planimétricos foram realizadas análises estatísticas baseadas em testes de hipóteses para verificar a existência de tendências planimétricas significativas neste produto e suas precisões (OLIVEIRA, 2011).

#### **4.2. Pré – processamento**

As imagens SAR e ópticas foram padronizadas quanto à projeção e quanto ao sistema de coordenadas geográficas, e foram geometricamente registradas entre si em nível de *subpixel*. Como mencionado no capítulo 2 esses são os principais processamentos necessários para a realização das combinações e fusões.

##### **4.2.1. Influência da precipitação e umidade no retroespalhamento das bandas da imagem ALOS/PALSAR**

Um importante aspecto a ser considerado antes de se iniciar os processos de fusões, combinações e classificações diz respeito à quantidade de precipitação nos dias anteriores à aquisição da imagem SAR, pois a quantidade de umidade influencia na constante dielétrica dos alvos, e por consequência no retroespalhamento dos mesmos.

Solos úmidos apresentam maior retroespalhamento do que solos secos nas mesmas condições de imageamento, pois as ondas emitidas pelo sensor SAR irão penetrar menos no solo, produzindo assim maior sinal de retorno para o sensor. Espera-se que áreas agrícolas com plantações saudáveis e/ou dosséis de florestas densas, como as florestas tropicais, apresentem alto conteúdo de umidade. Sendo assim, também é de se esperar que esses alvos produzam um sinal forte de retorno para os sensores SAR (HENDERSON; LEWIS, 1998). Portanto, a quantidade de umidade nas copas das árvores e no solo pode ter um impacto significativo nestas imagens.

O trabalho de Lucas et al. (2010) discute a influência da umidade na imagem ALOS/PALSAR em um ambiente de floresta densa. Estes autores mostraram que quando a imagem é adquirida durante períodos relativamente úmidos, os valores de retroespalhamento dos sinais das bandas HH e HV aumentavam significativamente, principalmente em áreas não florestadas ou com baixa biomassa. Ainda, segundo estes autores, ficou evidente a maior sensibilidade da banda HH à presença de umidade, sendo que esta sensibilidade pode ser atribuída à intensificação dos mecanismos de retroespalhamento resultante das interações entre os troncos e os solos úmidos (*double bounce*).

Outro fator que torna o sinal emitido pelo sensor mais sensível ao teor de umidade nos alvos é o ângulo de incidência. Em geral quanto menor o ângulo de incidência, mais sensível o sinal SAR será ao conteúdo de umidade dos alvos (MIKHAIL et al., 2001).

Baseado no exposto, foi verificado junto à Agência Nacional de Águas a possível ocorrência de chuva nas datas próximas à aquisição da imagem ALOS/PALSAR (ANA, 2011). A Figura 4.2 mostra os dados de duas estações pluviométricas, a Estação 1 (Santarém) e a Estação 2 (Mutum), sendo que a estação 2 é a mais próxima da área de estudo. Pode-se observar pelos dados desta estação que houve precipitação abundante nos dois dias que antecederam a aquisição da imagem ALOS/PALSAR.

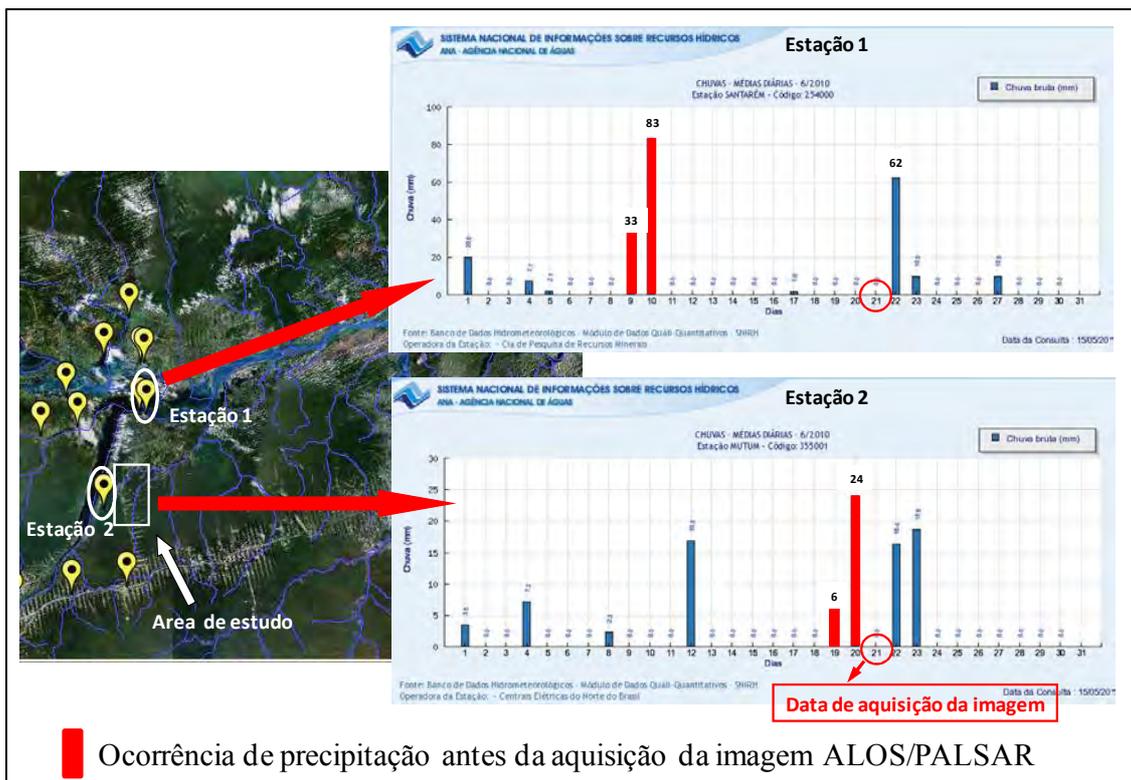


Figura 4.2. Precipitação diária.

Sendo assim, conclui-se que possivelmente os mecanismos de retroespalhamento dos alvos da cena foram influenciados pela umidade, aumentando o sinal de retorno para o sensor. Conseqüentemente, espera-se que a imagem SAR em questão também tenha sido influenciada pela umidade, tanto em sua aparência, quanto nas informações contidas em suas bandas. Portanto, os resultados encontrados e discutidos neste trabalho devem ser vistos à luz desta informação.

#### 4.2.2. Redução do ruído *speckle*

Um importante processamento na imagem SAR é a redução do ruído *speckle* (POHL; VAN GENDEREN, 1998). O ruído *speckle* é inerente às imagens SAR, e ocorre devido à natureza coerente das micro-ondas e é causado pelas interferências aleatórias construtivas e destrutivas no sinal; acarretando a formação também aleatória de áreas claras e escuras na imagem (JENSEN, 2009; MCNAIRN et al., 2009). Este efeito dificulta a interpretação das imagens SAR e os processamentos digitais, tais como

classificações e segmentações (MANSOURPOUR et al., 2006). Sendo assim, é importante reduzir a influência deste ruído na imagem fusionada, e uma das maneiras é através da aplicação de filtros que proporcionem a redução deste ruído na imagem SAR antes que se inicie o processo de fusão. Entretanto, cabe ressaltar que a redução do ruído culmina em perda de resolução espacial (HENDERSON; LEWIS, 1998).

Neste trabalho foi utilizado o filtro *Gama*, que é adaptativo e se baseia em um modelo de ruído multiplicativo considerando a distribuição *Gama* para o ruído *speckle*. Este filtro foi selecionado por preservar bem as informações radiométricas e principalmente informações de borda. Além disto, alguns trabalhos mostraram que áreas com vegetação são melhores modeladas quando se supõe a distribuição *Gama* para o ruído *speckle* (MANSOURPOUR et al., 2006). O Número Equivalente de Visada (*Equivalent Number of Looks-ENL*) é um dos parâmetros de entrada do filtro *Gama*. Para estimar o valor do ENL foram selecionadas 15 regiões em cada banda (HH e HV) que são consideradas homogêneas do ponto de vista estatístico. Isto significa dizer que nas imagens SAR em intensidade e amplitude as regiões amostrais devem apresentar distribuição dos níveis de cinza, respectivamente, *Gama* e Raiz da *Gama*. A Figura 4.3 mostra um exemplo de região homogênea do ponto de vista estatístico em uma imagem em amplitude. Posteriormente, foi estimado, para cada amostra o ENL através do método descrito em Frery et al. (2007), ao qual é também denominado de *Fractional Moment Estimate* por Anfinsen et al. (2009). O ENL de toda a imagem foi estimado pela média dos ENL das amostras.

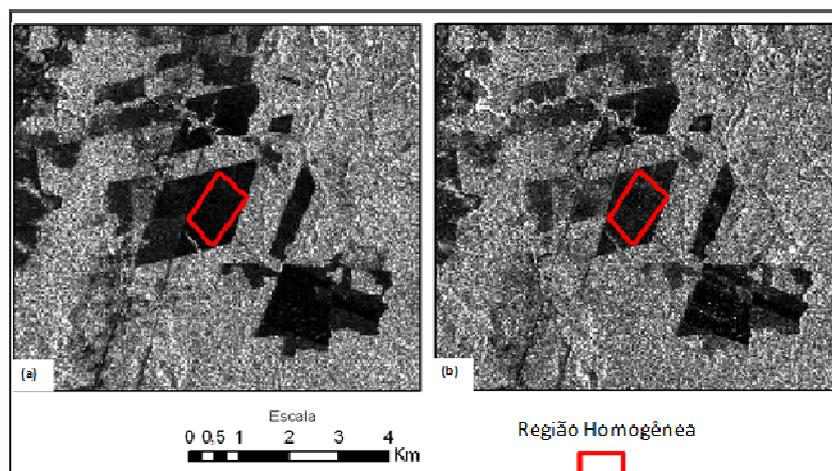


Figura 4.3. Exemplo de Região homogênea na imagem ALOS/PALSAR:(a) HV e (b) HH.

Para a seleção do tamanho das janelas de vizinhança das bandas HH e HV, o filtro *Gama* foi aplicado variando o tamanho da janela de 3 a 31, sendo que o tamanho das janelas são números ímpares. Então, para cada banda da imagem ALOS/PALSAR foram geradas 15 bandas filtradas totalizando assim 30 bandas. Para auxiliar na seleção da imagem filtrada foi calculada a Relação Sinal Ruído (*Signal to Noise Ratio-SNR*)

Para áreas homogêneas de imagens em intensidade a SNR é igual a  $ENL^{0,5}$  e para imagens em amplitude é igual a  $1,91*ENL^{0,5}$ . Sendo assim, para cada banda em amplitude filtrada foi calculado o ENL médio, das mesmas 15 regiões mencionadas anteriormente. Neste contexto, espera-se que imagem filtrada selecionada apresente poucas alterações nas características estatísticas e espaciais da imagem original. Para tanto, o critério de seleção foi baseado na relação custo/benefício, ou seja, foi selecionada a imagem filtrada que apresentou uma boa relação/ruído com o menor valor da janela de vizinhança.

### **4.3. Método de classificação**

O classificador que foi selecionado para classificar as imagens originais, fusionadas ou combinadas foi o MAXVER/ICM implementado no aplicativo Classificador Polarimétrico-7 (CORREIA, 1998; FRERY et al., 2007). Este classificador é supervisionado, pontual e contextual, e o processo de classificação inicia-se pela classificação de máxima verossimilhança (MAXVER), que consiste na extração de um vetor de atributos e no cálculo da probabilidade de um *pixel* pertencer a cada uma das classes definidas na fase de treinamento. Em seguida, associam-se os *pixels* da imagem à classe que apresentar maior verossimilhança (RICHARDS; JIA, 2006). Posteriormente é associada à classificação MAXVER a informação contextual dos *pixels* através do classificador ICM (*Iterated Conditional Modes*). Assim, se ocorrer muitos *pixels* de uma mesma classe no contexto espacial de um único *pixel* que pertence uma classe diferente, este *pixel* poderá ser reclassificado para a classe que predominou em seu contexto espacial (CORREIA, 1998).

Uma das razões que levou a escolha deste classificador é que vários trabalhos, dentre eles Michelson et al. (2000); Musa e Hussin (2000); Saroglu et al. (2004); Vega (2005);

Farah et al. (2008); Collet et al. (2009); Soria-Ruiz et al. (2010); Lu et al. (2011); utilizam o classificador MAXVER para verificar se as classificações das imagens fusionadas resultam na melhora da capacidade discriminatória das classes.

Sabe-se que no geral, os classificadores pontuais como o MAXVER não levam em consideração o contexto espacial do *pixel*, já o MAXVER/ICM sim, portanto este último classificador foi utilizado. Cabe ressaltar que o algoritmo MAXVER/ICM utilizado neste trabalho é baseado na distribuição gaussiana dos *pixels*. Neste caso, pode-se se ter alguns problemas com a eficiência do classificador uma vez que a distribuição dos dados SAR em geral não obedece a esta distribuição. O motivo para a escolha deste classificador é que ele possui baixo custo computacional (MCNAIRN et al., 2009).

#### **4.4. Seleção das amostras das classes de interesses**

Como o classificador utilizado neste trabalho foi o supervisionado MAXVER/ICM, torna-se necessária a seleção de amostras para o treinamento do classificador e de validação das classificações. Para tanto, inicialmente foram definidas as classes de interesses e coletadas as amostras das mesmas. As classes de interesse deste trabalho foram selecionadas de forma a permitir a classificação mais acurada do uso e cobertura da terra desta região, e por consequência, melhorar o monitoramento e o entendimento dos processos de ocupação da área em questão.

A seleção das amostras inicia-se com a segmentação das imagens LANDSAT5/TM e ALOS/PALSAR. Uma parte destas imagens segmentadas é mostrada na Figura 4.4a e 4.4b. A segmentação da imagem ALOS/PALSAR foi realizada por um algoritmo de segmentação específico para imagens SAR, denominado SegSAR (SOUSA JR, 2005). Já a imagem LANDSAT5/TM foi segmentada utilizando um algoritmo de segmentador de borda (XIAOYING, 2009). Os resultados dessas duas segmentações foram combinados produzindo uma imagem final segmentada (Figura 4.4c), a qual foi utilizada na seleção das amostras das classes de interesse. As segmentações foram combinadas para que as amostras das classes representassem áreas homogêneas tanto na imagem ALOS/PALSAR quanto na

imagem LANDSAT5/TM. Entretanto, a combinação dos segmentos resultou em regiões menores e/ou do tamanho de um *pixel*. Para este trabalho não seria pertinente coletar amostras de treinamento e teste menores ou do tamanho de um *pixel*. Estas regiões foram eliminadas através de um procedimento iterativo do cálculo de moda em uma vizinhança. Posteriormente foi aplicado nas amostras das classes um filtro de erosão. Este procedimento tem a finalidade de garantir que as amostras estejam completamente contidas dentro do segmento e não sofram influências de bordas.

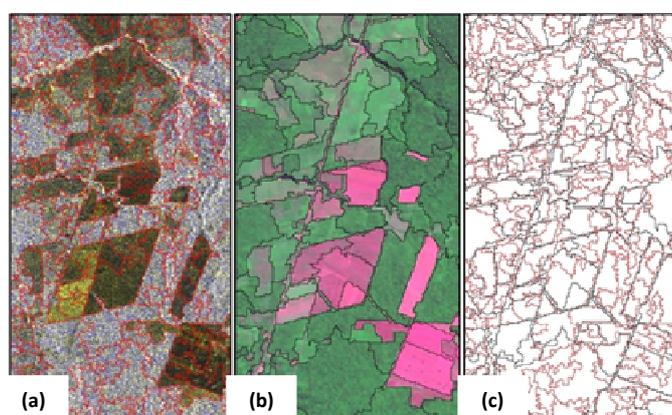


Figura 4 4. Segmentação das imagens: (a) ALOS/PALSAR, (b) LANDSAT5/TM e (c) combinação das segmentações anteriores.

Para a definição das classes de uso e cobertura da terra e seleção das amostras, foram consultados e analisados as imagens ALOS/PALSAR e LANDSAT5/TM, as segmentações combinadas, um banco de dados contendo fotos, localização geográfica e comentários sobre as áreas visitadas durante os trabalhos de campo realizados nos meses de maio e setembro de 2010. A localização geográfica dos comentários realizados em campo foi registrada, utilizando um Sistema de Posicionamento Global (*Global Positioning System-GPS*) da marca RICH CAPLIO 500 com uma precisão de 10 a 15 m.

As amostras de treinamento e teste foram efetivamente selecionadas observando vários aspectos, pois durante os trabalhos de campo foram fotografadas as paisagens que correspondiam aos pontos visitados e as suas respectivas coordenadas registradas com o GPS. Também foram anotadas várias características dos locais visitados, tais como ano em

que teve início a degradação da área, tipo de vegetação predominante entre outras. Como as fotografias digitais possuíam a direção em que as mesmas foram tiradas, foi possível identificar a direção da mesma sobre a imagem LANDSAT5/TM e ALOS/PALSAR e, conseqüentemente, o segmento da imagem segmentada que correspondia à paisagem registrada pela câmera. Desta forma foi possível verificar nas imagens citadas os padrões da área como cor, textura, estrutura dentre outras características e verificar se era pertinente selecionar aquela amostra para representar uma determinada classe.

#### **4.5. Extração de atributos SAR e ópticos**

Neste trabalho além das fusões e combinações com as imagens originais (óptica e SAR), também foram realizadas fusões com outros atributos extraídos destas imagens, pois se acredita que estes atributos possam colaborar na melhora da discriminação das classes de interesse. A descrição dos atributos extraídos das imagens originais é mostrada nas próximas seções.

##### **4.5.1. Extração dos atributos SAR**

###### **4.5.1.1. Razão de bandas**

As razões de bandas utilizadas neste trabalho foram HV/HH e NL. A primeira razão ressalta as feições que possuem elementos predominantemente na direção vertical, sendo assim pode ajudar na discriminação de diferentes tipos de vegetação (SHIMADA et al., 2009). Já a segunda razão é expressa por:

$$NL = \frac{HH \times HV}{HH + HV} \quad (4.1)$$

Sendo utilizada em Lu et al. (2011) objetivando o uso conjunto das informações presentes nas bandas HH e HV na fusão de dados ópticos com SAR.

#### 4.5.1.2. Imagem ALOS/PALSAR em Sigma zero ( $\sigma^0$ )

A informação radiométrica da imagem foi dada, originalmente, em amplitude. A conversão para sigma zero é dada por:

$$\sigma^0 = 10 \log_{10} (DN)^2 + fc \quad (4.2)$$

onde  $DN$  é o valor do nível de cinza do *pixel* em amplitude, e  $fc$  é o fator de correção, que tanto para HH quanto para HV é de -83 dB (SHIMADA et al., 2009).

#### 4.5.1.3. Primeira componente das bandas da imagem ALOS/PALSAR

A extração das componentes principais das imagens multipolarizadas tem por objetivo obter um novo conjunto de bandas. A este conjunto a primeira componente, denominada de  $PC_1HH\_HV$ , será usada como atributo. Nota-se que ao se utilizar somente a primeira PC reduz-se a dimensionalidade dos dados. Como a transformação por PC pode ser realizada utilizando a matriz de covariância ou de correlação. Para este trabalho todas as PCs foram processadas utilizando-se a matriz de correlação para que os dados fossem normalizados e, desta forma, o balanço de energia sofresse menores distorções.

#### 4.5.1.4. Atributos de textura e seleção dos respectivos tamanhos de janela

Para este trabalho foi proposto a utilização das medidas de texturas extraídas das bandas da imagem ALOS/PALSAR. Esta proposição é justificada, pois alguns trabalhos, como o de McNairn et al. (2009), obtiveram melhores resultados nas classificações dos dados ópticos combinados com medidas de texturas extraídas da imagem SAR.

Existem várias medidas de textura, sendo que as mesmas podem também variar de acordo com o tamanho da janela de vizinhança selecionada. Para este trabalho foi calculada uma medida de textura de primeira ordem, qual seja, coeficiente de variação (CV). As medidas de primeira ordem não levam em consideração a distribuição espacial dos níveis de cinza

de uma região da imagem (RENNÓ, 1995). Já as medidas de texturas de segunda ordem como as propostas por Haralick et al. (1973), baseiam-se nas estatísticas derivadas da matriz de co-ocorrência dos níveis de cinza de uma imagem (para maiores detalhes ver Rennó (1995)). Neste trabalho foram computadas 8 medidas de textura de segunda ordem: média (MED); variância (VAR); homogeneidade (HOM), contraste (CON), dissimilaridade (DIS), entropia (ENT), segundo momento (SM) e correlação(COR).

Entretanto, para a geração das medidas de textura é necessário definir o tamanho da janela de vizinhança, sendo que esta influencia consideravelmente na aparência da imagem, e provavelmente na informação que a mesma oferece tanto para os usuários quanto para os classificadores. Sendo assim, as 9 medidas de texturas citadas anteriormente foram computadas nas bandas da imagem ALOS/PALSAR variando o tamanho da janela de vizinhança de 3 a 31, em passos de 2 unidades. Sendo assim, cada medida de textura foi processada 15 vezes. Então, para cada banda da imagem ALOS/PALSAR foram geradas 135 bandas de textura. Como esta imagem possui 2 bandas foram geradas ao todo 270 bandas de texturas.

Diante deste cenário, torna-se custosa a realização de fusões com todas elas, sendo que o alto número de canais pode resultar em uma alta correlação entre os mesmos tornando o processamento custoso. Além disto, também pode ocorrer a maldição da dimensionalidade, ou seja, perda de acurácia na classificação devido ao aumento da dimensionalidade dos dados (OLIVEIRA et al., 2009).

As bandas geradas a partir de uma medida de textura variando apenas o tamanho da janela de vizinhança apresentam alta correlação. Assim, para diminuir a dimensão do espaço de atributos, e ao mesmo tempo, a possibilidade de selecionar bandas correlacionadas, foi selecionada apenas uma banda (janela) de cada medida de textura definida neste estudo. Para auxiliar nesta seleção foi utilizado um procedimento baseado nas distâncias das distribuições estatísticas de um ou mais atributos em função das classes de interesse. Assim, quanto maior a distância entre duas classes, maior é a

separabilidade das mesmas (OLIVEIRA et al., 2009). Entretanto, é necessário selecionar uma medida que represente a distância entre estas distribuições estatísticas no espaço de atributos. Neste estudo foi utilizada a distância de *Bhattacharyya*, que é uma distância estocástica que visa mensurar a similaridade entre duas distribuições estatísticas (BHATTACHARYYA, 1943). Assim, para uma janela de tamanho  $j$ , a distância de *Bhattacharyya* entre duas classes  $k$  e  $i$  cujos dados possuem uma distribuição Gaussiana é dada por:

$${}_jB_{ki} = \frac{1}{8}(\mu_k - \mu_i)^T \left[ \frac{\Sigma_k + \Sigma_i}{2} \right]^{-1} (\mu_k - \mu_i) + \frac{1}{2} \ln \frac{\left| \frac{\Sigma_k + \Sigma_i}{2} \right|}{\sqrt{|\Sigma_k| |\Sigma_i|}} \quad (4.3)$$

onde  $\mu_k$  e  $\mu_i$  são os vetores de média e  $\Sigma_k$  e  $\Sigma_i$  as matrizes de covariâncias estimadas para modelagem das funções densidade de probabilidade que descrevem as regiões das classes  $k$  e  $i$ .

Para que a seleção dos atributos seja realizada de forma satisfatória, é necessário definir uma função critério que possa avaliar a separabilidade das classes. Esta função critério deve maximizar a distância entre as classes a fim de otimizar a seleção de um atributo ou de um conjunto de atributos. Uma das funções critério que atende as especificações acima é a distância *Jeffries-Matusita* (JM) descrita pela Equação 4.4 (OLIVEIRA, 2005), para uma janela de tamanho  $j$ :

$${}_jJM_{ki} = \sqrt{2(1 - e^{-{}_jB_{ki}})} \quad (4.4)$$

onde  ${}_jB_{ki}$  é expresso pela Equação 4.3, note que JM varia entre 0 e  $2^{0,5}$ .

Entretanto, esta função critério avalia as distâncias de *Bhattacharyya* entre 2 classes. Para que a avaliação seja calculada de maneira global foi calculada a distância JM média. Assim, supondo-se que se tenha  $C$  classes, a distância JM média para uma dada janela de tamanho  $j$  é dada por:

$$\overline{JM}_j = \frac{1}{\binom{C}{2}} \sum_{\substack{k,i=1 \\ k < i}}^C {}_jJM_{ki} \quad (4.5)$$

onde  $\binom{C}{2}$  é a combinação de  $C$  classes tomadas duas a duas.

O critério de seleção do tamanho da janela ótimo para cada medida de textura foi baseado no custo benefício, ou seja, procurou-se atender o compromisso de modificar o mínimo possível a resolução espacial das imagens e ao mesmo tempo maximizar as distâncias entre as classes. Uma das formas de se atingir esta meta é selecionando uma banda de uma medida de textura que apresentasse um dos maiores valores da distância JM média com o menor tamanho da janela de vizinhança.

Portanto, o tamanho ótimo da janela ( $j^*$ ) para cada medida de textura foi determinado encontrando-se o mínimo valor de tamanho de janela  $j$  tal que apresentasse um ganho na distância JM média inferior a 5% em relação à janela tamanho  $j-2$ .

$$j^* = \min_j : \left[ \frac{JM_j - JM_{j-2}}{JM_{j-2}} \right] \leq 0,05 \quad j = 3,7,9, \dots, 31 \quad (4.6)$$

## 4.5.2. Extração dos atributos ópticos

### 4.5.2.1. Modelo linear de mistura espectral (MLME)

Uma imagem de sensoriamento remoto é formada por diferentes componentes que estão presentes dentro de um elemento de resolução (*pixel*). Sendo assim, a radiância medida pelo sensor óptico é resultado da integração das respostas de cada uma destas componentes. No Modelo linear de mistura espectral (MLME) supõe-se que o espectro medido por um sensor é a combinação linear do espectro de todas as componentes dentro do *pixel* (ADAMS et al., 1995). Este modelo baseia-se em princípios físicos e permite a extração de imagens frações que representam a proporção de cada componente dentro de um *pixel* (LU et al., 2004). As imagens frações têm grande

aplicabilidade na classificação do uso e cobertura da terra e para o monitoramento do desmatamento e vem sendo utilizado no projeto PRODES (<http://www.obt.inpe.br/prodesdigital/metodologia.html>).

As componentes de um *pixel* podem ser estimadas em qualquer imagem, desde que se tenha conhecimento do comportamento espectral destas componentes. Nota-se que para o processamento satisfatório deste modelo é necessário selecionar *pixels* puros conhecidos (*endmembers*), que representem cada componente que se deseja obter nas imagens-fração (GUIMARÃES et al., 2010). Neste trabalho as imagens-fração extraídas foram solo (IMF\_SL), sombra (IMF\_SM) e vegetação (IMF\_VEG), e os *endmembers* foram selecionados na própria imagem devido à facilidade de obtenção dos mesmos e para que os espectros medidos nas componentes dos *pixels* fossem da mesma escala dos dados da imagem (ROBERTS et al., 1998).

#### 4.5.2.2. Índice de vegetação por diferença normalizada

O Índice de vegetação por diferença normalizada (*Normalized Difference Vegetation Index-NDVI*) é um índice que visa melhorar a capacidade de discriminação de diferentes tipos de vegetação e entre áreas com vegetação e sem vegetação (JUSTICE et al. 1998). Entretanto, apresenta como desvantagens a não linearidade dos dados, a sensibilidade em destacar áreas de solos expostos em áreas de vegetação escassa, e a saturação do sinal quando se tem altos índices de área foliar (JUSTICE et al. 1998). O cálculo do NDVI utiliza o fluxo radiante refletido referente à região do vermelho e o fluxo radiante refletido no infravermelho próximo (Equação 4.7). Os valores deste índice são representados em um intervalo que varia de -1 e 1.

$$NDVI = \frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + \rho_{red}} \quad (4.7)$$

onde  $\rho_{nir}$  está representando os valores de reflectância correspondentes ao comprimento de onda no intervalo de 0,725 a 1,10 $\mu m$  e  $\rho_{red}$  representando os valores de reflectância correspondentes ao comprimento de onda no intervalo 0,62 a 0,70 $\mu m$ . Cabe citar que foi realizada na imagem LANDSAT5/TM, uma correção atmosférica que se baseia em um modelo de transferência radioativa denominado *Second Simulation of the Satellite Signal in the Solar Spectrum* (6s) para mitigar ou eliminar o efeito da atmosfera no cálculo deste índice.

#### 4.5.2.3. Índice de Monitoramento Ambiental Global

O Índice de Monitoramento Ambiental Global (*Global Environmental Monitoring Index-GEMI*) é um índice não-linear de vegetação e vem sendo utilizado em diversos trabalhos como Lu et al. (2005); Laurila et al. (2010); Bastarrika et al. (2011); Wolter e Townsend (2011). Este índice é mais sensível que o NDVI às feições e/ou objetos da cena que possuem baixos valores de reflectância e também minimiza os efeitos atmosféricos (CHUVIECO et al., 2008). Por estes motivos, ele foi selecionado para ser um dos atributos deste trabalho e está matematicamente descrito na Equação 4.8.

$$GEMI = \eta(1 - 0,25\eta) - \left( \frac{\rho_{red} - 0,125}{1 - \rho_{red}} \right) \quad (4.8)$$

com  $\eta = \frac{2(\rho_{nir}^2 - \rho_{red}^2) + 1,5\rho_{nir} + 0,5\rho_{red}}{\rho_{nir} + \rho_{red} + 0,5}$ ,  $\rho_{nir}$  representando os valores de reflectância

correspondentes ao comprimento de onda no intervalo 0,725 a 1,10  $\mu m$  e  $\rho_{red}$  representando os valores de reflectância correspondentes ao comprimento de onda no intervalo 0,62 a 0,70  $\mu m$ . Nota-se que para o cálculo deste índice também foi processada na imagem LANDSAT5/TM uma correção atmosférica (6s) para mitigar ou eliminar o efeito da atmosfera.

#### 4.5.2.4. Primeira componente principal das bandas da imagem LANDSAT5/TM

A extração das componentes principais das imagens multispectrais tem por objetivo obter um novo conjunto de bandas. A este conjunto a primeira componente, denominada de PC<sub>1</sub>TM, será usada como atributo. Nota-se que ao se utilizar somente a primeira PC

reduz-se a dimensionalidade dos dados. A matriz utilizada neste processo também foi a de correlação, sendo que a justificativa desta escolha é o mesmo explicado na seção 4.5.1.3.

#### 4.6. Seleção de um subconjunto ótimo de atributos SAR e ópticos

Como parte do processo de seleção de um subconjunto ótimo de atributos foi montada uma matriz de correlação utilizando toda a cena dos atributos ópticos e SAR descritos na Tabela 4.1, à exceção das bandas HH e HV e suas respectivas bandas  $\sigma^0$ . Observe que o método de seleção das 18 bandas de texturas SAR é descrita na seção 4.5.1.4.

Este procedimento tem por objetivo realizar a seleção dos dados ópticos e SAR menos correlacionados, diminuindo a dimensionalidade do espaço de atributos. Para iniciar o processo de seleção foi utilizado o valor da distância JM média, de tal forma que foi selecionado o atributo que resultou na maior distância JM dentre os atributos ópticos e SAR, os atributos que possuíam correlação com este atributo superior a 0,80 eram excluídos do processo de seleção. Posteriormente era analisado o próximo atributo que resultou na maior distância JM média, e o processo de exclusão já mencionado era repetido. Este processo foi repetido até que se chegasse a um subgrupo de atributos que possuíam entre si uma correlação inferior a 0,80. Nota-se que este processo foi realizado para os atributos ópticos e SAR separadamente.

Tabela 4 1. Atributos dos dados ópticos e SAR.

Dados ópticos	Dados SAR
6 Bandas da imagem original LANDSAT5/TM	2 Bandas da imagem filtrada ALOS/PALSAR
3 imagens - fração do MLME PC <sub>1</sub> extraída das 6 bandas	Razão de bandas HV/HH Índice NL
NDVI	PC <sub>1</sub> extraída das bandas HH e HV
GEMI	18 bandas de textura Bandas da imagem ALOS/PALSAR em $\sigma^0$
Total: 12 atributos	Total: 25 atributos

Portanto, dos 12 atributos ópticos foram selecionados  $r$  atributos e dos 25 atributos SAR foram selecionados  $g$  atributos de tal forma que  $r < 12$  e  $g < 25$ .

Após esta pré-seleção dos atributos menos descorrelacionados, procedeu-se a seleção de um subconjunto ótimo de atributos ópticos e SAR. Para tanto, foi processada uma busca exaustiva. Buscou-se, então, encontrar um subconjunto que apresentasse um alto valor da distância JM média e que contivesse um número de atributos menor que o conjunto formado por todos os atributos. Este procedimento é descrito a seguir.

Denominando-se  $\mathbf{A}$  o conjunto de todos os  $N$  atributos ( $N=r$ ) para os dados ópticos e  $N=g$  para os dados SAR, e  $P_n(\mathbf{A})$  o conjunto formado por todos os subconjuntos de  $\mathbf{A}$  com  $n$  elementos ( $n = 1, \dots, N$ ), a distância JM entre duas classes  $k$  e  $i$ , para o  $j$ -ésimo subconjunto de  $P_n(\mathbf{A})$  é denotada de  ${}_{j,n}JM_{ki}$ . A distância JM média para as  $C$  classes para este subconjunto é dada por:

$$\overline{JM}_{j,n} = \frac{1}{\binom{C}{2}} \sum_{\substack{k,i=1 \\ k < i}}^C {}_{j,n}JM_{ki} \quad (j=1, \dots, \binom{N}{n}) \quad (4.9)$$

onde  $\binom{M}{m}$  é a combinação de  $M$  elementos tomados  $m$  a  $m$ . Para cada  $P_n(\mathbf{A})$ , o subconjunto ótimo  $J_n^*$  com  $n$  atributos é dado por:

$$J_n^* = j : \overline{JM}_{j,n} = \max \left\{ \overline{JM}_{1,n}, \overline{JM}_{2,n}, \dots, \overline{JM}_{\binom{N}{n},n} \right\} \quad (4.10)$$

Finalmente, o conjunto ótimo é aquele composto de  $n^*-1$  atributos que possua um ganho na distância JM média inferior a 1%, quando comparado ao conjunto com  $n^*$  atributos, isto é  $n^*-1$  é dado por:

$$n^* - 1 = \min_n : \left[ \frac{\overline{JM}_{J_n^*} - \overline{JM}_{J_{n-1}^*}}{\overline{JM}_{J_{n-1}^*}} \right] \leq 0,01 \quad n=1, \dots, N. \quad (4.11)$$

Paralelamente aos procedimentos descritos pelas equações (4.10) e (4.11), foram gerados gráficos de média e desvio padrão de todos os atributos selecionados, pois caso um atributo não resultasse em uma separabilidade relativamente satisfatória das  $C$  classes de interesse, este atributo poderia ser excluído da seleção dos subconjuntos.

#### **4.7. Análise exploratória dos atributos selecionados**

Neste trabalho, a análise exploratória dos dados teve por objetivo entender melhor o comportamento dos atributos que participarão das combinações e dos processos de fusão de imagens em função das classes de interesse, visando auxiliar no processo de agrupamento das classes. Para tanto, tais atributos foram organizados em gráficos que mostram parâmetros estatísticos (média e desvio padrão) de um determinado atributo em função das classes de interesse (estas classes são descritas no Capítulo 5). Através destes gráficos é possível detectar a dificuldade de um determinado atributo na discriminação de algumas classes e, conseqüentemente indicar as classes que quando agrupadas resulte em uma boa separabilidade das demais classes. Para esta análise também foram consultadas as distâncias JM médias, pois estes valores possibilitam a hierarquização dos atributos em função da capacidade discriminatória das classes.

Além dos gráficos de média e desvio padrão também foram utilizados gráficos com pares de atributos. Nestes gráficos são mostrados o valor médio de cada classe de interesse e seu respectivo desvio padrão. As elipses são geradas a partir dos valores de desvio padrão, onde cada semieixo da elipse tem valor de um desvio padrão da classe para o atributo. Estes gráficos além de permitirem a visualização das classes que apresentam confusões entre si, também permitem identificar se um determinado par de atributos melhora ou não a discriminação das classes quando comparado com a utilização dos atributos em separado.

#### **4.8. Agrupamento de classes**

Neste trabalho foi realizado o agrupamento das classes que apresentaram baixa separabilidade, visando melhorar a acurácia das classificações. Para isso, foi adotado um método que utiliza distâncias estocásticas, computadas com base em um conjunto de atributos definidos inicialmente, para cada par de classes. A medida de distância empregada neste método foi a distância JM. Com o conhecimento das distâncias JM entre todos os pares de classes contidos em um conjunto inicial, é realizado o particionamento de tal conjunto em dois subconjuntos. Por sua vez, cada subconjunto é

particionado em dois novos subconjuntos, sucessivamente, enquanto houver ao menos um par de classes cuja distância estocástica entre elas é maior que um dado limiar, definido previamente. O processo de partição é baseado em um algoritmo desenvolvido inicialmente para problemas relacionados à otimização logística.

O resultado deste processo é uma árvore binária que indica quais classes devem ser agrupadas. O limiar utilizado neste trabalho foi igual a 1.0 (em unidades de distância JM). Com isso, subconjuntos compostos por classes cuja maior distância JM é igual ou inferior a 1.0, são agrupados em uma única classe. (DUTRA; NEGRI, 2012). (comunicação pessoal).

#### 4.9. Métodos de fusão

Os métodos de fusão dos dados ópticos com SAR que foram avaliados nesta dissertação estão apresentados na Tabela 4.2.

Transformação de cores IHS (IHS)
Transformação de <i>Brovey</i> (TB)
Análise por componentes principais (PC)
Análise por componentes principais seletivos (SCP)
<i>Wavelet á trous</i> simples (WA)
<i>Wavelet á trous</i> + PCA (WA_PC)
<i>Wavelet</i> simples (W)
<i>Wavelet</i> + IHS (WIHS)
<i>Wavelet</i> + PCA (WPC)
<i>Ehlers</i> ( <i>Ehlers</i> )

Em geral, os métodos de fusões utilizam somente uma banda das imagens SAR multipolarizadas. Porém, neste trabalho é proposto um método de integração da informação contida nas imagens SAR multipolarizadas e de seus atributos selecionados antes do processo de fusão. Esta integração consiste em realizar a PC na imagem multipolarizada ALOS/PALSAR ou dos atributos selecionados extraídos da mesma, e utilizar a primeira PC que contém maior parte da informação nos processos de fusões. Este procedimento tem por objetivo utilizar a maior quantidade de informação da

imagem SAR nas fusões. A matriz utilizada na PCA foi a de correlação, sendo que a justificativa desta escolha é a mesma explicada na seção 4.5.1.3.

Nesta dissertação foi utilizado o método de fusão IHS baseado no modelo de cones, pois este modelo tem apresentado melhores resultados do que as transformações IHS baseadas em outros modelos (HARRIS et al., 1999). Este método de fusão foi realizado no aplicativo livre *Spring* (CAMARA et al., 1996).

Os métodos de fusões TB e PCA foram processados no ENVI 4.7 (VISUAL INFORMATION SOLUTION, 2009). Nas fusões por PC o processo de substituição de uma componente pela imagem SAR somente deverá ser efetuada nas componentes de maior importância, para que o novo conjunto de bandas resultantes da transformação inversa contenha também informações do radar. Sendo assim, para este trabalho foi substituído apenas a primeira PC, pois esta componente possui maior parte das informações presente nas 6 bandas da imagem LANDSAT5/TM

Nesta dissertação foram testados dois algoritmos de fusão *Wavelet*, quais sejam *á trous* (WA) e o *Wavelet* (W). Os métodos de fusões que utilizam o algoritmo *á trous* incluindo o híbrido WA\_PC estão implementados no aplicativo livre *Terra Pixel*, disponível em <http://fusion.dpi.inpe.br/>. Estes métodos de fusões possuem a limitação de permitir a fusão, com apenas três bandas ópticas. Os métodos de fusões que utilizam o algoritmo *Wavelet* (W) incluindo os métodos híbridos WIHS, WPC estão implementados no aplicativo ERDAS 9.1 (LEICA GEOSYSTEMS GEOSPATIAL IMAGING, 2006). O método de fusão *Ehlers* também foi processado no citado aplicativo.

#### **4.10. Método de avaliação**

Os métodos quantitativos de avaliação das classificações realizadas em imagens combinadas ou fusionadas são frequentemente validados por comparação com os conjuntos de dados de campo (i.e., matriz de confusão) (CONGALTON, 1991). Neste trabalho foram realizadas 90 classificações e os resultados das mesmas foram comparados

quantitativamente através das matrizes de confusão, dos coeficientes de concordância *kappa* (global e por classe) e dos acertos globais, todos calculados baseado nas amostras de teste.

O coeficiente de concordância *kappa* foi proposto para a determinação da exatidão da classificação e leva em consideração no seu cálculo os acertos das classificações e os erros de omissão e comissão da mesma utilizando-se a matriz de confusão. A vantagem deste índice é que as comparações dos resultados podem ser realizadas através do teste de hipótese de igualdade entre pares de valores de *kappa* a um dado nível de significância (CONGALTON, 1991). Neste trabalho os testes de hipóteses foram unilaterais e consideraram um nível de significância de 5%.

O *Kappa* também pode ser calculado por classe, visando quantificar a exatidão da classificação para uma determinada classe. Como o coeficiente de concordância *Kappa* leva em consideração os erros e os acertos da classificação, ele é considerado mais adequado para avaliar a exatidão das classes do que a diagonal da matriz de confusão, ao qual expressa apenas a porcentagem de acerto das classes (FITZGERALD; LEES, 1994).

As matrizes de confusão das classificações foram utilizadas para auxiliar na identificação das classes que apresentaram confusão. Para tanto, estas matrizes são representadas graficamente. Nesta representação gráfica cada elemento da matriz de confusão é representado em porcentagem e associado a uma circunferência de área proporcional do valor do elemento. Valores inferiores a 5% não são representados nestas matrizes.

Para melhor discussão dos resultados, as classificações foram comparadas e analisadas separadamente formando três grupos. O primeiro grupo é formado pelas classificações resultantes das imagens originais e de seus atributos, o segundo é formado pelas classificações das imagens combinadas, e terceiro grupo é formado pelas classificações das imagens fusionadas. Dentro de cada grupo foram selecionadas as melhores classificações para análises mais detalhadas.



## **5. RESULTADOS E DISCUSSÕES**

O objetivo principal desta dissertação é avaliar diferentes formas de integrar dados de diferentes sensores imageadores (SAR e ópticos) com a finalidade de identificar a mais adequada para o mapeamento do uso e cobertura da terra de uma região de fronteira agrícola da Amazônia brasileira. Para tanto, nos tópicos seguintes serão apresentados, analisados e discutidos os resultados.

### **5.1. Fusões e combinações que foram processadas e avaliadas**

Como citado na sessão 4.10, neste trabalho foram classificadas e avaliadas 90 conjuntos de imagens, 2 imagens originais (LANDSAT5/TM e ALOS/PALSAR), 2 imagens formadas pelos atributos extraídos das imagens originais, 6 imagens combinadas e 80 imagens fusionadas por diferentes métodos. Os métodos de fusão IHS, TB, *Wavelet* + IHS e *Wavelet(s) á trous* utilizam como dados de entradas 3 bandas multiespectrais. Portanto, para se processar estas fusões foram selecionadas as bandas B2, B4, B5, pelo fato destas juntas resultarem no maior valor distância JM média. Estas bandas foram compostas no espaço de cores da seguinte forma: R(5) G(4) B(2). Na Tabela 5.1 são mostrados os 90 grupos de imagens que foram classificadas, suas descrições e as respectivas siglas utilizadas ao longo do texto.

Tabela 5.1. Descrição das imagens, combinações e fusões que serão classificadas e avaliadas.

	<b>Imagens, fusões e combinações</b>	<b>Siglas</b>
Original	<p>Bandas 1,2,3,4,5 e 7 da imagem LANDSAT5/TM</p> <p>Bandas HH e HV da imagem ALOS/PALSAR no formato amplitude filtradas (Gama 5x5)</p> <p>3 atributos selecionados dentre os 12 atributos ópticos</p> <p>3 atributos selecionados dentre os 25 atributos SAR</p>	<p><b>LANDSAT5/TM</b></p> <p><b>ALOS/PALSAR</b></p> <p><b>OPT<sub>3</sub></b></p> <p><b>SAR<sub>3</sub></b></p>
Combinações	<p>Combinação da imagem LANDSAT5/TM e da imagem ALOS/PALSAR</p> <p>Combinação da imagem LANDSAT5/TM e da banda HH da imagem ALOS/PALSAR</p> <p>Combinação da imagem LANDSAT5/TM e da banda HV da imagem ALOS/PALSAR</p> <p>Combinação da imagem ALOS/PALSAR e dos 3 atributos ópticos selecionados</p> <p>Combinação da imagem LANDSAT5/TM e dos 3 atributos SAR selecionados</p> <p>Combinação dos 3 atributos ópticos e 3 atributos SAR selecionados</p>	<p><b>TM_HH_HV</b></p> <p><b>TM_HH</b></p> <p><b>TM_HV</b></p> <p><b>OPT<sub>3</sub>HH_HV</b></p> <p><b>TM_SAR<sub>3</sub></b></p> <p><b>OPT<sub>3</sub>SAR<sub>3</sub></b></p>
Fusão IHS com 3 bandas TM	<p>Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a PC<sub>1</sub> (HH_HV) da imagem ALOS/PALSAR</p> <p>Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a banda HH da imagem ALOS/PALSAR</p> <p>Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a banda HV da imagem ALOS/PALSAR</p> <p>Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a PC<sub>1</sub> dos 3 atributos SAR selecionados</p>	<p><b>IHS_HH_HV</b></p> <p><b>IHS_HH</b></p> <p><b>IHS_HV</b></p> <p><b>IHS_SAR<sub>3</sub></b></p>
Fusão IHS com 3 atributos ópticos selecionados	<p>Fusão dos 3 atributos ópticos selecionados com a PC<sub>1</sub> (HH_HV) da imagem ALOS/PALSAR</p> <p>Fusão dos 3 atributos ópticos selecionados com a banda HH da imagem ALOS/PALSAR</p> <p>Fusão dos 3 atributos ópticos selecionados com a banda HV da imagem ALOS/PALSAR</p> <p>Fusão dos 3 atributos ópticos selecionados com a PC<sub>1</sub> dos 3 atributos SAR selecionados</p>	<p><b>IHS_OPT<sub>3</sub>HH_HV</b></p> <p><b>IHS_OPT<sub>3</sub>HH</b></p> <p><b>IHS_OPT<sub>3</sub>HV</b></p> <p><b>IHS_OPT<sub>3</sub>SAR<sub>3</sub></b></p>
Fusão TB com 3 bandas TM	<p>Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a PC<sub>1</sub> (HH_HV) da imagem ALOS/PALSAR</p> <p>Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a banda HH da imagem ALOS/PALSAR</p> <p>Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a banda HV da imagem ALOS/PALSAR</p> <p>Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a PC<sub>1</sub> dos 3 atributos SAR selecionados</p>	<p><b>TB_HH_HV</b></p> <p><b>TB_HH</b></p> <p><b>TB_HV</b></p> <p><b>TB_SAR<sub>3</sub></b></p>

(Continua)

Tabela 5.1 - Continuação

Fusão TB com 3 atributos ópticos selecionados	<p>Fusão dos 3 atributos ópticos selecionados com a PC<sub>1</sub> da imagem ALOS/PALSAR</p> <p>Fusão dos 3 atributos ópticos selecionados com a banda HH da imagem ALOS/PALSAR</p> <p>Fusão dos 3 atributos ópticos selecionados com a banda HV da imagem ALOS/PALSAR</p> <p>Fusão dos 3 atributos ópticos selecionados com a PC<sub>1</sub> dos 3 atributos SAR selecionados</p>	<p><b>TB_OPT<sub>3</sub>HH_HV</b></p> <p><b>TB_OPT<sub>3</sub>HH</b></p> <p><b>TB_OPT<sub>3</sub>HV</b></p> <p><b>TB_OPT<sub>3</sub>SAR<sub>3</sub></b></p>
Fusão PC com 6 bandas TM	<p>Fusão das 6 bandas originais LANDSAT5/TM com a PC<sub>1</sub> (HH_HV) da imagem ALOS/PALSAR</p> <p>Fusão das 6 bandas originais LANDSAT5/TM com a banda HH da imagem ALOS/PALSAR</p> <p>Fusão das 6 bandas originais LANDSAT5/TM com a banda HV da imagem ALOS/PALSAR</p> <p>Fusão das 6 bandas originais LANDSAT5/TM com a PC<sub>1</sub> dos 3 atributos SAR selecionados</p>	<p><b>PC<sub>6</sub>HH_HV</b></p> <p><b>PC<sub>6</sub>HH</b></p> <p><b>PC<sub>6</sub>HV</b></p> <p><b>PC<sub>6</sub>SAR<sub>3</sub></b></p>
Fusão PC com 3 bandas TM	<p>Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a PC<sub>1</sub> (HH_HV) da imagem ALOS/PALSAR</p> <p>Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a banda HH da imagem ALOS/PALSAR</p> <p>Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a banda HV da imagem ALOS/PALSAR</p> <p>Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a PC<sub>1</sub> dos 3 atributos SAR selecionados</p>	<p><b>PC<sub>3</sub>HH_HV</b></p> <p><b>PC<sub>3</sub>HH</b></p> <p><b>PC<sub>3</sub>HV</b></p> <p><b>PC<sub>3</sub>SAR<sub>3</sub></b></p>
Fusão PC com <i>n</i> atributos ópticos selecionados	<p>Fusão dos 3 atributos ópticos selecionados com a PC<sub>1</sub> (HH_HV) da imagem ALOS/PALSAR</p> <p>Fusão dos 3 atributos ópticos selecionados com a banda HH da imagem ALOS/PALSAR</p> <p>Fusão dos 3 atributos ópticos selecionados com a banda HV da imagem ALOS/PALSAR</p> <p>Fusão dos 3 atributos ópticos selecionados com a PC<sub>1</sub> dos 3 atributos SAR selecionados</p>	<p><b>PC_OPT<sub>3</sub>HH_HV</b></p> <p><b>PC_OPT<sub>3</sub>HH</b></p> <p><b>PC_OPT<sub>3</sub>HV</b></p> <p><b>PC_OPT<sub>3</sub>SAR<sub>3</sub></b></p>
Fusão SCP-SAR	<p>Fusão das 6 bandas originais LANDSAT5/TM com a PC<sub>1</sub> (HH_HV) da imagem ALOS/PALSAR</p> <p>Fusão das 6 bandas originais LANDSAT5/TM com a banda HH da imagem ALOS/PALSAR</p> <p>Fusão das 6 bandas originais LANDSAT5/TM com a banda HV da imagem ALOS/PALSAR</p> <p>Fusão das 6 bandas originais LANDSAT5/TM com a PC<sub>1</sub> dos 3 atributos SAR selecionados</p>	<p><b>SCP_HH_HV</b></p> <p><b>SCP_HH</b></p> <p><b>SCP_HV</b></p> <p><b>SCP_SAR<sub>3</sub></b></p>
Fusão <i>Wavelet á trous</i> simples com 3 bandas TM	<p>Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a PC<sub>1</sub> (HH_HV) da imagem ALOS/PALSAR</p> <p>Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a banda HH da imagem ALOS/PALSAR</p> <p>Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a banda HV da imagem ALOS/PALSAR</p> <p>Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a PC<sub>1</sub> dos 3 atributos SAR selecionados</p>	<p><b>WA_HH_HV</b></p> <p><b>WA_HH</b></p> <p><b>WA_HV</b></p> <p><b>WA_SAR<sub>3</sub></b></p>

(Continua)

Tabela 5.1 - Continuação

Fusão <i>Wavelet á trous</i> com 3 atributos ópticos selecionados	Fusão dos 3 atributos ópticos selecionados com a PC <sub>1</sub> (HH_HV) da imagem ALOS/PALSAR Fusão dos 3 atributos ópticos selecionados com a banda HH da imagem ALOS/PALSAR Fusão dos 3 atributos ópticos selecionados com a banda HV da imagem ALOS/PALSAR Fusão dos 3 atributos ópticos selecionados com a PC <sub>1</sub> dos 3 atributos SAR selecionados	<b>WA_OPT<sub>3</sub>HH_HV</b> <b>WA_OPT<sub>3</sub>HH</b> <b>WA_OPT<sub>3</sub>HV</b> <b>WA_OPT<sub>3</sub>SAR<sub>3</sub></b>
Fusão <i>Wavelet PC á trous</i> com 3 bandas TM	Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a PC <sub>1</sub> (HH_HV) da imagem ALOS/PALSAR Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a banda HH da imagem ALOS/PALSAR Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a banda HV da imagem ALOS/PALSAR Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a PC <sub>1</sub> dos 3 atributos SAR selecionados	<b>WAPC<sub>3</sub>HH_HV</b> <b>WAPC<sub>3</sub>HH</b> <b>WAPC<sub>3</sub>HV</b> <b>WAPC<sub>3</sub>SAR<sub>3</sub></b>
Fusão <i>Wavelet PC á trous</i> com 3 atributos ópticos selecionados	Fusão dos 3 atributos ópticos selecionados com a PC <sub>1</sub> (HH_HV) da imagem ALOS/PALSAR Fusão dos 3 atributos ópticos selecionados com a banda HH da imagem ALOS/PALSAR Fusão dos 3 atributos ópticos selecionados com a banda HV da imagem ALOS/PALSAR Fusão dos 3 atributos ópticos selecionados com a PC <sub>1</sub> dos 3 atributos SAR selecionados	<b>WAPC_OPT<sub>3</sub>HH_HV</b> <b>WAPC_OPT<sub>3</sub>HH</b> <b>WAPC_OPT<sub>3</sub>HV</b> <b>WAPC_OPT<sub>3</sub>SAR<sub>3</sub></b>
Fusão <i>Wavelet</i> simples	Fusão das 6 bandas originais LANDSAT5/TM com a PC <sub>1</sub> (HH_HV) da imagem ALOS/PALSAR Fusão das 6 bandas originais LANDSAT5/TM com a banda HH da imagem ALOS/PALSAR Fusão das 6 bandas originais LANDSAT5/TM com a banda HV da imagem ALOS/PALSAR Fusão das 6 bandas originais LANDSAT5/TM a PC <sub>1</sub> dos 3 atributos SAR selecionados	<b>W_HH_HV</b> <b>W_HH</b> <b>W_HV</b> <b>W_SAR<sub>3</sub></b>
Fusão <i>Wavelet</i> com 3 atributos ópticos selecionados	Fusão dos n atributos ópticos selecionados com a PC <sub>1</sub> (HH_HV) da imagem ALOS/PALSAR Fusão dos n atributos ópticos selecionados com a banda HH da imagem ALOS/PALSAR Fusão dos n atributos ópticos selecionados com a banda HV da imagem ALOS/PALSAR Fusão dos n atributos ópticos selecionados com a PC <sub>1</sub> dos 3 atributos SAR selecionados	<b>WOPT<sub>3</sub>HH_HV</b> <b>WOPT<sub>3</sub>HH</b> <b>WOPT<sub>3</sub>HV</b> <b>WOPT<sub>3</sub>SAR<sub>3</sub></b>
Fusão <i>Wavelet PC</i> com 6 bandas TM	Fusão das 6 bandas originais LANDSAT5/TM com a PC <sub>1</sub> (HH_HV) da imagem ALOS/PALSAR Fusão das 6 bandas originais LANDSAT5/TM com a banda HH da imagem ALOS/PALSAR Fusão das 6 bandas originais LANDSAT5/TM com a banda HV da imagem ALOS/PALSAR Fusão das 6 bandas originais LANDSAT5/TM com a PC <sub>1</sub> dos 3 atributos SAR selecionados	<b>WPC<sub>6</sub>HH_HV</b> <b>WPC<sub>6</sub>HH</b> <b>WPC<sub>6</sub>HV</b> <b>WPC<sub>6</sub>SAR<sub>3</sub></b>

(Continua)

Tabela 5.1 - Continuação

<p>Fusão <i>Wavelet</i> PC com 3 atributos ópticos selecionados</p>	<p>Fusão dos 3 atributos ópticos selecionados com a PC<sub>1</sub> (HH_HV) da imagem ALOS/PALSAR  Fusão dos 3 atributos ópticos selecionados com a banda HH da imagem ALOS/PALSAR  Fusão dos 3 atributos ópticos selecionados com a banda HV da imagem ALOS/PALSAR  Fusão dos 3 atributos ópticos selecionados com a PC<sub>1</sub> dos 3 atributos SAR selecionados</p>	<p><b>WPC_OPT<sub>3</sub>HH_HV</b>  <b>WPC_OPT<sub>3</sub>HH</b>  <b>WPC_OPT<sub>3</sub>HV</b>  <b>WPC_OPT<sub>3</sub>SAR<sub>3</sub></b></p>
<p>Fusão <i>Wavelet</i> IHS com 3 bandas TM</p>	<p>Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a PC<sub>1</sub> (HH_HV) da imagem ALOS/PALSAR)  Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a banda da imagem ALOS/PALSAR HH  Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a banda da imagem ALOS/PALSAR HV  Fusão das 3 bandas originais LANDSAT5/TM selecionadas pela distância JM média com a PC<sub>1</sub> dos 3 atributos selecionados dentre atributos SAR</p>	<p><b>WIHS_HH_HV</b>  <b>WIHS_HH</b>  <b>WIHS_HV</b>  <b>WIHS_SAR<sub>3</sub></b></p>
<p>Fusão <i>Wavelet</i> IHS com 3 atributos ópticos selecionados</p>	<p>Fusão de 3 atributos ópticos selecionados com a PC<sub>1</sub> (HH_HV) da imagem ALOS/PALSAR  Fusão de 3 atributos ópticos selecionados com a banda da imagem ALOS/PALSAR HH  Fusão de 3 atributos ópticos selecionados com a banda da imagem ALOS/PALSAR HV  Fusão de 3 atributos ópticos selecionados com a PC<sub>1</sub> dos 3 atributos selecionados dentre atributos SAR</p>	<p><b>WIHS_OPT<sub>3</sub>HH_HV</b>  <b>WIHS_OPT<sub>3</sub>HH</b>  <b>WIHS_OPT<sub>3</sub>HV</b>  <b>WIHS_OPT<sub>3</sub>SAR<sub>3</sub></b></p>
<p>Fusão <i>Ehlers</i> com 6 bandas TM</p>	<p>Fusão das 6 bandas originais LANDSAT5/TM com a PC<sub>1</sub> (HH_HV) da imagem ALOS/PALSAR  Fusão das 6 bandas originais LANDSAT5/TM com a banda HH da imagem ALOS/PALSAR  Fusão das 6 bandas LANDSAT5/TM com a banda HV da imagem ALOS/PALSAR  Fusão das 6 bandas originais LANDSAT5/TM com a PC<sub>1</sub> dos 3 atributos SAR selecionados</p>	<p><b>Ehlers_HH_HV</b>  <b>Ehlers_HH</b>  <b>Ehlers_HV</b>  <b>Ehlers_SAR<sub>3</sub></b></p>
<p>Fusão <i>Ehlers</i> com 3 atributos ópticos selecionados</p>	<p>Fusão dos 3 atributos ópticos selecionados com a PC<sub>1</sub> (HH_HV) da imagem ALOS/PALSAR  Fusão dos 3 atributos ópticos selecionados com a banda HH da imagem ALOS/PALSAR  Fusão dos 3 atributos ópticos selecionados com a banda HV da imagem ALOS/PALSAR  Fusão dos 3 atributos ópticos selecionados com a PC<sub>1</sub> dos 3 atributos SAR selecionados</p>	<p><b>Ehlers_OPT<sub>3</sub>HH_HV</b>  <b>Ehlers_OPT<sub>3</sub>HH</b>  <b>Ehlers_OPT<sub>3</sub>HV</b>  <b>Ehlers_OPT<sub>3</sub>SAR<sub>3</sub></b></p>

## 5.2. Definição das classes de interesse

Baseado no exposto na seção 4.4, as seguintes classes de uso e cobertura da terra foram definidas: Floresta Primária (FP), Floresta Primária em Exploração (FPE), Floresta Degradada (FD), Regeneração Antiga (RA), Regeneração Intermediária (Rint), Regeneração Inicial (RI), Pasto Sujo (PS), Pasto Limpo (PL), Pasto Limpo com Babaçu e Inajá (PLBI), Solo Preparado para Agricultura ou em pousio após a colheita (SP), Agricultura em Pousio de 7 a 24 meses (AP7/24), Soja100 (S100) e Soja40 (S40). A descrição de cada classe é apresentada na segunda coluna da Tabela 5.2. O número total de *pixels* é apresentado na terceira coluna desta tabela.

Tabela 5.2. Descrição das classes selecionadas e número de amostras coletadas.

Classes	Descrição	Números de <i>pixel</i> (amostras)
Floresta Primária – FP	Floresta intacta, que não foi modificada pela atividade humana	70631
Floresta Primária em exploração – FPE	Florestas com desmatamento seletivo	29256
Floresta Degradada – FD	Florestas Primárias que sofreram atividades de fogo	18644
Regeneração Antiga – RA	Florestas Secundárias com mais de 20 anos de regeneração	23282
Regeneração Intermediária – Rint	Florestas Secundárias de 8 a 20 anos de regeneração	4065
Regeneração Inicial – RI	Florestas Secundárias com menos de 8 anos de regeneração	6140
Pasto Sujo – PS	Terras usadas para pastagem com presença de árvores, arbustos e espécies invasoras	5104
Agricultura Pousio de 7 a 24 meses – AP7/24	Área de culturas agrícolas em pousio de 7 a 24 meses	1858
Pasto Limpo – PL	Terras usadas para pastagens, com pouca presença de árvores, arbustos e espécies invasoras	7046
Pasto Limpo com Babaçu e Inajá – PLBI	Terras usadas para pastagens com arbustos, espécies invasoras, Babaçu e Inajá	5377
Solo Preparado para Agricultura ou em pousio após colheita – SP	Áreas agrícolas em pousio após colheita ou preparadas para agricultura	8003
Soja100 – S100	Soja pronta para colheita (após 100 dias da semeadura, aproximadamente)	4933
Soja40 – S40	Soja com aproximadamente 40 dias da semeadura	1126

Após o agrupamento das classes estas amostras foram separadas em amostras de treinamento do classificador e de validação das classificações. Para tanto, aproximadamente 2/3 das amostras foram selecionadas para treinar o classificador e 1/3 para validar as classificações.

As localizações das amostras das classes de interesse estão demarcadas sobre a composição colorida R(HH) G(HV) B(HH) da imagem ALOS/PALSAR na Figura 5.1. Na Figura 5.2 são mostradas as fotos que representam as 13 classes de interesse.

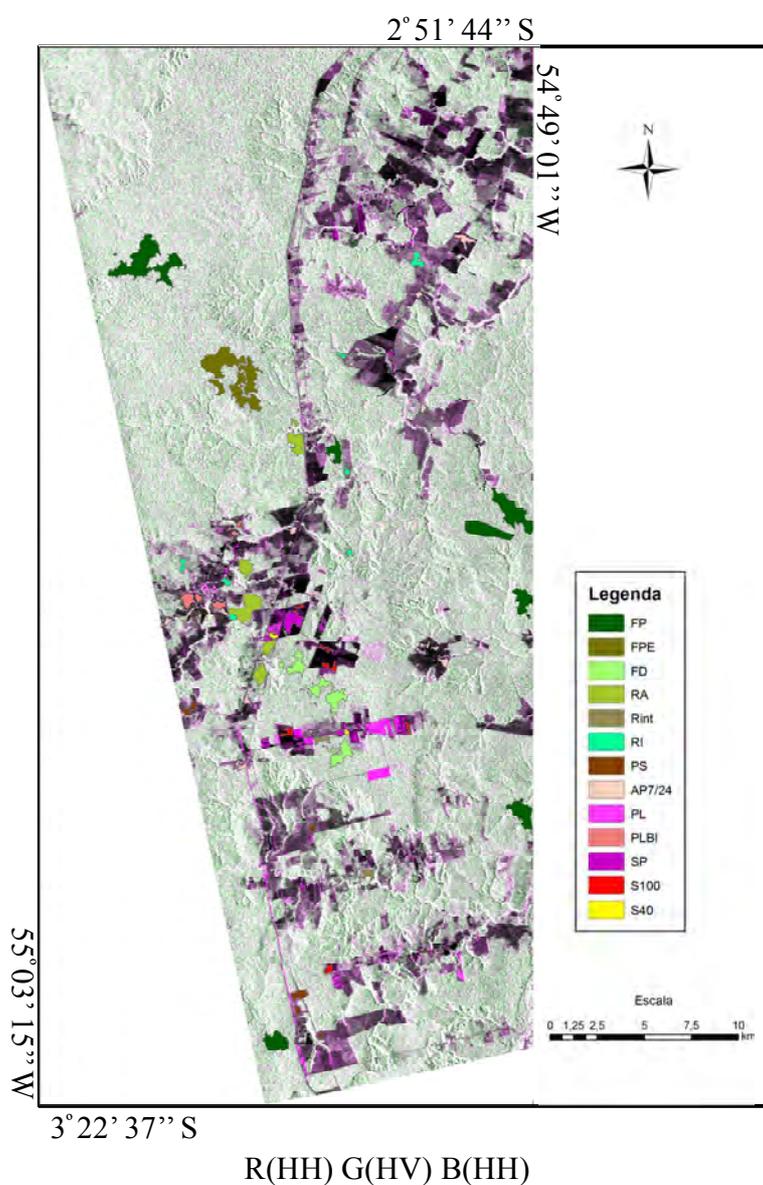


Figura 5.1. Localização das amostras das classes de interesse na imagem ALOS/PALSAR.

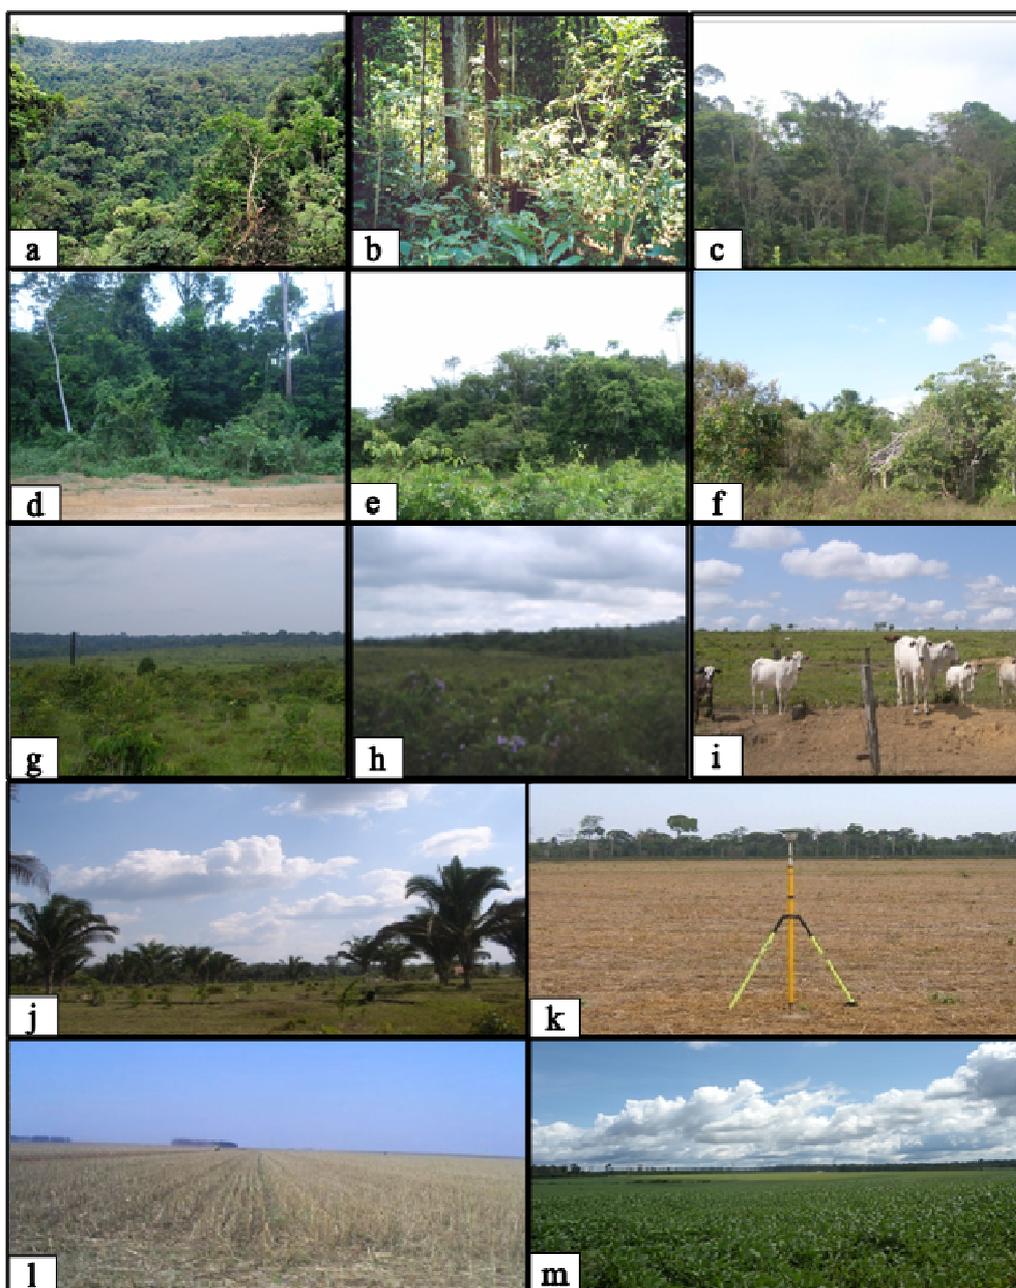


Figura 5.2. Fotografias que representam as 13 classes de interesse: a) FP, b) FPE, c) FD, d) RA, e) Rint, f) RI, g) PS, h) AP7/24, i) PL, j) PLBI, k) SP, l) S100 e m) S40.

### 5.3. Resultados da avaliação planimétrica da imagem ALOS/PALSAR

Os resultados mostraram que a imagem *Gecoded* apresentou tendências na resultante das componentes planimétricas de 139 m. Após a remoção da tendência foi verificado que esta imagem é classificada no PEC classe “A” para a escala de mapeamento 1:100.000.

Isto significa que os dados e anotações registrados em campo eram correspondentes às feições identificadas nas imagens LANDSAT5/TM e ALOS/PALSAR. Entretanto, cabe ressaltar que a área da imagem apresenta um relevo considerado plano, e, portanto, esta conclusão pode não ser válida para imagens de áreas com outras características geomorfológicas. Os resultados desta avaliação resultaram em um artigo intitulado: Avaliação planimétrica de imagens ALOS/PALSAR, modo *Fine-Beam Dual* (FDB), para uma área da Amazônia brasileira, ao qual será submetido à Revista Brasileira de Geociências. Este artigo é apresentado no Apêndice A.

#### **5.4. Pré-processamento**

Nas combinações e nos métodos de fusão parte-se do pressuposto que as imagens SAR e ópticas estejam padronizadas quanto à projeção e quanto ao sistema de coordenadas geográficas. Considera-se também que estas imagens estejam geometricamente registradas entre si, de preferência, em nível de *subpixel*. Estes procedimentos foram realizados nas imagens envolvidas neste trabalho, sendo que o corregristo apresentou um erro quadrático médio de 0,43 *pixel* (aprox. 5,38 m). A imagem utilizada como base para o corregristo foi a ALOS/PALSAR devido a sua melhor resolução espacial e acurácia planimétrica.

#### **5.5. Seleção do tamanho da janela de vizinhança do filtro de *speckle Gama***

Conforme a metodologia descrita na seção 4.2.2, o ENL médio estimado para as bandas HH e HV (amplitude) foram de 4,26 e 4,65, respectivamente. A Tabela 5.3 e as Figuras 5.3 e 5.4 mostram os valores da relação sinal/ruído estimados para as bandas filtradas HH e HV em função dos tamanhos das janelas de vizinhanças utilizadas na filtragem.

Como pode ser observado, as bandas filtradas que apresentaram uns dos maiores valores da relação sinal/ruído foram aquelas submetidas ao filtro *Gama* com janelas de vizinhança 5x5, 7x7, 9x9, 11x11 e 13x13. Com base uma avaliação visual o filtro com janela 5x5 foi escolhido. Nota-se que este tamanho de janela atende ao critério de escolha definido na metodologia, pois resultou em um dos maiores valores da relação sinal/ruído, com a

menor perda de resolução espacial. As bandas HH e HV filtradas utilizadas nos processamentos futuros serão denominadas HH\_5G e HV\_5G, respectivamente.

Tabela 5.3. Valores estimados para a relação sinal/ruído.

Tamanho da Janela de vizinhança	ENL HH	Relação Sinal/ Ruído HH = $(1,91 \sqrt{ENL})$	ENL HV	Relação Sinal/ Ruído HV = $(1,91 \sqrt{ENL})$
Original	4,26	3,94	4,65	4,12
3x3	14,50	7,27	14,51	7,28
<b>5x5</b>	<b>23,05</b>	<b>9,17</b>	<b>22,87</b>	<b>9,13</b>
<b>7x7</b>	<b>27,45</b>	<b>10,01</b>	<b>25,61</b>	<b>9,67</b>
<b>9x9</b>	<b>28,09</b>	<b>10,12</b>	<b>27,86</b>	<b>10,08</b>
<b>11x11</b>	<b>28,28</b>	<b>10,16</b>	<b>28,41</b>	<b>10,18</b>
<b>13x13</b>	<b>27,56</b>	<b>10,03</b>	<b>28,51</b>	<b>10,20</b>
15x15	27,54	10,02	28,39	10,18
17x17	28,21	10,14	27,31	9,98
19x19	27,56	10,03	26,07	9,75
21x21	27,02	9,93	24,79	9,51
23x23	26,70	9,87	24,20	9,40
25x25	27,31	9,98	23,72	9,30
27x27	26,64	9,86	23,19	9,20
29x29	26,31	9,80	23,02	9,16
31x31	26,31	9,80	22,86	9,13

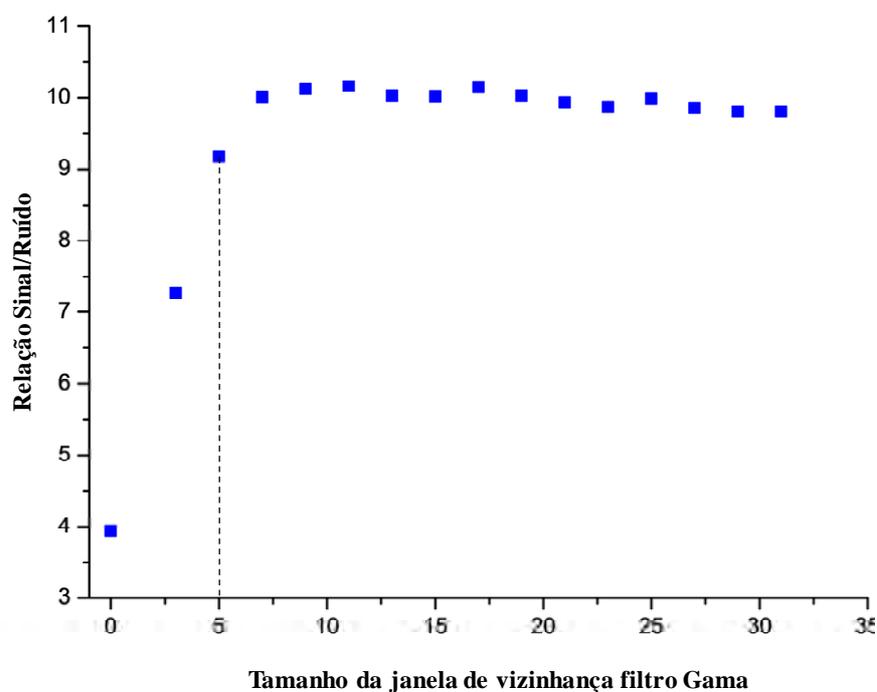


Figura 5.3. Valores estimados para a relação sinal/ruído da banda HH para diferentes tamanhos de janelas de vizinhança.

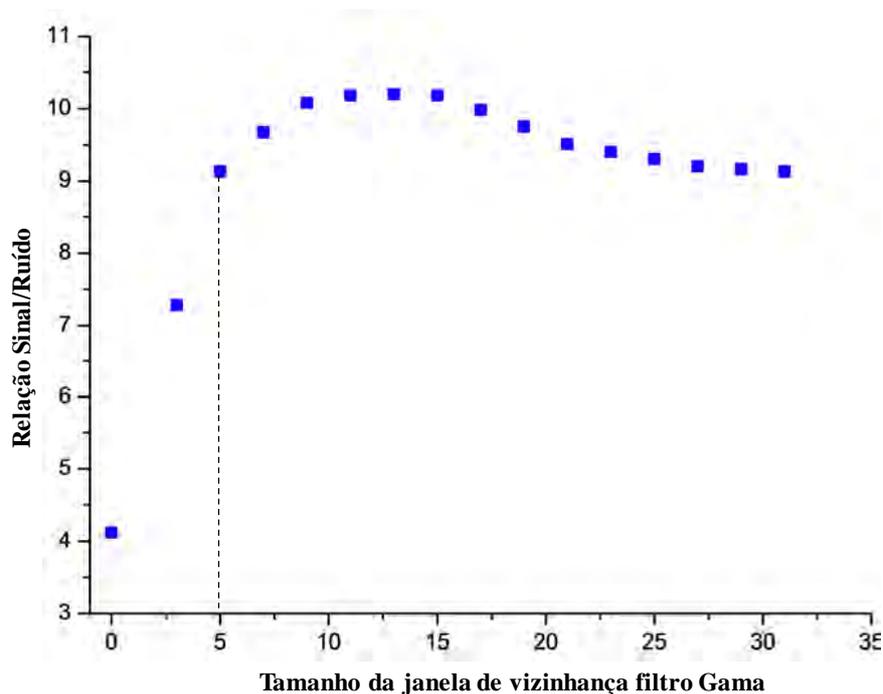


Figura 5.4. Valores estimados para a relação sinal/ruído da banda HV para diferentes tamanhos de janelas de vizinhança.

## 5.6. Extração de atributos SAR e ópticos

### 5.6.1. Extração dos atributos SAR

Como mostrado na seção 4.5.1 os seguintes atributos foram extraídos das bandas originais da imagem ALOS/PALSAR: razão de bandas,  $\sigma^0$ , primeira componente principal, e nove medidas de textura. Para cada medida de textura foi selecionada inicialmente um tamanho de janela de vizinhança. Os resultados deste processo de seleção são apresentados na seção a seguir.

### 5.6.2. Seleção dos tamanhos das janelas de vizinhança das bandas de texturas

No Apêndice B são mostrados, para cada medida de textura, e cada tamanho de janela, os valores da distância JM média e de seus respectivos ganhos em relação à distancia obtida com janela imediatamente menor. Neste apêndice são identificados também os tamanhos de janela selecionados para cada medida de textura e cada polarização. Os resultados desta seleção estão resumidos na Tabela 5.4 e Figura 5.5.

Tabela 5.4. Medidas de texturas seleccionadas.

Medida de textura	Tamanho da janela de vizinhança	Banda da imagem ALOS/PALSAR da qual foram extraídas as medidas de texturas	Sigla	Distância JM média em ordem crescente
Coefficiente de variação	19	HV	CV_19_HV	0,58
Coefficiente de variação	19	HH	CV_19_HH	0,59
Variância	11	HH	VAR_11_HH	0,62
Segundo Momento	13	HH	SM_13_HH	0,75
Contraste	13	HH	CON_13_HH	0,75
Entropia	13	HH	ENT_13_HH	0,78
Variância	7	HV	VAR_7_HV	0,79
Dissimilaridade	15	HH	DIS_15_HH	0,82
Homogeneidade	15	HH	HOM_15_HH	0,85
Correlação	11	HV	COR_11_HV	0,88
Correlação	9	HH	COR_9_HH	0,89
Contraste	11	HV	CON_11_HV	0,91
Entropia	9	HV	ENT_9_HV	0,97
Dissimilaridade	11	HV	DIS_11_HV	0,97
Segundo Momento	11	HV	SM_11_HV	0,98
Homogeneidade	11	HV	HOM_11_HV	0,98
Média	9	HH	MED_9_HH	0,99
Média	7	HV	MED_7_HV	1,08

Das 270 bandas de texturas, foram seleccionadas 18 bandas que são identificadas na Tabela 5.4.

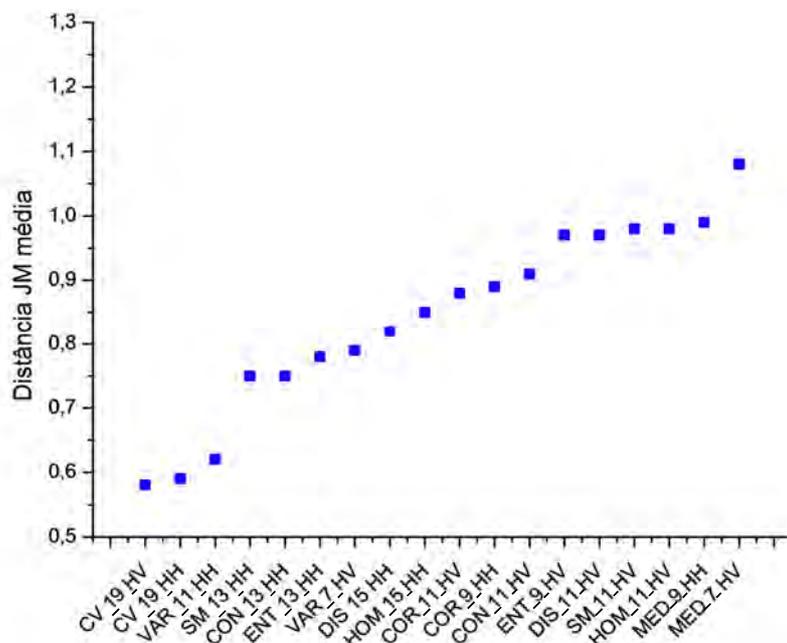


Figura 5.5. Medidas de texturas seleccionadas em ordem crescente da distância JM média.

Observando a Tabela 5.4 e a Figura 5.5, é possível notar que dentre todas as medidas de texturas selecionadas o Coeficiente de Variação foi a que apresentou a maior janela de vizinhança em ambas as bandas (19x19). Em associação a esta análise, também foi observado que ambas as medidas de texturas CV\_19\_HV e CV\_19\_HH resultaram nas menores distâncias JM médias dentre as medidas de texturas selecionadas (Figura 5.5). Pode-se inferir que isto ocorreu devido às características inerentes desta medida de textura, e ao fato desta não levar em consideração em seu cálculo a distribuição espacial dos níveis de cinza de uma região da imagem. Como pode ser observada em duas regiões diferentes nas imagens (Figura 5.6 c e d), esta medida de textura degrada as bordas das classes. Além disto, introduz feições falsas na imagem, como pode ser visualizado nas áreas indicadas pelas setas pretas.

Em contrapartida, a medida de textura que resultou no maior valor da distância JM média, em ambas as bandas, foi a Média de *Haralick* (Figura 5.6 a e b). Nestas figuras é possível perceber que as feições são melhores discriminadas. Acredita-se que este resultado esteja atrelado as características inerentes a esta medida e, por ser uma medida de *Haralick*, leva em consideração em seu cálculo a distribuição espacial dos níveis de cinza de uma região da imagem. Associado a isto os tamanhos das janelas de vizinhança são relativamente pequenos (respectivamente, 9-HV e 7-HH), o que evita a degradação das bordas e o aparecimento de feições falsas na imagem. Como a área de estudo é uma região de fronteira agrícola, nela coexiste áreas de agricultura familiar, que são relativamente pequenas, com áreas de culturas de grãos comerciais (i.e, soja) e pastagens, que são relativamente grandes. Portanto, acredita-se que não é aconselhável utilizar, seja para se processar fusões ou melhorar a visualização de feições, medidas de texturas de imagens SAR com tamanhos de janelas superiores a 15x15, pois a heterogeneidade espacial destas regiões pode ser subjugada.

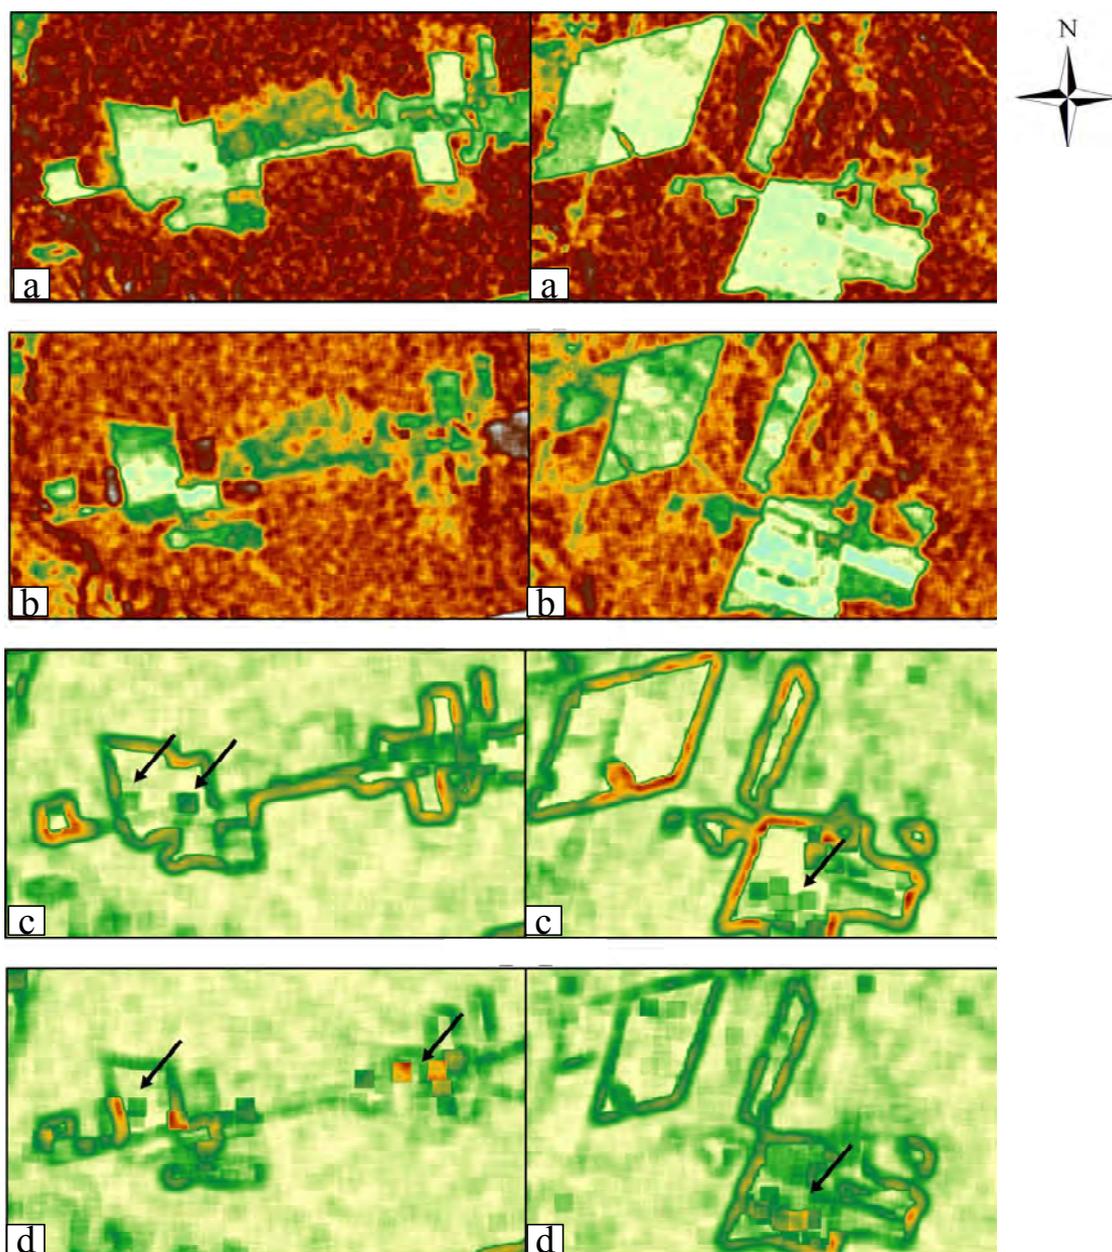


Figura 5.6. Áreas das bandas de textura Média e do Coeficiente de Variação: a) MED\_7\_HV, b) MED\_9\_HH, c) CV\_19\_HV e d) CV\_19\_HH.

### 5.6.3. Atributos ópticos

Os atributos extraídos das bandas ópticas utilizados neste trabalho são descritos na seção 4.5.2 e mostrados na Figura 5.7, em duas áreas distintas da imagem.

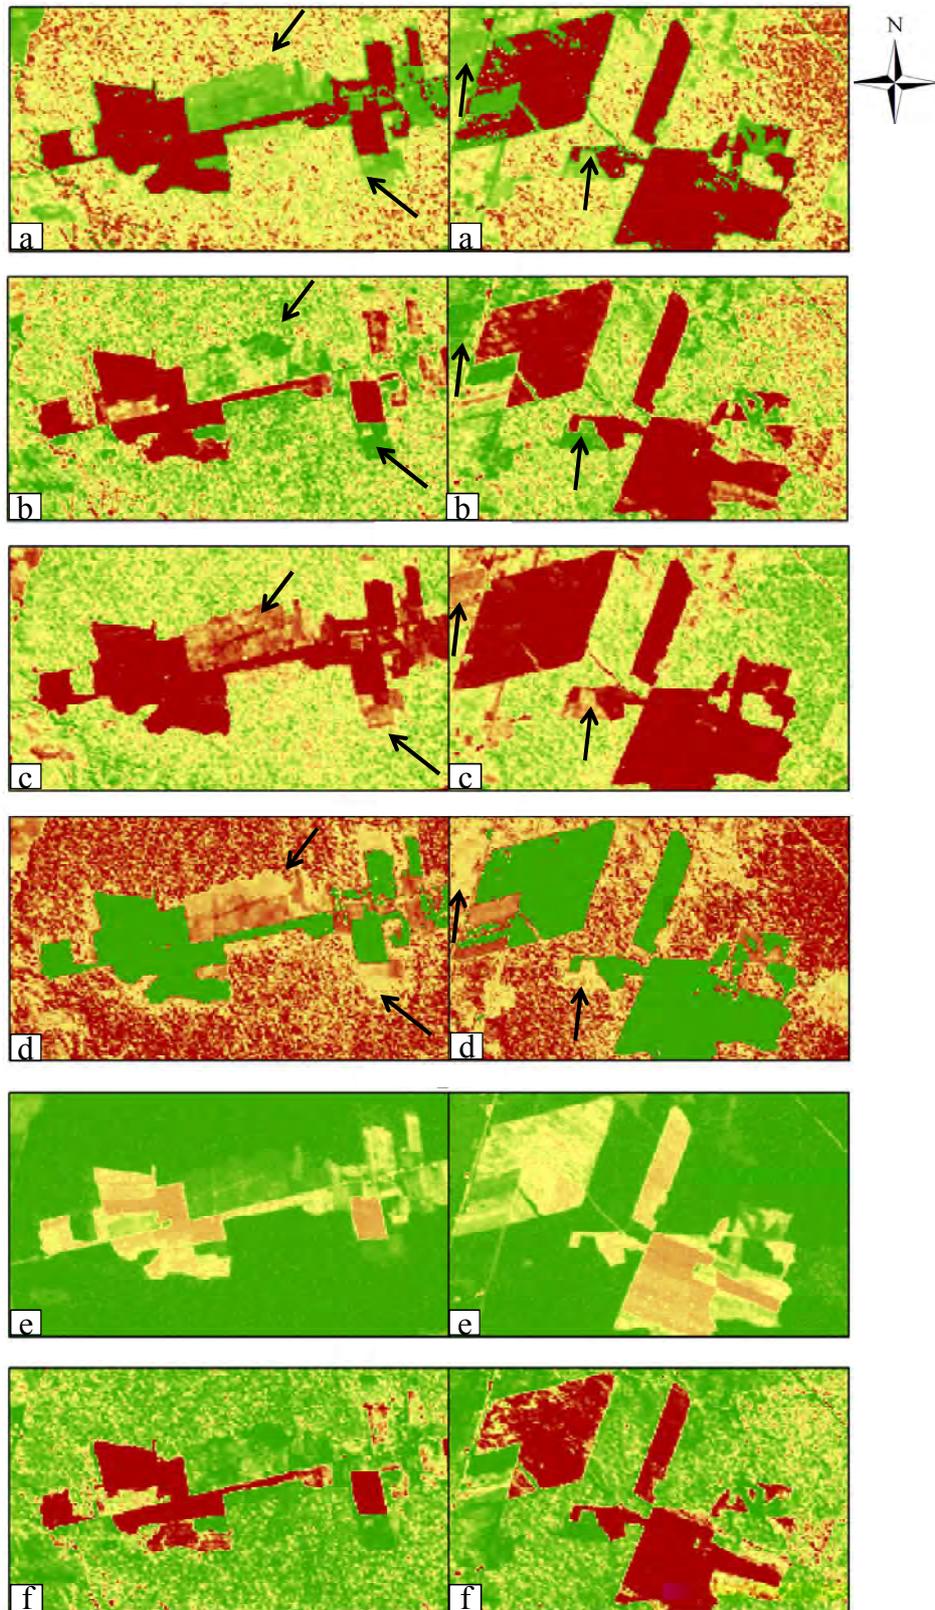


Figura 5.7. Área das bandas dos atributos ópticos: a)  $PC_1$ , b) IMF\_VEG, c) IMF\_SM, d) IMF\_SL, e) NDVI e f) GEMI.

Como pode ser observado todos os atributos parecem discriminar bem as diferentes feições, presentes nestas regiões. Porém, os atributos  $PC_1$ , IMF\_VEG, IMF\_SM e IM\_SL discriminam melhor as classes florestadas e de estágios sucessionais intermediárias como exemplificado nas áreas indicadas pelas setas pretas.

### **5.7. Seleção de atributos**

Em concordância com a metodologia apresentada na seção, 4.6 foi montada uma matriz de correlação dos dados ópticos e SAR (ver Apêndice C), a fim de selecionar dados descorrelacionados para a busca exaustiva de um subconjunto ótimo. No Apêndice D são mostrados os gráficos de média e desvio padrão de todos os atributos em função das 13 classes de interesse, pois eles auxiliaram na seleção dos atributos ópticos e SAR.

Os valores das distâncias JM média são mostrados na Figura 5.8 para os 25 atributos de radar e na Figura 5.9 para os 12 atributos ópticos. Pode-se observar que os atributos de radar com maiores distâncias JM médias são os atributos MED\_7\_HV, NL, HV\_5G, e  $PC_{1HH\_HV}$ . Entretanto, uma análise da Tabela do Apêndice C mostra que estes atributos são altamente correlacionados. Analogamente, observa-se uma alta correlação entre os atributos ópticos com maiores distâncias JM médias ( $PC_{1TM}$ , B5, B2 e IMF\_SL). Uma análise mais detalhada destas correlações é feita na seção a seguir, para a seleção dos atributos.

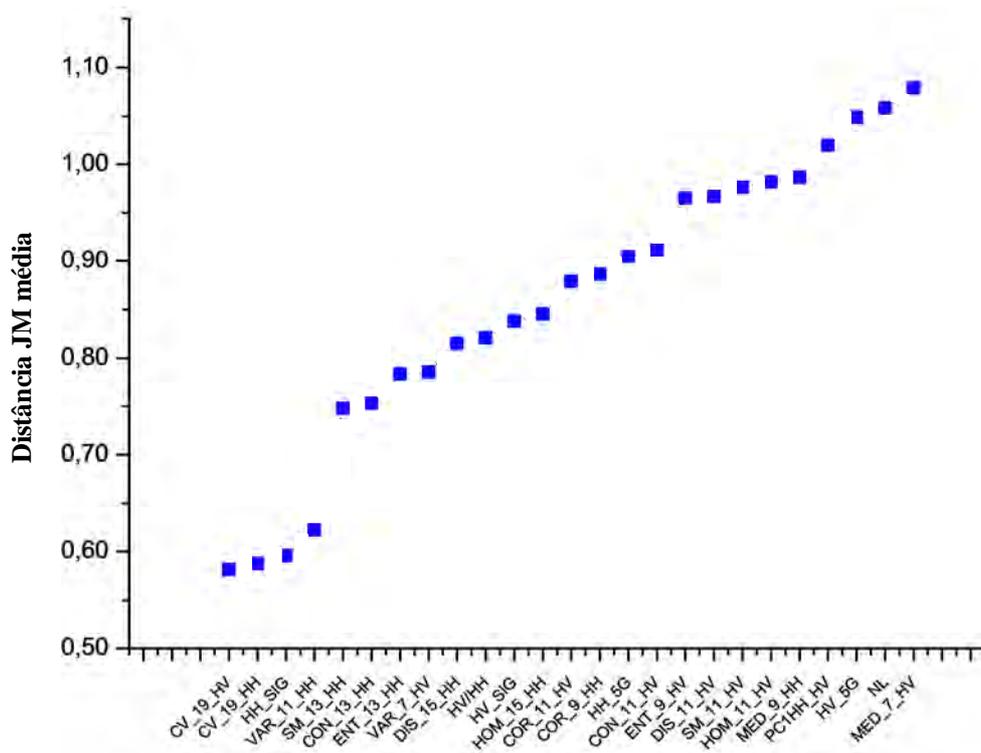


Figura 5.8. Valores da distância JM média para os atributos SAR.

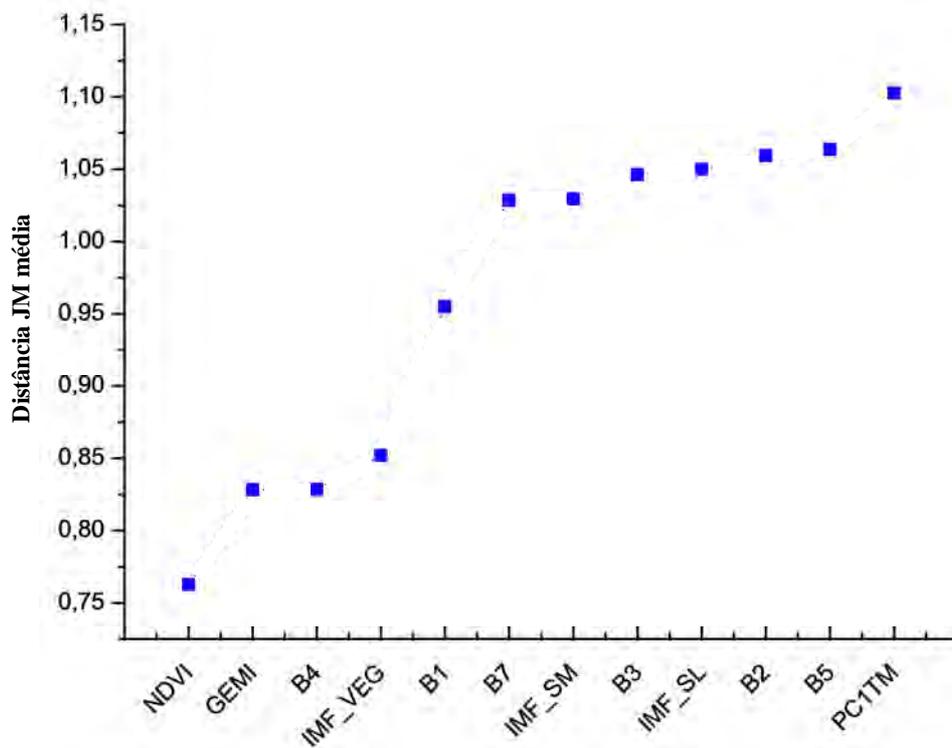


Figura 5.9. Valores da distância JM média para os atributos ópticos.

### 5.7.1. Seleção de atributos SAR

Baseado no processo de seleção descrito na seção 4.6, nesta seção será mostrado o resultado da seleção do subconjunto de atributos SAR que participarão das combinações e dos processos de fusão de imagens. Como as bandas HH e HV filtradas irão participar de todos os processos de fusões e combinações, estas bandas foram previamente excluídas do processo de seleção bem como suas respectivas bandas  $\sigma^0$ .

Como pode ser observado na Figura 5.8 o atributo SAR que resultou na maior distância JM média foi o MED\_7\_HV (1,08), sendo assim foram excluídos todos os atributos que possuíam uma correlação superior a 0,80 com este atributo (NL, PC<sub>1</sub>HH\_HV, MED\_9\_HH, DIS\_11\_HV e ENT\_9\_HV). O próximo atributo que apresentou a maior distância JM média foi o HOM\_11\_HV. Este atributo é altamente correlacionado com o atributo SM\_11\_HV (0,84), sendo assim este último atributo também foi excluído. Seguindo este processo, os próximos maiores valores da distância JM média foram observados nos atributos CON\_11\_HV, COR\_9\_HH, COR\_11\_HV, HOM\_15\_HH e HV/HH sendo que estes não apresentaram nenhuma correlação com outros atributos acima de 0,80, portanto estes atributos foram selecionados para participar da busca exaustiva. O próximo atributo da lista foi o DIS\_15\_HH, sendo que este apresentou uma correlação com o atributo ENT\_13\_HH e CON\_13\_HH acima de 0,80, sendo assim estes dois últimos atributos foram também excluídos. Os atributos VAR\_7\_HV, SM\_13\_HH e VAR\_11\_HH, não apresentaram correlação acima de 0,80 com nenhum atributo e foram, portanto, selecionados. Finalmente, foi excluído o atributo CV\_19\_HV, por possuir correlação de 0,85 com CV\_19\_HH e menor valor da distância JM. Em resumo, foram selecionados 12 atributos (MED\_7\_HV, HOM\_15\_HH, DIS\_15\_HH, CV\_19\_HH, CON\_11\_HV, COR\_9\_HH, VAR\_7\_HV, VAR\_11\_HV, HV/HH, HOM\_11\_HV, SM\_13\_HH, CON\_11\_HV) para participar da busca exaustiva, a qual é descrita na seção 4.6.

Após o cálculo da distância média JM para as  $(2^{12} - 1)$  combinações (equação 4.9), foi escolhido o subconjunto ótimo com  $n$  atributos ( $n = 1, \dots, 12$ ), através da equação 4.10. Os resultados desse processo são mostrados na Tabela 5.5 e Figura 5.10. Também são

apresentados, em porcentagem, os respectivos valores do ganho da maior distância JM média de um subconjunto com  $n$  atributos em relação à maior distância JM média do subconjunto com  $n-1$  atributos.

O subconjunto ótimo, segundo o critério descrito pela equação 4.11, é o subconjunto formado pelos atributos **MED\_7\_HV**, **HOM\_15\_HH**, **DIS\_15\_HH**, **CV\_19\_HH**, **COR\_11\_HV** e **COR\_9\_HH**. Este subconjunto está realçado em negrito na Tabela 5.5 e pelas setas na Figura 5.10.

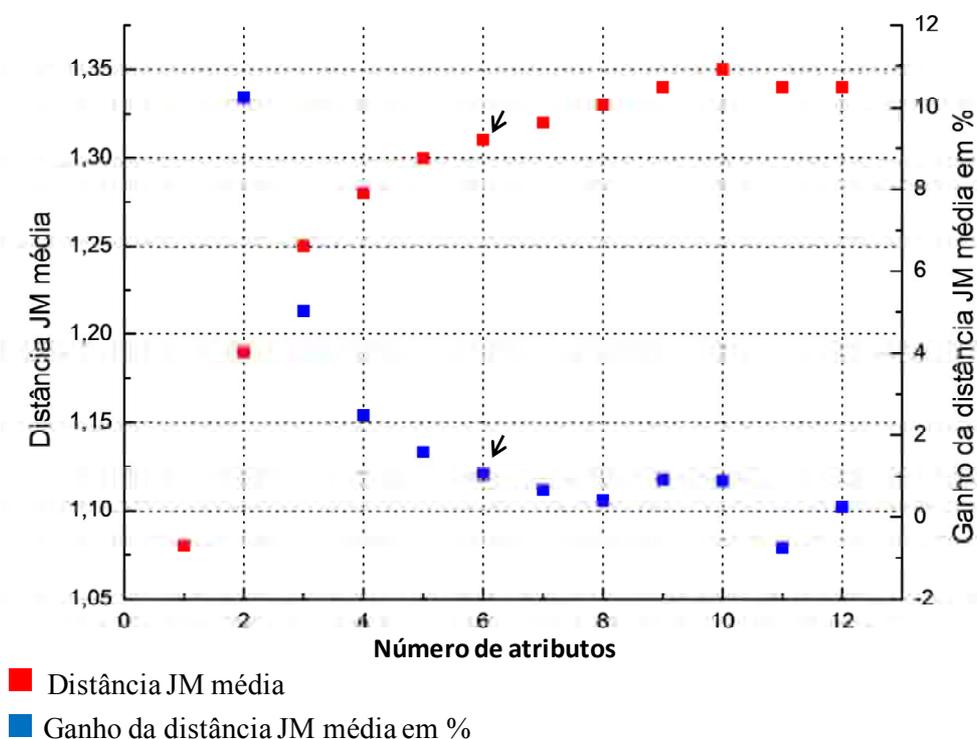


Figura 5.10. Seleção de um subconjunto ótimo de atributos SAR.

Entretanto, ao se observar os gráficos de média e desvio padrão destes atributos, foi possível notar que as medidas de textura **CV\_19\_HH**, **COR\_11\_HV** e **COR\_9\_HH** não apresentaram satisfatória separabilidade entre as 13 classes de interesse (Figura 5.11). Aliado a isto é possível notar nas imagens destes atributos o surgimento de feições falsas como exemplificado nas áreas indicadas pelas setas pretas nas Figuras 5.11 a, b e c. O surgimento destas feições falsas pode ser um dos fatores que colaboraram com a confusão entre as classes de interesse visualizadas nos gráficos de média e desvio padrão.

Tabela 5.5. Seleção de um subconjunto ótimo de atributos SAR.

Números de atributos (n)	Números de subconjuntos possíveis de serem formados com $n$ atributos	Atributos											Distância JM média	Ganho da distância JM média (%)			
(n)	$\binom{12}{n}$																
1	12	MED_7_HV											1,08				
2	66	MED_7_HV	HOM_15_HH										1,19	10,24			
3	220	MED_7_HV	HOM_15_HH	DIS_15_HH								1,25	5,02				
4	495	MED_7_HV	HOM_15_HH	DIS_15_HH	CV_19_HH						1,28	2,47					
5	792	MED_7_HV	HOM_15_HH	DIS_15_HH	CV_19_HH	COR_11_HV						1,30	1,58				
<b>6</b>	<b>924</b>	<b>MED_7_HV</b>	<b>HOM_15_HH</b>	<b>DIS_15_HH</b>	<b>CV_19_HH</b>	<b>COR_11_HV</b>	<b>COR_9_HH</b>						<b>1,31</b>	<b>1,04</b>			
7	792	MED_7_HV	HOM_15_HH	DIS_15_HH	CV_19_HH	COR_11_HV	COR_9_HH	VAR_7_HV					1,32	0,66			
8	495	MED_7_HV	HOM_15_HH	DIS_15_HH	CV_19_HH	COR_11_HV	COR_9_HH	VAR_7_HV	VAR_11_HV				1,33	0,40			
9	220	MED_7_HV	HOM_15_HH	DIS_15_HH	CV_19_HH	CON_11_HV	SM_13_HH	HOM_11_HV	VAR_11_HV	HV/HH			1,34	0,92			
10	66	MED_7_HV	HOM_15_HH	DIS_15_HH	CV_19_HH	CON_11_HV	SM_13_HH	VAR_7_HV	VAR_11_HV	HV/HH	HOM_11_HV			1,35	0,89		
11	12	MED_7_HV	HOM_15_HH	DIS_15_HH	CV_19_HH	COR_11_HV	COR_9_HH	VAR_7_HV	VAR_11_HV	CON_11_HV	HOM_11_HV	SM_13_HH			1,34	-0,76	
12	1	MED_7_HV	HOM_15_HH	DIS_15_HH	CV_19_HH	CON_11_HV	COR_9_HH	VAR_7_HV	VAR_11_HV	HV/HH	HOM_11_HV	SM_13_HH	CON_11_HV			1,34	0,23

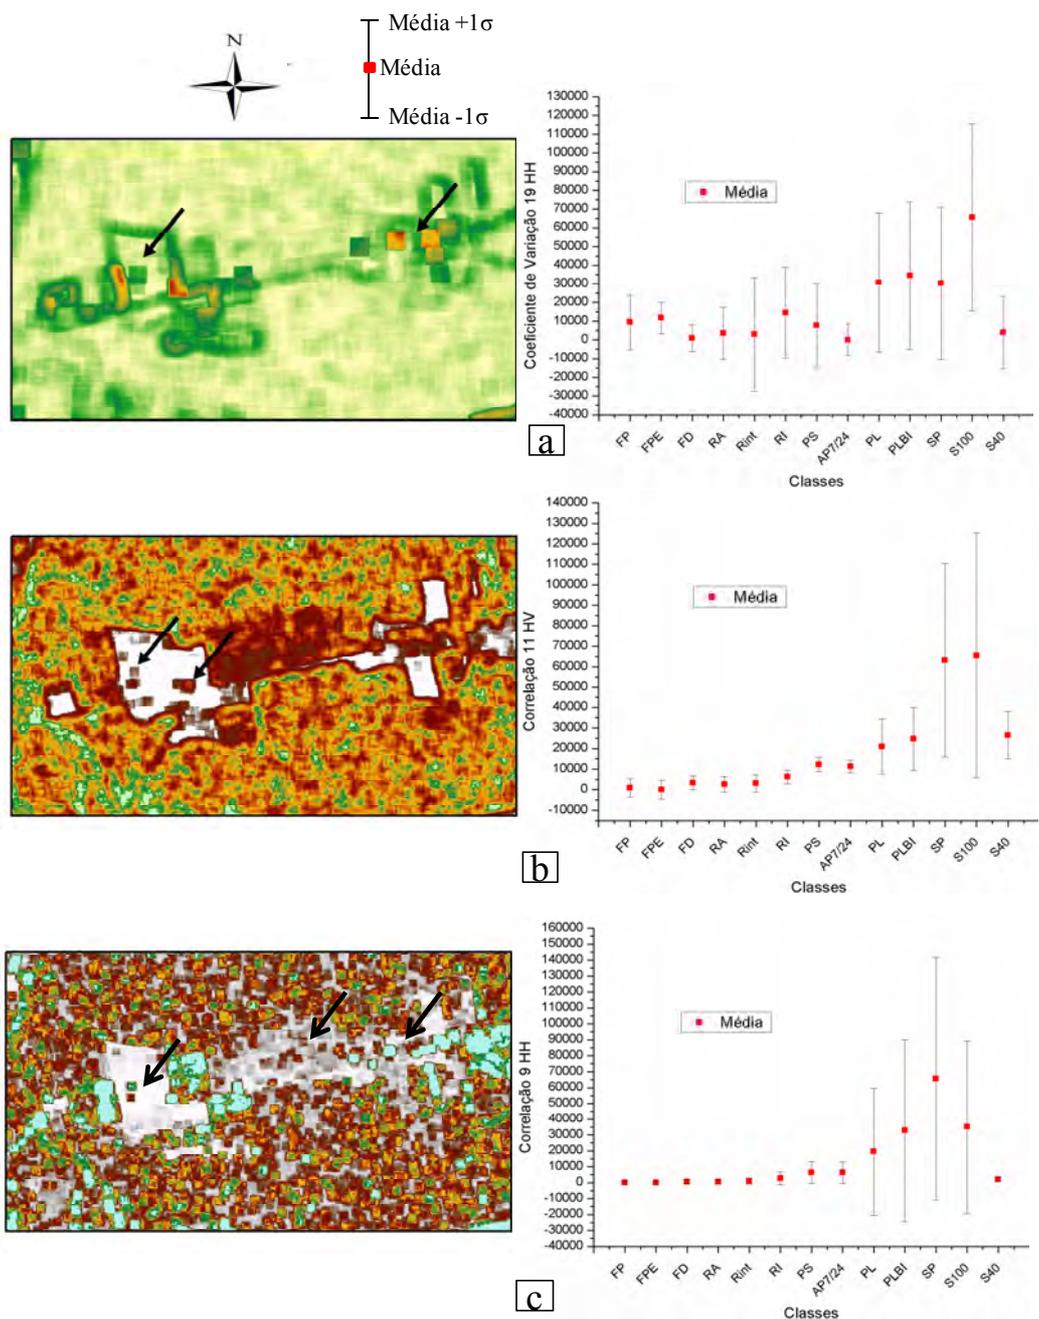


Figura 5.11. Atributos SAR para uma parte da área de estudo e respectivos gráficos da média e desvio padrão das classes de interesse: a) CV\_19\_HH, b) COR\_11\_HV e c) COR\_9\_HH.

Após estas análises foram selecionados três atributos SAR (MED\_7\_HV, HOM\_15\_HH e DIS\_15\_HH) para participarem das combinações e dos processos de fusão de imagens. A Figura 5.12 apresenta estes atributos para uma parte da área em estudo, assim como os respectivos gráficos das médias e dos desvios padrões das classes de interesse. Pode-

se observar através destes gráficos que estes atributos permitem uma melhor separabilidade de algumas classes do que os atributos ilustrados na Figura 5.11. Uma análise mais detalhada desta separabilidade é feita na seção 5.8, em conjunto com os atributos ópticos.

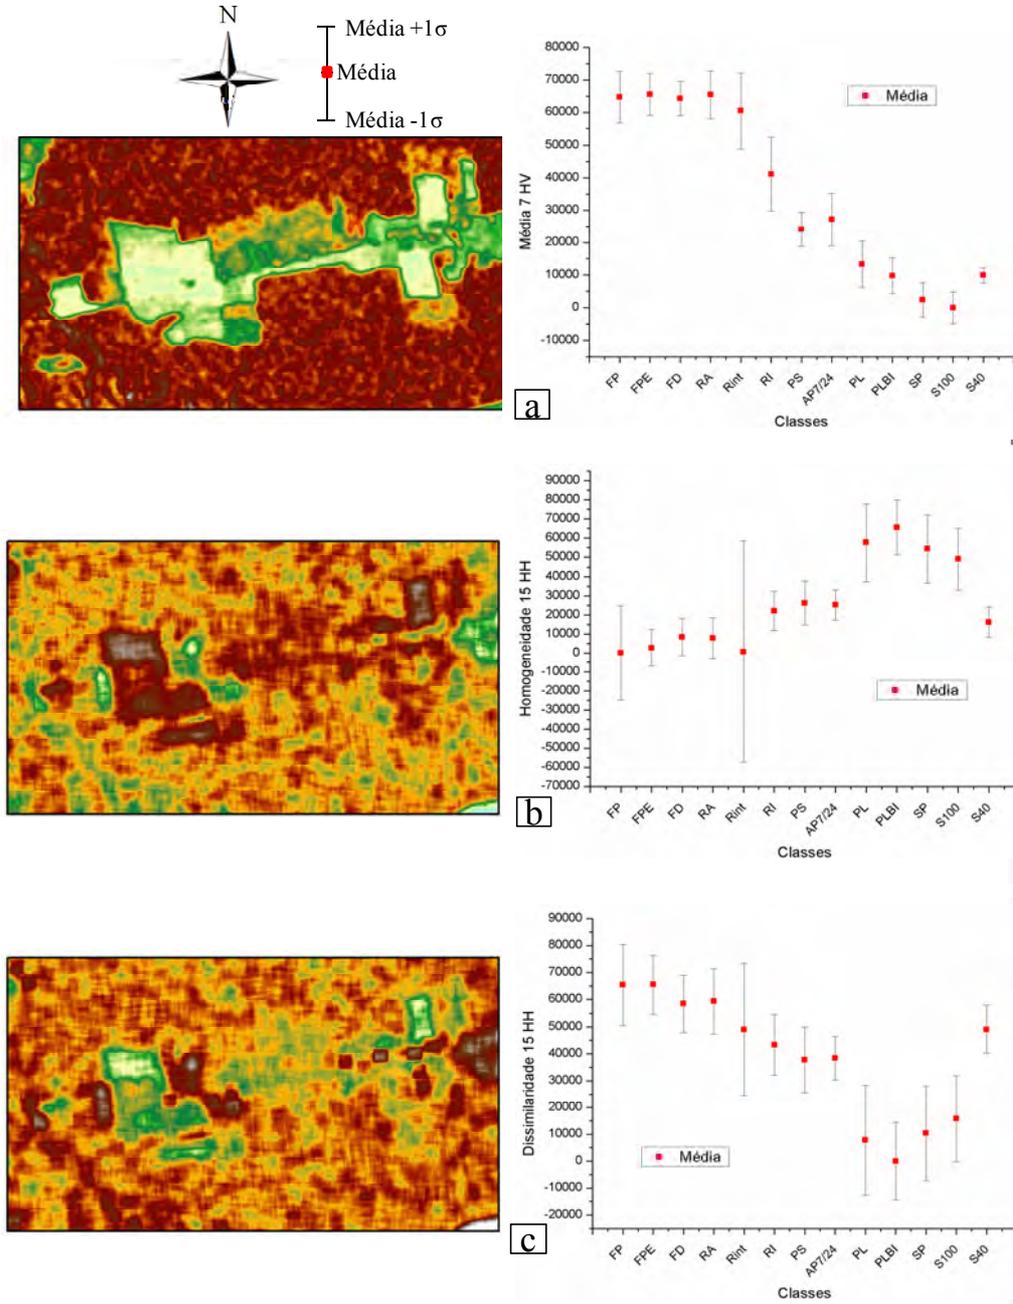


Figura 5.12. Atributos SAR selecionados para análises e processamentos futuros com os respectivos gráficos de média e desvio padrão das classes em estudo: a) MED\_7\_HV, b) HOM\_15\_HH e c) DIS\_15\_HH.

### 5.7.2. Seleção de atributos ópticos

Analisando-se a Figura 5.9, o primeiro atributo óptico a ser selecionado deverá ser a primeira PC das bandas da imagem LANDSAT5/TM. Entretanto, como ela é altamente correlacionada com o atributo B5 (correlação de -0,98), optou-se pela seleção deste último atributo, uma vez que ele também possui uma alta distância JM média e por ser formado por uma única banda, enquanto que para o cálculo da primeira PC seria necessária a utilização de todas as bandas da imagem LANDSAT5/TM.

Analogamente ao procedimento descrito para os dados SAR, todos os demais atributos que resultaram em uma correlação superior a 0,80 com a banda 5 foram excluídos do processo de seleção (B2, IMF\_SL, B3, IMF\_SM, B7 e B1). Os atributos IMF\_VEG e B4 são altamente correlacionados (0,97), mas IMF\_VEG foi o atributo selecionado por possuir maior distância JM média.

Os índices NDVI e GEMI não possuem dados correlacionados com nenhuma das bandas selecionadas, eles também seriam selecionados. Entretanto, após a observação dos gráficos dos atributos ópticos foi verificado que estes dois atributos não apresentam uma separabilidade satisfatória das classes de interesse se comparado com os demais atributos (ver Figuras D2. 11 e D2. 12 do Apêndice D). Este fato está em concordância com os valores das distâncias JM médias, pois são os atributos com os valores mais baixos (ver Figura 5.9). Sendo assim, ambos os atributos foram excluídos do processo de seleção.

Dado o exposto, apenas os atributos IMF\_VEG e B5 são selecionados. Nota-se que estes atributos possuem uma baixa correlação (0,25). No entanto, para que todas as fusões possam ser realizadas são necessários pelo menos três atributos. Para tanto, os atributos correlacionados que resultaram em valores relativamente altos da distância JM foram cotados para compor o terceiro membro dos atributos ópticos (B1, B2, B3, B7, IMF\_SL e IMF\_SM).

Para a seleção do terceiro atributo, foi efetuada uma análise exploratória da separabilidade destes atributos, através dos gráficos de média e desvio padrão em função das 13 classes de interesse. Na Figura 5.13 são apresentados estes gráficos,

ressaltando-se, visualmente o grupo de classes que, eventualmente, poderiam ser separados por cada atributo. É possível notar que o atributo IMF\_SM é o único que apresenta visivelmente maior separabilidade nas classes florestadas (FP, FPE, FD, RA, Rint e RI) além de ser o atributo que separa visualmente o maior número de classes. Portanto, pela análise da Figura 5.13, foi selecionado como terceiro atributo IMF\_SM.

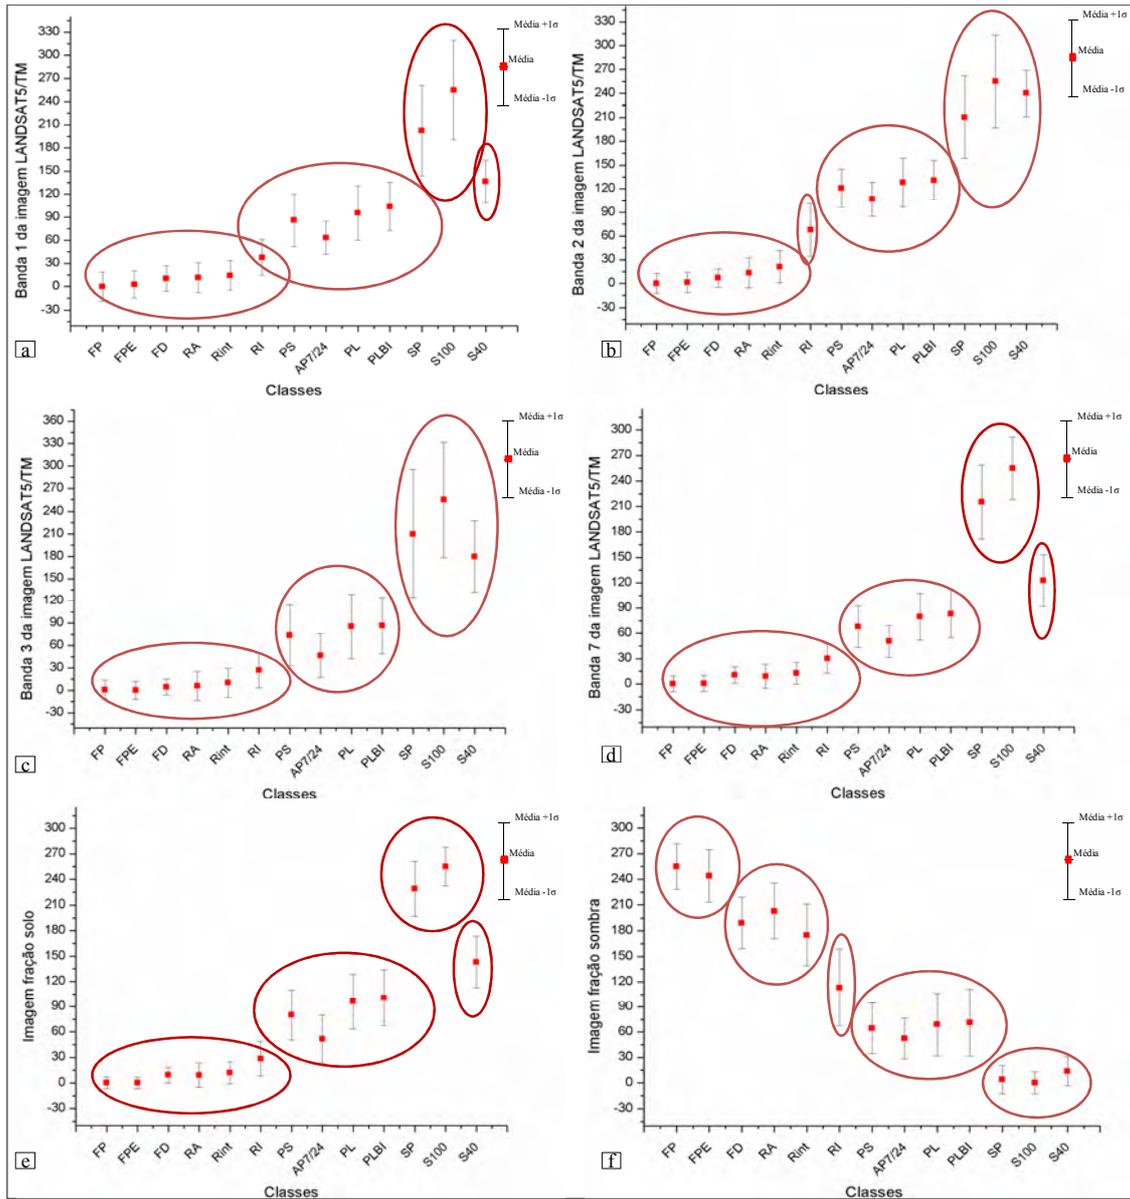


Figura 5.13. Gráficos de média e desvio padrão das classes em estudo para os atributos ópticos: a) B1, b) B2, c) B3, d) B7, e) IMF\_SL e f) IMF\_SM.

Então finalmente foram selecionados 3 atributos ópticos para participarem das combinações e dos processos de fusão de imagens. Cabe ressaltar que as fusões que utilizam o método IHS os atributos ópticos foram compostos da seguinte forma no espaço de cores: R(B5), G(IMF\_VEG), B(IMF\_SM).

### **5.8. Análise exploratória dos dados que participaram dos processos de fusão**

Esta seção tem por objetivo efetuar uma análise exploratória de todos os atributos ópticos e SAR que participaram dos processos de fusão e de combinação de imagens. Como apresentado na Tabela 5.1, essas fusões foram efetuadas utilizando-se as imagens originais (ópticas e radar filtradas), os atributos selecionados descritos na seção 5.7 (três ópticos e três SAR) e a primeira componente principal dos dados SAR, tanto originais (PC<sub>1</sub>HH\_HV) quanto dos atributos selecionados (PC<sub>1</sub>SAR<sub>3</sub>). Portanto, nas análises que se seguem foram utilizados 15 gráficos de média e desvio padrão sendo que 8 são dos atributos ópticos (B1, B2, B3, B4, B5, B7, IMF\_VEG e IMF\_SM) e 7 dos atributos SAR (HH\_5G, HV\_5G, PC<sub>1</sub>HH\_HV, MED\_7\_HV, HOM\_15\_HH, DIS\_15\_HH e PC<sub>1</sub>SAR<sub>3</sub>). Além destes gráficos também foram gerados 15 gráficos de média e desvio padrão com todas as possíveis combinações 2 a 2 dos 6 atributos ópticos e SAR selecionados na seção 5.7. Estes 30 gráficos são mostrados no Apêndice E.

Analisando-se os citados gráficos pode-se constatar que a confusão entre as classes varia de acordo com o atributo, ou seja, existem atributos que são, em teoria, melhores para discriminar as classes de interesse. Neste cenário tem destaque a banda HV\_5G, a medida de textura MED\_7\_HV e a primeira PC extraída tanto a partir das bandas da imagem ALOS/PALSAR (PC<sub>1</sub>HH\_HV) quanto dos 3 atributos SAR selecionados (PC<sub>1</sub>SAR<sub>3</sub>). Os gráficos de média e desvio padrão das classes de interesse são ilustrados na Figura 5.14. As elipses nesta figura agrupam as classes com maior confusão entre si. Os referidos atributos apresentaram menor confusão entre as classes não florestadas como PS, AP7/24, PL, PLBI, SP, S100 e S40. Entretanto, não foi possível observar o mesmo desempenho nas classes florestadas como FP, FPE, FD, RA e Rint sendo que este fato também é observado nos demais atributos SAR (ver Figuras do Apêndice E).

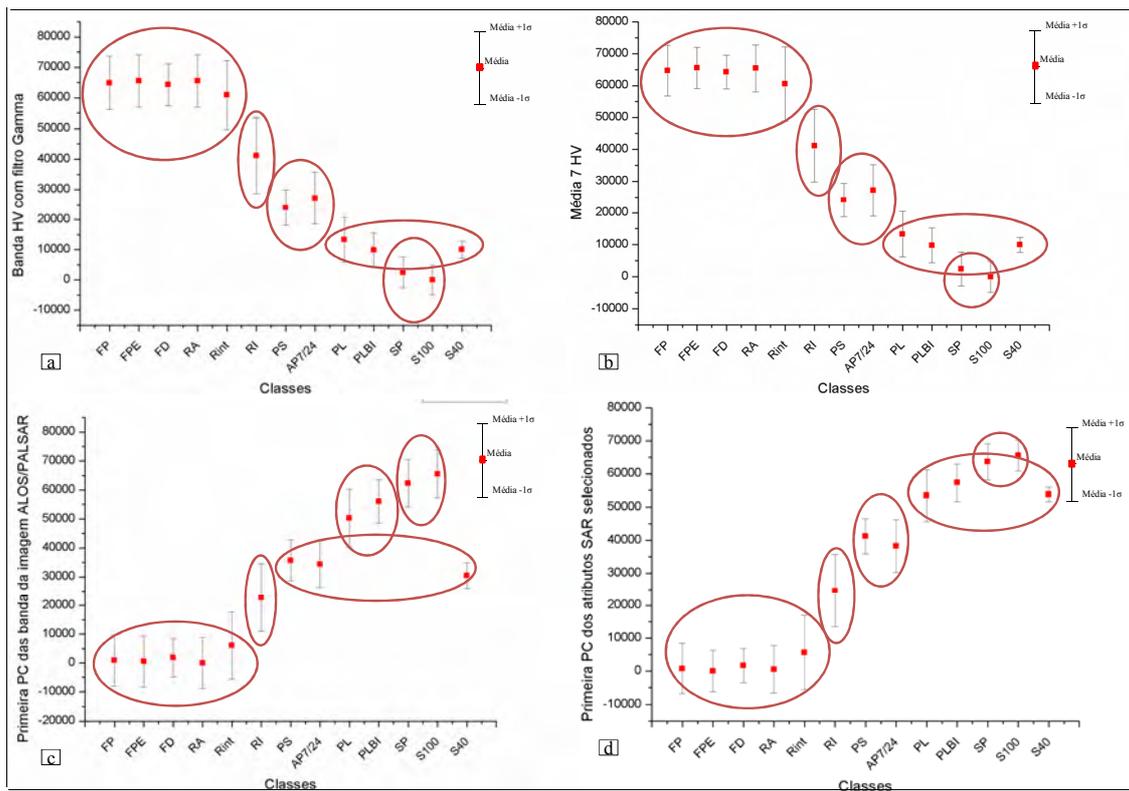


Figura 5.14. Gráficos de média e desvio padrão das classes em estudo para os atributos SAR: a) HV\_SIG, b) MED\_7\_HH, c) PC<sub>1</sub>HH\_HV e d) PC<sub>1</sub>SAR<sub>3</sub>.

Os dados ópticos analisados apresentaram a mesma característica dos atributos SAR, ou seja, no geral a confusão entre as classes varia de acordo com o atributo. Neste cenário tem destaque a banda 5 (B5) da imagem LANDSAT5/TM e o atributo referente a imagem fração sombra (IMF\_SM), pois os gráficos mostraram menor confusão entre as 13 classes de interesse, destacando-se a discriminação para as classes não florestadas como PS, AP7/24 PL, PLBI, SP, S100 e S40 (Figura 5.15). Nota-se que o atributo IMF\_SM também se destacou na discriminação das classes florestadas FP, FPE, FD, RA e Rint, pois foi o atributo óptico que apresentou separabilidade dentre estas classes.

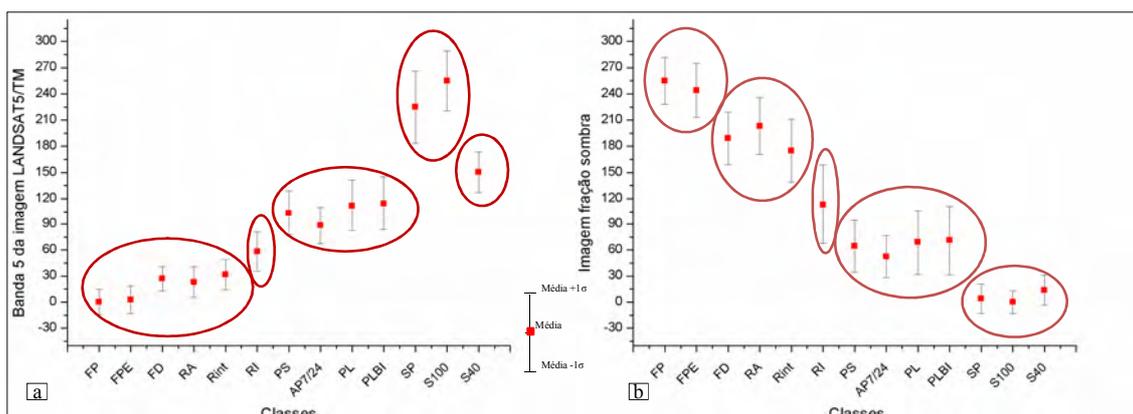


Figura 5.15. Gráficos de média e desvio padrão das classes de interesse para os atributos ópticos: a) B5 e b) IMF\_SM.

Os gráficos de média e desvio padrão das classes em estudo formadas por pares de atributos também mostraram que a confusão entre as classes varia dependendo dos atributos. Os pares de atributos que culminaram em uma maior confusão entre as classes, ou em outras palavras, que resultaram em um menor número de classes possíveis de serem separadas foram: DIS\_15\_HH, IMF\_VEG; HOM\_15\_HH, IMF\_VEG; DIS\_15\_HH e HOM\_15\_HH. Na Figura 5.16 são mostrados os gráficos destes 3 pares de atributos, onde são marcadas o valor médio de cada classe de interesse e seu respectivo desvio padrão. Nestes gráficos as elipses são geradas a partir dos valores de um desvio padrão, onde cada semieixo da elipse tem valor de um desvio padrão da classe para o atributo.

Nota-se assim, que todos os pares de atributos em análise envolvem os atributos extraídos das medidas de texturas HH. Então, conclui-se que a utilização destes pares de atributos provavelmente não irá proporcionar boa separabilidade das classes de interesse.

Em contrapartida, foi possível observar a importância do atributo MED\_7\_HV, pois além de apresentar a maior distância JM média dentre os demais atributos SAR, os gráficos mostram que quando se associa este atributo aos demais atributos SAR extraídos da banda HH diminui a confusão entre as 13 classes. Este fato pode ser verificado através da

Figura 5.17, que mostra as médias e os desvios padrões das classes de interesse para os pares de atributos MED\_7\_HV versus DIS\_15\_HH e MED\_7\_HV versus HOM\_15\_HH.

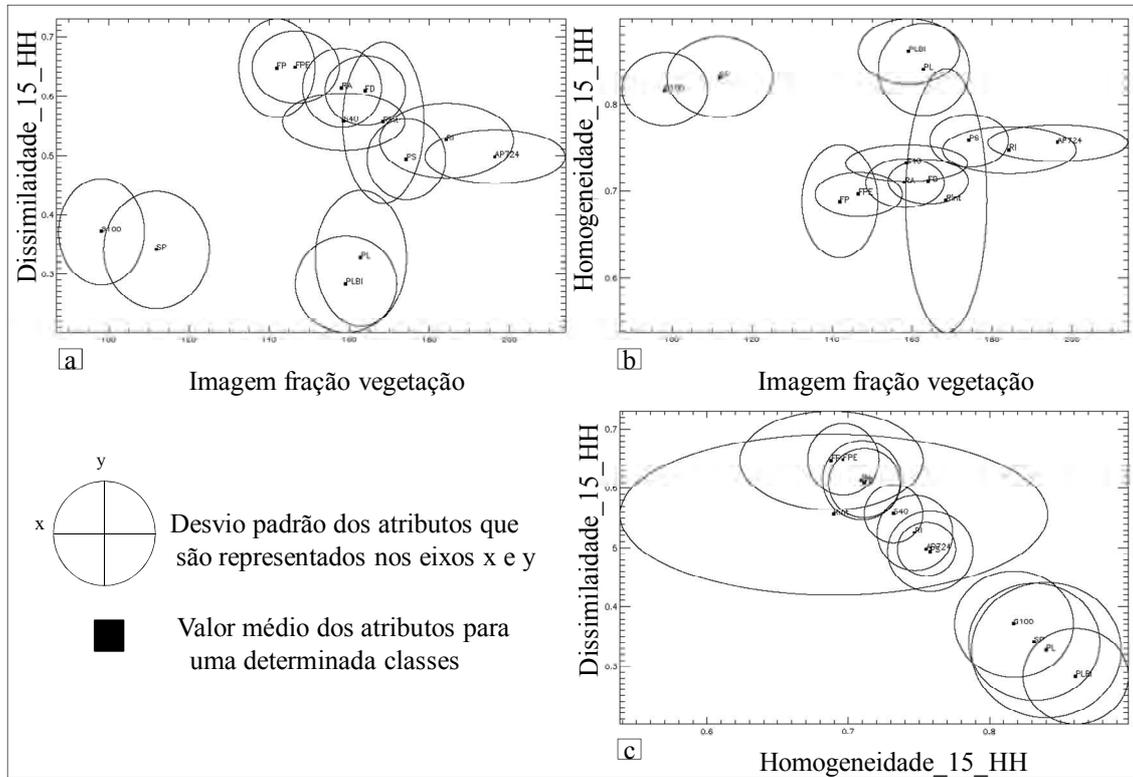


Figura 5.16. Gráficos de média e desvio padrão dos pares de atributos: a) DIS\_15\_HH e IMF\_VEG, b) HOM\_15\_HH e IMF\_VEG, c) DIS\_15\_HH e HOM\_15\_HH.

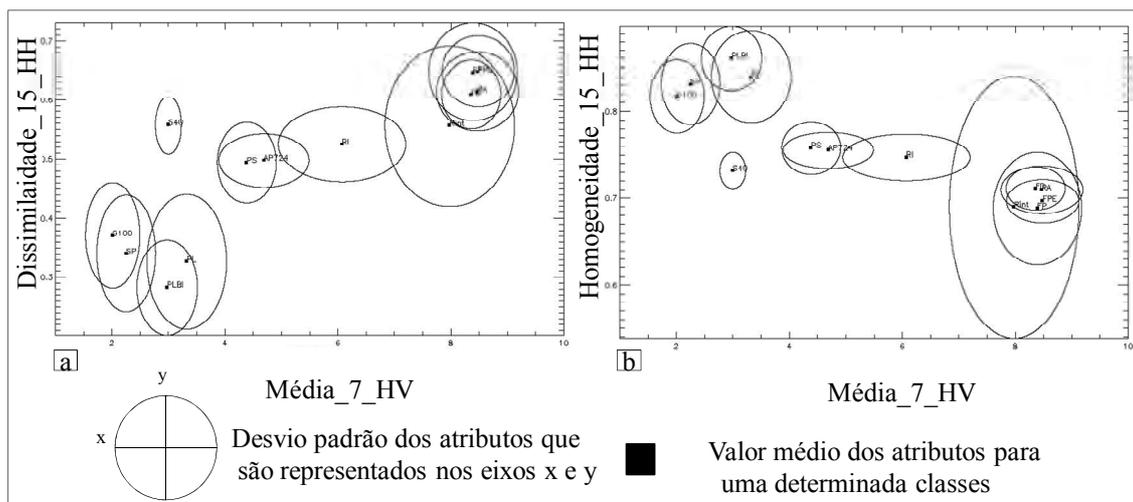


Figura 5.17. Gráficos de média e desvio padrão dos pares de atributos: a) DIS\_15\_HH e MED\_7\_HV, b) HOM\_15\_HH e MED\_7\_HV.

Nos demais gráficos de médias e desvio padrão da Figura 5.18 formados por pares de atributos ópticos e SAR foi possível agrupar visualmente as 13 classes em estudo em 7 classes. Nota-se que dentre estes 7 gráficos, 6 apresentaram o mesmo tipo de agrupamento de classes: FP+FPE, FD+RA+Rint, RI, PS+AP7/24, PL+PLBI, S100+SP e S40. Coincidentemente, estes 6 gráficos são formados pelos 3 atributos SAR (DIS\_15\_HH, HOM\_15\_HH e MED\_7\_HV) associados aos atributos ópticos selecionados IMF\_SM e B5. Este fato mostra que a utilização conjunta destes atributos pode melhorar a discriminação das classes de interesse.

Quando os gráficos de média e desvio padrão são formados por pares de atributos ópticos, no geral, apresentam boa separabilidade das classes de interesse, sendo que neste cenário tem destaque os gráficos formados pelos atributos B5 e IMF\_VEG e pelos atributos IMF\_SM e IMF\_VEG. Nota-se que estes pares de atributos resultaram na maior separabilidade das classes de interesse, sendo possível agrupar visualmente as 13 classes em 8 classes como ilustrado na Figura 5.19.

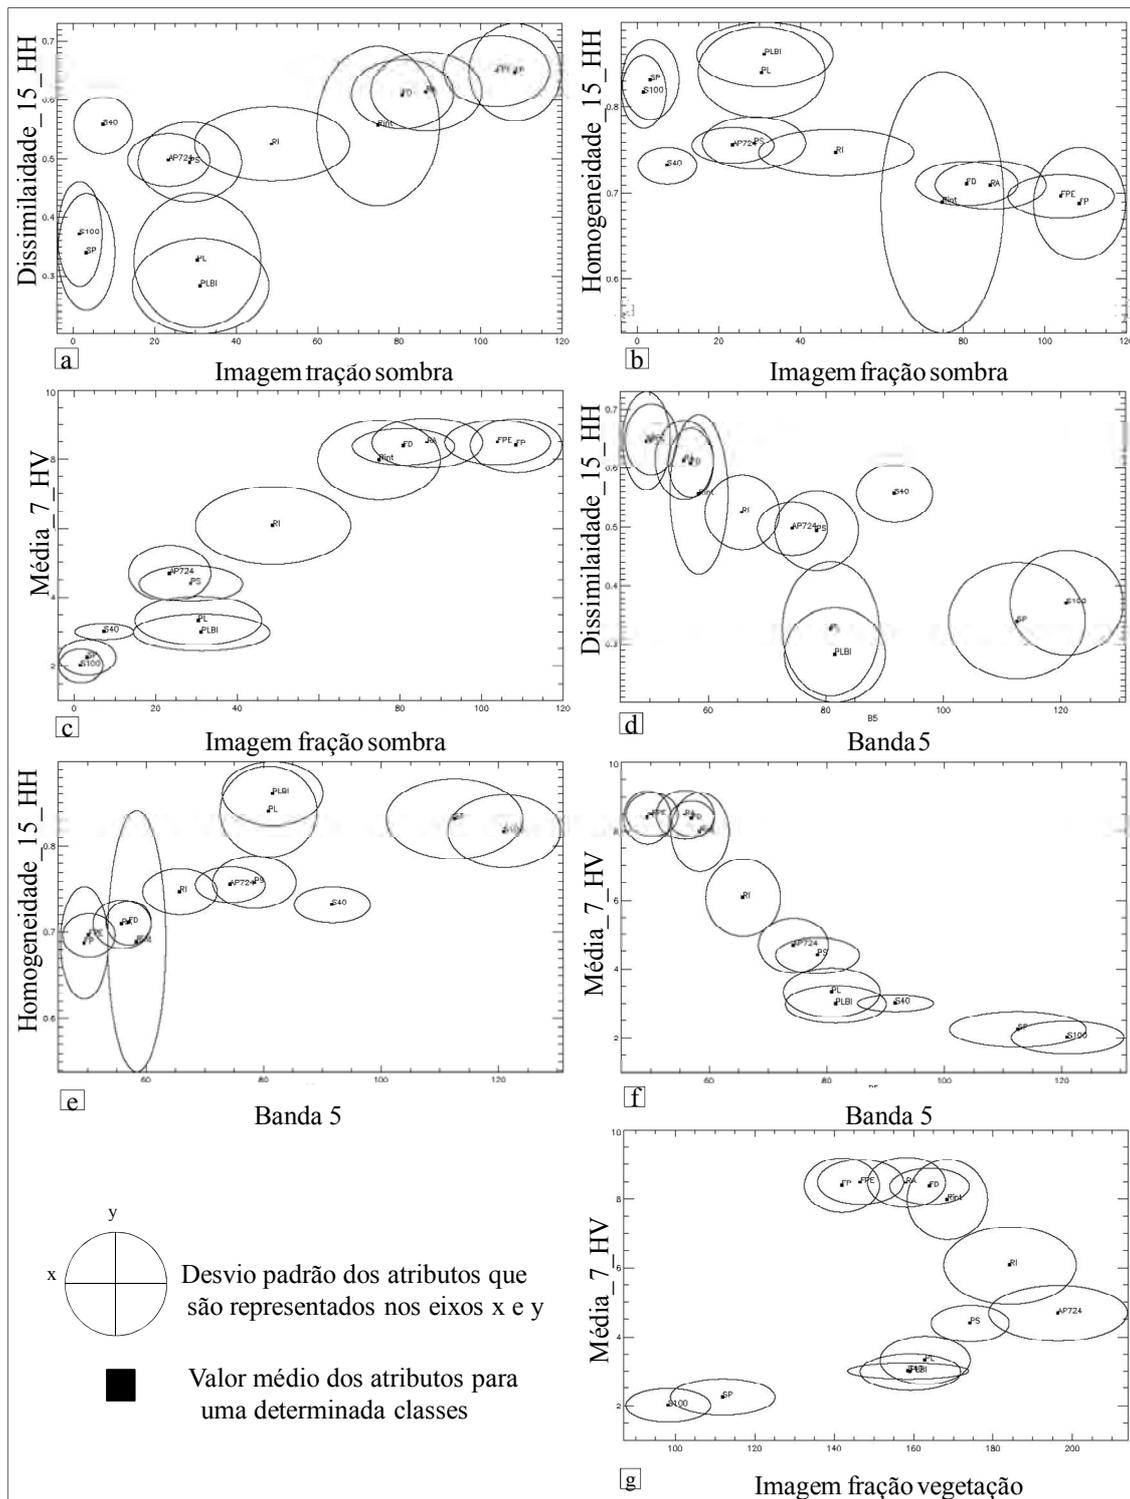


Figura 5.18. Gráficos de média e desvio padrão dos pares de atributos: a) DIS\_15\_HH e IMF\_SM, b) HOM\_15\_HH e IMF\_SM, c) MED\_7\_HV e IMF\_SM, d) DIS\_15\_HH e B5, e) HOM\_15\_HH e B5 f) MED\_7\_HV e B5, g) MED\_7\_HV e IMF\_VEG.

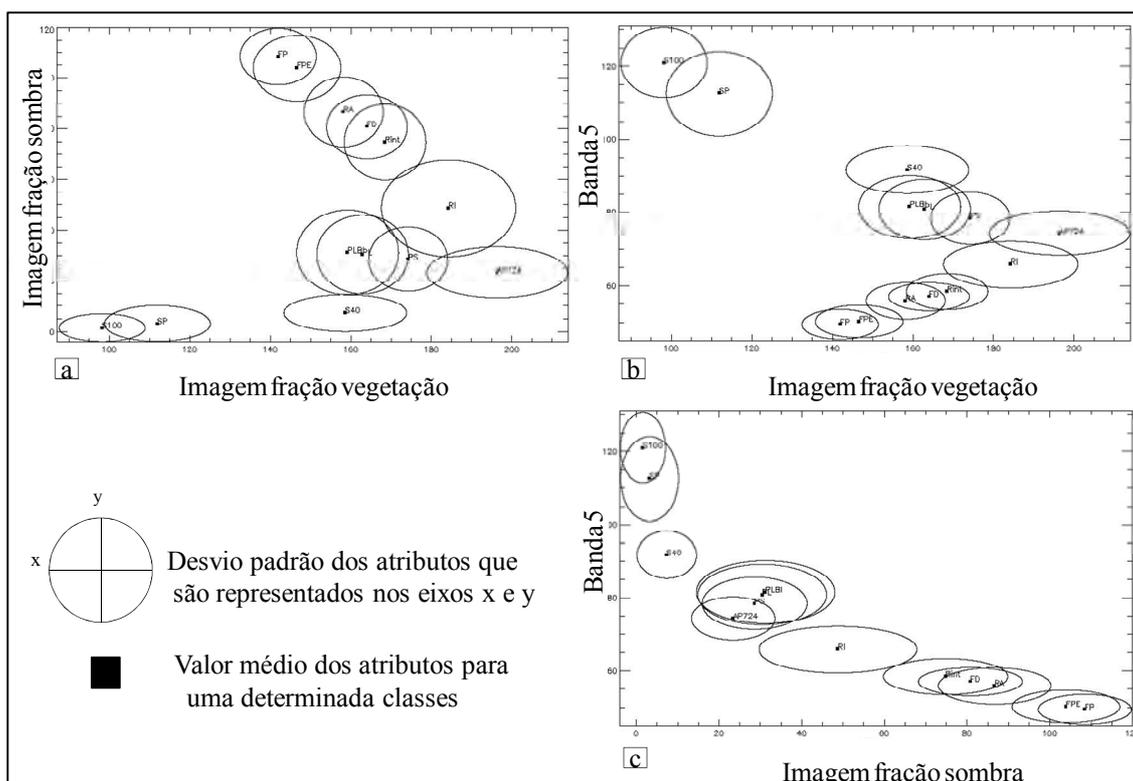


Figura 5.19. Gráficos de média e desvio padrão dos pares de atributos: a) IMF\_SM e IMF\_VEG, b) B5 e IMF\_VEG c) B5 e IMF\_SM.

Desta forma, ao final desta análise foi possível verificar que as classes florestadas FP, FPE, FD, RA e Rint, apresentam alguma separabilidade apenas quando pelo menos um dos dois atributos é oriundo dos dados ópticos. Fato este que ressalta a importância dos dados ópticos na discriminação das classes florestadas. Nota-se também que na maioria destes gráficos as classes florestadas foram agrupadas em dois grupos, da seguinte forma: FP +FPE e FD+RA+Rint.

As classes RI e S40 apresentaram separabilidade das demais classes na maioria dos gráficos de média e desvio padrão formados por pares de atributos (ver Figuras do Apêndice E). Ainda neste cenário é possível observar que todos os pares de atributos resultam em gráficos deste tipo nos quais é evidente a confusão entre as classes SP e S100. As classes PS e AP7/24 apresentaram confusão em 8 dos 15 gráficos de média e desvio padrão (ver Figuras E16, E17, E18, E22, E23, E24, E26, E27 do Apêndice E). As classes PL e PLBI também apresentaram confusão entre si, e foram agrupadas em uma única classe

na maioria destes gráficos. A partir desta análise exploratória é possível inferir sobre as classes que irão resultar em maiores confusões entre si, e conseqüentemente, também inferir sobre as classes que devem ser agrupadas em uma única classe. Esta análise servirá de apoio para o agrupamento das 13 classes de interesse, o qual é tratado na sessão 5.9.

### 5.9. Agrupamento das 13 classes de interesse

Como exposto, o agrupamento de algumas classes tem por objetivo aumentar a acurácia das classificações. Para auxiliar neste agrupamento foi utilizado o aplicativo descrito na seção 4.8, utilizando como base os 6 atributos ópticos e SAR selecionados na seção 5.7.1 e 5.7.2. Justifica-se a escolha destes atributos pelo fato de maximizarem a distância JM média das 13 classes, além de possuírem pouca correlação. Optou-se por utilizar também o mesmo número de atributos ópticos e SAR para evitar que o resultado do agrupamento fosse tendencioso. Para auxiliar na visualização do resultado deste aplicativo foi montada uma árvore de decisão que mostra quais classes devem ser agrupadas e/ou separadas com base no critério da distância JM. Utilizou-se como limiar o valor 1.0. A Figura 20 apresenta a árvore de decisão, destacando em verde as classes finais agrupadas. Pode-se verificar que foram agrupadas as classes FPE, FD e RA, PS e AP7/24, PL e PLBI, SP e S100, totalizando 8 classes de uso e cobertura da terra.

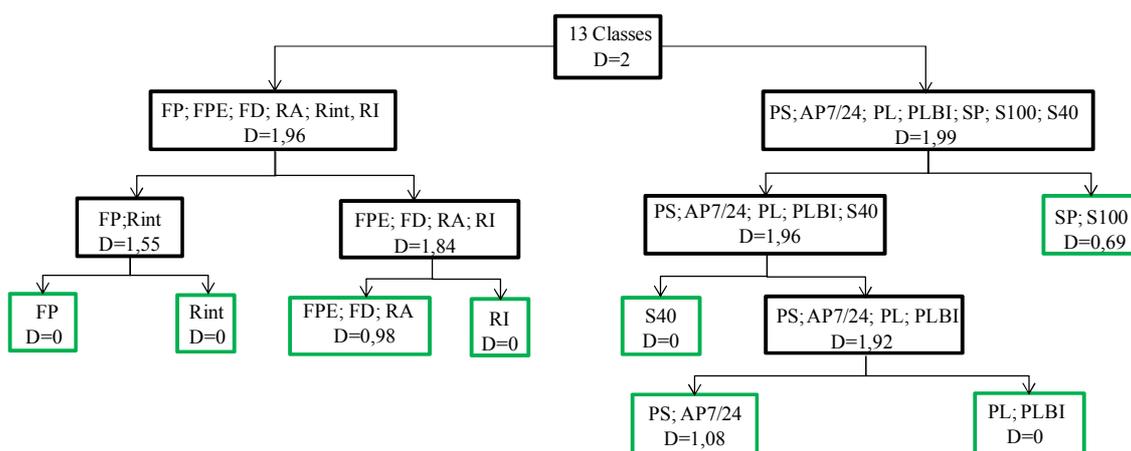


Figura 5.20. Árvore de decisão do aplicativo para o agrupamento das 13 classes de interesse.

Entretanto, observando-se os gráficos do Apêndice E, pode-se verificar que as classes FP e FPE apresentavam confusão entre si. Então, optou-se por agrupar estas classes o que resultou em oito classes de interesse. Portanto, as classes de interesse que serão utilizadas nas classificações ficam assim discriminadas: Floresta Primária e Floresta Primária em Exploração (FP+FPE), Floresta Degradada com Regeneração Antiga (FD+RA), Regeneração Intermediária (Rint), Regeneração Inicial (RI), Pasto Sujo com Agricultura em Pousio de 7 a 24 meses (PS+AP7/24), Pasto Limpo com Pasto Limpo com Babaçu e Inajá (PL+PLBI), Solo Preparado para a Agricultura e Soja 100 (SP+S100) e Soja 40 (S40).

Para realizar as classificações e suas respectivas avaliações foi necessária a coleta de amostras de treinamento e de validação. O número de *pixels* que foram utilizados no treinamento e na validação das classificações, bem como o número total de *pixels* e a cor associada a cada classe são apresentados nas quatro últimas colunas da Tabela 5.6.

Tabela 5.6. Classes de interesse selecionadas e número de amostras coletadas.

Classes	Número de polígonos/Número de pixels	Número de polígonos/Amostras de Treinamento	Número de polígonos/Amostras de Validação	Número de polígonos/Número de pixels (Total)	Cor
Floresta Primária – FP Floresta Primária em Exploração – FPE	17/70631 9/29256	14/60647	12/39240	26/99887	
Floresta Degradada – FD Regeneração Antiga – RA	20/1864 6/23282	18/27397	8/14529	26/41926	
Regeneração Intermediária – Rint	10/4065	8/2566	2/1499	10/4065	
Regeneração Inicial – RI	9/6140	6/4424	3/1716	9/6140	
Pasto Sujo – PS Agricultura Pousio de 7 a 24 meses – AP7/24	6/5104 12/1858	14/5075	4/1887	18/6962	
Pasto Limpo – PL Pasto Limpo com Babaçu e Inajá – PLBI	16/7046 7/5377	15/9385	8/3038	23/12423	
Solo Preparado para Agricultura – SP Soja100 – S100	8/8003 8/4933	10/9540	6/3396	16//12936	
Soja40 – S40	4/1126	3/746	1/380	4/1126	

## 5.10. Análise das classificações

Após processadas as 90 classificações os resultados das mesmas foram avaliados através de testes de hipótese unilateral de igualdade entre pares de valores dos índices *Kappas*, ao nível de significância de 5%. Para auxiliar nas análises que se seguem foi construída uma tabela de tamanho de 90 x 90 (ver Apêndice F), que mostra os resultados destes testes entre todas as classificações. Na parte inferior desta tabela, abaixo da diagonal principal, são mostrados os valores do teste t. Enquanto que na parte superior da tabela acima da diagonal principal, são apresentados os valores dos testes.

### 5.10.1 Imagens originais LANDSAT5/TM, ALOS/PALSAR e seus atributos

Nesta seção são analisados e comparados os resultados das classificações das imagens LANDSAT5/TM, OPT<sub>3</sub>, ALOS/PALSAR e SAR<sub>3</sub> com a finalidade de selecionar as imagens classificadas que apresentaram melhores resultados. Estas imagens serão analisadas mais detalhadamente através de suas respectivas matrizes de confusão e dos índices *Kappas* (das classificações e por classe).

A Figura 5.21 apresenta os valores dos índices *Kappas* para estas classificações. Nesta figura, estes valores, são expressos relativos ao valor do índice *Kappa* da imagem LANDSAT5/TM e são descritos por cores. As cores vermelho, amarelo e verde significam respectivamente que os resultado do índice *Kappa* de uma determinada classificações foi estatisticamente pior, igual ou melhor que a da classificação da imagem LANDSAT5/TM.

Como todas as classificações em análise apresentaram valores do índice *Kappa* estatisticamente diferentes foi possível hierarquizar estes valores em ordem decrescente, de tal forma que, o maior valor foi o da classificação da imagem LANDSAT5/TM (0,652), o segundo valor foi o da classificação dos atributos OPT<sub>3</sub> (0,580). Em terceiro lugar ficou o valor da classificação dos atributos SAR<sub>3</sub> (0,317), e por último o valor da classificação da imagem ALOS/PALSAR filtrada (0,136).

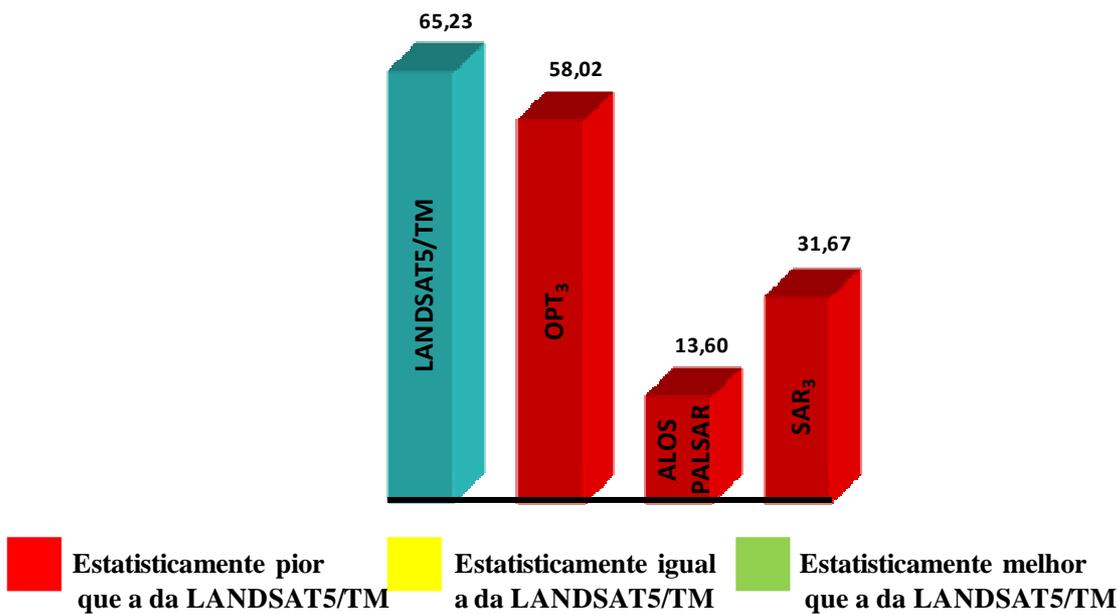
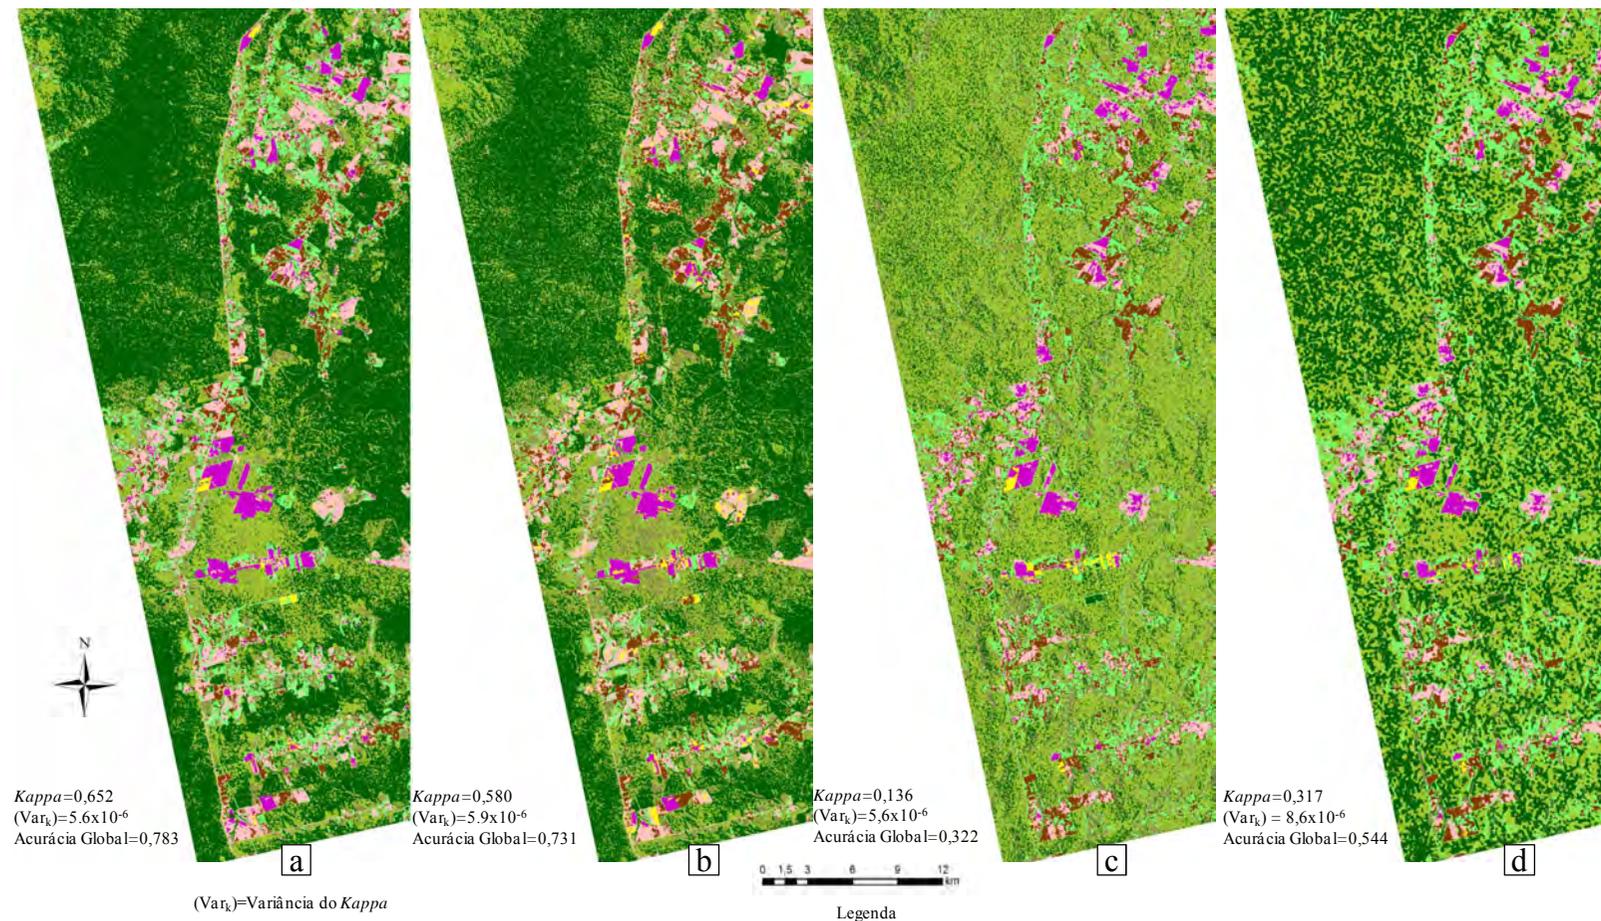


Figura 5.21. Valores dos índices *Kappas*.

Pode-se observar que a classificação da imagem original LANDSAT5/TM resultou em um valor do índice *Kappa* estatisticamente superior ao valor do índice *Kappa* da classificação de seus atributos. Entretanto, vale lembrar que para a classificação da imagem original LANDSAT5/TM são utilizadas 6 bandas, já na classificação de seus atributos são utilizados metade no número de bandas (3 bandas). Apesar da diferença no número de bandas o valor do índice *Kappa* da classificação dos atributos ópticos representa 88,9% do valor do índice *Kappa* da classificação da imagem LANDSAT5/TM.

Para a imagem e atributos SAR, a classificação dos atributos selecionados resultou em um valor do índice *Kappa* estatisticamente superior ao valor do índice *Kappa* da imagem original. Nota-se que para a classificação dos atributos SAR são utilizados 3 bandas enquanto que na classificação da imagem ALOS/PALSAR são utilizadas 2 bandas. Entretanto, a classificação dos atributos (SAR<sub>3</sub>) melhorou em aproximadamente 133% o valor do índice *Kappa* da classificação da imagem SAR original, confirmando a importância desses atributos para a classificação do uso e cobertura da terra.

A Figura 5.22 apresenta as quatro imagens classificadas com os respectivos valores dos índices *Kappas* e de acurácia global.



Floresta Primária – FP	Floresta Degradada – FD	Regeneração Intermidiária – Rint	Regeneração Inicial – RI
Floresta Primária em Exploração – FPE	Regeneração Antiga – RA		
Pasto Sujo – PS	Pasto Limpo – PL	Solo Preparado para Agricultura – SP	Soja40 – S40
Agricultura Pousio de 7 a 24 meses – AP7/24	Pasto Limpo com Babaçu e Inajá – PLBI	Soja100 – S100	

Figura 5.22 Classificações das imagens: a) LANDSAT5/TM, b) OPT<sub>3</sub>, c) ALOS/PALSAR e d) SAR<sub>3</sub>.

É nítida nestas imagens a alta confusão entre as classes FD+FPE e FD+RA quando somente os dados de radar (ALOS/PALSAR e SAR<sub>3</sub>) são utilizados. Entretanto, também é possível notar que na classificação da imagem ALOS/PALSAR as feições geomorfológicas são melhor visualizadas. Outro fato que chama a atenção é o surgimento de feições falsas na classificação da imagem SAR<sub>3</sub> que podem influenciar negativamente na qualidade e na acurácia da mesma. Estas feições costumam surgir em regiões da imagem que possuem classes com áreas de menores dimensões como é o caso das classes de agricultura. Este fato pode ser melhor visualizado na Figura 5.23 nas áreas indicadas pelas setas pretas.

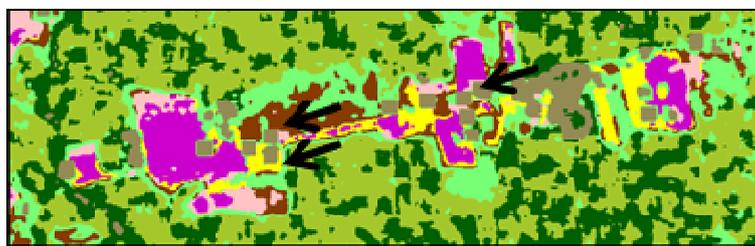


Figura 5.23. Visualização da classificação SAR<sub>3</sub> em uma região de agricultura selecionada na imagem.

Como pode ser observado não é possível realizar uma análise clara das classificações baseado apenas em uma avaliação visual. Desta forma, para um melhor entendimento destes resultados foram analisados os *Kappas* por classes.

Para auxiliar nesta análise foram realizados testes de hipóteses entre os valores dos *Kappas* por classe. Na Figura 5.24 são mostrados os valores dos índices *Kappas* por classe bem como se estes são estatisticamente inferiores, iguais ou superiores ao valor do índice *Kappa* por classe da classificação da imagem LANDSAT5/TM. Para tanto, foi utilizado o mesmo esquema de cores da Figura 5.21. Na parte superior da figura é mostrado o acréscimo percentual no valor do índice *Kappa* por classe, relativo ao resultado da classificação da imagem LANDSAT5/TM. Observa-se que os valores dos índices *Kappas* por classe são estatisticamente iguais ao da classificação da imagem LANDSAT5/TM, ou que o acréscimo em relação à mesma foi inferior a 1 % não são mostrados nesta figura.

Acréscimo em relação à classificação da imagem LANDSAT5/TM em % ( $K_1/K_2$ )

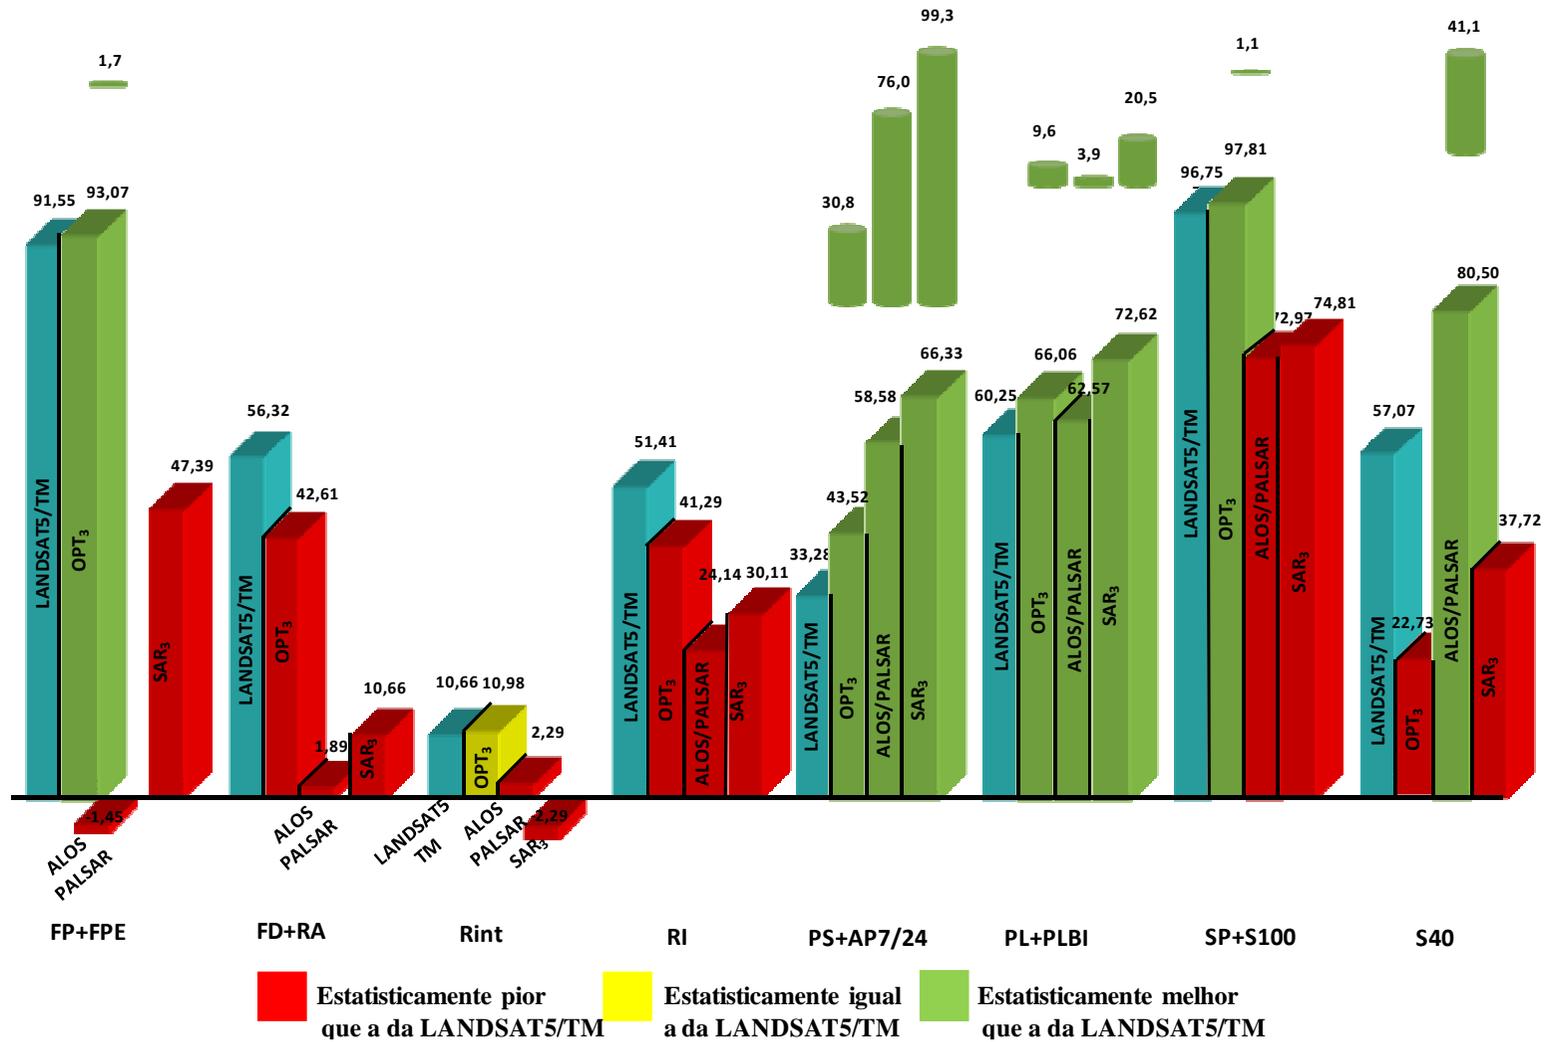


Figura 5.24. Gráfico dos *Kappas* por classe das classificações das imagens originais LANDSAT5/TM, ALOS/PALSAR, OPT<sub>3</sub> e SAR<sub>3</sub>.

Os resultados dos testes de hipótese dos *Kappas* por classe mostraram que as classes florestadas FP+FPE, FD+RA, Rint, RI e a classe SP+S100 são melhores discriminadas pela classificação da imagem óptica e de seus atributos (OPT<sub>3</sub>). O valor do *Kappa* da classe Rint nas citadas classificações, foram estatisticamente iguais, ocupando juntas a primeira posição, enquanto que as classes FP+FPE e SP+S100 foram melhores discriminadas pela classificação dos atributos ópticos (OPT<sub>3</sub>). As demais classes FD+RA e RI foram melhores discriminadas classificando-se a LANDSAT5/TM.

As classes não florestadas PS+AP7/24 e PL+PLBI foram melhores discriminadas pelas classificações dos atributos (SAR<sub>3</sub>). A classe S40 foi melhor discriminada pela classificação da imagem ALOS/PALSAR. Baseado no exposto foi decidido que para as análises futuras mais detalhadas das classificações através da matriz de confusão e dos índices *Kappas* (das classificações e por classe) serão utilizadas a imagem LANDSAT5/TM e os atributos SAR (SAR<sub>3</sub>). Entretanto, em algumas análises a imagem original ALOS/PALSAR será incluída para verificar a aplicabilidade da mesma em um ambiente complexo como a área de estudo selecionada.

Nota-se que só seria vantajoso realizar as combinações ou fusões de imagens caso estas resultassem em classificações mais acuradas que as classificações das imagens originais. Isto é, classificações com valores de índices *Kappa* superiores ao obtido com a classificação da imagem LANDSAT5/TM. Sendo assim, nas análises que se seguem, frequentemente, os valores dos índices *Kappas* (da classificação e por classe) em análise serão comparados com os resultantes da classificação da imagem LANDSAT5/TM. Esta comparação será mostrada em figuras similares às Figuras 5.21 e 5.24, com o mesmo esquema de cores já utilizados nas mesmas. Os acréscimos nos valores dos índices *Kappas* (das classificações e por classe) na maioria das figuras também serão mostrados em porcentagem conforme já explicado nesta seção.

### 5.10.2. Imagens combinadas

Nesta seção são analisados e comparados os resultados das classificações das 6 imagens combinadas com a finalidade de selecionar as imagens classificadas que apresentaram melhores resultados. Estas imagens serão analisadas mais detalhadamente através de suas respectivas matrizes de confusão e dos índices *Kappas* (das classificações e por classe).

A Figura 5.25 apresenta os valores de *Kappa* das classificações das imagens combinadas ressaltando as classificações que são estatisticamente iguais (amarelo), melhores (verde) e piores (vermelho) que a classificação da imagem LANDSAT5/TM. O teste de hipótese para pares de valores *Kappas* mostrou que a classificação da combinação TM\_SAR<sub>3</sub> (0,678) resultou estatisticamente no maior valor deste índice quando comparado com as demais classificações com um acréscimo de 4% em relação a classificação da imagem LANDSAT5/TM. Sendo assim esta classificação foi a selecionada para análises futuras já citadas.

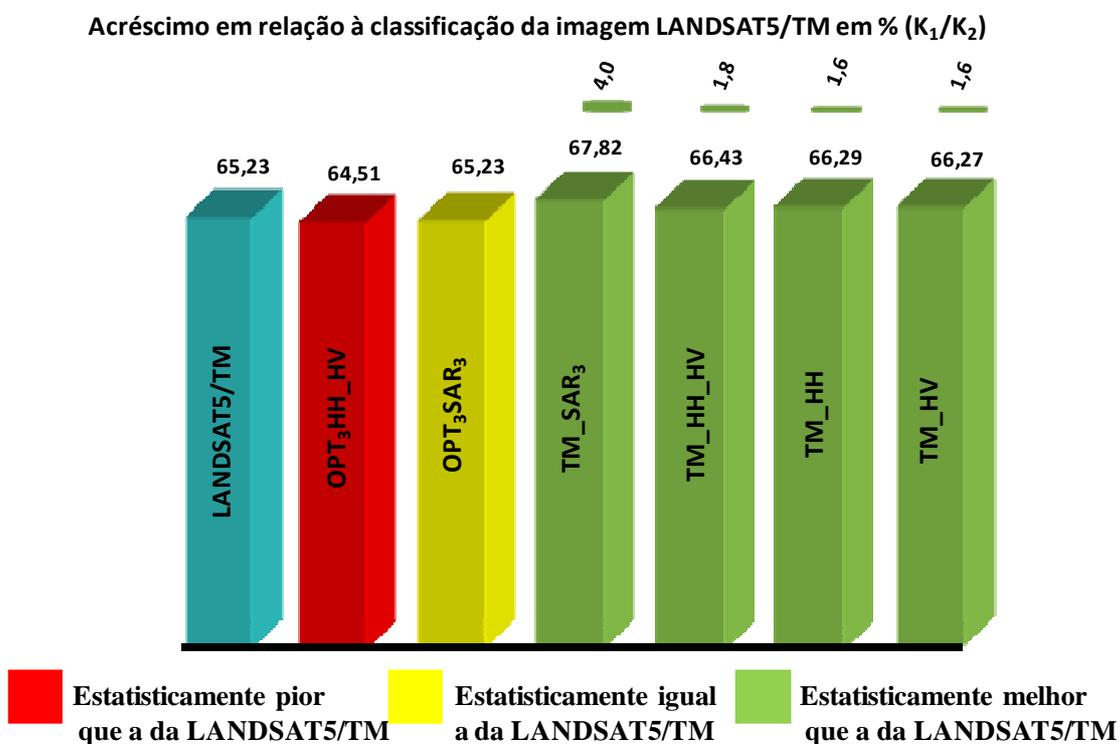


Figura 5.25. Resultado das classificações das imagens combinadas e comparação com o resultado de classificação da imagem LANDSAT5/TM.

Neste cenário cabe comentar que para a classificação  $TM\_SAR_3$  foi utilizada o maior número de atributos (9). As classificações das combinações  $TM\_HH$ ,  $TM\_HV$  e  $TM\_HH\_HV$ , são estatisticamente iguais entre si, sendo que o número de bandas são respectivamente 7, 7 e 8. Esta avaliação nos leva a acreditar que, para a área de estudo em questão, a melhora no índice *Kappa* das classificações ocorre independentemente se a combinação com a imagem LANDSAT5/TM foi realizada com a banda HH, HV ou ambas as bandas. A classificação da imagem  $OPT_3SAR_3$  possui o número de bandas igual ao da imagem LANDSAT5/TM, sendo que os valores dos índices *Kappas* destas classificações são estatisticamente iguais. Na classificação  $OPT_3HH\_HV$  foi utilizado o menor número de atributos (5), coincidentemente esta foi a classificação que resultou no valor do índice *Kappa* estatisticamente inferior ao da imagem LANDSAT5/TM. Sendo assim, acredita-se que o número de atributos utilizado nas classificações das imagens combinadas pode ser um dos fatores que influencia na acurácia das classificações.

### **5.10.3. Imagens fusionadas**

Como exposto na seção 4.10. Nesta seção são analisados e comparados os resultados das classificações das 80 imagens fusionadas com a finalidade de selecionar as imagens classificadas que apresentaram melhores resultados. Estas imagens serão analisadas mais detalhadamente através de suas respectivas matrizes de confusão e dos índices *Kappas* (das classificações e por classe).

Primeiramente será analisado cada método de fusão seguindo a Tabela 4.2. Para auxiliar nesta análise foi utilizada a Figura 5.26 ao qual são mostrados os valores dos índices *Kappas* das classificações descritas na Tabela 5.1.

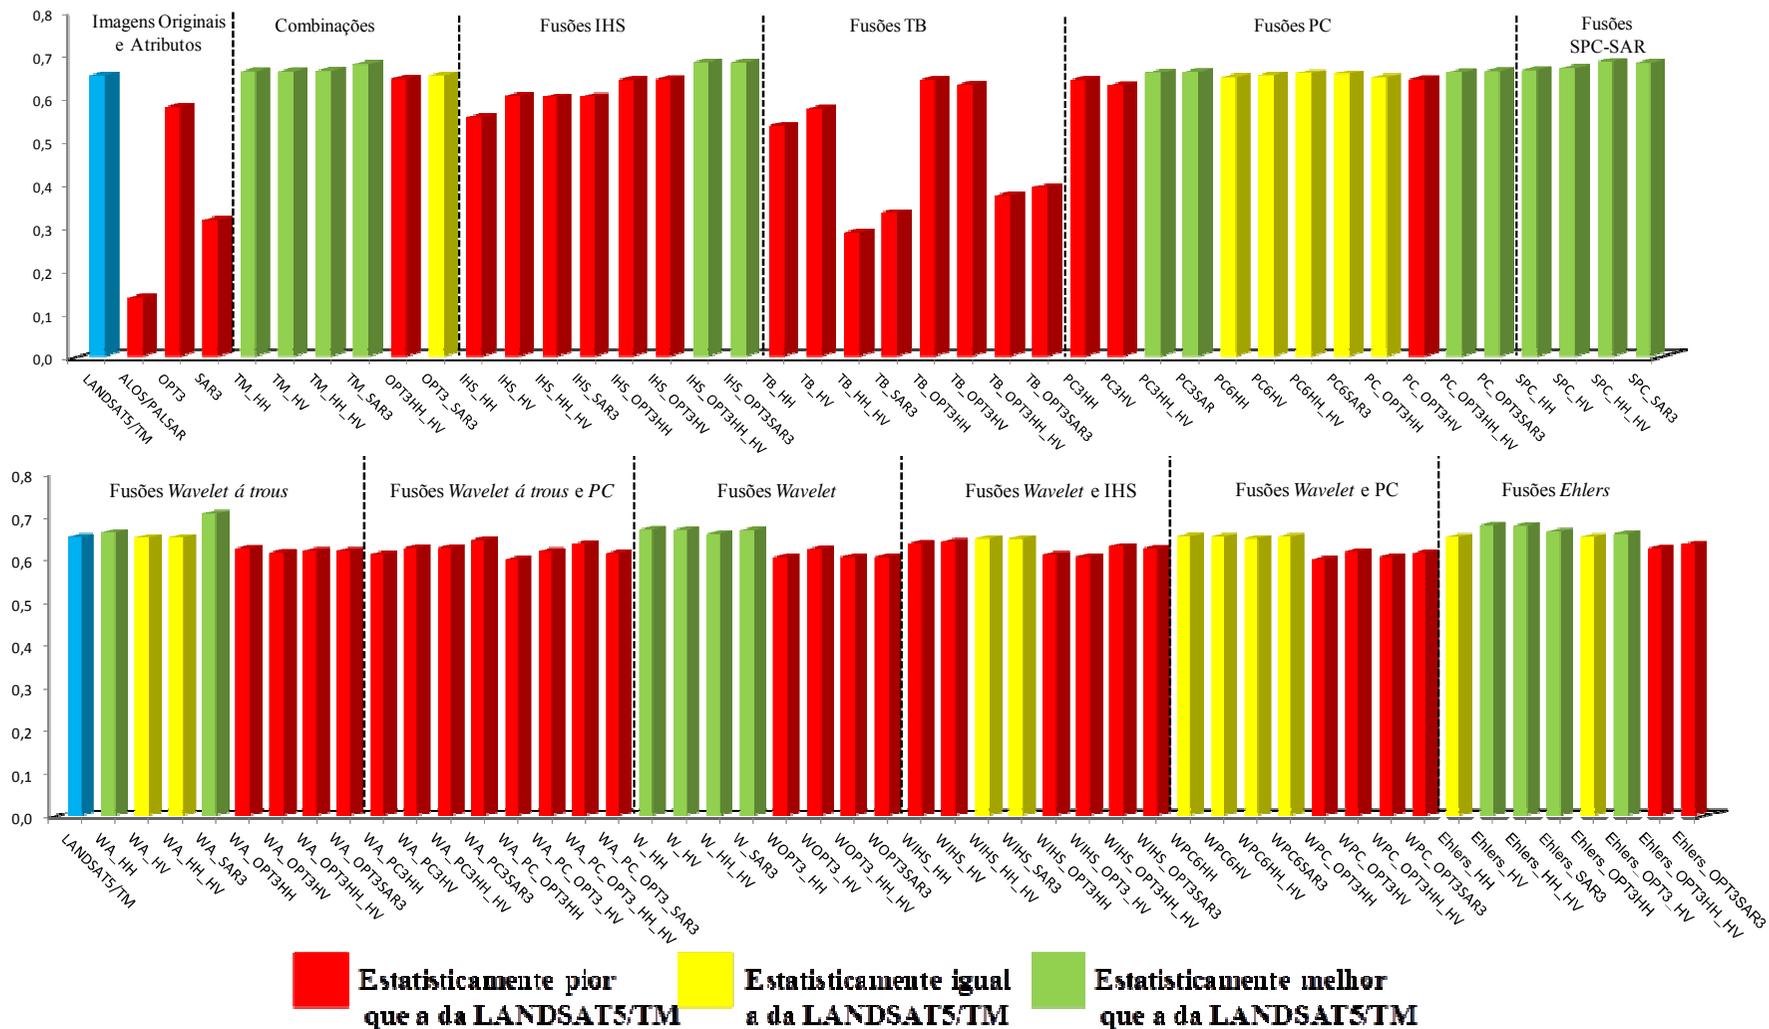


Figura 5.26. Valores dos índices *Kappa* das 90 classificações e comparação estatística com o resultado de classificação da imagem LANDSAT5/TM.

Fusões IHS: Estas fusões foram processadas com 3 bandas originais da imagem LANDSAT5/TM e com os 3 atributos ópticos selecionados.

Das oito fusões realizadas com este método (IHS\_HH, IHS\_HV, IHS\_HH\_HV, IHS\_SAR<sub>3</sub>, IHS\_OPT<sub>3</sub>HV, IHS\_OPT<sub>3</sub>HH, IHS\_OPT<sub>3</sub>HH\_HV e IHS\_OPT<sub>3</sub>SAR<sub>3</sub>) somente as fusões IHS\_OPT<sub>3</sub>HH\_HV (0,683) e IHS\_OPT<sub>3</sub>SAR<sub>3</sub> (0,682) resultaram em classificações com os valores dos índices *Kappas* estatisticamente superiores ao *Kappa* da classificação da imagem LANDSAT5/TM (0,652).

Fusões TB: Estas fusões foram processadas com 3 bandas originais da imagem LANDSAT5/TM e com os 3 atributos ópticos selecionados.

Nenhuma das oito fusões realizadas com o método de fusão TB (TB\_HH, TB\_HV, TB\_HH\_HV, TB\_SAR<sub>3</sub>, TB\_OPT<sub>3</sub>HH, TB\_OPT<sub>3</sub>HV, TB\_OPT<sub>3</sub>HH\_HV e TB\_OPT<sub>3</sub>SAR<sub>3</sub>) resultou em classificações com valores dos índices *Kappas* estatisticamente iguais ou superiores ao *Kappa* da classificação da imagem LANDSAT5/TM.

Fusões PC: Estas fusões foram processadas com 3 e 6 bandas originais da imagem LANDSAT5/TM e com os 3 atributos ópticos selecionados.

Das doze fusões realizadas com o método de fusão por PC (PC<sub>3</sub>HH, PC<sub>3</sub>HV, PC<sub>3</sub>HH\_HV, PC<sub>3</sub>SAR, PC\_OPT<sub>3</sub>HH, PC\_OPT<sub>3</sub>HV, PC\_OPT<sub>3</sub>HH\_HV, PC\_OPT<sub>3</sub>SAR<sub>3</sub>, PC<sub>6</sub>HH, PC<sub>6</sub>HV, PC<sub>6</sub>HH\_HV e PC<sub>6</sub>SAR<sub>3</sub>) apenas as fusões PC<sub>3</sub>HH\_HV (0,659), PC<sub>3</sub>SAR (0,661), PC\_OPT<sub>3</sub>HH\_HV (0,660) e PC\_OPT<sub>3</sub>SAR<sub>3</sub> (0,664) resultaram em classificações com os valores dos índices *Kappas* estatisticamente superiores ao *Kappa* da classificação da imagem LANDSAT5/TM.

Fusões SPC-SAR: Estas fusões foram processadas com 6 bandas originais da imagem LANDSAT5/TM.

Todas as quatro fusões realizadas com o método de fusão SPC-SAR resultaram em classificações com os valores dos índices *Kappas* estatisticamente superiores ao *Kappa* da classificação da imagem LANDSAT5/TM.

Fusões Wavelet á trous: Estas fusões foram processadas com 3 bandas originais da imagem LANDSAT5/TM e com os 3 atributos ópticos selecionados.

Das oito fusões realizadas com o método de fusão *Wavelet á trous* (WA\_HH, WA\_HV, WA\_HH\_HV, WA\_SAR<sub>3</sub>, WA\_OPT<sub>3</sub>HH, WA\_OPT<sub>3</sub>HV, WA\_OPT<sub>3</sub>HH\_HV e WA\_OPT<sub>3</sub>SAR<sub>3</sub>) somente a fusão WA\_SAR<sub>3</sub> (0,705) resultou em uma classificação com o valor do índice *Kappa* estatisticamente superior ao *Kappa* da classificação da imagem LANDSAT5/TM.

Fusões Wavelet á trous e PC: Estas fusões foram processadas com 3 bandas originais da imagem LANDSAT5/TM e com os 3 atributos ópticos selecionados.

Nenhuma das oito fusões realizadas com o método de fusão *Wavelet á trous* e PC (WA\_PC<sub>3</sub>HH, WA\_PC<sub>3</sub>HV, WA\_PC<sub>3</sub>HH\_HV, WA\_PC<sub>3</sub>SAR<sub>3</sub>, WA\_PC\_OPT<sub>3</sub>HH, WA\_PC\_OPT<sub>3</sub>HV, WA\_PC\_OPT<sub>3</sub>HH\_HV e WA\_PC\_OPT<sub>3</sub>SAR<sub>3</sub>) resultaram em classificações com os valores dos índices *Kappas* estatisticamente superiores ao *Kappa* da classificação da imagem LANDSAT5/TM.

Fusões Wavelet: Estas fusões foram processadas com 6 bandas originais da imagem LANDSAT5/TM e com os 3 atributos ópticos selecionados.

Das oito fusões realizadas com o método de fusão *Wavelet* (W\_HH, W\_HV, W\_HH\_HV, W\_SAR<sub>3</sub>, WOPT<sub>3</sub>HH, WOPT<sub>3</sub>HV, WOPT<sub>3</sub>HH\_HV e WOPT<sub>3</sub>SAR<sub>3</sub>) quatro W\_HH (0,670), W\_HV (0,669), W\_HH\_HV (0,660), W\_SAR<sub>3</sub> (0,668) resultaram em classificações com os valores dos índices *Kappas* estatisticamente iguais ou superiores ao *Kappa* da classificação da imagem LANDSAT5/TM.

Fusões Wavelet e PC: Estas fusões foram processadas com 6 bandas originais da imagem LANDSAT5/TM e com os 3 atributos ópticos selecionados.

Nenhuma das oito fusões realizadas com o método de fusão *Wavelet* e PC (WPC<sub>6</sub>HH, WPC<sub>6</sub>HV, WPC<sub>6</sub>HH\_HV, WPC<sub>6</sub>SAR<sub>3</sub>, WPC\_OPT<sub>3</sub>HH, WPC\_OPT<sub>3</sub>HV, WPC\_OPT<sub>3</sub>HH\_HV e WPC\_OPT<sub>3</sub>SAR<sub>3</sub>) resultaram em classificações com os valores

dos índices *Kappas* estatisticamente superiores ao *Kappa* da classificação da imagem LANDSAT5/TM.

*Fusões Wavelet e IHS*: Estas fusões foram processadas com 3 bandas originais da imagem LANDSAT5/TM e com os 3 atributos ópticos selecionados.

Nenhuma das oito fusões realizadas com o método de fusão *Wavelet* e IHS (WIHS\_HH, WIHS\_HV, WIHS\_HH\_HV, WIHS\_SAR<sub>3</sub>, WIHS\_OPT<sub>3</sub>HH, WIHS\_OPT<sub>3</sub>HV, WIHS\_OPT<sub>3</sub>HH\_HV e WIHS\_OPT<sub>3</sub>SAR<sub>3</sub>) resultou em classificações com os valores dos índices *Kappas* estatisticamente superiores ao *Kappa* da classificação da imagem LANDSAT5/TM.

*Fusões Ehlers*: Estas fusões foram processadas com 6 bandas originais da imagem LANDSAT5/TM e com os 3 atributos ópticos selecionados.

Das oito fusões realizadas com o método de fusão *Ehlers* (*Ehlers\_HH*, *Ehlers\_HV*, *Ehlers\_HH\_HV*, *Ehlers\_SAR<sub>3</sub>*, *Ehlers\_OPT<sub>3</sub>HH*, *Ehlers\_OPT<sub>3</sub>HV*, *Ehlers\_OPT<sub>3</sub>HH\_HV* e *Ehlers\_OPT<sub>3</sub>SAR<sub>3</sub>*) quatro, quais sejam, *Ehlers\_HV* (0,679), *Ehlers\_HH\_HV* (0,678), *Ehlers\_SAR<sub>3</sub>* (0,665) e *Ehlers\_OPT<sub>3</sub>HV* (0,660) resultaram em classificações com os valores dos índices *Kappas* estatisticamente superiores ao *Kappa* da classificação da imagem LANDSAT5/TM.

Em resumo, das 80 fusões realizadas 20 resultaram classificações com valores dos índices *Kappas* superiores ao da imagem LANDSAT5/TM. Os valores destes índices são mostrados na Figura 5.27 na ordem decrescente.

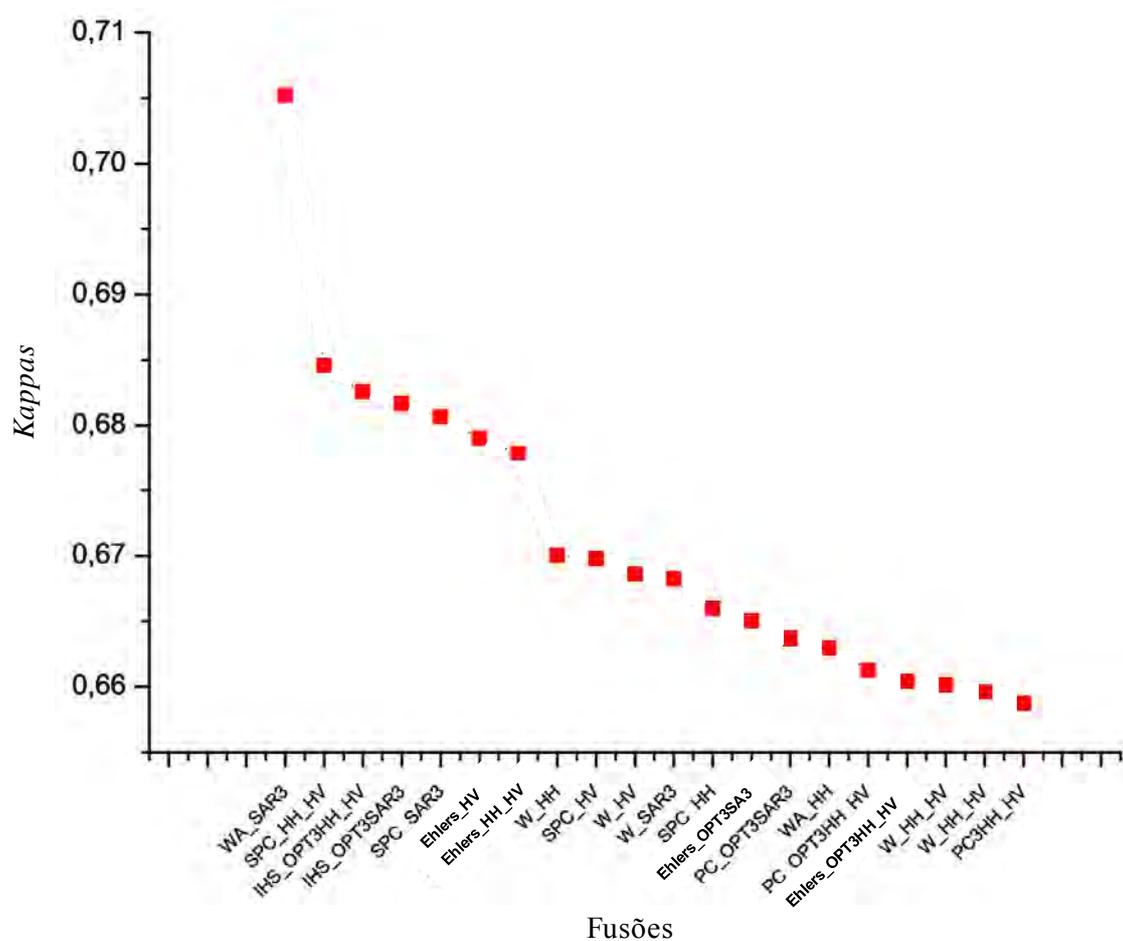


Figura 5.27. Fusões cujas classificações apresentaram valores dos índices *Kappas* estatisticamente superiores ao *Kappa* da classificação da imagem LANDSAT5/TM (0,652).

Destas classificações, as sete primeiras (WA\_SAR<sub>3</sub> - 0,705), (SPC\_HH\_HV - 0,685), (IHS\_OPT<sub>3</sub>HH\_HV - 0,683), (IHS\_OPT<sub>3</sub>SAR<sub>3</sub> - 0,682), (SPC\_SAR<sub>3</sub> - 0,681), (*Ehlers*\_HV - 0,679), (*Ehlers*\_HH\_HV - 0,678), resultaram em valores dos índices *Kappas* estatisticamente iguais ou superiores ao valor resultante da classificação da imagem combinada TM\_SAR<sub>3</sub> (0,678), que foi selecionada na seção 5.10.2. Sendo assim, optou-se por selecionar estas 7 classificações para análises mais detalhadas.

#### 5.10.4. Análise das classificações selecionadas

Nesta seção são realizadas análises mais detalhadas das classificações das imagens LANDSAT5/TM, SAR<sub>3</sub>, TM\_SAR<sub>3</sub>, WA\_SAR<sub>3</sub>, SPC\_HH\_HV, IHS\_OPT<sub>3</sub>HH\_HV,

IHS\_OPT<sub>3</sub>SAR<sub>3</sub>, SPC\_SAR<sub>3</sub>, *Ehlers\_HV* e *Ehlers\_HH\_HV*, totalizando assim 10 classificações. Para fins de exemplificação, a Figura 5.28 apresenta algumas destas imagens fusionadas compostas no espaço de cores RGB.

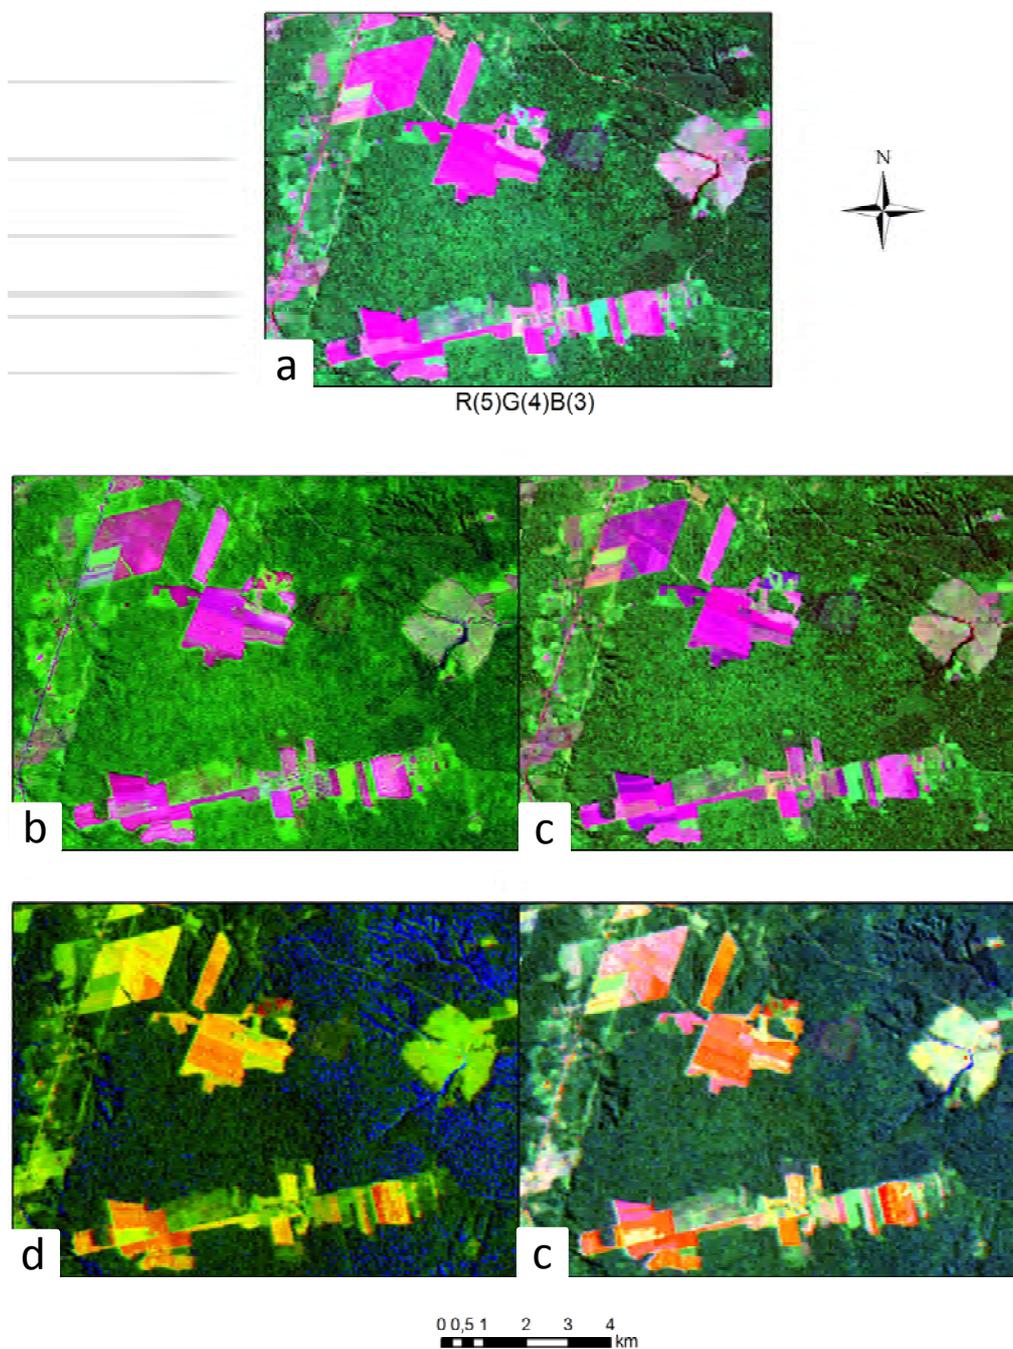


Figura 5.28. Exemplo de imagens fusionadas compostas no espaço RGB: a) Imagem LANDSAT5/TM, b) *Ehlers\_HH\_HV*, c) *WA\_SAR<sub>3</sub>*, d) *IHS\_OPT<sub>3</sub>HH\_HV* e e) *SPC\_SAR<sub>3</sub>*.

Para auxiliar nas análises que se seguem, os valores dos *Kappas* das classificações são mostrados na Figura 5.29. Na Tabela 5.7 são mostrados os valores da estatística *z* (triângulo inferior) e valores-*p* (triângulo superior) dos testes de hipótese entre os pares de classificações. Os valores-*p* acima de 0,05 indicam que a hipótese de igualdade de classificações é aceita a este nível de significância. Valores-*p* abaixo de 0,05 e valores *z* positivos (negativos) indicam que o valor de *Kappa* da classificação indicada na coluna (linha) é superior ao valor de *Kappa* da respectiva linha (resp. coluna) ao nível de significância  $p/2$ .

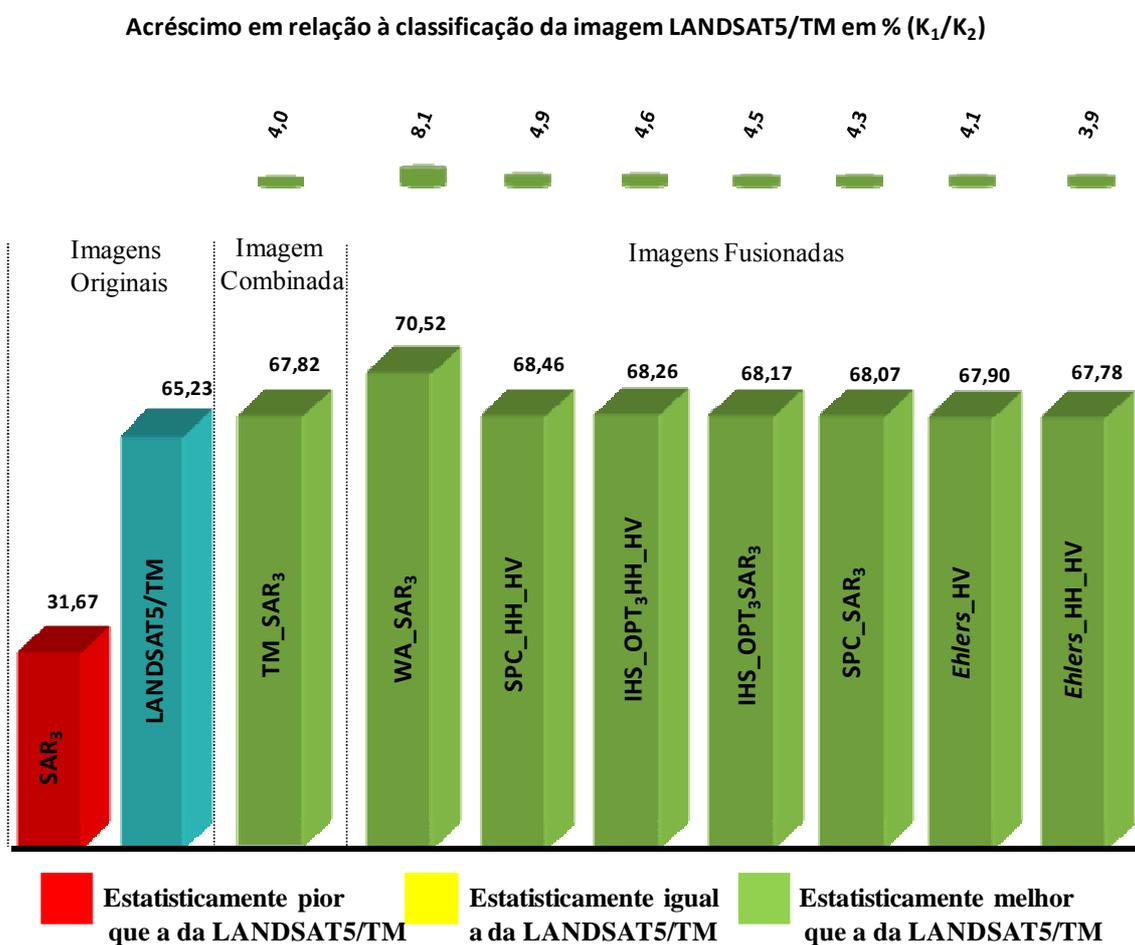


Figura 5.29. Valores dos índices *Kappas* das classificações selecionadas.

Tabela 5.7. Testes de hipótese z entre os pares de *Kappas*.

Imagens	Kappa	Var(K) x 10 <sup>-6</sup>	SAR <sub>3</sub>	LANDSAT5/TM	TM_SAR <sub>3</sub>	WA_SAR <sub>3</sub>	SPC_HH_HV	IHS_OPT <sub>3</sub> HH_HV	IHS_OPT <sub>3</sub> SAR <sub>3</sub>	SPC_SAR <sub>3</sub>	Ehlers_HV	Ehlers_HH_HV
SAR <sub>3</sub>	0,3167	8,58	x	0,46	0,46	0,46	0,46	0,46	0,46	0,46	0,46	0,46
LANDSAT5/TM	0,6523	5,57	-0,09	x	0,50	0,49	0,50	0,50	0,50	0,50	0,50	0,50
TM_SAR <sub>3</sub>	0,6782	5,95	-0,09	-0,01	x	0,50	0,50	0,50	0,50	0,50	0,50	0,50
WA_SAR <sub>3</sub>	0,7052	5,28	-0,10	-0,02	-0,01	x	0,50	0,50	0,50	0,50	0,50	0,50
SPC_HH_HV	0,6846	5,34	-0,10	-0,01	0,00	0,01	x	0,50	0,50	0,50	0,50	0,50
IHS_OPT <sub>3</sub> HH_HV	0,6826	5,40	-0,10	-0,01	0,00	0,01	0,00	x	0,50	0,50	0,50	0,50
IHS_OPT <sub>3</sub> SAR <sub>3</sub>	0,6817	5,43	-0,10	-0,01	0,00	0,01	0,00	0,00	x	0,50	0,50	0,50
SPC_SAR <sub>3</sub>	0,6807	5,47	-0,10	-0,01	0,00	0,01	0,00	0,00	0,00	x	0,50	0,50
Ehlers_HV	0,6790	5,17	-0,10	-0,01	0,00	0,01	0,00	0,00	0,00	0,00	x	0,50
Ehlers_HH_HV	0,6778	5,11	-0,10	-0,01	0,00	0,01	0,00	0,00	0,00	0,00	0,00	x

Valor-*p* maior que 0,05      *Kappas* Iguais  
 Valor-*p* menor que 0,05      *Kappas* Diferentes  
 *Kappa* da classificação da imagem da linha melhor que o *Kappa* da classificação da imagem na coluna  
 *Kappa* da classificação da imagem da linha pior que o *Kappa* da classificação da imagem na coluna

O pior valor do índice *Kappa* foi o da classificação dos atributos SAR (SAR<sub>3</sub>), o qual é estatisticamente inferior a todos os *Kappas* das demais classificações. A classificação da imagem LANDSAT5/TM apresentou o segundo pior resultado, sendo somente superior à classificação SAR<sub>3</sub>. Entretanto, a combinação destas 2 imagens (TM\_SAR<sub>3</sub>) resultou em um valor do índice *Kappa* estatisticamente superior ao valor deste índice resultante da classificação da imagem LANDSAT5/TM.

O método de fusão que resultou no maior valor do índice *Kappa*, foi o que utilizou o algoritmo *Wavelet à trous* usando as 3 bandas da imagem LANDSAT5/TM (B2, B4 e B5) e a primeira componente principal dos 3 atributos SAR selecionados (MED\_7\_HV, HOM\_15\_HH e DIS\_15\_HH). *Kappa* este que é estatisticamente superior a todos os *Kappas* das demais classificações. Fato que pode ser atribuído à eficiência do citado algoritmo associado aos dados que foram fusionados, pois estes são descorrelacionados e maximizam a separabilidade das classes de interesse. Atrelado a isto, nota-se que as medidas de texturas tendem a destacar as bordas das feições e suavizar as áreas homogêneas. Portanto, conclui-se que a introdução destas informações nas bandas multiespectrais resultou na melhora da discriminação das áreas homogêneas ao mesmo tempo em que reforça as áreas de transição entre as mesmas, o que culminou na melhora da acurácia da classificação.

Outro método de fusão que melhorou a acurácia de algumas classificações foi o IHS, sendo que as classificações das fusões IHS\_OPT<sub>3</sub>HH\_HV e IHS\_OPT<sub>3</sub>SAR<sub>3</sub> são estatisticamente iguais. Os valores dos índices *Kappas* destas classificações foram estatisticamente inferiores somente a classificação da imagem WA\_SAR<sub>3</sub>. O método de fusão por IHS é considerado simples e eficaz apesar de possuir a limitação de permitir a fusão com apenas 4 bandas. Entretanto, além das fusões IHS\_OPT<sub>3</sub>HH\_HV e IHS\_OPT<sub>3</sub>SAR<sub>3</sub> terem sido processadas utilizando dados ópticos que maximizam a separabilidade das classes de interesse (OPT<sub>3</sub>), acredita-se que boa parte das informações contidas nas bandas da imagem LANDSAT5/TM encontram-se nos 3 atributos ópticos selecionados. Isto porque o valor do índice *Kappa* da classificação dos atributos OPT<sub>3</sub>

representa 89% do valor do índice *Kappa* da classificação das 6 bandas da imagem LANDSAT5/TM. Os atributos OPT<sub>3</sub> foram fusionados com a primeira PC extraídas das bandas HH e HV e dos 3 atributos SAR. Sendo assim, conclui-se que para que o método de fusão IHS apresente bons resultados é necessário que ele seja realizado com métodos e técnicas que reduzem a dimensionalidade dos dados, para que estes representem boa parte da informação dos dados originais.

A fusão por SPC apresentou, de maneira geral, melhores resultados que as combinações ou demais fusões, mesmo quando uma só banda SAR foi utilizada. Entretanto, a utilização das duas polarizações SAR ou de seus atributos melhora os resultados das classificações. Acredita-se que os bons resultados das classificações das fusões SPC\_HH\_HV e SPC\_SAR<sub>3</sub> também estejam atrelados à redução da dimensionalidade dos dados SAR, pois estas fusões também foram processadas utilizando como dados SAR de entrada a primeira PC extraída das bandas da imagem ALOS/PALSAR e dos 3 atributos SAR selecionados. Para o bom desempenho deste método de fusão a redução da dimensionalidade dos dados ópticos também parece ser importante. Neste cenário cabe comentar que a PC<sub>1</sub> extraída das bandas 1,2 e 3 têm uma relação com a região do espectro eletromagnético que fornece informação sobre a vegetação fotossinteticamente ativa. A banda 4 está relacionada com a região do espectro eletromagnético que fornece informação sobre o vigor vegetativo de tal forma que, quanto maior o fluxo radiante refletido mais vigorosa é a vegetação em questão. Já a primeira PC extraída das bandas 5 e 7 fornece informações sobre a absorção da água e de compostos como carbono (PARADELLA et al., 2001). A manutenção destas informações nos processos de fusões pode ser uns dos fatores que colabora para o bom desempenho do citado método de fusão.

O método de fusão *Ehlers* apresentou bons resultados quando banda a HV e a primeira PC extraída das bandas HH e HV estavam envolvidas no processo de fusão, mostrando assim, que este método de fusão resultou na melhora da acurácia das classificações quando pelo menos a banda HV estava envolvida no processo. Acredita-se que a melhora na acurácia das classificações ocorreu porque este método preserva as

informações espectrais ao mesmo tempo em que introduz informações espaciais minimizando a introdução de ruídos nas imagens fusionadas (e.g. detalhes falsos). (KLONUS; EHLERS, 2009).

Uma das justificativas para que os demais métodos de fusão não apresentaram melhores resultados na discriminação das classes em estudo é que nas fusões por TB as características espectrais das imagens multiespectrais não são preservadas na imagem fusionada. No método de fusão que utiliza PCs além das distorções espectrais, acredita-se que a retirada das informações contidas na  $PC_1$  da imagem LANDSAT5/TM resulta em perda de informação que impede que as classificações resultantes destas fusões melhorem a discriminação das classes de interesse.

Neste cenário ainda é possível notar que a maioria das classificações em análise resultou de processos de fusões que utilizam a primeira PC das bandas HH e HV e dos atributos  $SAR_3$  mostrando assim, que o processamento proposto que permite a integração dos dados SAR antes de se iniciar os processos de fusões apresenta aplicabilidade.

Somente a fusão *Ehlers* apresentou bons resultados com uma única banda envolvida no processo que é a HV. Sendo assim, caso o usuário tenha acesso a apenas uma banda o indicado é que seja selecionada a banda HV e que o método de fusão *Ehlers* seja utilizado.

Os resultados das classificações da imagem combinada e das fusões são mostrados na Figura 5.30.

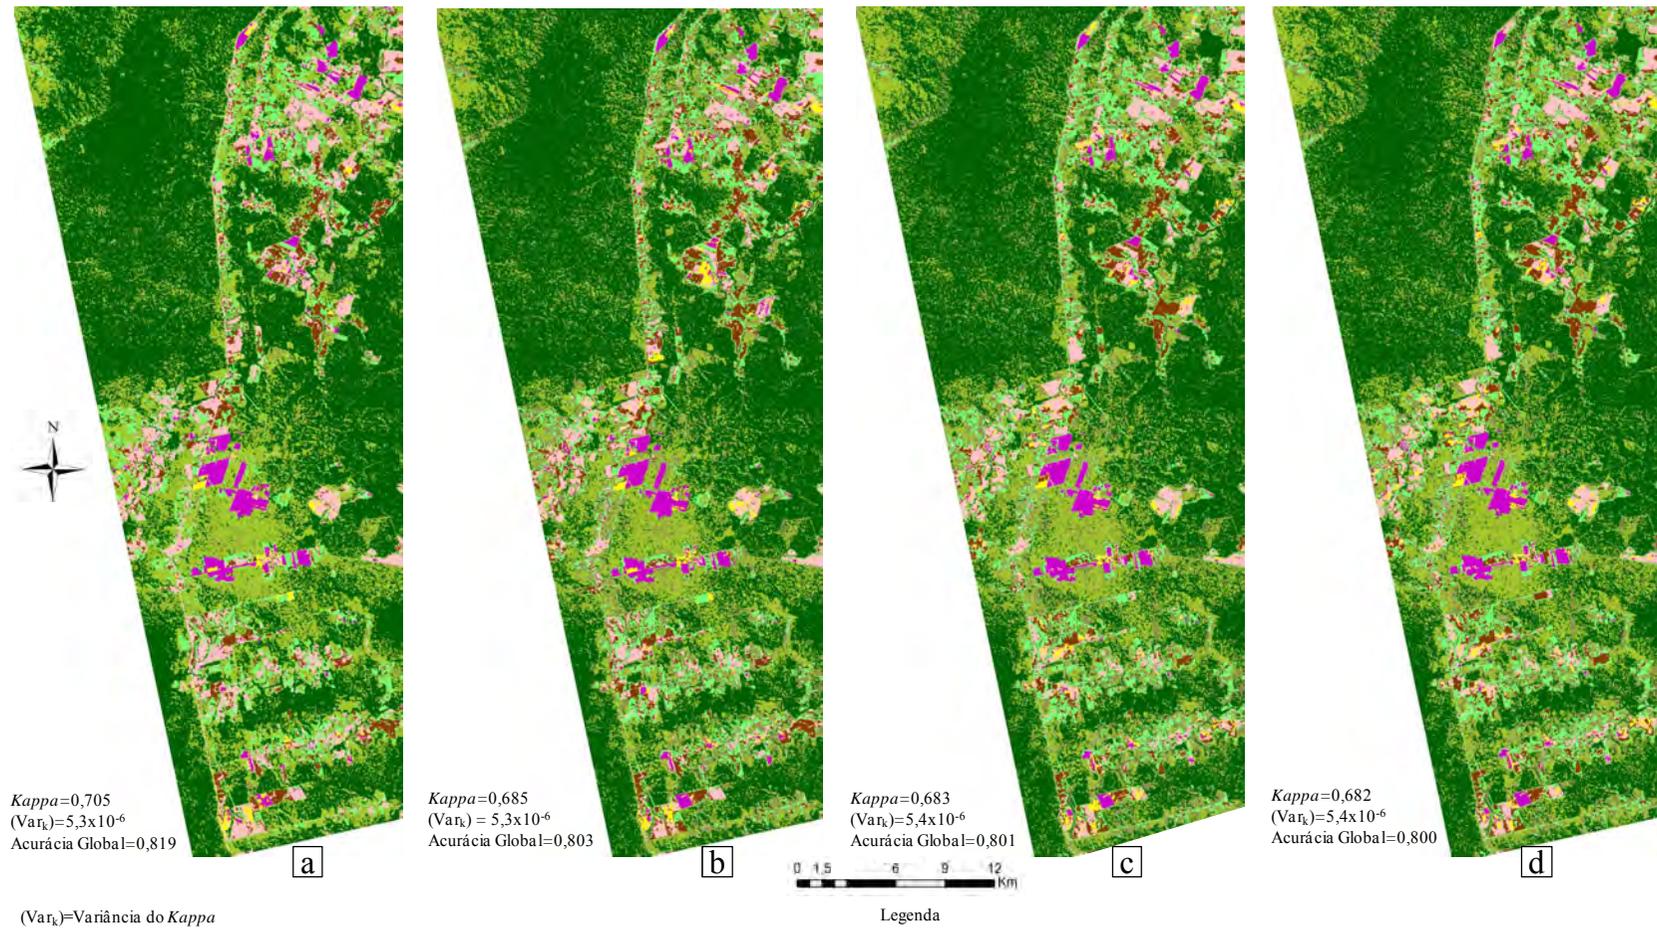


Figura 5.30

(Continua)

Figura 5.29 - Continuação

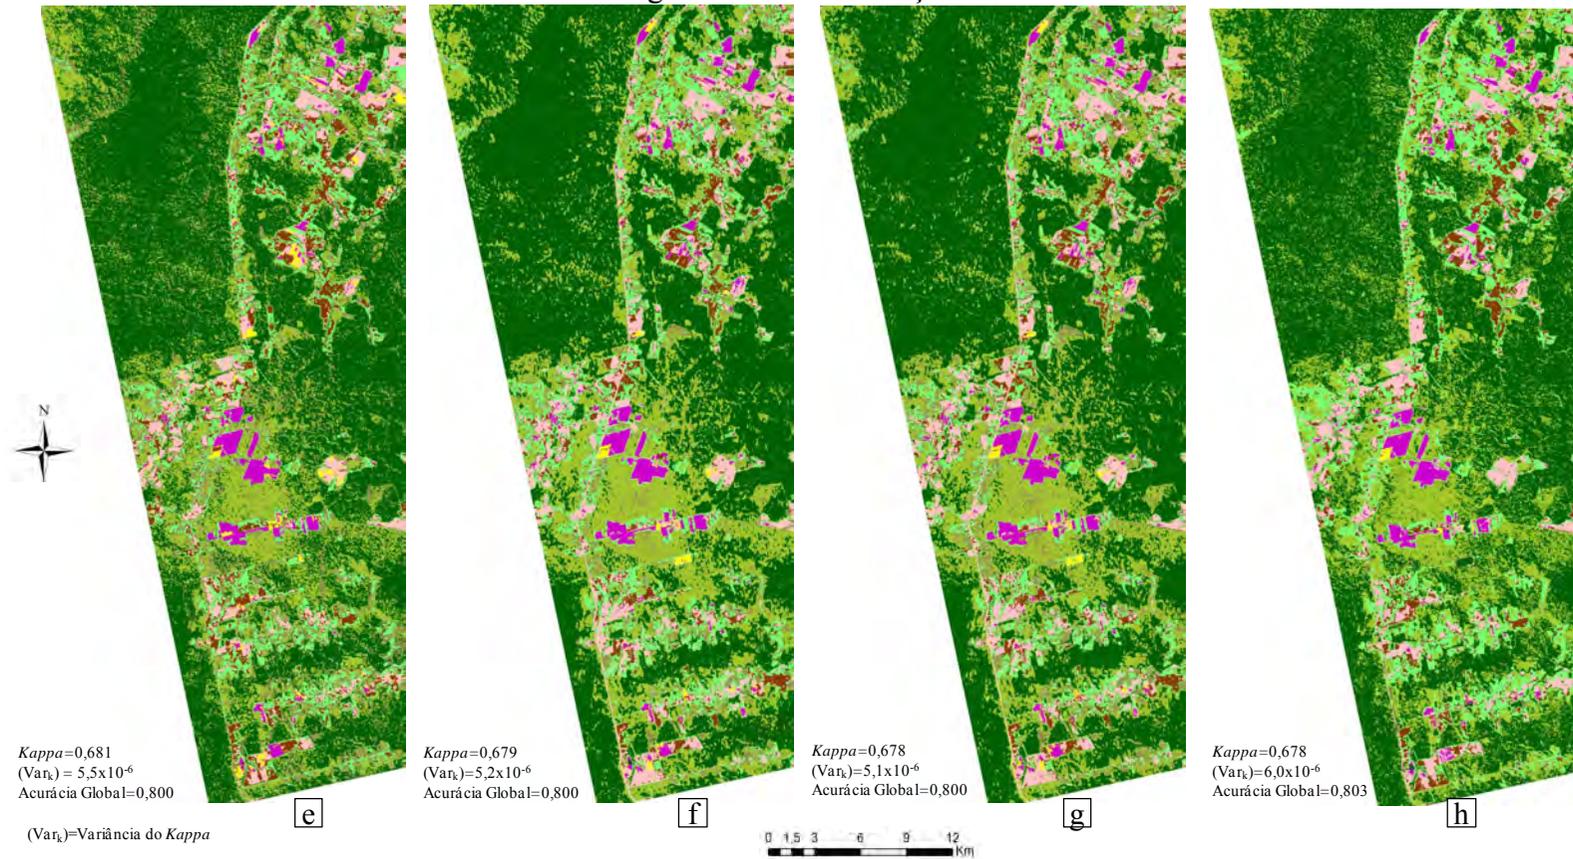


Figura 5.30. Classificações das imagens selecionadas: a) WA\_SAR<sub>3</sub>, b) SPC\_HH\_HV, c) IHS\_OPT<sub>3</sub>HH\_HV, d) IHS\_OPT<sub>3</sub>SAR<sub>3</sub>, e) SPC\_SAR<sub>3</sub>, f) Ehlers\_HV, g) Ehlers\_HH\_HV e h) TM\_SAR<sub>3</sub>.

Neste cenário um fato chamou a atenção, assim como a classificação da imagem SAR<sub>3</sub>, na classificação da imagem combinada TM\_SAR<sub>3</sub> também foi observado o surgimento de feições falsas que podem influenciar negativamente na qualidade e na acurácia da mesma. Estas feições costumam surgir em regiões da imagem que possuem classes com áreas de menores dimensões como é o caso das classes de agricultura. Este fato pode ser melhor visualizado na Figura 5.31 nas áreas indicadas pelas setas pretas.



Figura 5.31. Visualização da classificação TM\_SAR<sub>3</sub> em uma região de agricultura selecionada na imagem.

Como pode ser observado não é possível realizar uma análise clara das classificações baseado apenas em uma avaliação visual. Desta forma, para o melhor entendimento destes resultados foram analisados os *Kappas* por classe. Esta análise foi realizada através do gráfico dos *Kappas* por classe de interesse apresentado na Figura 5.32. Na Tabela 5.8 são mostrados os números de atributos envolvidos nas fusões e combinações que apresentaram melhores resultados nas classificações para verificar se este fator influencia na exatidão das mesmas. Para tanto, as classificações serão ordenadas em ordem decrescente dos valores dos índices *Kappas*. Como pode ser observado nesta tabela acredita-se que o resultado das classificações das imagens fusionadas está mais relacionado com a aplicação de técnicas de seleção dos atributos e diminuição da dimensionalidade dos mesmos do que propriamente com o número de atributos envolvidos.

Tabela 5.8. Número de atributos utilizados nas fusões selecionadas.

Fusões e Combinações	<i>Kappas</i> das classificações	Número de atributos ópticos/sigla	Número de atributos SAR/sigla	Número total de atributos
WA_SAR <sub>3</sub>	0,705	3/B2, B4, B5	1/PC <sub>1</sub> SAR <sub>3</sub>	4
SPC_HH_HV	0,685	3/ PC <sub>1</sub> (B1, B2e B3), B4, PC <sub>1</sub> (B5, B7)	1/PC <sub>1</sub> HH_HV	4
IHS_OPT <sub>3</sub> HH_HV	0,683	3/OPT <sub>3</sub>	1/PC <sub>1</sub> HH_HV	4
IHS_OPT <sub>3</sub> SAR <sub>3</sub>	0,682	3/OPT <sub>3</sub>	1/PC <sub>1</sub> SAR <sub>3</sub>	4
SPC_SAR <sub>3</sub>	0,681	3/ PC <sub>1</sub> (B1, B2 e B3), B4, PC <sub>1</sub> (B5, B7)	1/PC <sub>1</sub> SAR <sub>3</sub>	4
<i>Ehlers</i> _HV	0,679	6/bandas originais	1/Banda HV	7
<i>Ehlers</i> _HH_HV	0,678	6/bandas originais	1/PC <sub>1</sub> HH_HV	7
TM_SAR <sub>3</sub>	0,678	6/bandas originais	3/SAR <sub>3</sub>	9

Acréscimo em relação à classificação da imagem LANDSAT5/TM em % ( $K_1/K_2$ )

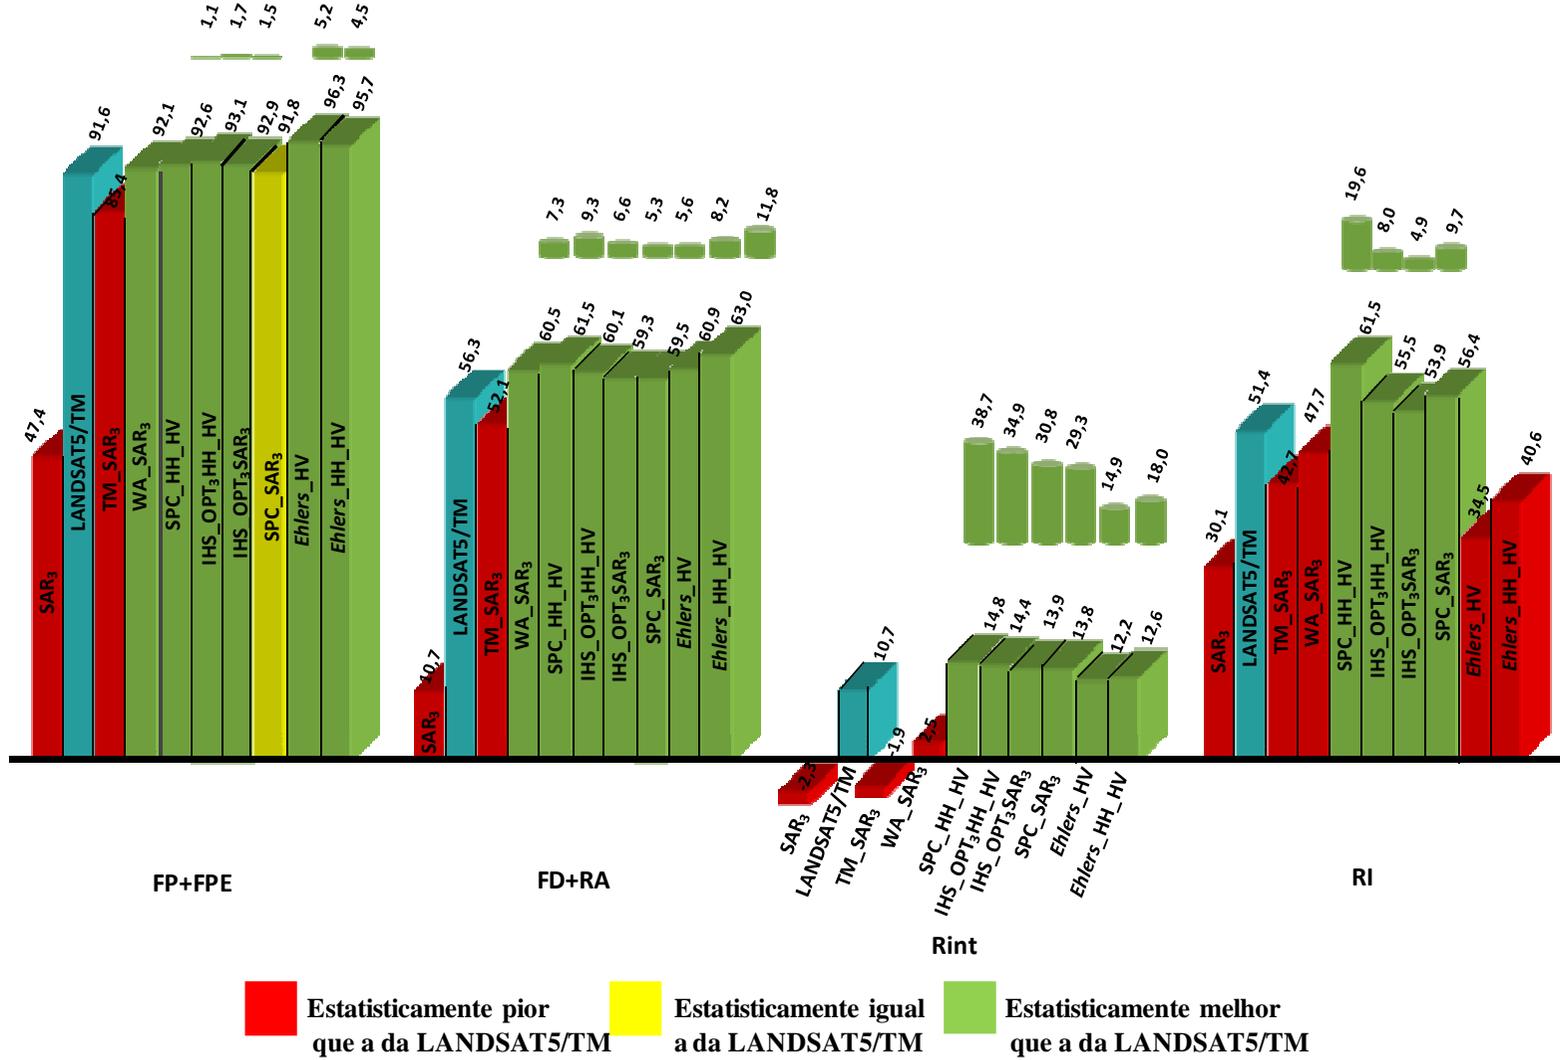


Figura 5.32

(Continua)

Figura 5.32 - Continuação

Acréscimo em relação à classificação da imagem LANDSAT5/TM em % ( $K_1/K_2$ )

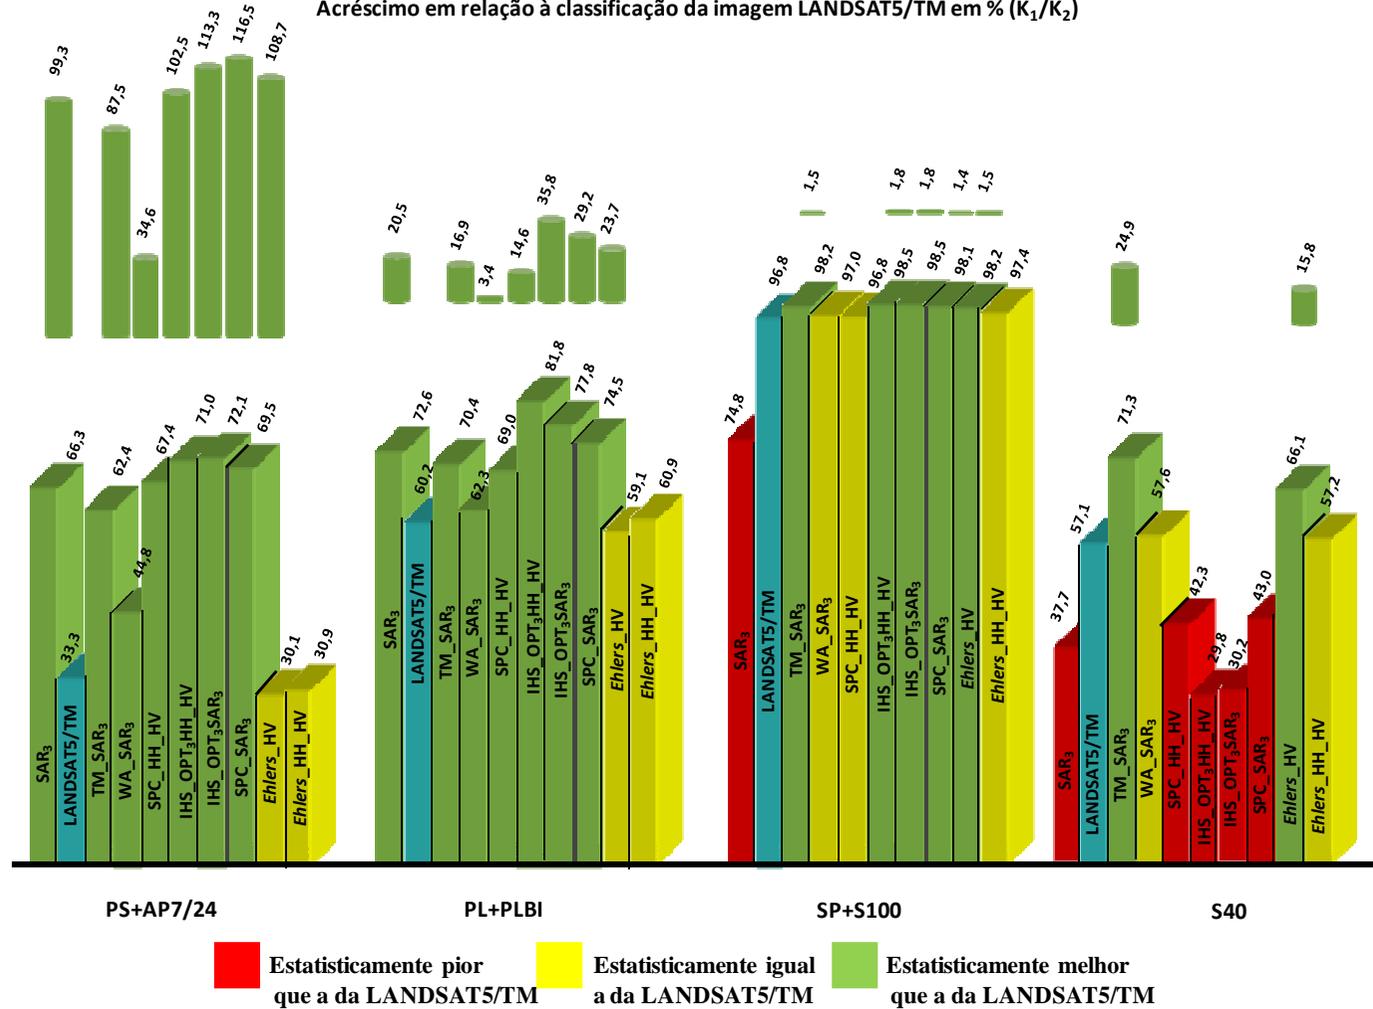


Figura 5.32. Gráfico dos *Kappas* por classe das classificações das imagens selecionadas com o resultado do teste de hipótese.

Na classe FP+FPE somente as classificações das imagens ALOS/PALSAR, SAR<sub>3</sub>, TM\_SAR<sub>3</sub> e SPC\_SAR<sub>3</sub> apresentaram os valores dos índices *Kappas* estatisticamente iguais ou inferiores ao da classificação da imagem LANDSAT5/TM. Neste contexto, tem destaque a classificação da imagem fusionada *Ehlers\_HV*, pois foi esta classificação que resultou no maior índice *Kappa* por classe. O acréscimo percentual no valor do índice *Kappa* desta classificação relativo ao resultado da classificação da imagem LANDSAT5/TM foi de aproximadamente 5,2%. Acredita-se que este resultado é devido à eficiência do algoritmo de fusão aliada à informação discriminatórias contida na banda HV para este tipo de classe de interesse. A banda HV está relacionada com informações sobre os mecanismos de espalhamento volumétrico que colaboram na discriminação entre áreas densamente florestadas das demais áreas.

Na classe FD+RA somente as classificações das imagens ALOS/PALSAR, SAR<sub>3</sub>, TM\_SAR<sub>3</sub> apresentaram os valores dos índices *Kappas* estatisticamente inferiores ao valor do *Kappa* da classificação da imagem LANDSAT5/TM. Nesta classe tem destaque a classificação da imagem fusionada *Ehlers\_HH\_HV*, pois foi a que estatisticamente resultou no maior índice *Kappa* por classe. O acréscimo percentual no valor do índice *Kappa* desta classificação relativo ao resultado da classificação da imagem LANDSAT5/TM foi de aproximadamente 11,8%.

Na classe Rint as classificações que resultaram em índices *Kappas* estatisticamente inferiores ao da classificação da imagem LANDSAT5/TM foram ALOS/PALSAR, SAR<sub>3</sub>, TM\_SAR<sub>3</sub> e WA\_SAR<sub>3</sub>. Já as classificações das fusões SPC\_HH\_HV, IHS\_OPT<sub>3</sub>HH\_HV, IHS\_OPT<sub>3</sub>SAR<sub>3</sub> e SPC\_SAR<sub>3</sub> são estatisticamente iguais entre si, e se destacaram, pois resultaram estatisticamente nos maiores índices *Kappas*. Os acréscimos percentuais nos valores dos índices *Kappas* destas classificações relativo ao resultado da classificação da imagem LANDSAT5/TM foram de aproximadamente 38,7%, 34,9%, 30,8% e 29,3%, respectivamente. Foi verificado que esta classe, de maneira geral, foi a que resultou nos menores valores dos índices *Kappas* por classe, indicando assim que para melhorar os resultados das classificações o agrupamento desta classe com outras classes parece ser importante.

Na classe RI 4 classificações SPC\_HH\_HV, SPC\_SAR<sub>3</sub>, IHS\_OPT<sub>3</sub>HH\_HV e IHS\_OPT<sub>3</sub>SAR<sub>3</sub> resultaram em índices *Kappas* estatisticamente superiores à classificação da imagem LANDSAT5/TM. Nota-se que estas fusões são as mesmas que melhoraram a discriminação da classe Rint. Entretanto, neste cenário destacou-se a classificação da fusão SPC\_HH\_HV, pois esta apresentou estatisticamente o maior valor do citado índice. O acréscimo percentual no valor do índice *Kappa* desta classificação relativo ao resultado da classificação da imagem LANDSAT5/TM foi de aproximadamente 19,6%.

Nas classes PS+AP7/24 e PL+PLBI, somente as classificações das imagens *Ehlers\_HV* e *Ehlers\_HH\_HV* apresentaram os valores dos índices *Kappas* estatisticamente iguais ao valor do índice *Kappa* da classificação da imagem LANDSAT5/TM, sendo que todas as demais classificações resultaram em valores do índice *Kappa* estatisticamente superiores. Para a classe PS+AP7/24 as classificações das fusões IHS\_OPT<sub>3</sub>HH\_HV e IHS\_OPT<sub>3</sub>SAR<sub>3</sub> apresentaram valores dos índices *Kappa* estatisticamente iguais entre si e superiores às demais classificações. Os acréscimos percentuais nos valores dos índices *Kappas* destas classificações relativos ao resultado da classificação da imagem LANDSAT5/TM foram de aproximadamente 111,3% e 116,5%, respectivamente. Nota-se que estes são os maiores valores de acréscimo por classe dentre as 8 classes de interesse.

Na classe PL+PLBI a classificação da fusão IHS\_OPT<sub>3</sub>HH\_HV, resultou estatisticamente no maior valor deste índice. O acréscimo percentual no valor do índice *Kappa* desta classificação relativo ao resultado da classificação da imagem LANDSAT5/TM foi de aproximadamente 35,8%.

Na classe SP+S100 as classificações das imagens SPC\_SAR<sub>3</sub>, TM\_SAR<sub>3</sub>, *Ehlers\_HV*, IHS\_OPT<sub>3</sub>HH\_HV e IHS\_OPT<sub>3</sub>SAR<sub>3</sub> resultaram em valores do índice *Kappa* estatisticamente iguais entre si e superiores ao valor do índice *Kappa* da classificação da imagem LANDSAT5/TM. Os acréscimos percentuais nos valores dos índices *Kappas* destas classificações relativos ao resultado da classificação da imagem LANDSAT5/TM foram de aproximadamente 1,4%, 1,5%, 1,5%, 1,8% e 1,8%, respectivamente. Nota-se que estes são uns dos menores valores de acréscimo por classe dentre as 8 classes de

interesse. Portanto, a utilização conjunta dos dados ópticos e SAR não contribui na melhora da discriminação desta classe se comparado com as demais 7 classes de interesse.

Na classe S40, a classificação da imagem ALOS/PALSAR foi estatisticamente superior a todos os demais resultados das classificações das imagens em análise. O Acréscimo percentual no valor do índice *Kappa* desta classificação relativo ao resultado da classificação da imagem LANDSAT5/TM foi de aproximadamente 41,1%.

A Tabela 5.9 mostra as classificações que resultaram estatisticamente nos maiores valores dos índices *Kappas* por classe e o acréscimo percentual das mesmas em relação ao resultado da classificação da imagem LANDSAT5/TM.

Tabela 5.9. Maiores acréscimos percentuais nos valores dos índices *Kappas* por classe.

Classes	Métodos de fusão	Acréscimo
FP+FPE	<i>Ehlers_HV</i>	5,2
FD+RA	<i>Ehlers_HH_HV</i>	11,8
Rint	SPC_HH_HV	38,7
RI	SPC_HH_HV	19,6
PS+AP7/24	IHS_OPT <sub>3</sub> HH_HV	113,3
PL+PLBI	IHS_OPT <sub>3</sub> HH_HV	35,8
SP+S100	IHS_OPT <sub>3</sub> HH_HV	1,8
S40	ALOS/PALSAR	41,1

De maneira geral pode-se observar que as classes florestadas FP+FPE e FD+RA são melhores discriminadas pelas fusões realizadas pelo método *Ehlers* em que a banda HV esta envolvida no processo de fusão. As classes de estágios sucessionais intermediárias Rint+RI foram melhores discriminadas pelas classificações resultantes das fusões SPC\_HH\_HV, SPC\_SAR<sub>3</sub>, IHS\_OPT<sub>3</sub>HH\_HV e IHS\_OPT<sub>3</sub>SAR<sub>3</sub>, com destaque para a classificação da fusão SPC\_HH\_HV. A classe PS+AP7/24 foi notavelmente melhor discriminada pelas classificações das fusões IHS\_OPT<sub>3</sub>HH\_HV e IHS\_OPT<sub>3</sub>SAR<sub>3</sub>. A classe PL+PLBI foi melhor discriminada pela classificação da fusão IHS\_OPT<sub>3</sub>HH\_HV. A classe SP+S100 foi melhor discriminada pelas classificações das imagens IHS\_OPT<sub>3</sub>HH\_HV, IHS\_OPT<sub>3</sub>SAR<sub>3</sub>, TM\_SAR<sub>3</sub>, SPC\_SAR<sub>3</sub> e *Ehlers\_HV*. Já a classe S40 foi melhor discriminada pela classificação da imagem original ALOS/PALSAR.

Nota-se que 7 classes são melhores discriminadas por fusões em que pelo menos a banda HV está envolvida no processo. Destas 7 classes 5 foram melhor discriminadas por fusões em que a primeira PC das bandas da imagem ALOS/PALSAR ou de seus atributos (SAR<sub>3</sub>) estava envolvida nos processos de fusões, o que reforça a aplicabilidade do processamento proposto de integração dos dados SAR multipolarizados antes dos processos de fusões.

Assim, concluí-se o uso conjunto dos dados ópticos e micro-ondas melhora a classificação de todas as classes de interesse em estudo. Parece haver um método de fusão específico para melhora na discriminação de uma determinada classe. Estes são os casos das classes de Florestadas FP+FPE e FD+RA com o método de fusão *Ehlers* em que pelo menos a banda HV esta envolvida no processo de fusão, do método de fusão SPC\_HH\_HV com as classes de florestas secundárias Rint e RI e também do método de fusão IHS\_OPT<sub>3</sub>HH\_HV com as classes PS+AP7/24, PL+PLBI e SP+S100. A classe S40 parece ser melhor discriminada pela classificação da imagem ALOS/PALSAR. Outra observação importante é que a polarização HV esta presente na maioria dos métodos de fusão que aumentaram o percentual dos índices *Kappa* por classes. Mostrando assim, a importância da mesma na discriminação das classes.

Em concordância com a metodologia apresentada na seção 4.10, as análises das matrizes de confusão das classificações selecionadas foram utilizadas para verificar quais classes apresentam maiores confusões entre si. Analisando as figuras que representam as matrizes de confusão (ver Apêndice G) foi possível observar uma grande confusão entre as classes FD+RA e Rint, e também entre as classes PS+AP7/24 e PL+PLBI. Estes dois pares de classes apresentaram os maiores erros de classificação. Desta forma, as classes FD+RA e Rint foram agrupadas em uma nova classe denominada de FD+RA+Rint, assim como as classes PS+AP7/24 e PL+PLBI também foram agrupadas na classe Pasto (PA). Portanto, um novo conjunto de classes é formado, o qual é descrito na Tabela 5.10, contendo 6 classes de interesse.

Tabela 5.10. Descrição do novo conjunto de classes e número de amostras coletadas.

Classes	Número de polígonos/Número de <i>pixels</i>	Número de polígonos/Amostras de Treinamento	Número de polígonos/Amostras de Validação	Número de polígonos/Número de <i>pixels</i> (Total)	Cor
Floresta Primária – FP Floresta Primária em Exploração – FPE	17/70631 9/29256	14/60647	12/39240	26/99887	
Floresta Degradada – FD Regeneração Antiga – RA Regeneração Intermediária – Rint	20/1864 6/23282 10/4065	26/29963	10/16028	36/45991	
Regeneração Inicial – RI	9/6140	6/4424	3/1716	9/6140	
Pasto – PA	6/5104 12/1858 16/7046 7/5377	29/14404	12/4925	41/19898	
Solo Preparado para Agricultura – SP Soja100 – S100	8/8003 8/4933	10/9540	6/3396	16//12936	
Soja40 – S40	4/1126	3/746	1/380	4/1126	

### **5.10.5. Análise das classificações das imagens originais e das melhores classificações com 6 classes**

A Figura 5.33 apresenta os valores dos índices *Kappas* das classificações realizadas com 6 classes de interesse. Observe que as imagens classificadas com 6 classes são as mesmas que foram abordadas na seção anterior. Outro fato a ser notado é que esta figura é similar à Figura 5.32, sendo assim, o padrão de exibição dos resultados das classificações é o mesmo.

Analisando os valores dos *Kappas* das classificações das imagens originais e seus atributos, foi observado que novamente a classificação da combinação SAR<sub>3</sub> resultou em um índice *Kappa* estatisticamente superior ao da *Kappa* da classificação da imagem ALOS/PALSAR. A classificação dos atributos ópticos OPT<sub>3</sub> foi estatisticamente inferior ao da imagem LANDSAT5/TM. Então, nas análises que se seguem a classificação OPT<sub>3</sub> não será analisada. Já a imagem ALOS/PALSAR poderá participar de algumas avaliações para verificar a aplicabilidade da mesma em um ambiente complexo como a área de estudo selecionada.

Os valores dos índices *Kappas* de todas as classificações em análise e seus respectivos resultados do teste z são mostrados na Tabela 5.11. Como era de se esperar os índices *Kappas* das classificações com 6 classes aumentaram quando comparados com as mesmas imagens classificadas com 8 classes, à exceção da classificação da imagem combinada TM\_SAR<sub>3</sub>. Nota-se também que somente as classificações das imagens fusionadas resultaram em valores dos índices *Kappas* estatisticamente superiores ao valor do índice *Kappa* da classificação da imagem LANDSAT5/TM. Ao contrário do que se esperava a classificação com 6 classes da combinação TM\_SAR<sub>3</sub> resultou em um *Kappa* estatisticamente inferior ao da imagem LANDSAT5/TM. Esta constatação indica que os resultados das classificações por fusões podem ser superiores aos resultados das classificações das combinações. Para entender melhor este resultado a classificação da combinação TM\_SAR<sub>3</sub> irá participar das análises que se seguem

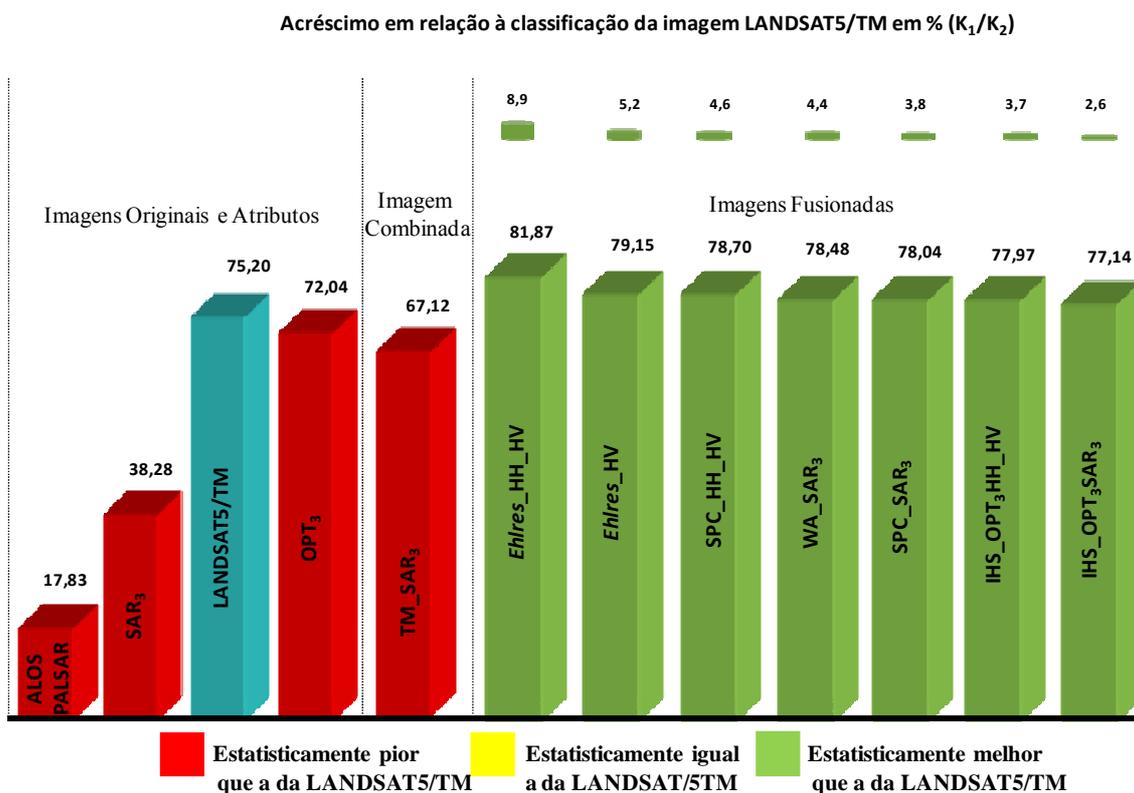


Figura 5.33. Valores dos índices *Kappas* das classificações realizadas com 6 classes de interesse.

Entre as imagens fusionadas tem destaque as classificações das imagens resultantes das fusões realizadas pelo método *Ehlers*, pois a classificação da imagem *Ehlers\_HH\_HV* resultou estatisticamente no maior valor do índice *Kappa*. Em segundo lugar ficaram as classificações das fusões *Ehlers\_HV* e *SPC\_HH\_HV*, sendo estas duas estatisticamente iguais.

Desta maneira, conclui-se que as 7 imagens fusionadas abordadas nesta seção melhoram a classificação da área de estudo, mesmo quando o número de classes em estudo é alterado. Nas Figuras 5.34 e 5.35 são mostradas as imagens das classificações com 6 classes. Nestas figuras é possível notar que as feições geomorfológicas são melhor visualizadas na classificação da imagem ALOS/PALSAR, sendo que o mesmo não ocorre com as classificações dos seus atributos e demais classificações. Entretanto, a confusão entre as classes de florestas também é maior nesta imagem e na classificação de seus atributos SAR<sub>3</sub>.

Tabela 5.11. Testes de hipótese z entre os pares de *Kappas*.

Imagens	Kappa	Var(K) x 10 <sup>-6</sup>	ALOS_PALSAR	SAR <sub>3</sub>	LANDSAT5/TM	Ehlers_HH_HV	Ehlers_HV	SPC_HH_HV	WA_SAR <sub>3</sub>	SPC_SAR <sub>3</sub>	IHS_OPT <sub>3</sub> HH_HV	IHS_OPT <sub>3</sub> SAR <sub>3</sub>	TM_SAR <sub>3</sub>
ALOS_PALSAR	0,1783	8,43	x	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
SAR <sub>3</sub>	0,3828	7,94	-50,54	x	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
LANDSAT5/TM	0,7520	5,21	-155,37	-101,81	x	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
TM_SAR <sub>3</sub>	0,6712	6,54	-127,41	-75,78	23,59	x	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Ehlers_HH_HV	0,8187	3,96	-181,98	-126,36	-22,02	-45,54	x	0,00	0,00	0,00	0,00	0,00	0,00
Ehlers_HV	0,7915	4,37	-171,43	-116,48	-12,75	-36,43	9,44	x	0,07	0,01	0,00	0,00	0,00
SPC_HH_HV	0,7870	4,57	-168,82	-114,25	-11,18	-34,75	10,86	1,50	x	0,23	0,02	0,01	0,00
WA_SAR <sub>3</sub>	0,7848	4,66	-167,64	-113,23	-10,42	-33,95	11,56	2,23	0,73	x	0,08	0,05	0,00
SPC_SAR <sub>3</sub>	0,7804	4,71	-166,11	-111,77	-9,01	-32,57	13,01	3,68	2,16	1,43	x	0,41	0,00
IHS_OPT <sub>3</sub> HH_HV	0,7797	4,67	-166,19	-111,76	-8,81	-32,42	13,27	3,91	2,39	1,66	0,22	x	0,00
IHS_OPT <sub>3</sub> SAR <sub>3</sub>	0,7714	4,79	-163,16	-108,92	-6,14	-29,79	15,98	6,62	5,08	4,34	2,90	2,69	x

 Valor-*p* maior que 0,05      *Kappas* Iguais  
 Valor-*p* menor que 0,05      *Kappas* Diferentes  
 *Kappa* da classificação da imagem da linha melhor que o *Kappa* da classificação da imagem na coluna  
 *Kappa* da classificação da imagem da linha pior que o *Kappa* da classificação da imagem na coluna

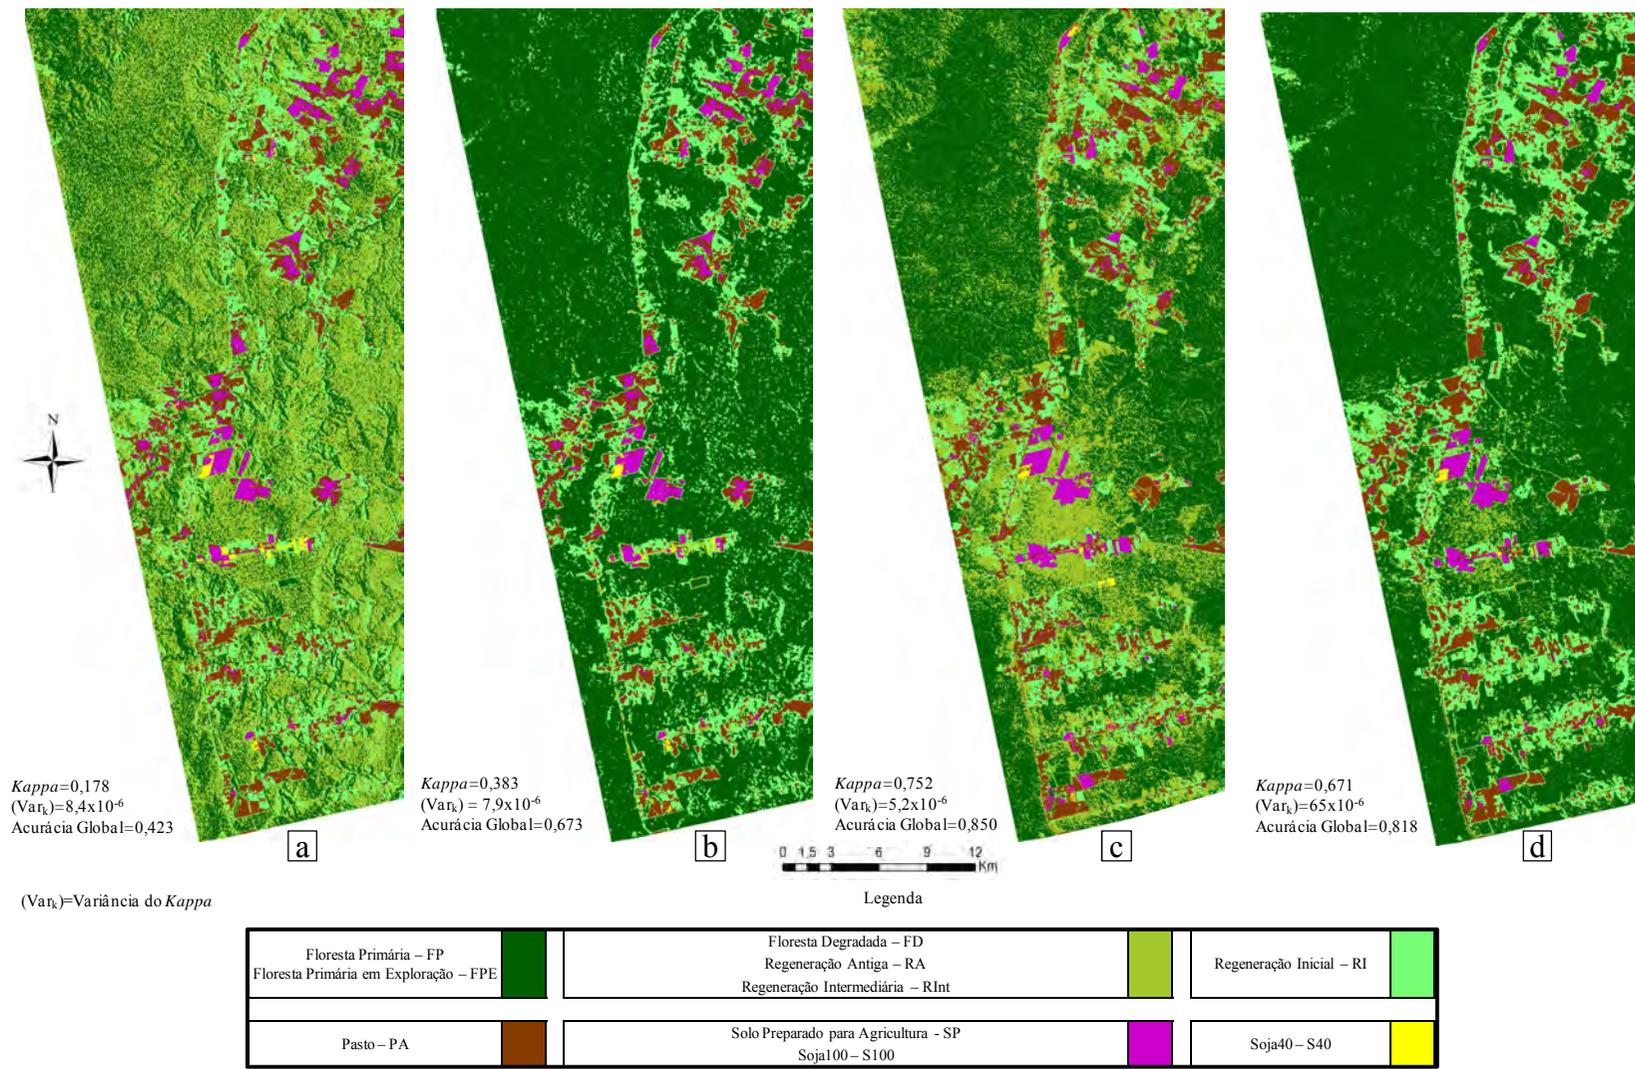


Figura 5.34. Classificações das imagens: a) ALOS/PALSAR, b) SAR<sub>3</sub>, c) LANDSAT5/TM e d) TM\_SAR<sub>3</sub>.

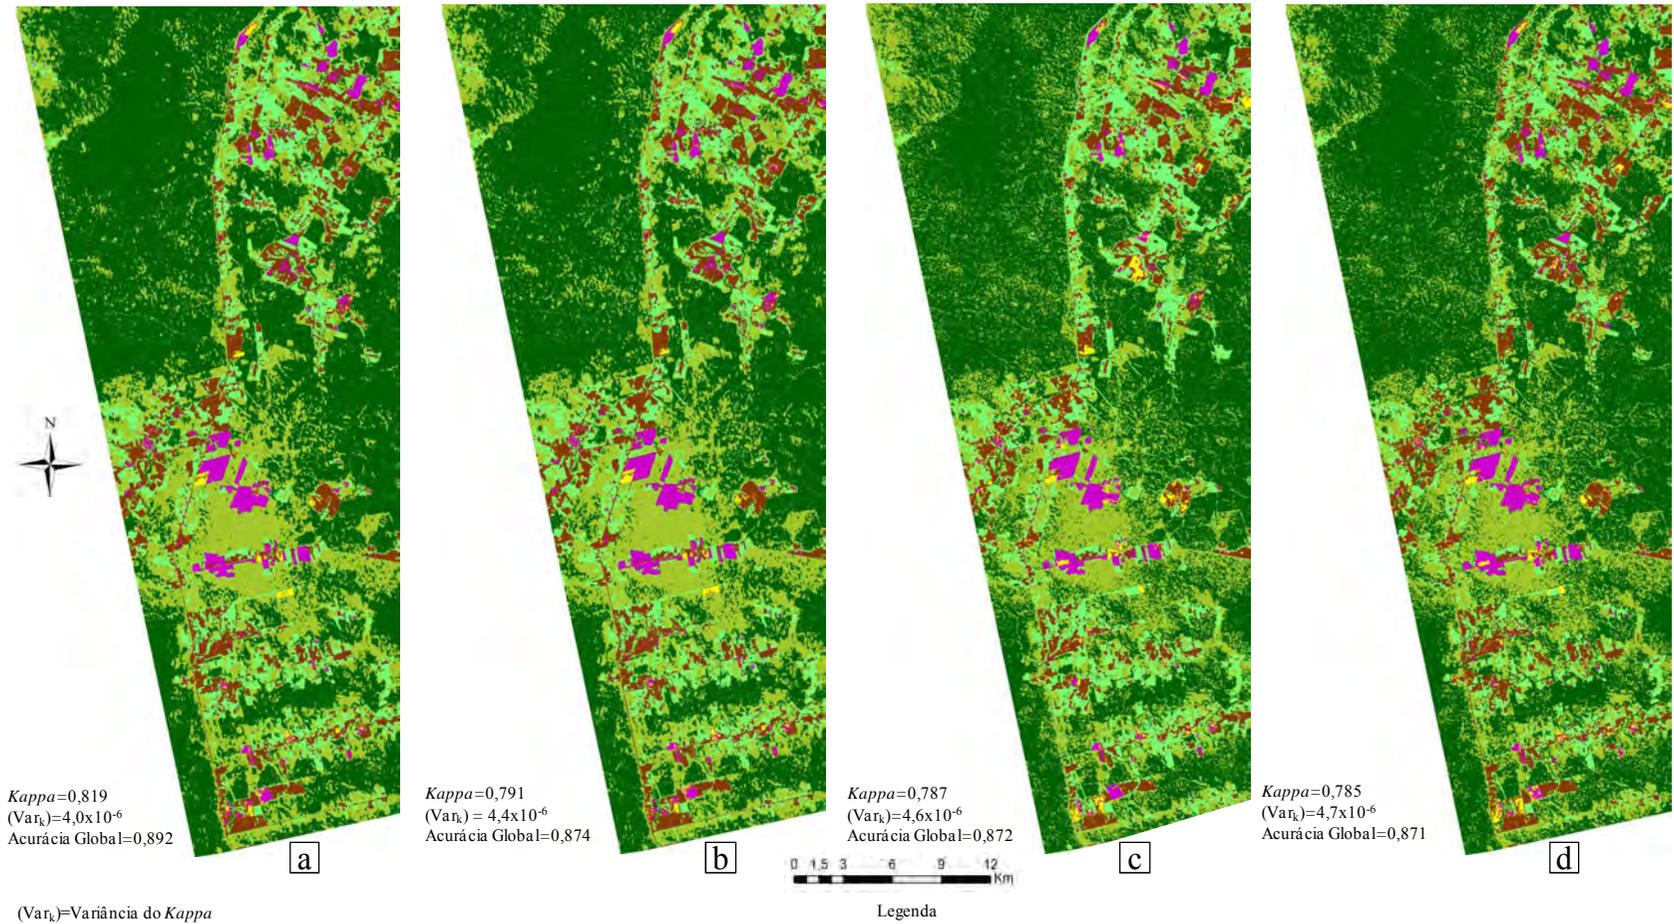


Figura 5.35

(Continua)

Figura 5.35 – Continuação

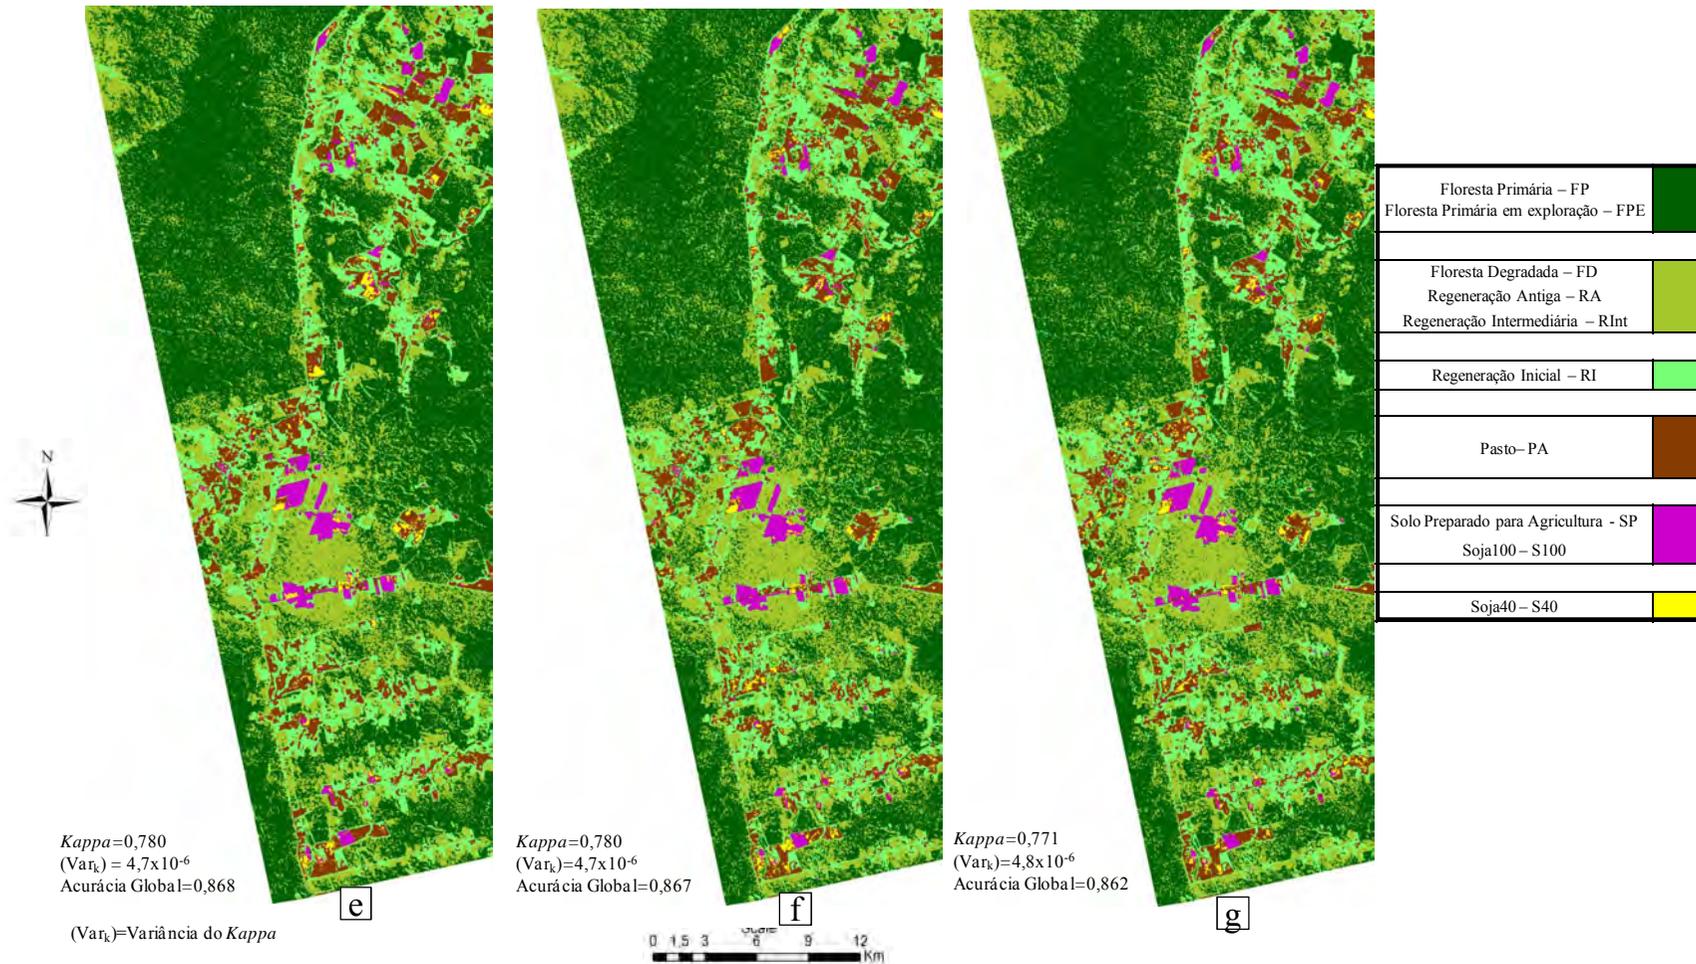


Figura 5.35. Classificações das imagens fusionadas: a) *Ehlers\_HH\_HV*, b) *Ehlers\_HV*, c) *SPC\_HH\_HV*, d) *WA\_SAR<sub>3</sub>*, e) *SPC\_SAR<sub>3</sub>*, f) *IHS\_OPT<sub>3</sub>HH\_HV*, g) *IHS\_OPT<sub>3</sub>SAR<sub>3</sub>*.

Nas classificações com 6 classes da imagens SAR<sub>3</sub> e da combinação TM\_SAR<sub>3</sub> também foram observadas o surgimento de feições falsas que podem influenciar negativamente na qualidade e na acurácia da mesma. Estas feições costumam surgir em regiões da imagem que possuem classes com áreas de menores dimensões como é o caso das classes de agricultura. Este fato pode ser melhor visualizado na Figura 5.36 nas áreas indicadas pelas setas pretas.

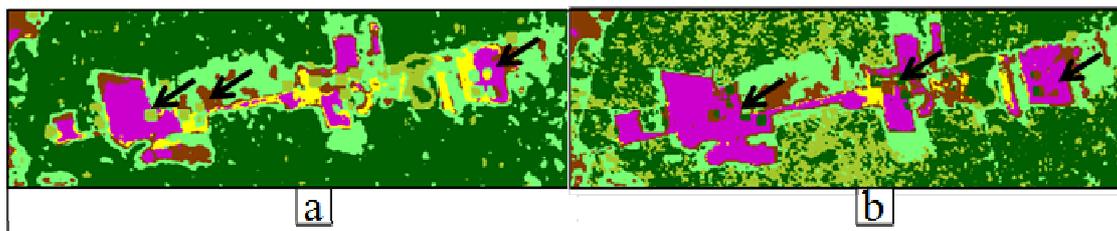


Figura 5.36. Visualização das classificações em uma região de agricultura selecionada na imagem: a) SAR<sub>3</sub> e c) TM\_SAR<sub>3</sub>.

Como pode ser observado não é possível realizar uma análise clara das classificações baseado apenas em uma avaliação visual. Sendo assim, para o melhor entendimento dos resultados das classificações foram analisados os *Kappas* por classe. O gráfico com os valores dos *Kappas* são mostrados na Figura 5.37 bem como o acréscimo percentual relativo ao *Kappa* da classificação da imagem LANDSAT5/TM.

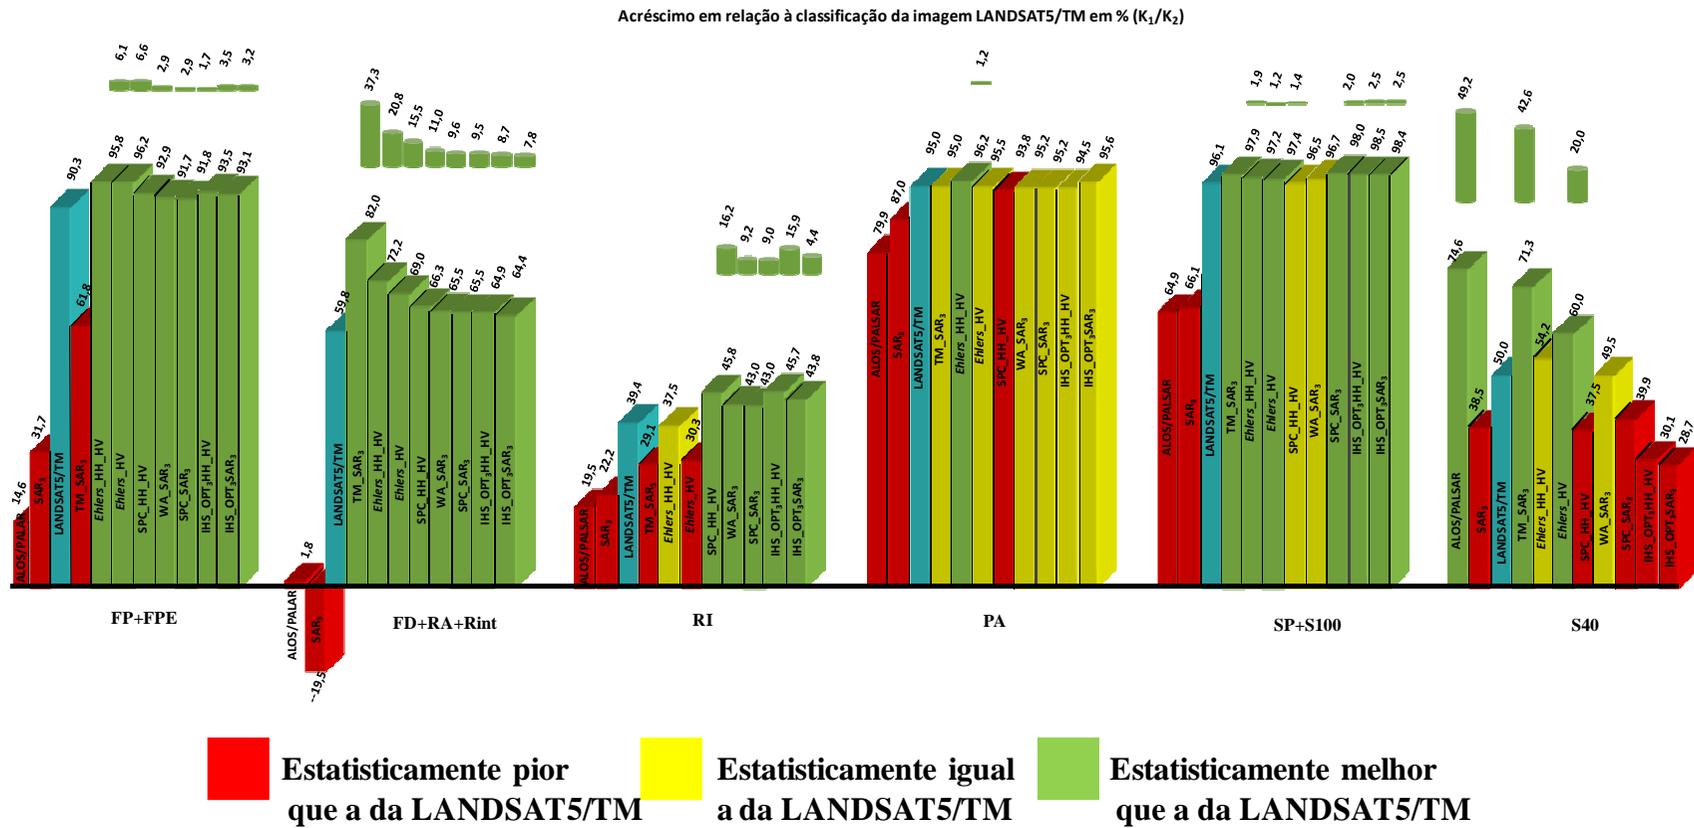


Figura 5.37. Kappa por classe das imagens classificadas selecionadas.

A Tabela 5.12 mostra as classificações que resultaram estatisticamente nos maiores valores dos índices *Kappas* por classe e o acréscimo percentual das mesmas em relação ao resultado da classificação da imagem LANDSAT5/TM.

Tabela 5.12. Maiores acréscimos percentuais nos valores dos índices *Kappas* por classe com 6 classes.

Classes	Métodos de fusão	Acréscimo
FP+FPE	<i>Ehlers_HV</i>	6,6
FD+RA+Rint	TM_SAR <sub>3</sub>	37,3
RI	SPC_HH_HV	16,2
PA	<i>Ehlers_HH_HV</i>	1,2
SP+S100	IHS_OPT <sub>3</sub> HH_HV	2,5
S40	ALOS/PALSAR	49,2

Na classe FP+FPE somente as classificações das imagens SAR<sub>3</sub> e TM\_SAR<sub>3</sub>, apresentaram os valores dos índices *Kappas* estatisticamente inferiores ao da classificação da imagem LANDSAT5/TM. Neste contexto, tem destaque a classificação da imagem fusionada *Ehlers\_HV*, pois foi esta classificação que resultou estatisticamente no maior índice *Kappa* por classe. O acréscimo percentual no valor do índice *Kappa* desta classificação relativo ao resultado da classificação da imagem LANDSAT5/TM foi de aproximadamente 6,6%.

Na classe FD+RA+Rint somente a classificação da imagem SAR<sub>3</sub> apresentou o valor dos índices *Kappa* estatisticamente inferior ao da classificação da imagem LANDSAT5/TM. Nesta classe tem destaque a classificação da imagem combinada TM\_SAR<sub>3</sub>, pois foi a que resultou estatisticamente no maior índice *Kappa* por classe. O acréscimo percentual no valor do índice *Kappa* desta classificação relativo ao resultado da classificação da imagem LANDSAT5/TM foi de aproximadamente 37,3%.

Observando-se a Tabela 5.12 e a Figura 5.37 pode-se notar que embora a classificação da combinação TM\_SAR<sub>3</sub> tenha se destacado na classificação das classes florestadas FD+RA+Rint, na classe florestada FP+FPE o *Kappa* desta classificação foi

estatisticamente inferior ao da classificação da imagem LANDSAT5/TM, portanto, acredita-se que não é aconselhável utilizar a classificação desta combinação para discriminar as classes florestadas. A classificação da fusão *Ehlers\_HV* foi estatisticamente superior as demais classificações na classe FP+FPE. Na classe FD+RA+Rint a classificação da imagem *Ehlers\_HH\_HV* apresentou estatisticamente o segundo maior valor do índice *Kappa*. Portanto, o resultado desta análise está em concordância com a análise das classificações realizadas com 8 classes, que concluiu que as classes florestadas são melhores discriminadas pelas fusões realizadas pelo método *Ehlers* em que pelo menos a banda HV está envolvida no processo de fusão.

Na classe RI as classificações, *IHS\_OPT<sub>3</sub>HH\_HV* e *SPC\_HH\_HV* resultaram em índices *Kappas* estatisticamente iguais entre si e superiores ao da classificação da imagem LANDSAT5/TM. Os acréscimos percentuais nos valores dos índices *Kappas* destas classificações relativos ao resultado da classificação da imagem LANDSAT5/TM foram de aproximadamente 15,9% e 16,2%, respectivamente. Com 8 classes teve destaque a classificação da fusão *SPC\_HH\_HV*. Por este motivo a classificação da fusão *SPC\_HH\_HV* é a indicada para discriminar as classes de estágios sucessionais.

Na classe PA, somente a classificação da imagem *Ehlers\_HH\_HV* apresentou o valor do índice *Kappa* estatisticamente superior ao da classificação da imagem LANDSAT5/TM. O acréscimo percentual no valor do índice *Kappa* desta classificação relativo ao resultado da classificação da imagem LANDSAT5/TM foi de aproximadamente 1,2%. Nota-se que este é um dos menores valores de acréscimo por classe dentre as 6 classes de interesse. Portanto, a utilização conjunta dos dados ópticos e SAR não contribuiu na melhora da discriminação desta classe se comparado com as demais 5 classes de interesse.

Repare que a classificação da imagem *Ehlers\_HH\_HV* foi uma das classificações que apresentou maiores dificuldades em separar as classes PS+AP7/24 e PL+PLBI. Este fato pode ser observado na Figura 5.38, que é a representação da matriz de confusão desta

classificação com 8 classes. Portanto, o agrupamento destas classes na classe pasto favoreceu a notavelmente e classificação desta imagem fusionada. Assim, conclui-se que se a prioridade for manter as classes de pastos separadas a classificação da imagem IHS\_OPT3HH\_HV é a indicada (ver Figura 5.32), entretanto, se estas classes forem agrupadas recomenda-se a utilização da classificação da fusão *Ehlers\_HH\_HV*.

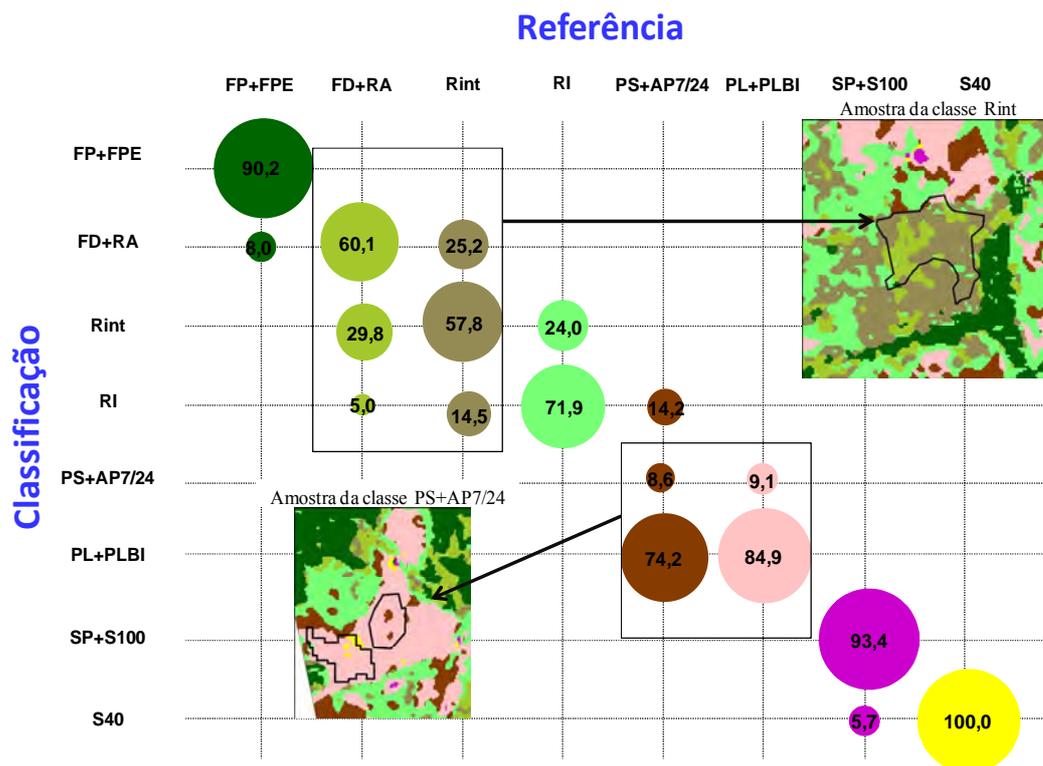


Figura 5.38. Matriz de confusão da classificação da imagem *Ehlers\_HH\_HV* com 8 classes.

Na classe SP+S100 as classificações das imagens SPC\_SAR<sub>3</sub>, IHS\_OPT3HH\_HV e IHS\_OPT3SAR<sub>3</sub> resultaram em valores do índice *Kappa* estatisticamente iguais entre si e superiores ao valor do índice *Kappa* da classificação da imagem LANDSAT5/TM. Os acréscimos percentuais nos valores dos índices *Kappas* destas classificações relativos ao resultado da classificação da imagem LANDSAT5/TM foram de aproximadamente 2,0%, 2,5% e 2,5%, respectivamente. Nota-se estas classificações foram as mesmas que se destacaram nas classificações com 8 classes, sendo estas portanto indicadas para a discriminação desta classe

Na classe S40, a classificação das imagens TM\_SAR<sub>3</sub> e ALOS/PALSAR foram estatisticamente iguais entre si e superiores a todos os demais índices *Kappas* das classificações das imagens em análise. Os acréscimos percentuais nos valores dos índices *Kappas* destas classificações relativos ao resultado da classificação da imagem LANDSAT5/TM foram de aproximadamente 42,6% e 49,2%. A classificação com 8 classes que apresentou maior exatidão nesta classe foi a da ALOS/PALSAR. Como a classificação da combinação TM\_SAR<sub>3</sub> apresentou detalhes falsos tanto nas classificações com 6 e 8 classes em regiões de agricultura, aconselha-se utilizar a classificação da imagem ALOS/PALSAR na discriminação da referida classe.

Através da análise do *Kappa* por classe foi possível entender porque o *Kappa* da classificação da combinação TM\_SAR<sub>3</sub> foi estatisticamente inferior ao da classificação da imagem LANDSAT5/TM. Embora esta classificação tenha se destacado na discriminação das classes FD+RA+Rint e S40, e tenha resultado em um *Kappa* estatisticamente superior ao da classificação da imagem LANDSAT5/TM na classe SP+S100, nas demais classes o valor do *Kappa* foi estatisticamente inferior ao da imagem LANDSAT5/TM. Nota-se que esta foi a única classificação que resultou em *Kappas* por classes estatisticamente inferiores ao da classificação da imagem LANDSAT5/TM. Em contrapartida, a classificação da fusão *Ehlers\_HH\_HV*, não apresentou nenhum valor do *Kappa* por classe inferior ao da classificação da imagem LANDSAT5/TM. Das 6 classes em análise 4 apresentaram o valor do índice *Kappa* estatisticamente superior ao da classificação da imagem LANDSAT5/TM, com destaque na discriminação de 2 classes (FP+FPE e PA). Nas classes RI e S40 o *Kappa* foi estatisticamente igual ao da imagem LANDSAT5/TM. Esta análise está em concordância com o *Kappa* da classificação visto que este foi estatisticamente superior às demais classificações.

Assim, concluí-se que o uso conjunto dos dados ópticos e SAR melhora a classificação de todas as classes de interesse em estudo. Nas classificações com 6 classes também parece haver um método de fusão específico para melhorar a discriminação de uma determinada classe, sendo que na maioria das classes os métodos são os mesmos já

comentados na seção 5.10.4. Estes são os casos das classes florestadas FP+FPE e FD+RA+Rint com o método de fusão *Ehlers* em que pelo menos a banda HV está envolvida no processo de fusão. O mesmo ocorre com o método SPC\_HH\_HV e a classe de RI, assim como também com o método de fusão IHS\_OPT<sub>3</sub>HH\_HV e a classe SP+S100. Novamente a classe S40 foi melhor discriminada pela classificação da imagem ALOS/PALSAR.

A exceção neste cenário foi a classificação da classe PA, pois esta apresentou um resultado diferente das classes de origem PS+AP<sub>7/24</sub> e PL+PLBI. Portanto, conclui-se que se a prioridade for manter as classes de pastos separadas a classificação IHS\_OPT<sub>3</sub>HH\_HV é a indicada (ver Figura 5.32), entretanto, se estas classes forem agrupadas recomenda-se a utilização da fusão *Ehlers*\_HH\_HV. Outra observação já realizada na seção 5.10.4 que permanece nesta análise é a importância da polarização HV, pois geralmente esta banda está presente nos métodos de fusões que aumentaram o percentual da classificação de cada uma das classes em estudo.

Observou-se que a maioria dos métodos de fusões que apresentaram bons resultados, foram processados utilizando a primeira PC das bandas HH e HV ou atributos SAR selecionados. Analisando-se os *Kappas* por classe das classificações com 6 classes foi observado que 4 classes foram melhor discriminadas por fusões em que a primeira PC das bandas da imagem ALOS/PALSAR ou de seus atributos SAR<sub>3</sub> estava envolvida nos processos de fusões. Sendo assim, pode-se concluir que o método proposto de integração de imagens SAR multipolarizadas e de seus atributos apresenta aplicabilidade.

No Apêndice H são mostradas as figuras que representam as matrizes de confusão das classificações realizadas com 6 classes. Ao observá-las é possível notar que dentre as classificações em análise a resultante da fusão *Ehlers*\_HH\_HV foi a que apresentou relativamente menor confusão entre as classes como pode ser observado na Figura 5.39.

Ao se comparar a representação das matrizes de confusão da classificação da imagem *Ehlers*\_HH\_HV com 8 e 6 classes (Figuras 5.38 e 5.39) é possível observar a importância

do agrupamento das classes PS+AP7/24 e PL+PLBI na classe PA e da classe Rint na classe (FD+RA+Rint). Isto porque é notável a diminuição da confusão destas classes com as demais classes de interesse quando agrupadas. Este fato também é observado quando se compara as figuras que representam as matrizes de confusão das mesmas imagens selecionadas classificadas com 8 e com 6 classes (ver Apêndices G e H) o que reforça a importância de se agrupar as referidas classes para diminuir a confusões entre as mesmas, e por consequência melhorar a exatidão das classificações.

### Referência

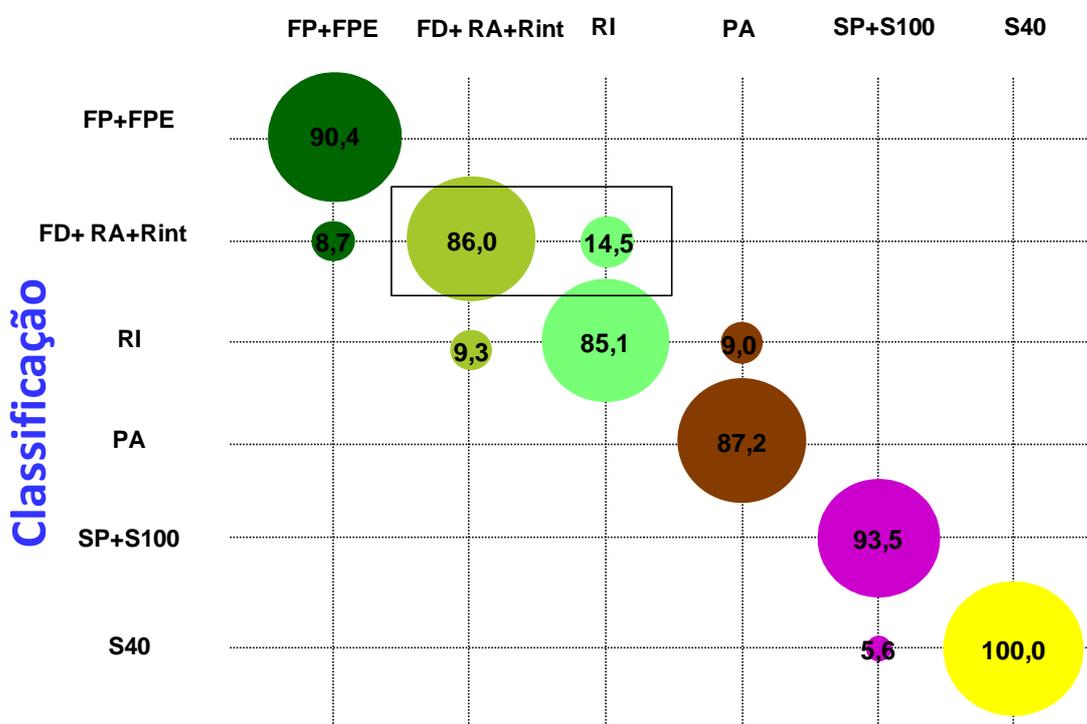


Figura 5.39. Matriz de confusão da classificação da imagem *Ehlers\_HH\_HV* com 6 classes.



## 6. CONCLUSÕES E RECOMENDAÇÕES

Esta dissertação teve o objetivo de avaliar diferentes formas de integrar dados (fusões e combinações) de diferentes sensores imageadores (SAR e ópticos) visando identificar a mais adequada para o mapeamento do uso e cobertura da terra de uma região da Amazônia brasileira. Como objetivos específicos podem-se listar a identificação das classes que são melhores discriminadas com a utilização conjunta dos dados ópticos e SAR, e também avaliar um modo de integrar a informação contida em imagens SAR multipolarizadas antes dos processos de fusões.

Para atingir este objetivo, várias etapas de trabalho foram efetuadas, destacando-se: 1) avaliação planimétrica da imagem ALOS/PALSAR; 2) determinação de tamanhos de janelas adequados para a extração de medidas de textura de imagens SAR; 3) desenvolvimento e aplicação de uma metodologia para a determinação de um conjunto de atributos visando à classificação de uso e cobertura da terra e 4) avaliação e comparação dos resultados das classificações das imagens integradas por combinação e por diferentes métodos de fusões.

A avaliação planimétrica da imagem ALOS/PALSAR *Geocoded* para a área em questão apresentou tendências na resultante das componentes planimétricas de 139 m. Após a remoção da tendência a imagem foi classificada no PEC classe “A” para a escala de mapeamento de 1:100.000. Isto significa que os dados e anotações registrados em campo eram correspondentes às feições identificadas nas imagens LANDSAT5/TM e ALOS/PALSAR. Este fato reforça a qualidade das classificações e das validações das mesmas, uma vez que as feições identificadas em campo correspondem as mesmas feições nas imagens.

O estudo sobre a determinação dos tamanhos de janelas adequados para a extração de medidas de textura de dados SAR levou à conclusão que para a região em estudo, em que coexistem áreas de agricultura familiar, que são relativamente pequenas, com áreas de culturas de grãos comerciais (e.g., soja) e pastagens, que são relativamente grandes

não é aconselhável utilizar, seja para processar fusões ou melhorar a visualização de feições, tamanhos de janelas superiores a 15x15, pois a heterogeneidade espacial destas regiões pode ser subjugada.

O método utilizado para selecionar subconjuntos ótimos de atributos descrito na seção 4.6 mostrou-se eficiente. Entretanto, recomenda-se que este seja aplicado em dados desconcorrelacionados, e que a seleção dos atributos seja realizada em conjunto com análises exploratórias dos dados. Os atributos de radar selecionados consistiram de três medidas extraídas da matriz de co-ocorrência proposta por *Haralick*: média da banda na polarização HV com janela 7x7 (MED\_7\_HV), homogeneidade e dissimilaridade da banda na polarização HH com janela 15x15 (HOM\_15\_HH e DIS\_15\_HH, respectivamente). Os atributos ópticos selecionados foram a banda 5 (B5) da imagem LANDSAT5/TM, e as imagens frações de vegetação (IMF\_VEG) e de sombra (IMF\_SM).

A análise exploratória dos atributos ópticos e SAR mostrou a importância dos atributos ópticos na discriminação das classes florestadas (FP, FPE, FD, RA e Rint). Também mostrou que a imagem SAR tem aplicabilidade na discriminação das classes não florestadas (PS, AP7/24, PL, PLBI, SP, S100 e S40). Neste cenário, a análise dos gráficos formados por pares de atributos se mostrou útil, pois permitiu visualizar que a utilização conjunta dos dados ópticos com SAR pode ser vantajosa em um ambiente complexo como a área em questão.

Para responder à questão sobre a melhor forma de integração de dados ópticos e SAR para a classificação do uso e cobertura da terra, foram processadas 2 imagens originais (LANDSAT5/TM e ALOS/PALSAR), 2 imagens formadas pelos atributos extraídos das imagens originais, 6 imagens combinadas e 80 imagens fusionadas por diferentes métodos. Portanto, 90 imagens distintas, no total, foram classificadas e tiveram seus resultados avaliados.

Considerando as classificações das imagens originais (LANDSAT5/TM e ALOS/PALSAR) e de seus atributos selecionados (OPT<sub>3</sub> e SAR<sub>3</sub>), foi observado que a classificação da imagem original LANDSAT5/TM apresentou maior exatidão ( $K = 0,652$ ). Entretanto, como a região de estudo esta localizada na Amazônia, nem sempre é possível adquirir imagens ópticas sem a presença destas nuvens. Portanto, vale ressaltar que, nas classificações com 8 classes, a utilização do conjunto de atributos de textura de radar (SAR<sub>3</sub> –  $K = 0,317$ ) melhorou em aproximadamente 133% o valor do índice *Kappa* da classificação da imagem SAR original ( $K = 0,136$ ). Desempenho similar foi observado nas classificações com 6 classes, pois a classificação dos atributos (SAR<sub>3</sub> –  $K = 0,383$ ) melhorou em aproximadamente 114% o valor do índice *Kappa* da classificação da imagem SAR original ( $K = 0,178$ ). Baseado no exposto, conclui-se que a classificação dos atributos de texturas é uma opção interessante para melhorar a exatidão da classificação da área em questão quando se tem acesso apenas a dados SAR. Porém, deve-se levar em consideração o surgimento de feições falsas nestas classificações. Em contra partida, na análise visual destas classificações com 6 e 8 classes foi possível observar algumas feições geomorfológicas nas classificações da imagem ALOS/PALSAR. Nota-se que este fato não é observado nas classificações de seus atributos. Esta observação reforça a aplicabilidade das imagens SAR na visualização destas feições.

Foi possível observar que várias classificações resultantes das imagens fusionadas e combinadas apresentaram valores dos índices *Kappas* estatisticamente superiores ao da imagem original LANDSAT5/TM. Dentre estas classificações foram selecionadas as combinações e fusões que resultaram nos maiores valores dos índices *Kappas*. A classificação da combinação que apresentou o melhor resultado se comparado com a classificação da imagem LANDSAT5/TM e das demais combinações, foi a que utilizou as seis bandas da imagem LANDSAT5/TM e os três atributos de textura de radar (TM\_SAR<sub>3</sub> –  $K = 0,678$ ). Somente duas classificações de imagens fusionadas são estatisticamente superiores a esta combinação: a fusão *Wavelet á trous* usando a primeira componente principal dos atributos SAR (WA\_SAR<sub>3</sub> –  $K = 0,705$ ) e a fusão SPC com a primeira componente principal dos dados SAR originais (SPC\_HH\_HV –  $K = 0,685$ ). Entretanto, uma análise visual da classificação desta combinação mostrou alguns detalhes

falsos. Este resultado indica que os resultados de classificação por fusões podem ser superiores aos da combinação, mas é necessário que se escolha o método de fusão e os atributos apropriados. Este fato é mais notável quando as classificações são realizadas com 6 classes, pois neste contexto a classificação da combinação TM\_SAR<sub>3</sub> foi estatisticamente inferior à classificação da imagem LANDSAT5/TM.

Para melhorar a exatidão da classificação do uso e cobertura da terra, da área em questão, com 8 classes de interesse recomenda-se os métodos de fusões *Ehlers*, *Wavelet á trous*, IHS e SPC. Entretanto, estes 3 últimos métodos de fusões apresentaram bons resultados somente quando as fusões foram processadas utilizando a primeira PC das bandas da imagem ALOS/PALSAR ou dos 3 atributos SAR selecionados. Deve-se ressaltar que para que a fusão IHS apresentasse bons resultados foi necessário utilizar os atributos ópticos selecionados (OPT<sub>3</sub>). O método de fusão *Ehlers* também apresentou bons resultados, sendo que os melhores resultados foram obtidos quando os dados originais ópticos foram utilizados e pelo menos a banda HV esteve envolvida no processo de fusão. Sendo assim, caso o usuário possua apenas uma banda SAR na polarização HV este método é o indicado. A desvantagem deste método é que ele, geralmente, está implementado em aplicativos comerciais.

Na análise das figuras que representam as matrizes de confusão entre as 8 classes de interesse, foi observada maior confusão entre as classes FD+RA com Rint e PS+AP7/24 com PL+PLBI. Com o agrupamento destas classes, os resultados das classificações das imagens fusionadas apresentaram valores dos índices *Kappas* estatisticamente superiores ao valor do índice *Kappa* da classificação da imagem LANDSAT5/TM. O maior valor global de *Kappa* foi obtido com a classificação da fusão pelo método de *Ehlers* utilizando a primeira componente principal dos dados SAR (*Ehrlres\_HH\_HV*), seguido pelos métodos de *Ehlers* com a polarização HV (*Ehrlres\_HV*) e pelo método SPC utilizando a primeira componente principal dos dados SAR (*SPC\_HH\_HV*). Assim, conclui-se que os métodos de fusões selecionados melhoram a classificação da área de estudo, mesmo quando foi alterado o número de classes. Observando-se as representações das matrizes de confusão

das classificações com 6 classes foi notado que as maiores confusões ocorreram entre as classes RI e FD+RA+Rint, e entre as classes de PA e RI, mostrando a dificuldade em se classificar corretamente a classe de Regeneração intermediária.

De maneira geral os métodos de fusão que não melhoraram significativamente a exatidão das classificações se comparado com a classificação da imagem LANSAT5/TM foram: Transformada de *Brovey*, fusões IHS com os dados originais ópticos e uma polarização de radar, *Wavelet* com os atributos ópticos selecionados, *Wavelet* ou *Wavelet à trous* com PC e *Wavelet* com IHS. Portanto, não se aconselha a utilização dos mesmos para fins de classificação do uso e cobertura da terra da área em questão.

Outro objetivo deste estudo foi identificar as classes que são melhores discriminadas com a utilização conjunta dos dados ópticos e SAR, com a finalidade de auxiliar usuários e pesquisadores a selecionarem os métodos de fusões que melhor discriminam as classes prioritárias em um determinado estudo. Baseado nas análises dos índices *Kappas* por classes com 8 e 6 classes conclui-se que o uso conjunto dos dados ópticos e SAR melhora a classificação de todas as classes de interesse em estudo. Nas classificações com 8 e 6 classes parece haver um método de fusão específico para melhorar a discriminação de uma determinada classe. Estes são os casos das classes florestadas FP+FPE e FD+RA+Rint com o método de fusão *Ehlers* em que pelo menos a banda HV esta envolvida no processo, do método de fusão SPC\_HH\_HV com as classes de florestas secundárias RI e Rint, IHS\_OPT<sub>3</sub>\_HH\_HV com a classe SP+S100. A classe S40 foi melhor discriminada pela classificação da imagem ALOS/PALSAR em ambos os casos (8 e 6 classes de estudos). A exceção neste cenário foi a classificação da classe PA, pois esta apresentou um resultado diferente das classes de origem PS+AP7/24 e PL+PLBI. Assim, conclui-se que se a prioridade for manter as classes de pastos separadas a classificação da imagem IHS\_OPT<sub>3</sub>HH\_HV é a indicada, entretanto, se estas classes forem agrupadas recomenda-se a utilização da fusão *Ehlers*\_HH\_HV. Conclui-se também que a banda HV contém informações importantes na melhora da discriminação das

classes de interesse, pois geralmente esta banda está presente nos métodos de fusões que aumentaram o percentual da classificação de cada uma das classes em estudo.

Considerando as classificações mencionadas acima, para as classificações com 8 classes, os maiores acréscimos nos valores dos índices *Kappas* por classe em relação à classificação da imagem LANDSAT5/TM foram, em ordem decrescente as classes PS+AP7/24 (113,3%), S40 (41,1%), Rint (38,7%), PL+PLBI (35,8%), RI (19,6%), FD+RA (11,8%), FP+FPE (5,2%) e SP+S100 (1,8%). Considerando as classificações mencionadas acima, para as classificações com 6 classes, os maiores acréscimos nos valores dos índices *Kappas* por classe em relação à classificação da imagem LANDSAT5/TM foram, em ordem decrescente as classes S40 (49,2%), FD+RA+Rint (20,8%), RI (16,2%), FP+FPE (6,6%), SP+S100 (2,5%) e PA (1,2%).

Comparando-se os acréscimos nos valores dos índices *Kappas* por classe entre as classificações com 8 e 6 classes foi possível notar que as maiores alterações nestes valores ocorreram nas classes que foram influenciadas pelo agrupamento das classes PS+AP7/24, PL+PLBI e Rint. Pode-se observar que quando as classes PS+AP7/24 (113,3%) e PL+PLBI (35,8%), são agrupadas na classe PA o acréscimo em relação ao *Kappa* da classificação LANDSAT5/TM foi de 1,2%. Acredita-se que isto ocorreu devido à dificuldade das classificações em discriminar estas classes PS+AP7/24 e PL+PLBI, pois o agrupamento das mesmas resultou na melhora nos valores destes índices em todas as classificações, inclusive na da LANDSAT5/TM. Esta análise é visualizada na representação das matrizes de confusão mostradas nesta dissertação. O acréscimo deste índice foi maior na classe FD+RA (11,8%) quando a classe Rint foi agrupada a esta (FD+RA+Rint - 20,8%). Primeiramente isto indica a dificuldade de todas as classificações em discriminar a classe Rint das demais classes. Esta constatação é observada nos valores dos *Kappas* por classe das classificações com 8 classes e nas figuras que representam as matrizes de confusões das classificações supracitadas. Portanto, conclui-se que o agrupamento destas classes é importante para melhorar a acurácia das classificações da área de estudo em questão. Nota-se que estas análises reforçam a aplicabilidade desta forma de

representação das matrizes de confusão na visualização das classes que apresentam consideráveis confusões entre si e no auxílio que a mesma fornece na decisão sobre quais classes devem ser agrupadas.

O último objetivo deste estudo foi propor e avaliar uma forma de se realizar fusões com imagens SAR multipolarizadas de forma que a informação contida nas bandas polarizadas ou de dados extraídos dos mesmos participem dos processos de fusões. O método proposto consiste em extrair a primeira componente dos dados de radar ou dos atributos extraídos dos mesmos e utilizar esta banda nos processos de fusão.

Observou-se que a maioria dos métodos de fusões que apresentaram bons resultados, foi processada utilizando a primeira PC das bandas HH e HV e dos atributos SAR selecionados. Analisando-se os *Kappas* por classe das classificações com 8 classes foi observado que destas, 6 classes foram melhor discriminadas por fusões em que a primeira PC das bandas da imagem ALOS/PALSAR ou de seus atributos (SAR<sub>3</sub>) estava envolvida nos processos de fusões. Analisando-se, agora, os *Kappas* por classe das classificações com 6 classes foi observado que destas, 4 classes foram melhor discriminadas por fusões em que a primeira PC das bandas da imagem ALOS/PALSAR ou de seus atributos (SAR<sub>3</sub>) estava envolvida nos processos de fusões. Sendo assim, pode-se concluir que o método proposto de integração de imagens SAR multipolarizadas e de atributos apresenta aplicabilidade. Este resultado torna-se importante no contexto atual em que a tendência é construção de sensores SAR que registram dados em mais de duas bandas com diferentes polarizações. Acredita-se que os resultados aqui apresentados tenham aplicabilidade em outras áreas que possuam padrão de ocupação similar ao da área de estudo selecionada, ou seja, áreas de fronteira agrícola na Amazônia.

Para trabalhos futuros sugere-se que mais testes e análises com imagens SAR e ópticas originais, combinadas e fusionadas sejam realizadas em outras regiões de fronteira agrícola na Amazônia para se confirmar a hipótese supracitada. A aplicação de classificadores não paramétricos nas imagens abordadas neste trabalho, também será um estudo interessante visto que permitiria verificar se o tipo de classificador aplicado nas

imagens influencia nos resultados aqui apresentados. Também se sugere que estudos sejam desenvolvidos com a finalidade de possibilitar a realização de testes de hipóteses baseados em distâncias estocásticas para melhor auxiliar a seleção dos atributos. Para verificar a capacidade discriminatória da classificação da imagem ALOS/PALSAR em culturas de soja sugere-se que mais testes e análises sejam realizados com estas imagens registradas em datas que predominam nas áreas ocupadas pela agricultura a cultura de soja com aproximadamente 40 dias da semeadura. Esta análise também pode ser realizada em outras regiões que predominam esta cultura. Aconselha-se que imagens de radar em outras frequências sejam utilizadas em combinações e fusões para analisar a aplicabilidade das mesmas na discriminação de classes de interesse.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ACHARYA, T.; TSAI, S.P. **JPEG2000 Standard for image compression**: concepts, algorithms and VLSI architectures. Hoboken: Wiley-Interscience, 2005. 296p.
- ADAMS, J.B.; SABOL, D.E.; KAPOS, V.; FILHO, A. R.; ROBERTS, D.A.; SMITH, M.O.; GILLESPIE, A. R. Classification of multispectral images based on fractions of endmembers: application to land-cover change in the Brazilian Amazon. **Remote Sensing of Environment**, v. 52, p.137-154, 1995.
- ANFENSEN, S. N.; MEMBER, S.; DOULGERIS, A. P.; MEMBER, S.; ELTOFT, T. Estimation of the equivalent number of looks in polarimetric synthetic aperture radar imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v.47, p. 3795-3809, 2009.
- AGÊNCIA NACIONAL DE ÁGUAS (ANA). **Sistema Nacional de Informações sobre Recursos Hídricos (SNIRH)**. Disponível em: <<http://www.ana.gov.br/portalsnirh/>>. Acesso em: 20 fev 2011.
- AMARSAIKHAN, D.; GANZORIG, M.; ACHE, P.; BLOTEVOGLE, H. The integrated use of optical and InSAR data for urban land-cover mapping. **International Journal of Remote Sensing**, v. 28, p. 1161-1171, 2007.
- AMOLINS, K.; ZHANG, Y.; DARE, P. Wavelet based image fusion techniques: An introduction, review and comparison. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 62, p. 249-263, 2007.
- BASTARRIKA, A.; CHUVIECO, E.; MARTÍN, M. P. Mapping burned areas from Landsat TM/ETM+ data with a two-phase algorithm: Balancing omission and commission errors. **Remote Sensing of Environment**, v.115, p. 1003-1012, 2011.
- BHATTACHARYYA, A. On a measure of divergence between two statistical populations defined by their probability distributions. **Bulletin of the Calcutta Mathematics Society**, v. 35, p. 99–110, 1943.
- BURINI, A.; PUTIGNANO, C.; DEL FRATE, F.; LICCIARDI, G.; PRATOLA, C. SCHIAVON, G.; SOLIMINI, D. TerraSar-X/SPOT-5 fused images for supervised land cover classification. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM. (IGARSS), 2008, Boston. **Anais...** Boston: IEEE, 2008, p. 373-376, On-line. Disponível em: <<http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=4780106>>. Acesso: 9 out 2011.
- BWANGOY, J.R. B.; HANSEN, M. C.; ROY, D. P.; GRANDI, G. D.; JUSTICE, C. O. Wetland mapping in the Congo basin using optical and radar remotely sensed data and derived topographical indices. **Remote Sensing of Environment**, v.114, p.73-86, 2010.

- CAMARA, G.; SOUZA, R. C. M.; FREITAS U. M.; GARRIDO, J. SPRING: Integrating remote sensing and GIS by object-oriented data modelling. **Computers & Graphics**, v. 20, p. 395-403, 1996.
- CARDILLE, J. A.; FOLEY, J. A. Agricultural land-use change in Brazilian Amazônia between 1980 and 1995: Evidence from integrated satellite and census data. **Remote Sensing of Environment**, v. 87, p. 551-562, 2003.
- CASTAÑEDA, C.; DUCROT, D. Land cover mapping of wetland areas in an agricultural landscape using SAR and Landsat imagery. **Journal of Environmental Management**, v. 90, p. 2270-2277, 2009.
- CHAVEZ JR., P. S.; BERLIN, G. L.; SOWERS, L. B. Statistical method for selecting Landsat MSS ratios. **Journal of Applied Photographic Engineering**, v. 8, p. 23-31, 1982.
- CHEN, C. H.; PETER HO, P.G. Statistical pattern recognition in remote sensing. **Pattern Recognition**, v. 41, p. 2731-2741, 2008.
- CHIBANI, Y. Additive integration of SAR features into multispectral SPOT images by means of the à trous wavelet decomposition. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 60, p. 306-314, 2006.
- CHUVIECO, E.; ENGLEFIELD, P.; TRISHCHENKO, A. P.; LUO, Y. Generation of long time series of burn area maps of the boreal forest from NOAA – AVHRR composite data. **Remote Sensing of Environment**, v. 112, p. 2381-2396, 2008.
- COLLET, C.; CHANUSSOT, J.; HEHDI, K. **Multivariate image processing: methods and applications**, 2009. 455p. Disponível em: <[http://picabia.ustrasbg.fr/lisit/perso/collet/collet/ftp/tmp/book\\_sansFig.pdf](http://picabia.ustrasbg.fr/lisit/perso/collet/collet/ftp/tmp/book_sansFig.pdf)>. Acesso em: 26 fev. 2011.
- CONGALTON, R.G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, p. 35-46, 1991.
- 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, São Jose dos Campos. 1998. Disponível em: <<http://urlib.net/sid.inpe.br/deise/1999/09.14.14.45>>. Acesso em: 01 fev. 2011.
- CRÓSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. Campinas, São Paulo: IG/UNICAMP, 1992. 170p.

CUNHA, E. R. S. P. **Integração digital de imagens de radar e Landsat-TM dados geológicos e aerogamaespectrométricos no auxílio ao mapeamento geológico da região do complexo granítico estrela - Pará (PA).** 2002. 147 p. (INPE-9858-TDI/868). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2002. Disponível em: <<http://urlib.net/sid.inpe.br/jeferson/2003/08.01.13.19>>. Acesso em: 26 fev. 2011.

DONG, J.; ZHUANG, D.; HUANG, Y.; FU, J. Advances in multi-sensor data fusion: Algorithms and applications. **Sensors**, v. 9, p. 7771-7784, 2009.

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.** São José dos Campos: INPE, 2009. 52 p. (INPE-15739-RPQ/824). Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m18@80/2009/04.24.14.45>>.

European Space Agency information on ALOS PALSAR products for ADEN users (ESA). Local Paris: EESA, 2007. 15p. Disponível em: <[http://earth.eo.esa.int/pcs/alos/palsar/articles/ALOS\\_PI\\_Symposium\\_PALSAR\\_Verification.pdf](http://earth.eo.esa.int/pcs/alos/palsar/articles/ALOS_PI_Symposium_PALSAR_Verification.pdf)>. Acesso em: 18 de mar. 2011.

FARAH, I. R.; BOULILA, W.; ETTABAA, K. S.; AHMED, M. B. Multiapproach system based on fusion of multispectral images for land-cover classification. **IEEE Transactions on Geoscience and Remote Sensing**, v. 46, p. 4153-4161, 2008.

FATONE, L.; MAPONI, P.; ZIRILLI, F. An image fusion approach to the numerical inversion of multifrequency electromagnetic scattering data. **Inverse Problems**, v. 17, p. 1689-1701, 2001.

FEINGERSH, T.; GORTE, B.G.H.; VAN LEEUWEN, H.J.C. Fusion of SAR and SPOT image data for crop mapping. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM 2001, Sydney, 9-13 July, p.873-875. **Anais...** 2001. DVD.

FITZGERALD, R. W.; LEES, B. G. Assessing the classification accuracy of multisource remote sensing data. **Remote Sensing of Environment**, v. 47, p. 362-358, 1994.

FRERY, A. C.; FREITAS, C. C.; CORREIA, A. H. Classifying multifrequency fully polarimetric imagery with multiple sources of statistical evidence and contextual information, **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, p. 3098-3109, 2007.

GABER, A.; KOCH, M.; EL-BAZ, F. Textural and compositional characterization of WadiFeiran deposits, Sinai Peninsula, Egypt, using Radarsat-1, PALSAR, SRTM and ETM+ data. **Remote Sensing**, v. 2, p. 52-75, 2009.

- GALO, M.; CAMARGO, P. O. O uso do GPS no controle de qualidade de cartas. In: CONGRESSO BRASILEIRO DE CADASTRO TÉCNICO MULTIFINALITÁRIO (COBRAC), Florianópolis, SC. **Anais...** Florianópolis: UFSC, 1994.
- GONÇALVES, F. D.; RODRIGUES, S. W. P.; COSTA, F. R.; MIRANDA, F. P. Multi-sensor data fusion for geomorphological and environmental sensitivity index mapping in the Amazonian mangrove coast, Brazil. **Journal of Coastal Research**, v.56, p. 1592-1596, 2009.
- GONZALEZ, R.C.; WOODS, R. E. **Digital Image Processing**. 2.ed, New York: Prentice-Hall, 2002. 793p.
- GUIMARÃES, R. J. P. S.; FREITAS, C. C.; DUTRA, L. V.; SCHOLTE, R. G. C.; AMARAL, R. S.; DRUMMOND, S. C.; SHIMABUKURO, Y. E.; OLIVEIRA, G. C.; CARVALHO, O. S. Evaluation of a linear spectral mixture model and vegetation indices (NDVI and EVI) in a study of schistosomiasis mansoni and *Biomphalaria glabrata* distribution in the state of Minas Gerais, Brazil. **Memórias do Instituto Oswaldo Cruz**, v. 105, p. 512-518, July 2010.
- HARALICK, R. M.; SHANMUGAM, K.; DISTEIN, H. Textural features for image classification. **IEEE transactions on systems, man and cybernetics**, v. 3, p. 610-621, 1973.
- HARRIS, J. R.; VILJOEN, D. W.; RENCZ, A. N. Integration and visualization of geoscience data. In: RENEZ, A. N. **Remote Sensing for the Earth Sciences**. (3<sup>a</sup> ed.). Remote Sensing for the Earth Sciences: Manual of remote sensing: John Wiley & Sons, Inc, 1999. p. 307-354.
- HENDERSON, F. M.; LEWIS, A. J. **Principle and applications of imaging radar: manual of remote sensing**, New York : John Wiley & Sons, Inc., 1998. 896 p.
- HOUGHTON, R. A. Tropical deforestation and atmospheric carbon dioxide. **Climate Change**. v.19, p. 99-118, 1991.
- HUANG, S.; CRABTREE, R. L.; CHRISTOPHER, P.; GROSS, P. Estimating the quantity and quality of coarse woody debris in Yellowstone post-fire forest ecosystem from fusion of SAR and optical data. **Remote Sensing of Environment**, v. 113, p. 1926-1938, 2009.
- HUANG, S.; POTTER, C.; CRABTREE, R. L.; HAGER, S.; GROSS, P. Fusing optical and radar data to estimate sagebrush, herbaceous, and bare ground cover in Yellowstone. **Remote Sensing of Environment**, v. 114, p. 251-264, 2010.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Imagem do Satélite ALOS**. Disponível em: <<http://www.ibge.gov.br/alos/>>. Acesso em: 20 de out. 2011.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Mapa da Amazônia legal**: Fronteira agrícola. Texto introdutório. Disponível em: <[http://www.ibge.gov.br/home/geociencias/geografia/mapas\\_doc3.shtm](http://www.ibge.gov.br/home/geociencias/geografia/mapas_doc3.shtm)>. Acesso em: 25 set. 2011.

INSTITUTO DE PESQUISA ECONÔMICA APLICADA. **Mudanças do clima no Brasil**: aspectos econômicos, sociais e regulatórios. Brasília, 2011. v. 1, p.436.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Classificador Polarimétrico-7**. Disponível em: <<http://www.dpi.inpe.br/cursos/ser410/laboratorio.php>>. Acesso em: 09 out. 2010.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **Monitoramento da Floresta Amazônica Brasileira por Satélite**. Disponível em: <<http://www.obt.inpe.br/prodes/>>. Acesso em: 25 set. 2011.

JAPAN AEROSPACE EXPLORATION AGENCY (JAXA). **ALOS/PALSAR Level 1.1/1.5 product Format description** <English Version>. NEB-070062A. 2008. 156 p. Disponível em: <[http://www.eorc.jaxa.jp/ALOS/en/doc/fdata/PALSAR\\_x\\_Format\\_EL.pdf](http://www.eorc.jaxa.jp/ALOS/en/doc/fdata/PALSAR_x_Format_EL.pdf)>. Acesso em: 10 nov. 2010.

JENSEN, J. R. **Sensoriamento remoto do ambiente**: uma perspectiva em recursos terrestres. São José dos Campos: Parêntese, 2009. 598 p.

JUSTICE, C. O.; VERMOTE, E.; TOWNSHEND, J.R.G.; DEFRIES, R.; ROY, D.P.; HALL, D.K.; SALOMONSON, V.V.; PRIVETTE, J.L.; RIGGS, G.; STRAHLER, A.; LUCHT, W.; MYNENI, R.B.; KNYAZIKHIN, Y.; RUNNING, S.W.; NEMANI, R.R.; ZHENGMING, W.; HUETE, A.R.; VAN LEEUWEN, W.; WOLFE, R.E.; GIGLIO, R.; MULLER, J.; LEWIS, P.; BARNESLEY, M.J. The Moderate Resolution Imaging Spectroradiometer (MODIS): land remote sensing for global change research. **IEEE Transactions on Geoscience and Remote Sensing**, v.36, p. 1228-1249, 1998.

KLONUS, S.; EHLERS, M. Image fusion using Ehlers spectral characteristics preservation algorithm. **GIScience & Remote Sensing**, v.44, p. 93-116, 2007.

KLONUS, S.; EHLERS, M. Performance of evaluation methods in image fusion. In: INTERNATIONAL CONFERENCE ON INFORMATION FUSION, Seattle. **Anais...**, 12., 2009. Disponível em: <<http://isif.org/fusion/proceedings/fusion09CD/data/papers/0136.pdf>> Acesso em: 06 fev. 2012.

LAURILA, H.; KARJALAINEN, M.; KLEEMOLA, J.; HYYPPÄ, J. Cereal yield modeling in finland using optical and radar remote sensing. **Remote Sensing**, v. 2, p. 2185-2239, 2010.

LEICA GEOSYSTEMS GEOSPATIAL IMAGING. **ERDAS IMAGINA**. 9.1. SL, 2006.

LI, G.; LU, D.; MORAN, E.; HETRICK, S. Land-cover classification in a moist tropical region of Brazil with Landsat Thematic Mapper imagery, **International Journal of Remote Sensing**, v. 32, p. 8207-8230, 2011.

LI, G.; LU, DE.; MORAN, E.; SANT'ANNA, J. S. A comparative analysis of land-use and land-cover classification methods in a moist tropical region of the Brazilian Amazon, **Remote Sensing of Environment**, (Submitted).

LIU, X.; KAFATOS, M.; GOMEZ, R. B.; GOETZ, S. J. Combining MISR, ETM+ and SAR data to improve land cover and land use classification for carbon cycle research. , In: IEEE WORKSHOP ON ADVANCES IN TECHNIQUES FOR ANALYSIS OF REMOTELY SENSED, 2003, Greenbelt. **Anais...Greenbelt: IEEE**, 2003, p. 80- 85, On-line. Available in: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=01295177>>. Acesso: 9 out 2011

LU, D. Integration of vegetation inventory data and Landsat TM image for vegetation classification in the western Brazilian Amazon. **Forest Ecology and Management**, v. 213, p. 369-383, 2005.

LU, D.; BATISTELLA, M.; MORAN, E. Land-cover classification in the Brazilian Amazon with the integration of Landsat ETM+ and Radarsat data. **International Journal of Remote Sensing**, v. 28, p. 5447-5459, 2007.

LU, D.; BATISTELLA, M.; MORAN, E. Multitemporal spectral mixture analysis for Amazonian land-cover change detection. **Canadian Journal of Remote Sensing**, v.30, p.87-100, 2004.

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

LUCAS, R.; ARMSTON, J.; FAIRFAX, R.; FENSHAM, A. A.; ACCAD, A.; CARREIRAS, J.; KELLY, J.; BUNTING, P.; CLEWLEW, D.; BRAY, S.; METCALFE, D.; DWYER, J.; BOWEN, M.; EYRE, T.; LAIDLAW, M.; SHIMADA, M. An evaluation of the ALOS PALSAR L-band backscatter above ground biomass relationship Queensland, Australia: Impacts of surface moisture condition and vegetation structure. **Earth**, v. 3, p. 576-593, 2010.

MACHADO, L. A fronteira agrícola na Amazônia. In: BECKER, B.K.; CHRISTOFOLETTI, A.; DAVIDOCH, F. R.; GEIGER, R. P. P. (eds.). **Geografia e meio ambiente no Brasil**. 2. ed. São Paulo: Hucitec, 2005. p.181-217.

MANSOURPOUR, M.; RAJABI, M.A.; BLAIS, J.A.R. Effects and performance of speckle noise reduction filters on active radar and SAR images, In: WORKSHOP ON TOPOGRAPHIC MAPPING FROM SPACE, Feb, 14-16, 2006, Ankara, Turkey. Electronic **Anais...** <[http://www.isprs.org/proceedings/XXXVI/1-W41/makaleler/Rajabi\\_Speckle\\_Noise.pdf](http://www.isprs.org/proceedings/XXXVI/1-W41/makaleler/Rajabi_Speckle_Noise.pdf)>. Acesso: 29 ago.2011.

MERCHANT, D. C. Spatial accuracy standards for large scale line maps. In: AMERICAN CONGRESS ON SURVEYING AND MAPPING, 42., 1982, Falls Church, VA, USA. **Anais...** Gaithersburg, MD, USA: ACMS, 1982. v. 1, p. 222- 231.

MCNAIRN, H.; CHAMPAGNE, C.; SHANG, J.; HOLMSTROM, D.; REICHERT, G. Integration of optical and Synthetic Aperture Radar (SAR) imagery for delivering operational annual crop inventories. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 64, p. 434-449, 2009.

MICHELSON, D. B.; LILJEBERG, B. M.; PILESJÖ, P. Comparison of algorithms for classifying swedish landcover using Landsat TM and ERS-1 SAR data. **Remote Sensing of Environment**, v. 71, p. 1-15, 2000.

MIKHAIL, E. M.; BETHEL, J. S.; MCGLONE, J. C. **Introduction to modern photogrammetry**, New York: John Wiley & Sons Inc, 2001. 479p.

MORAN, E. F.; BRONDIZIO, E. S.; TUCKER, J. M., SILVA-FORSBERG, M. C., MCCRACKEN, S.; FALESI, I. Effects of soil fertility and land-use on forest succession in Amazônia. **Forest Ecology and Management**, v. 139, p. 93-108, 2000.

MORETTIN, P.A.; BUSSAB, W.O. **Estatística básica**. 5ª edição. São Paulo: Saraiva 2005. p.526.

MUSA, M.K.A.; HUSSIN, Y.A. Multi-data fusion for sustainable forest management: a case study from northern part of selangor, malaysia. In: INTERNATIONAL ARCHIVES OF PHOTOGRAMMETRY AND REMOTE SENSING, 33., 2000, Amsterdam. **Anais...** . Disponível em:<[http://www.isprs.org/proceedings/XXXIII/congress/part7/559\\_XXXIII-part7.pdf](http://www.isprs.org/proceedings/XXXIII/congress/part7/559_XXXIII-part7.pdf)> Acesso em: 19 ago. 2011.

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION (NASA) **Shuttle Radar Topography Mission**: the mission to map the world. 17 jun. 2009. Disponível em: <<http://www2.jpl.nasa.gov/srtm/>>. Acesso em: 12 jul. 2010.

NATIONAL STANDARD DATA INFRASTRUCTURE. **Geospatial positioning accuracy standards part 3: national standard for spatial data accuracy**, 1998, USGS, 28 p.

NOBRE, C. A.; SELLERS, P. J.; SHUKLA, J. Amazonian deforestation and regional climate change. **Journal of Climate**, v.4, p. 957-988, 1991.

OLIVEIRA, C. G. **Avaliação da informação planialtimétrica derivada de dados RADARSAT-2 e terraSAR-X para produção de cartas topográficas na escala 1:50.000**. 2011. 208 p. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2011. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3A54QKB>>. Acesso em: 10 out. 2011.

OLIVEIRA, C. G.; PARADELLA, W. R., An Assessment of the altimetric information derived from space borne SAR (RADARSAT-1, SRTM3) and optical (ASTER) data for cartographic application in the Amazon region, **Sensors**, 8, p. 3819 – 3829, 2008.

OLIVEIRA, J. A. **Classificação de regiões usando atributos de forma e seleção de atributos**. 2005. 104 p. (INPE-13746-TDI/1050). Dissertação (Mestrado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005. Disponível em: <<http://urlib.net/sid.inpe.br/iris@1913/2005/05.05.13.41>> Acesso em 11 nov 2011.

OLIVEIRA, J. A.; DUTRA, L. V.; RENNÓ, C. D.; CRUZ JUNIOR, D. C. Método Estatístico de Seleção de Canais Aplicado a Classificação de Imagens. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14. (SBSR), 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 7007-7014. DVD, On-line. ISBN 978-85-17-00044-7. (INPE-15963-PRE/10572). Disponível em: <<http://urlib.net/dpi.inpe.br/sbsr@80/2008/11.17.22.45.53>>. Acesso em: 18 mar. 2012.

OSTROWSKI, J. A.; CHENG, P. DEM extraction from stereo SAR satellite imagery. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2000, Honolulu Hawaii, USA. **Anais...** Honolulu: IEEE, 2000. p. 2176-2178.

PARADELLA, W. R.; SANTOS, A. R.; VENEZIANI, P.; MORAIS, M. C. O Sinergismo de imagens standard descendente do Radarsat-1 e Thematic Mapper do Landsat-5 em aplicação geológica na Amazônia. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 10. (SBSR), 2001, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2001. p. 315-322. DVD, On-line. ISBN 85-17-00016-1. (INPE-8257-PRE/4047). Disponível em: <<http://urlib.net/dpi.inpe.br/lise/2001/09.14.11.53>>. Acesso em: 04 dez. 2011.

PCI GEOMATICS. **Geomatica OrthoEngine User Guide**, version 10.3, Ontario, Richmond Hill, Canada. 2010. 179 p.

PIERCE, L. E.; WALKER, W. S.; DOBSON, M. C.; HUNSAKER, J.K.; FITES-KAUFMAN.; DUBAYAH, R. Fusion of optical and SAR data for forestry applications in the Sierra Nevada of California. In: IEEE International Geoscience and Remote Sensing Symposium. (IGARSS), 2002, 24-28 Junho, Toronto. **Anais...** Toronto: IEEE, 2002, p. 7536-7538, On-line. Available in: <<http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=1026249>>. Acesso: 9 out 2011.

POHL, C.; VAN GENDEREN, J. L. Multisensor image fusion in remote sensing: concepts, methods and applications. **International Journal of Remote Sensing**, v. 19, p. 823-854, 1998.

POUTEAU, R.; STOLL, B. Fusion for classes in difficulty: For Accurate and speed tropical rainforests classification. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2011, Vancouver. p. 740-743. **Anais...** Vancouver: British Columbia, 2011. DVD.

PROGRAMA DE CÁLCULO DO DESFLORESTAMENTO DA AMAZÔNIA (PRODES). **Instituto Nacional de Pesquisas Espaciais (INPE)**. Disponível em: <<http://www.obt.inpe.br/prodes/>>. Acesso em: 25 set 2011.

RENNÓ, C. D. **Avaliação de medidas texturais na discriminação de classes de uso utilizando imagens SIR-C/X-SAR do perímetro irrigado de Bebedouro, Petrolina, PE**. 1995. 111 p. (INPE-10441-TDI/926). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1995. Available in: <<http://urlib.net/sid.inpe.br/jeferson/2004/03.05.11.22>>. Acesso: 19 ago. 2011.

RENZULLO, L.; BARRETT, D.; MARKS, A.; HILL, M. J.; GUERSCHMAN, J. P.; QIAOZHEN MU.; RUNNING, S.W. Multi-sensor model-data fusion for estimation of hydrologic and energy flux parameters. **Remote Sensing of Environment**, v. 112, p. 1306-1319, 2008.

RICHARDS, J. A.; JIA, X. **Remote sensing digital image analysis: an introduction**. 4.ed. Berlin: Springer-Verlag, 2006. 439 p.

ROBERTS, D.A.; BATISTA, G.T.; PEREIRA, J.L.; WALLER, E.K.; NELSON, B.W. Change identification using multitemporal spectral mixture analysis: applications in eastern Amazonia. In: LUNETTA R.S.; ELVIDGE C.D. **Remote sensing change detection: environmental monitoring methods and applications**. Chelsea, Mich: Ann Arbor Mich, 1998. p.137-161.

RODRIGUES, T. G. **Análise da viabilidade de mapeamento topográfico (escala 1:100.000) na região Amazônica através da integração de informações altimétricas SRTM-3 e planimétrica PALSAR: uma avaliação para a Serra dos Carajás (PA)**. 2010. 163 p. (sid.inpe.br/mtc-m19@80/2010/06.24.11.30-TDI). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2010. Disponível em: <<http://urlib.net/8JMKD3MGP7W/37NKP3B>>. Acesso em: 06 dez. 2011.

RODRIGUES, T. G.; PARADELLA, W. R.; OLIVEIRA, C. G. Evaluation of the altimetry from SRTM-3 and planimetry from high-resolution PALSAR FBD data for semi-detailed topographic mapping in the Amazon Region. **Anais da Academia Brasileira de Ciências**, v. 83, p. 953-966, 2011.

ROSENQVIST, A.; SHIMADA, M.; WATANABE, M.; TADONO, T.; YAMAUCHI, K. Implementation of Systematic Data Observation Strategies for ALOS PALSAR, PRISM and AVNIR-2. In: IEEE 2004 INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2004, Anchorage, Alaska. **Anais...** Anchorage:IEEE, 2004. p. 4527- 4530. DVD.

SANO, E. E.; FERREIRA, L. G.; HUETE, A. R. Synthetic aperture radar (L-band) and optical vegetation index of discriminating the Brazilian savanna physiognomies: a comparative analysis. **Earth Interactions**, v. 9, p. 1-15, 2005.

SAROGLU, E.; BEKTAS, F; GOKSEL, M.C. Fusion multi-sensor remote sensing data: assessing the quality of resulting images. In: INTERNATIONAL SOCIETY OF PHOTOGRAMMETRY AND REMOTE SENSING, 2004, Istanbul, Turkey 12-23 July. **Anais...** Available in: <<http://www.isprs.org/proceedings/XXXV/congress/comm4/papers/414.pdf>>. Acesso: 12 nov. 2010.

SHAMSHAD, A.; WAS HUSSIN, W.M.A.; SANUSI, S. A. M. Comparison of different data fusion approaches for surface features extraction using Quickbird images. In: INTERNATIONAL SYMPOSIUM ON GEOINFORMATICS FOR SPATIAL INFRASTRUCTURE DEVELOPMENT IN EARTH AND APPLIED SCIENCES, 2004, Hanoi, Vietnam. **Anais...** Available in: <<http://gisws.media.osaka-cu.ac.jp/gisideas04/viewpaper.php?id=94>>. Acesso: 29 ago.2011.

SHIMADA, M.; MEMBER, S.; ISOGUCHI, O.; TADONO, T.; ISONO, K. PALSAR Radiometric and geometric calibration. **IEEE Transactions on Geosciences and Remote Sensing**, v. 47, p. 3915-3932, 2009.

SHIMADA, M.; TADONO, T.; ROSENQVIST, A. Advanced Land Observing Satellite (ALOS) and Monitoring Global Environmental Change. **Proceedings of the IEEE**, v. 98, p. 780-799, 2010.

SILVA, F. C. **Implementação e avaliação de métodos de fusão para geração de imagens coloridas de alta resolução**. 2009. 89 p. (INPE-15730-TDI/1476). Dissertação (Mestrado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m18@80/2009/01.27.14.15>>. Acesso em: 11 jun. 2012.

SILVA, W. B.; PEREIRA, L. O.; SANT'ANNA, S. J. S.; FREITAS, C. C.; GUIMARÃES, R. J. P. S.; FRERY, A. C. Land cover discrimination at brazilian amazon using region based classifier and stochastic distance. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM. 2011, Vancouver, 24-29 July, p. 2900-2903. **Anais...** 2011. DVD.

SOARES, S. M.; SANT' ANNA, S. S. J.; KUNTSCHIK, G. Image processing techniques. In: FIRST LATINO-AMERICAN SEMINAR ON RADAR REMOTE SENSING, 1, 1996, Buenos Aires. **Anais...** Buenos Aires, Argentina: SP 407, 1996. p. 115-123. DVD.

SORIA-RUIZ, J.; FERNANDEZ-ORDONEZ, Y.; WOODHOUSE, I. H. Land-cover classification using radar and optical images: a case study in Central Mexico. **International Journal of Remote Sensing**, v. 31, p. 3291-3305, 2010.

SOUSA JÚNIOR, M. A. **Segmentação multi-níveis e multi-modelos para imagens de radar e ópticas**. 2005. 131 p. (INPE-14466-TDI/1147). Tese (Doutorado em 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: 18 abr. 2011.

TADONO, T.; ROSENQVIST, A. Advanced Land Observing Satellite (ALOS) and Monitoring Global Environmental Change. **Anais of the IEEE**, v. 98, p. 780-799, 2010.

TOUTIN, T. Geometric processing of remote sensing images: models, algorithms and methods. **International Journal of Remote Sensing**, v. 25, p. 1893-1924, 2004.

TOUTIN, T.; CHÉNIER, R. 3-D Radargrammetric Modeling of RADARSAT-2 Ultrafine Mode: Preliminary Results of the Geometric Calibration. **IEEE Transactions on Geoscience and Remote Sensing Letters**, v. 6, p. 611-615, 2009.

TOUTIN, T. Impact of RADARSAT-2 SAR ultrafine-mode parameters on stereo-radargrammetric DEMs. **IEEE Transactions on Geoscience and Remote Sensing**, v. 48, p. 3816-3823, 2010.

VEGA, B. **Image fusion of optical and microwave data to assess criteria and indicador (C&I) related to Forest encroachment, for certification processo of Sustainable Forest Management (SFM)**. 2005. 81 p. Dissertação (Mestrado em Geo-information Science and Earth Observation) – International Institute for Geo-information Science and Earth Observation, Enschede, Netherlands. 2005. Available in: <[http://www.itc.nl/library/papers\\_2005/msc/nrm/vega.pdf](http://www.itc.nl/library/papers_2005/msc/nrm/vega.pdf)>. Acesso: 12 jun. 2010.

VISUAL INFORMATION SOLUTION. **ENVI. 4.7**. 2009. SL, CD-ROM.

XIAOYING, J. Segmentation based image processing system. **US 2009/0123070 A1** (PATENT APPLICATION PUBLICATION), 2009.

VAN ZYL, J. J. The Shuttle Radar Topography Mission (SRTM): a breakthrough in remote sensing of topography. **Acta Astronautica**, v. 48, p. 559-565. 2001.

VIJAYARAJ, V.; YOUNAN, N.; O'HARA. Concepts of image fusion in remote sensing applications. In: IEEE 2006 INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2006, Denver. **Anais...** Denver: IEEE, 2006. p. 3798-3801, DVD.

WALD, L. Some terms of reference in data fusion. **IEEE Transactions on Geosciences and Remote Sensing**, v.37, p. 1190-1193, 1999.

WALFIR, P.; FILHO, M. S.; PARADELLA, W. R. Use of RADARSAT-1 fine mode and Landsat-5 TM selective principal component analysis for geomorphological mapping in a macrotidal mangrove coast in the Amazon Region. **Canadian Journal of Remote Sensing**, v. 31, p. 214-224, 2005.

WALKER, W. S.; BACCINI, A.; KELLNDORFER, J. M.; STICKLER, C.M.; SUN, M.; LAPORTE, N. T.; GOETZ S. J. Mapping of land cover and above-ground biomass in the Amazon basin from multi-spectral fusion of ALOS/PALSAR and LANDSAT data sources. In: IEEE 2011 INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2011, Vancouver. **Anais...** Vancouver: British Columbia, 2011. DVD.

WALKER, W.; KELLNDORFER, J.; LAPOINT, E.; HOPPUS, M.; WESTFALL, J. An empirical InSAR-optical fusion approach to mapping vegetation canopy height. **Remote Sensing of Environment**, v. 109, p. 482-499, 2007.

WASKE, B.; BENEDIKTSSON, J. A. Fusion of support vector machines for classification of multisensor data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, p. 3858-3866, 2007.

WASKE, B.; LINDEN, S. V. D. Classifying multilevel imagery from SAR and optical sensors by decision fusion. **IEEE Transactions on Geoscience and Remote Sensing**, v. 46, p. 1457-1466, 2008.

WIJAYA, A.; GLOAGUEN, R. Fusion of ALOS PALSAR and Landsat ETM data for land cover classification and biomass modeling using non-linear methods. In: IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 2009, Cape Town. **Anais...** Cape Town: IEEE, 2009, p.581-584, On-line. Available in: <[http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=5417824&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs\\_all.jsp%3Farnumber%3D5417824](http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=5417824&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs_all.jsp%3Farnumber%3D5417824)>. Acesso: 9 out 2011.

WOLTER, P. T.; TOWNSEND, P. A. Remote sensing of environment multi-sensor data fusion for estimating forest species composition and abundance in northern Minnesota. **Remote Sensing of Environment**, v. 115, p. 671-691, 2011.

WOODHOUSE, I. H. **Introduction to microwave remote sensing**. Boca Raton: CRC Press, Taylor & Francis Group, 2006. 369p.

ZHANG, J . Multisource Remote Sensing Data Fusion: Status and Trends, **International Journal of Image and Data Fusion**, v.1, p.5-24, 2010.

ZHU, X.; CHEN, J.; GAO, F.; CHEN, X.; MASEK, J. G. An enhanced spatial and temporal adaptive reflectance fusion model for complex heterogeneous regions. **Remote Sensing of Environment**, v. 114, p. 2610-2623, 2010.



# APÊNDICE A - AVALIAÇÃO PLANIMÉTRICA DE IMAGENS ALOS/PALSAR, MODO FINE BEAM DUAL (FBD), PARA UMA ÁREA DA AMAZÔNIA BRASILEIRA

## Resumo

As imagens de radar multipolarizadas ALOS/PALSAR, têm aplicabilidade em vários estudos e são fornecidas em diversos níveis de processamentos e formatos. As imagens ALOS/PALSAR FBD 1.5 no formato *Geocoded* apresentam a vantagem de serem disponibilizadas com correções geométricas de sistema, o que diminui ou exclui a necessidade de que estas correções sejam realizadas pelos usuários. A desvantagem desta imagem é que estas correções consideram apenas a altitude média da área coberta pela cena o que pode limitar o seu uso em áreas de relevo acidentado. Portanto, o objetivo deste estudo é avaliar, através das análises de tendência e a precisão, os dados planimétricos desta imagem e de uma ortoimagem gerada a partir da imagem ALOS/PALSAR no formato *Georeferenced* em uma área com relevo plano na Amazônia, comparar a precisão planimétrica entre estas imagens e verificar se a aplicação dos modelos de ortorretificação rigorosos *Toutin's 3D Radargrammetric Model* e *Radar Specific Model* melhoram a acurácia planimétrica da imagem *Geocoded*. Os resultados mostraram que a imagem *Geocoded* foi classificada no Padrão de exatidão cartográfico brasileiro classe "A" para a escala de mapeamento 1:100.000, e que o Circular Map Accuracy Standard foi de 16,92 m. A acurácia planimétrica da ortoimagem foi estatisticamente superior ao da imagem *Geocoded*, porém, a desvantagem de se utilizar a ortoimagem é que para a sua geração é necessária a aplicação do modelo rigoroso *Radar Specific Modelo*, o qual, na maioria das vezes, esta implementado em aplicativos comerciais dificultando seu acesso por parte dos usuários. Os modelos rigorosos testados não melhoraram de forma significativa a precisão planimétrica da imagem *Geocoded*, portanto, a aplicação destes modelos nesta imagem não é aconselhável.

**Palavras-chave:** Sensoriamento Remoto, ALOS/PALSAR, ortoimagens, avaliação planimétrica, Amazônia Brasileira.

**Key-words:** Remote Sensing, ALOS/PALSAR, Orthoimagens, planimetric assessment, Brazilian Amazon.

## A.1. INTRODUÇÃO

As imagens de sensoriamento remoto vêm sendo utilizadas como base e/ou dados de entrada em diversas áreas de pesquisa, tais como cartografia, geografia, engenharia, biologia, etc. Entretanto, a presença de distorções geométricas nestas imagens, principalmente as relacionadas com o sistema de aquisição, pode ser um limitante no uso destes dados devido à perda de correspondência da geometria das feições na imagem com as mesmas feições no terreno (TOUTIN, 2004). Este fato é agravado quando se utilizam dados geográficos provenientes de sistemas de aquisições diferentes, pois possuem seus próprios erros e distorções. Caso estes erros não sejam removidos ou minimizados, os diferentes dados podem apresentar falta de correspondência espacial, e conseqüentemente os processamentos e as informações extraídas dos mesmos podem ser imprecisos e até mesmo inválidos (TOUTIN, 2004).

Dentre as técnicas e métodos de correções geométricas existentes, uma das mais importantes é a ortorretificação. Este processamento visa mitigar e/ou remover significantes distorções geométricas nas imagens que possam limitar o uso das mesmas como fontes diretas de dados e/ou informações (TOUTIN, 2004). O resultado da ortorretificação é uma ortoimagem, sendo que esta pode ser definida como uma imagem georreferenciada em que os deslocamentos de objetos, devido à orientação do sensor, com relação às variações do relevo do terreno foram minimizados. As ortoimagens possuem as características geométricas de um mapa, ou seja, a escala da imagem é constante em toda a cena (RODRIGUES, 2011). No caso de imagens adquiridas por Radares de Abertura Sintética (*Synthetic Aperture Radar - SAR*), as correções geométricas são de notável importância uma vez que estes sistemas adquirirão imagens em visada lateral.

Atualmente, a *Japan Aerospace Exploration Agency (JAXA)* fornece imagens SAR multipolarizadas adquiridas pelo sensor PALSAR (*Phased Array L-band Synthetic Aperture Radar*) a bordo do satélite ALOS (*Advanced Land Observing Satellite*). Estas imagens vêm sendo utilizadas em vários trabalhos com diferentes finalidades. Shimada et al. (2009) e Shimada et al. (2010) afirmam que elas apresentam grande aplicabilidade

na observação da superfície da terra, monitoramento ambiental global, monitoramento de florestas, estimativa de biomassa, classificação e monitoramento do uso e cobertura da terra, dentre outras.

Uma das grandes vantagens dos sensores imageadores SAR é a capacidade de adquirir dados sob condições atmosféricas adversas. Especialmente no bioma Amazônico esta vantagem é importante devido a grande ocorrência de nuvens. Ainda neste contexto é importante destacar mais uma vantagem dos sensores SAR que operam na frequência 1.25 GHz (banda L comprimento de onda de aprox. 23,5 cm) como o PALSAR, pois estes sinais possuem a capacidade de penetrar na vegetação densa produzindo assim dados mais precisos sobre as estruturas vegetacionais.

Embora o satélite ALOS tenha sido desativado em 26 de maio de 2011 as imagens adquiridas pelos seus sensores, entre eles o PALSAR, ainda podem ser utilizadas em diversos estudos. Visando a continuidade do programa ALOS, em dezembro de 2008 a JAXA aprovou o desenvolvimento do satélite ALOS-2 o qual irá portar um sensor similar ao PALSAR, com lançamento previsto para 2013. A continuidade do programa ALOS/PALSAR justifica e reforça a necessidade de se realizar estudos que visam avaliar a acurácia planimétrica destas imagens, especialmente em trabalhos que envolvam dados de séries temporais nos quais a qualidade das análises e avaliações dos resultados depende diretamente da qualidade da acurácia planimétrica dos produtos gerados.

A JAXA fornece as imagens do PALSAR em diversos níveis de processamentos e formatos. Devido a este fato, muitas vezes surgem dúvidas por parte do usuário final sobre qual é o nível de processamento e o formato de imagem mais adequado para seu estudo em função da acurácia requerida. A lógica desta hierarquização é que quanto maior o nível de processamento em que a imagem é fornecida, mais processamentos, como correções geométricas e radiométricas, foram realizados por esta agência e por consequência, menores são os processamentos que usuário terá que realizar.

No nível de processamento 1.5 as imagens ALOS/PALSAR *Fine-Beam Dual* (FBD) são fornecidas em *ground range* e amplitude. Neste nível de processamento existem ainda duas opções relacionadas com a orientação das imagens: a *Georeferenced* e a *Geocoded*. Na primeira opção, *Georeferenced*, as imagens são disponibilizadas na mesma orientação da órbita do satélite, enquanto na segunda opção, *Geocoded*, as imagens são disponibilizadas em um sistema de projeção cartográfica e são orientadas para o norte geográfico.

De acordo com Rodrigues (2010) e Rodrigues et al. (2011), utilizando como base imagens no formato *Georeferenced* é possível gerar uma ortomagem com uma precisão planimétrica compatível com o Padrão de Exatidão Cartográfica Brasileiro (PEC), classe “A”, para a escala 1:100.000 mesmo em áreas com relevo acidentado. Para tanto, é necessário a aplicação de um modelo matemático rigoroso específico para imagens SAR e a utilização de um Modelo Digital de Superfície (MDS), como o gerado pela *Shuttle Radar Topography Mission* (SRTM-3) (VAN ZYL, 2001), pois assim as informações referentes à variação de altitude do terreno são levadas em consideração na aplicação do modelo rigoroso. Nota-se que para a aplicação desta metodologia de ortorretificação não é necessário a utilização de pontos de controle obtidos em campo, pois os modelos rigorosos foram desenvolvidos para aproveitar ao máximo as informações e parâmetros do posicionamento do satélite e do sensor, e por este motivo proporciona alta acurácia posicional diminuindo ou mesmo excluindo a quantidade de *Ground Control Points* (GCPs) necessários ao processo de ortorretificação das imagens SAR (TOUTIN, 2004). Neste cenário, cabe ressaltar que os processamentos descritos por Rodrigues (2010) e Rodrigues et al. (2011) devem ser realizados pelos usuários o que acaba exigindo dos mesmos maiores conhecimentos conceituais e operacionais de imagens SAR. Além disto, nem sempre o usuário tem acesso ao modelo rigoroso utilizado na metodologia descrita pelos citados autores, pois na maioria das vezes, estes modelos estão implementados em aplicativos comerciais.

As imagens PALSAR no formato *Geocoded* exigem menor conhecimento conceitual e operacional por parte dos usuários, pois são fornecidas com correções geométricas de sistema e são associadas a um sistema de projeção cartográfica (*Universal Transversa de*

*Mercator* - UTM) e ao datum *World Geodetic System 1984* (WGS-84). Este fato minimiza ou mesmo exclui a necessidade da realização de processamentos e correções geométricas por parte dos usuários. Entretanto, na imagem *Geocoded*, as correções geométricas de sistema não consideram as informações referentes à variação de altitude do terreno, mas apenas a altitude média do mesmo. Isto pode resultar em distorções geométricas que podem inviabilizar a utilização destas imagens como produtos cartográficos em algumas áreas que possuam relevos mais acidentados (OLIVEIRA, 2008).

Baseado no exposto, este trabalho tem por objetivo avaliar a acurácia planimétrica de uma imagem ALOS/PALSAR FBD, 1.5 *Geocoded* e de uma ortoimagem disponibilizada gratuitamente pelo IBGE gerada a partir da imagem ALOS/PALSAR FBD, 1.5 *Georeferenced* em uma área de relevo plano localizada na Amazônia Brasileira. Estas avaliações tem a finalidade de verificar em qual escala classe “A” definidas pelo PEC brasileiro as imagens podem ser enquadradas e calcular o *Circular Map Accuracy Standard* (CMAS) (NSDI, 1998). Também foi verificado se a aplicação de modelos matemáticos rigorosos de ortorretificação melhoram a acurácia planimétrica da imagem *Geocoded*. Para tanto, na imagem *Geocoded* foram processados dois modelos rigorosos o *Toutin’s 3D Radargrammetric Model* (TRM) e o *Radar Specific Model* (RSM) utilizando MDS do SRTM-3. Para avaliar estas imagens, as mesmas também foram classificadas em uma escala seguindo o PEC classe A, e também foi calculado o CMAS.

Este trabalho foi organizado em seções, as quais são descritas a seguir. Os materiais, métodos bem com a área de estudo abordada no trabalho é apresentada na seção 2. Na seção 3 são apresentados e discutidos os resultados e finalmente na seção 4 são apresentadas as considerações finais e as conclusões dos resultados obtidos.

## **A.2. MATERIAL E MÉTODOS**

### **A.2.1. Área de estudo**

A área de estudo abrange parte do município de Belterra, no estado do Pará, mesorregião do Baixo Amazonas, entre as coordenadas 3°22’37”S e 55°03’15”W; 2°51’44”S e

54°49'01"W, com aproximadamente 1.117 km<sup>2</sup> conforme ilustra a Figura A.2.1. Nesta Figura observa-se a imagem *Geocoded* na composição R(HH) G(HV) B(HH).

Esta região do estudo é caracterizada por um clima quente e úmido e predominância de floresta tropical úmida. Quanto à geomorfologia, a região é considerada plana e tem uma altitude média de 138 m.

A ocupação desta área teve início por volta de 1970 quando o governo federal iniciou uma política de incentivo à ocupação da Amazônia Brasileira. Para tanto, o governo federal financiou a construção da rodovia BR-163 (Cuiabá-Santarém), o que intensificou a ocupação da região. Associado a este investimento também foi intensificado o desmatamento e as atividades articuladas a este processo, tais como a extração de madeira, abertura de áreas agrícolas e de pastagens. Atualmente, a região apresenta uma grande diversidade quanto ao uso e ocupação da terra sendo possível observar atividades como a pecuária extensiva e cultivo de grãos (soja, arroz, milho, sorgo e feijão).

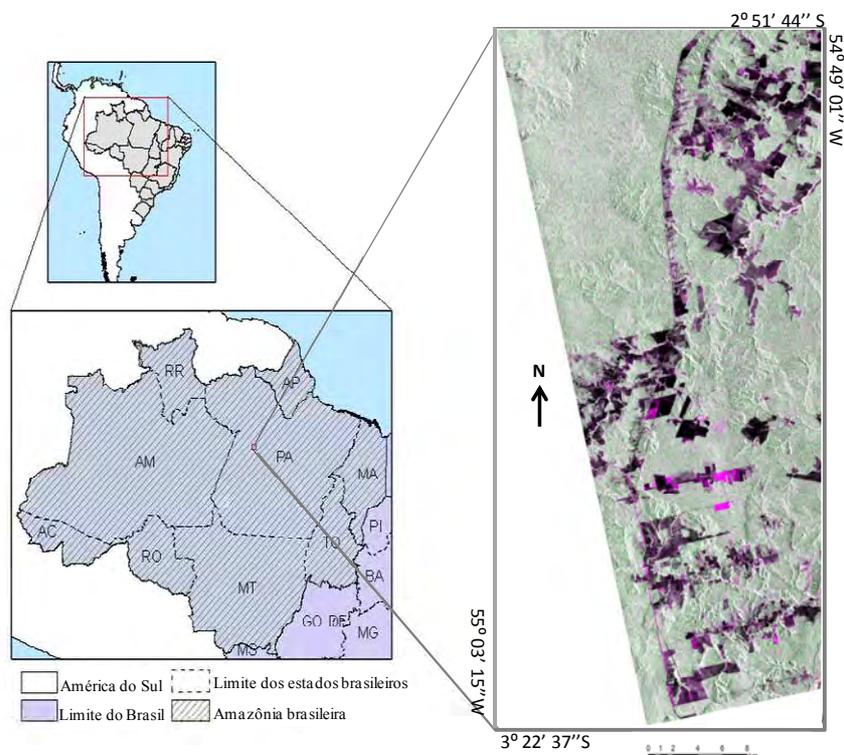


Figura A.2.1. Localização da área de estudo.

## A.2.2. Abordagem metodológica

Na Figura A.2.2 é apresentado o fluxograma metodológico indicando os processamentos utilizados na geração das ortomagens e na avaliação planimétrica das imagens abordadas neste trabalho.

As avaliações planimétricas foram realizadas sobre a imagem ALOS/PALSAR adquiridas no modo FBD, nível de processamento 1.5 *Geocoded* e sobre a ortomagem gerada a partir da imagem ALOS/PALSAR FBD 1.5 *Georeferenced* disponibilizada pelo IBGE. A imagem *Geocoded* foi adquirida no dia 21/06/2010 e a *Georeferenced* em 30/04/2008. As principais características destas imagens estão apresentadas na Tabela A.2.1.

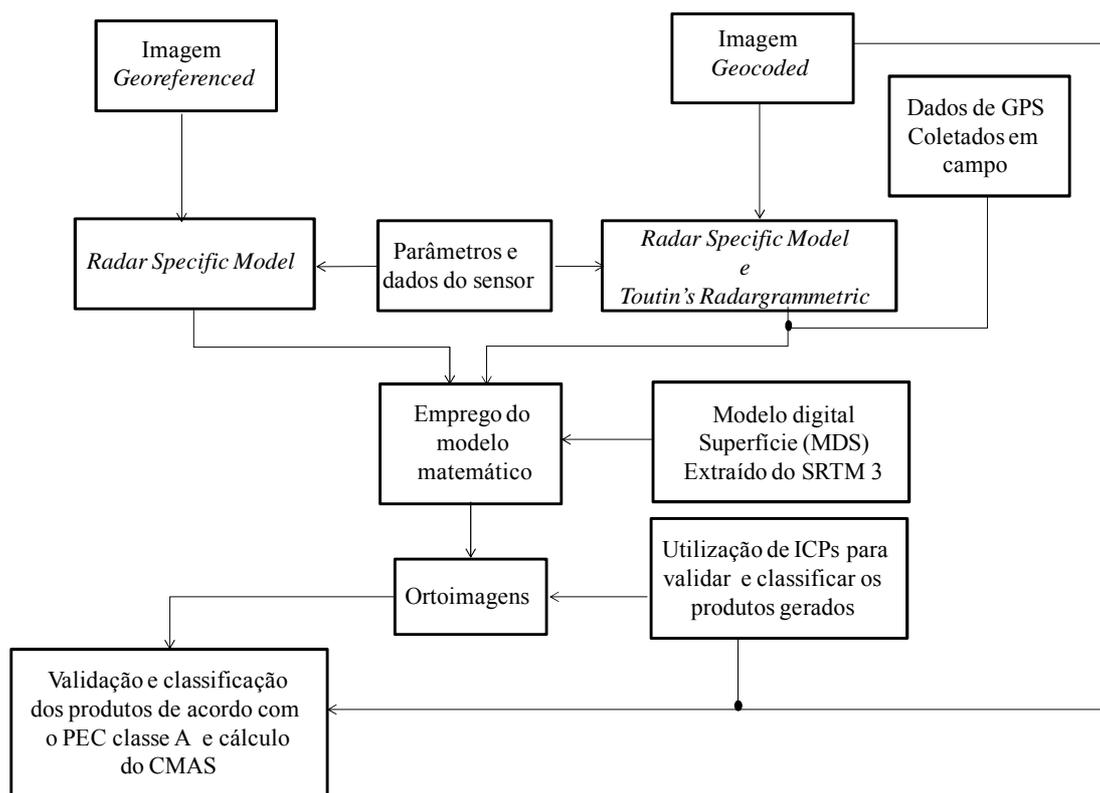


Figura A.2.2. Fluxograma metodológico.

Tabela A.2.1. Características das imagens ALOS/PALSAR.

Características	Imagem ALOS/PALSAR FBD 1.5 <i>Geocoded</i>	Imagem ALOS/PALSAR FBD 1.5 <i>Georeferenced</i>
Data de aquisição	21/06/2010	30/04/2008
Comprimento de onda	Band L (aprox. 23 cm)	
Modo de operação	<i>Fine Beam Dual</i> (FBD)	
Polarizações	HH e HV	
Ângulo de incidência	34,3°	
Espaçamento entre os <i>pixels</i>	12,5 m × 12,5 m	
Resolução (range × azimuth)	19 m × 10 m	
Faixa imageada	70 km	
Resolução radiométrica	16 bits	
Nível de correção	1.5 <i>Geocoded</i>	1.5 <i>Georeferenced</i>
Órbita	Ascendente	

Para verificar a influência da utilização de diferentes modelos matemáticos de correções geométricas na qualidade posicional das ortomagens PALSAR *Geocoded*, foram testados dois modelos matemáticos rigorosos comumente utilizados na ortorretificação de imagens SAR, quais sejam, *Toutin's 3D Radargrammetric Model* (TRM) e o *Radar Specific Model* (RSM). Os modelos matemáticos utilizados para a geração das ortomagens estão disponíveis no *software PCI Geomatica OrthoEngine* (PCI GEOMATICS, 2010), e os passos de processamentos implementados no *software* são apresentados por Ostrowski e Cheng (2000). Para a aplicação destes modelos é necessária a utilização de GCPs e de um MDS. O MDS utilizado na aplicação dos modelos rigorosos foi o SRTM-3. Para a aplicação dos modelos rigorosos de ortorretificação na imagem *Geocoded*, validação e classificação das imagens abordadas neste trabalho foram utilizados 37 pontos de controle de campo GCPs localizados em feições notáveis. Estes dados planialtimétricos foram adquiridos em uma campanha de campo realizada em setembro de 2009 com receptores GPS Geodésicos da marca *Trimble* 4000 modelo SSE/SSI. A precisão planimétrica obtida após o processamento dos dados foi de

1,2 cm com solução fixa. Os processamentos aplicados pelo IBGE na imagem *Georeferenced* são os apresentados por Rodrigues (2010) e Rodrigues et al. (2011). Basicamente, estes processamentos consistem na aplicação do modelo *Radar Specific Model*. Para tanto, pode-se utilizar o MDS SRTM-3 que é disponibilizado gratuitamente pela *National Aeronautics and Space Administration-NASA*. Nesta metodologia de geração de ortoimagens é dispensável a utilização de GCPs.

### A.3. RESULTADOS E DISCUSSÃO

No total foram avaliadas 5 imagens, 1 no formato *Geocoded*, 1 ortoimagem gerada a partir da imagem *Georeferenced* disponibilizada gratuitamente pelo IBGE e 3 imagens resultantes da aplicação dos modelos rigorosos de ortorretificação na imagem *Geocoded*. O modelo RSM foi aplicado duas vezes na imagem *Geocoded* sendo que em uma foi utilizado 1 GCP e na outra 8 GCP. Para a aplicação do modelo TRM é necessário a utilização de no mínimo 6 GCPs (teoricamente) (Toutin e Chénier 2009; TOUTIN, 2010). Por este motivo, para a aplicação deste modelo na imagem *Geocoded* foram utilizados 8 GCPs.

Para a validação planimétrica das 5 imagens foram utilizados 20 pontos independentes de verificação (*Independent Check Points – ICPs*), pois de acordo com Merchant (1982), 20 ICPs distribuídos na área da imagem é o suficiente para avaliar a sua acurácia posicional. Para validar a remoção das tendências nas componentes planimétricas das imagens e ortoimagens foram utilizados 9 ICPs.

A validação planimétrica dos produtos SAR foi baseada na análise estatística das discrepâncias entre as coordenadas observadas nos produtos e as coordenadas de referência. Esta discrepância é expressa, em cada ponto, por:

$$\Delta x = x_{o,i} - x_{r,i} \quad (1)$$

onde  $x_{o,i}$  e  $x_{r,i}$  são, respectivamente, os valores das coordenadas geográficas observadas na imagem e as de referência obtidas em campo.

A análise de exatidão foi dividida em análise de tendência e de precisão. Estas análises são baseadas em testes de hipóteses paramétricos (*t-Student* e *Qui-quadrado*) nos quais se supõe que os resíduos planimétricos e a resultante dos mesmos apresentam distribuição Gaussiana. No entanto, um espaço amostral com 20 pontos pode ser insuficiente para ser enquadrado no teorema do limite central. Portanto, foi verificada a normalidade dos resíduos planimétricos antes de se realizar qualquer análise de exatidão. Para isto foi utilizado o teste paramétrico de *Shapiro-Wilk*. Os testes de hipóteses realizados foram unilaterais considerando um nível de significância de 5 %. Para as avaliação das imagens é importante definir que o eixo x faz referência a direção Leste – Oeste e o eixo y a direção Norte-Sul. Os resultados dos testes bem como o *p-valor* associado encontram-se Tabela A.3.1.

Tabela A.3.1. Resultado do teste de Shapiro-Wilk.

Imagens ALOS/PALSAR FBD 1.5	Teste de <i>Shapiro-Wilk</i> (resultante das componentes dos resíduos planimétricos de x e y)	<i>P-Valor</i>
Ortoimagem (RSM) 1.5 <i>Georeferenced</i> sem GCP-IBGE	Normal	0,93
Imagem ALOS/PALSAR FBD 1.5 <i>Geocoded</i>	Normal	0,56
Imagem (RSM) 1.5 <i>Geocoded</i> com 1 GCP	Normal	0,47
<b>Imagem (RSM) 1.5 <i>Geocoded</i> com 8 GCPs</b>	<b>N_Normal</b>	0,01
Imagem (TRM) 1.5 <i>Geocoded</i> com 8 GCPs	Normal	0,06

Como pode ser observado a resultante das componentes dos resíduos planimétricos de todas as imagens apresentaram distribuição normal, à exceção da imagem resultante da aplicação de modelo (RSM) 1.5 *Geocoded* com 8 GCPs. Observe que o teste de normalidade foi rejeitado considerando 5% de significância, porém aceito considerando 10% de significância. Portanto, o teste de precisão foi realizado em todas as imagens supracitadas.

A análise de precisão tem por objetivo verificar se o resultado do desvio padrão dos resíduos planimétricos (resíduos amostrais) atende a determinada escala cartográfica de acordo com a classificação definida pelo PEC. Esta análise é embasada no teste de hipótese que utiliza a distribuição *Qui-quadrado* e tem como hipótese nula que a

variância amostral é estatisticamente igual ou menor à variância especificada pelo PEC, para uma determinada escala.

$$H_0: \sigma_e^2 \leq \sigma_{PEC}^2$$

$$H_1: \sigma_e^2 > \sigma_{PEC}^2 \quad (2)$$

onde  $\sigma_e^2$  é a variância dos resíduos planimétricos nas direções das coordenadas x e y, ou na resultante das mesmas e  $\sigma_{PEC}^2$  é a variância especificada pelo PEC de acordo com o DEC.

Para a avaliação da precisão considera-se que o desvio padrão ( $\sigma$ ) limite seja definido a partir do DEC ( $\sigma_{PEC}$ ) como mostrado na Tabela A.3.2. No PEC existem classes em que um produto cartográfico pode ser enquadrado. Neste trabalho foi considerada a precisão exigida na classe A, pois esta é a que exige maior rigor na precisão planimétrica de um determinado produto cartográfico para que seja classificada em uma escala. A relação apresentada nesta tabela é aplicada quando se deseja comparar o desvio padrão das resultantes das componentes planimétricas x e y ( $\sigma_{x,y}$ ).

Tabela A.3.2. Parâmetros para o cálculo do desvio padrão limite em função do DEC.

Classes de um produto cartográfico	Desvio padrão limite definido pelo PEC
<b>A</b>	<b>0,3 mm do DEC</b>
B	0,5 mm do DEC
C	0,6 mm do DEC

Então, tomando como exemplo a escala de 1:100.000 o  $\sigma_{PEC}$  limite é igual a 30 m. Quando os testes são realizados para as componentes (x e y) em separado considera-se que  $\sigma_x = \sigma_{PEC}/\sqrt{2}$  (Galo e Camargo 1994). Portanto, o desvio padrão limite para as componentes planimétricas em separado, tomando como exemplo o PEC classe A para a escala 1:100.000 é de 21,2 m.

Os resultados da análise de precisão apresentados na Tabela A.3.3 mostram que, considerando um nível de significância de 5%, a ortoimagem adquirida junto ao IBGE foi classificada no PEC classe A para a escala 1:50.000. Este resultado mostra que os

processamentos aplicados a partir da imagem *Georeferenced* resultaram em uma maior precisão planimétrica se comparado com as demais imagens analisadas.

As imagens (RSM) 1.5 *Geocoded* com 8 GCP e (TRM) 1.5 *Geocoded* com 8GCP foram classificadas no PEC classe A para a escala de 1:150.000. Portanto concluí-se que aplicação destes modelos de ortorretificação na imagem ALOS/PALSAR FBD 1.5 *Geocoded* não melhorou de forma significativa a qualidade do posicionamento planimétrico da imagem. Portanto, para uma área de relevo plano não é indicado a aplicação destes modelos na imagem *Geocoded*.

Tabela A.3.3. Resultados da análise de precisão.

Imagens	$\sigma_{x,y}$ (m)	$\sigma_{PEC}$ (m)	Escala	<i>p</i> -valor
Ortoimagem (RSM) 1.5 <i>Georeferenced</i> sem GCP-IBGE	12,35	15	1:50.000	0,16
Imagem ALOS/PALSAR FBD 1.5 <i>Geocoded</i>	23,31	30	1:100.000	0,09
Imagem (RSM) 1.5 <i>Geocoded</i> com 1 GCP	26,37	30	1:100.000	0,26
Imagem (RSM) 1.5 <i>Geocoded</i> com 8 GCP	54,17	45	1:150.000	0,09
Imagem (TRM) 1.5 <i>Geocoded</i> com 8GCP	48,66	45	1:150.000	0,27

A imagem ALOS/PALSAR FBD 1.5 *Geocoded* e a imagem (RSM) 1.5 *Geocoded* com 1 GCP foram classificadas no PEC classe A para a escala 1:100.000. Para verificar se a precisão planimétrica destas imagens é estatisticamente igual foi realizado o teste de hipótese F de Snedecor que avalia a igualdade entre variâncias. (Equação 3).

$$\begin{aligned}
 H_0: \sigma_1^2 / \sigma_2^2 &= 1 \\
 H_1: \sigma_1^2 / \sigma_2^2 &< 1
 \end{aligned}
 \tag{3}$$

na qual  $\sigma_1^2$  é a variância das resultantes das componentes planimétricas da imagem *Geocoded* e  $\sigma_2^2$  é a variância das resultantes das componentes planimétricas da imagem (RSM) 1.5 *Geocoded* com 1 GCP .

O resultado deste teste é mostrado na Tabela A.3.4 e, foi verificado que a imagem *Geocoded* e a imagem (RSM) 1.5 *Geocoded* com 1 GCP são estatisticamente iguais.

Sendo assim, concluí-se que a aplicação do modelo RMS com 1 GCP não melhorou a acurácia planimétrica da imagem *Geocoded*.

Tabela A.3.4. Resultado do teste de hipótese F de *Snedecor*.

Imagem e ortomagens (resultante de x e y)	$\sigma_{x,y}$ (m)	ICPs	p-valor
Ortoimagem (RSM) 1.5 <i>Geocoded</i> com 1 GCP	26,37	20	0,30
ALOS/PALSAR 1.5 <i>Geocoded</i>	23,31	20	

As avaliações das imagens também foram realizadas utilizando o *Circular Map Accuracy Standard* – CMAS considerando 95% de probabilidade. O CMAS leva em consideração no seu cálculo o *Root Mean Square Erro* – RMSE conforme pode ser observado na equação 4. Nota-se que para este cálculo considerou-se que o  $RMSE_x \neq RMSE_y$ . Para tanto, o RMSE foi calculado utilizando a equação 5 (NSDI, 1998).

$$CMAS = 2,698 * RMSE \quad (4)$$

$$RMSE = \sqrt{\frac{\sum (x_{o,i} - x_{r,i})^2 + (y_{o,i} - y_{r,i})^2}{n}} \quad (5)$$

onde  $n$  é o número ICPs utilizados na validação das imagens.

Os resultados das avaliações das imagens utilizando o CMAS são apresentados na Tabela A.3.5.

Tabela A.3.5. Resultado da avaliação utilizando o CMAS.

Imagens	CMAS m (95%)
Ortoimagem (RSM) 1.5 <i>Georeferenced</i> sem GCP-IBGE	12,28
ALOS/PALSAR FBD 1.5 <i>Geocoded</i>	16,92
Ortoimagem (RSM) 1.5 <i>Geocoded</i> com 1 GCP	25,85
Ortoimagem (RSM) 1.5 <i>Geocoded</i> com 8 GCP	66,13
Ortoimagem (TRM) 1.5 <i>Geocoded</i> com 8GCP	43,53

Como pode ser observado a ortoreferenciada gerada a partir da imagem *Georeferenced* e a imagem *Geocoded* apresentaram os menores valores do CMAS. A imagem (RSM) 1.5

*Geocoded* com 1 GCP, (RSM) 1.5 *Geocoded* com 8 GCP e (TRM) 1.5 *Geocoded* com 8GCP apresentaram os maiores valores do CMAS. Assim, conclui-se que a aplicação dos modelos rigorosos de ortorretificação na imagem *Geocoded* não melhoraram a acurácia posicional dos dados planimétricos para uma área de relevo plano.

A análise de tendência visa identificar erros sistemáticos no produto cartográfico e para isto utiliza-se o teste de hipótese que utiliza a distribuição *t-Student*. Este teste tem como hipótese nula que a média dos resíduos planimétricos ( $\mu_e$ ) é igual a zero (Equação 6). Em outras palavras, que os resíduos planimétricos são livres de erros sistemáticos.

$$\begin{aligned} H_0: \mu_e &= 0 \\ H_1: \mu_e &\neq 0 \end{aligned} \tag{6}$$

A remoção das tendências nas direções x e y foi realizada por meio da subtração do valor médio amostral dos resíduos de cada componente planimétrica da imagem ou ortoimagem em questão (GALO; CAMARGO, 1994).

Esta análise foi realizada na imagem ALOS/PALSAR FBD 1.5 *Geocoded* e na ortoimagem adquirida junto ao IBGE, e os resultados mostraram que ambas as imagens apresentavam tendências nas direções x e y (Tabela A.3.6).

Tabela A.3.6 Resultado da análise de tendência.

Imagem e Ortoimagem	Média (x)	Média (y)	t-Student (x)	t-Student (y)
ALOS/PALSAR FBD 1.5 <i>Geocoded</i>	-131.8	-32.7	Tendencioso	Tendencioso
Ortoimagem (RSM) 1.5 <i>Georeferenced</i> sem GCP-IBGE	-44.3	-15.2	Tendencioso	Tendencioso

Pode ser notar nas Figuras A.3.1 e A.3.2 que o deslocamento na imagem ALOS/PALSAR FBD 1.5 *Geocoded* é maior que a da ortoimagem adquirida junto ao IBGE.

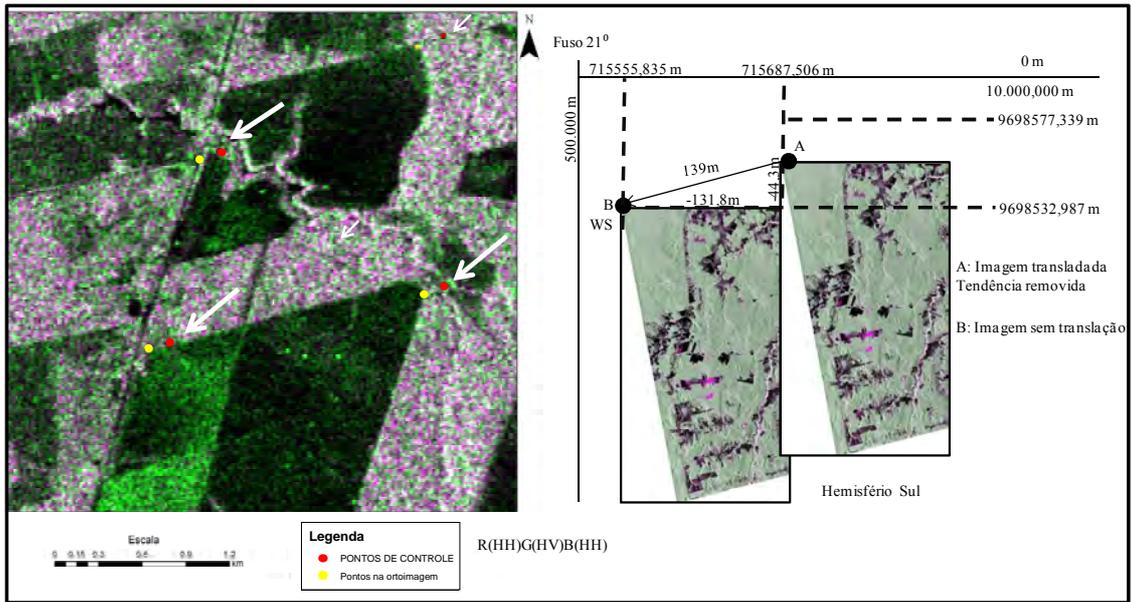


Figura A.3.1 Tendência dos resíduos das componentes planimétricas x e y da imagem ALOS/PALSAR FBD 1.5 *Geocoded*.

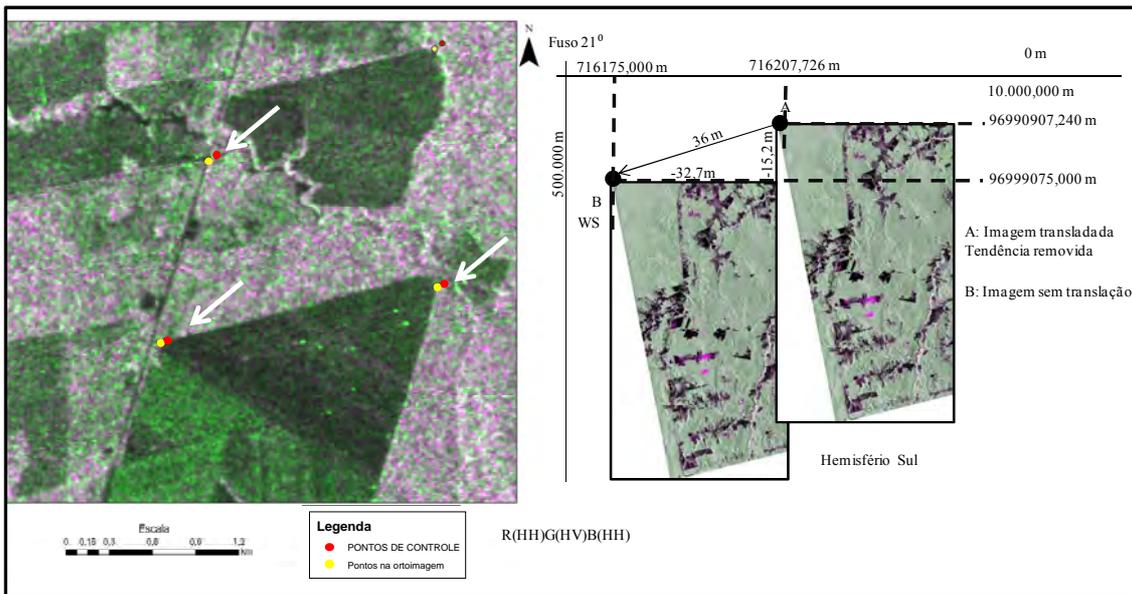


Figura A.3.2. Tendência dos resíduos das componentes planimétricas x e y da ortomagem adquirida junto ao IBGE.

Após a remoção destas tendências nas componentes planimétricas, foram utilizados 9 ICPs para verificar se estas tendências haviam sido removidas. O resultado do teste *t-Student* confirmou a remoção das tendências.

#### A.4. CONCLUSÃO E CONSIDERAÇÕES FINAIS

Conclui-se que a ortoimagem adquirida junto ao IBGE apresentou significativamente maior precisão nos dados planimétricos que os demais produtos SAR analisados. Esta ortoimagem foi compatível com uma escala de 1:50.000 seguindo a classificação do PEC brasileiro classe para A, o CMAS foi de 12,28 m. Este tipo de ortoimagem é disponibilizada gratuitamente pelo IBGE para a região da Amazônia Legal e Nordeste Brasileiro. As datas de aquisição destas imagens compreendem o ano de 2008. Portanto, caso o usuário necessite de um ortoimagem de outro ano ou local, aconselha-se que a imagem ALOS/PALSAR FBD 1.5 seja adquirida junto a JAXA no formato *Georeferenced* e que os processamentos realizados pelo IBGE e descritos por Rodrigues (2010); Rodrigues et al. (2011) sejam aplicados pelo usuário. Acredita-se que, dentre as imagens SAR analisadas, esta ortoimagem seja a mais adequada para estudos realizados em áreas que não apresentem relevo plano, pois a sua correção geométrica considera as variações de altitude do terreno. Porém, a desvantagem deste método de ortorretificação é a dificuldade do usuário ter acesso ao modelo rigoroso *Radar Specific Model*, uma vez que, em geral ele está implementado em aplicativos comerciais.

Os dados planimétricos da imagem *Geocoded* foram compatíveis com a escala 1:100.000 seguindo a classificação do PEC brasileiro para classe A, o CMAS foi de 16,92 m. Acredita-se que esta imagem tem aplicabilidade em áreas de relevo plano, pois as correções geométricas de sistema consideram apenas a altitude média do mesmo. Baseado nas análises de precisão pode-se concluir que a aplicação dos modelos matemáticos rigorosos para a ortorretificação da imagem ALOS/PALSAR FBD 1.5 *Geocoded* não melhoraram significativamente a qualidade do seu posicionamento planimétrico.

Este estudo demonstra a necessidade da realização das análises de tendências e remoção das mesmas para que as imagens SAR em questão possam ser classificadas no PEC classe A para escala uma escala de mapeamento. Este ajuste é fundamental para diversas aplicações, principalmente em estudos que envolvam dados provenientes de diferentes fontes e/ou com diferentes datas, pois caso as tendências identificadas não

sejam removidas as feições registradas nas imagens podem não ter correspondência espacial e, por consequência, vários estudos podem ter seus resultados seriamente comprometidos. Portanto, embora o PEC brasileiro não mencione a necessidade desta análise aconselha-se que ela seja realizada em qualquer imagem ou produto cartográfico para garantir a qualidade dos dados planimétricos.

### ***Agradecimentos***

Os autores agradecem ao Engenheiro Carlos Alberto Saldanha por gentilmente disponibilizar os dados de GPS geodésico coletados em campo. Ao Instituto Nacional de Ciência e Tecnologia (INCT) para Mudanças Climáticas por financiar o desenvolvimento de pesquisas na Amazônia Brasileira. À JAXA pelo fornecimento da imagem ALOS/PALSAR FBD 1.5 *Geocoded*. E a coordenação de aperfeiçoamento de pessoal de nível superior (CAPES) pela concessão de bolsa de mestrado ao primeiro autor.



## APÊNDICE B - SELEÇÃO DOS TAMANHOS DAS JANELAS DAS MEDIDAS DE TEXTURAS

De acordo com a metodologia exposta na seção 4.5.1.4 foi selecionado o tamanho da janela do filtro para o cálculo da medida de textura que resultou em um ganho na distância JM média inferior a 5% em relação à banda da mesma medida de textura a qual foi aplicada uma janela de vizinhança de tamanho  $n - 2$ . As tabelas e figuras a seguir mostram, para cada medida de textura e para cada polarização, os valores das distâncias JM médias e seus respectivos ganhos. O tamanho da janela selecionada é identificado em negrito nas tabelas e por uma flecha nos gráficos.

Tabela B.1. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Contraste, banda HH.

Medida de textura e tamanho da janela de vizinhança	Distância JM média Banda HH	Ganho da distância JM média (%) Banda HH
Contraste 3	0,43	
Contraste 5	0,51	17,40
Contraste 7	0,60	18,55
Contraste 9	0,68	13,04
Contraste 11	0,73	7,19
<b>Contraste 13</b>	<b>0,75</b>	<b>3,53</b>
Contraste 15	0,77	1,79
Contraste 17	0,77	0,62
Contraste 19	0,76	-0,95
Contraste 21	0,77	0,19
Contraste 23	0,77	0,84
Contraste 25	0,77	0,17
Contraste 27	0,77	-0,19
Contraste 29	0,77	-0,42
Contraste 31	0,76	-0,54

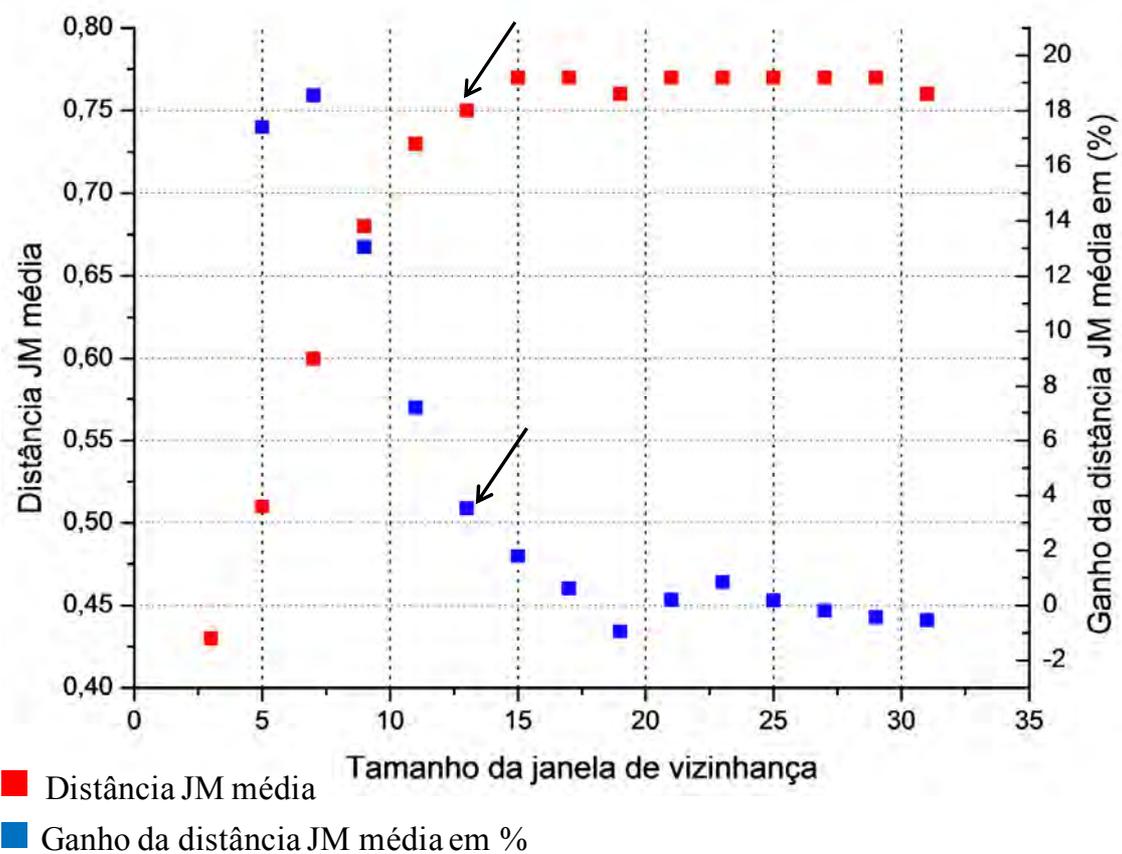


Figura B.1. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Contraste, banda HH.

Tabela B.2. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Contraste, banda HV.

Medida de textura e tamanho da janela de vizinhança	Distância JM média Banda HV	Ganho da distância JM média (%) Banda HV
Contraste 3	0,69	
Contraste 5	0,77	12,55
Contraste 7	0,84	8,91
Contraste 9	0,89	5,35
<b>Contraste 11</b>	<b>0,91</b>	<b>2,83</b>
Contraste 13	0,93	1,66
Contraste 15	0,94	1,28
Contraste 17	0,95	0,89
Contraste 19	0,95	0,66
Contraste 21	0,96	0,43
Contraste 23	0,96	0,25
Contraste 25	0,96	0,16
Contraste 27	0,96	0,08
Contraste 29	0,96	0,00
Contraste 31	0,96	-0,05

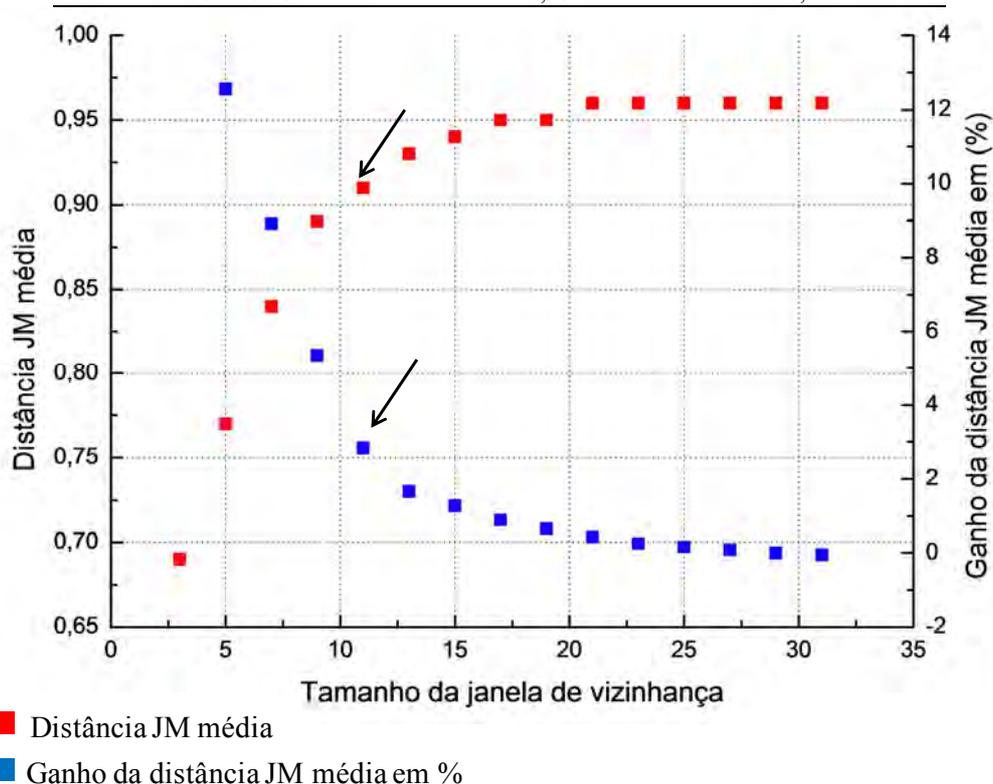


Figura B.2. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Contraste, banda HV.

Tabela B.3. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Correlação, banda HH.

Medida de textura e tamanho da janela de vizinhança	Distância JM média Banda HH	Ganho da distância JM média (%) Banda HH
Correlação 3	0,40	
Correlação 5	0,78	93,27
Correlação 7	0,85	8,64
<b>Correlação 9</b>	<b>0,89</b>	<b>4,23</b>
Correlação 11	0,91	2,30
Correlação 13	0,91	0,96
Correlação 15	0,91	-0,35
Correlação 17	0,90	-1,18
Correlação 19	0,89	-0,72
Correlação 21	0,89	-0,95
Correlação 23	0,86	-3,29
Correlação 25	0,83	-3,37
Correlação 27	0,82	-1,56
Correlação 29	0,80	-1,56
Correlação 31	0,79	-1,54

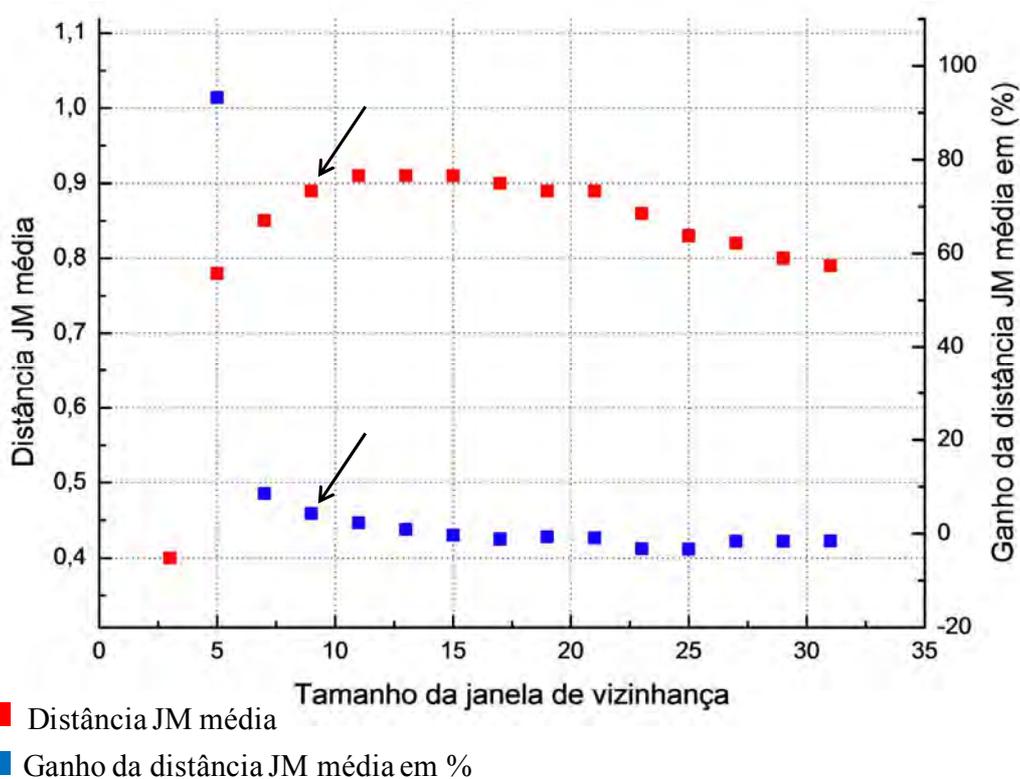


Figura B.3. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Correlação, banda HH.

Tabela B.4. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Correlação, banda HV.

Medida de textura e tamanho da janela de vizinhança	Distância JM média Banda HV	Ganho da distância JM média (%) Banda HV
Correlação 3	0,19	
Correlação 5	0,70	273,95
Correlação 7	0,77	10,69
Correlação 9	0,84	8,35
<b>Correlação 11</b>	<b>0,88</b>	<b>4,68</b>
Correlação 13	0,91	3,68
Correlação 15	0,94	3,20
Correlação 17	0,96	2,44
Correlação 19	0,98	1,86
Correlação 21	0,99	1,40
Correlação 23	1,00	0,54
Correlação 25	1,01	1,00
Correlação 27	1,02	0,99
Correlação 29	1,02	0,00
Correlação 31	1,03	0,98

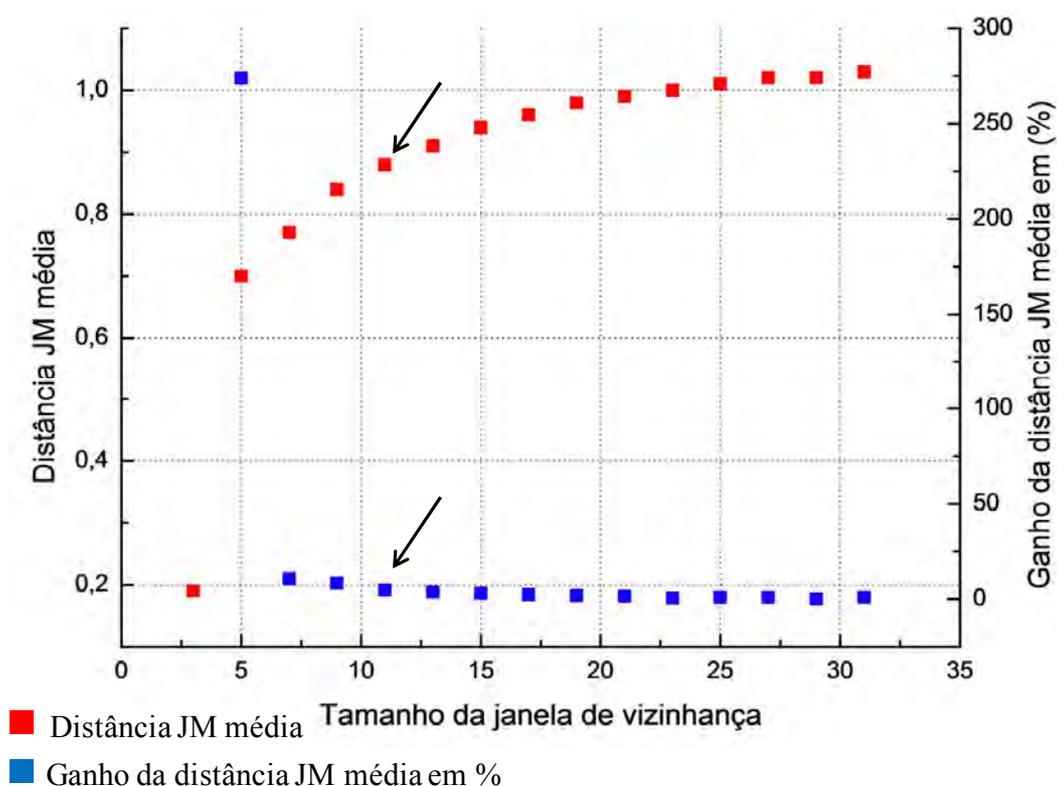


Figura B.4. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Correlação, banda HV.

Tabela B.5. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Coeficiente de Variação, banda HH.

Medida de textura e tamanho da janela de vizinhança	Distância JM média Banda HH	Ganho da distância JM média (%) Banda HH
Coeficiente de Variação 3	0,09	
Coeficiente de Variação 5	0,21	126,98
Coeficiente de Variação 7	0,30	43,05
Coeficiente de Variação 9	0,38	24,06
Coeficiente de Variação 11	0,44	15,51
Coeficiente de Variação 13	0,49	11,78
Coeficiente de Variação 15	0,53	9,04
Coeficiente de Variação 17	0,57	6,27
<b>Coeficiente de Variação 19</b>	<b>0,59</b>	<b>3,79</b>
Coeficiente de Variação 21	0,60	2,94
Coeficiente de Variação 23	0,62	2,39
Coeficiente de Variação 25	0,63	2,39
Coeficiente de Variação 27	0,65	2,31
Coeficiente de Variação 29	0,66	2,21
Coeficiente de Variação 31	0,68	1,85

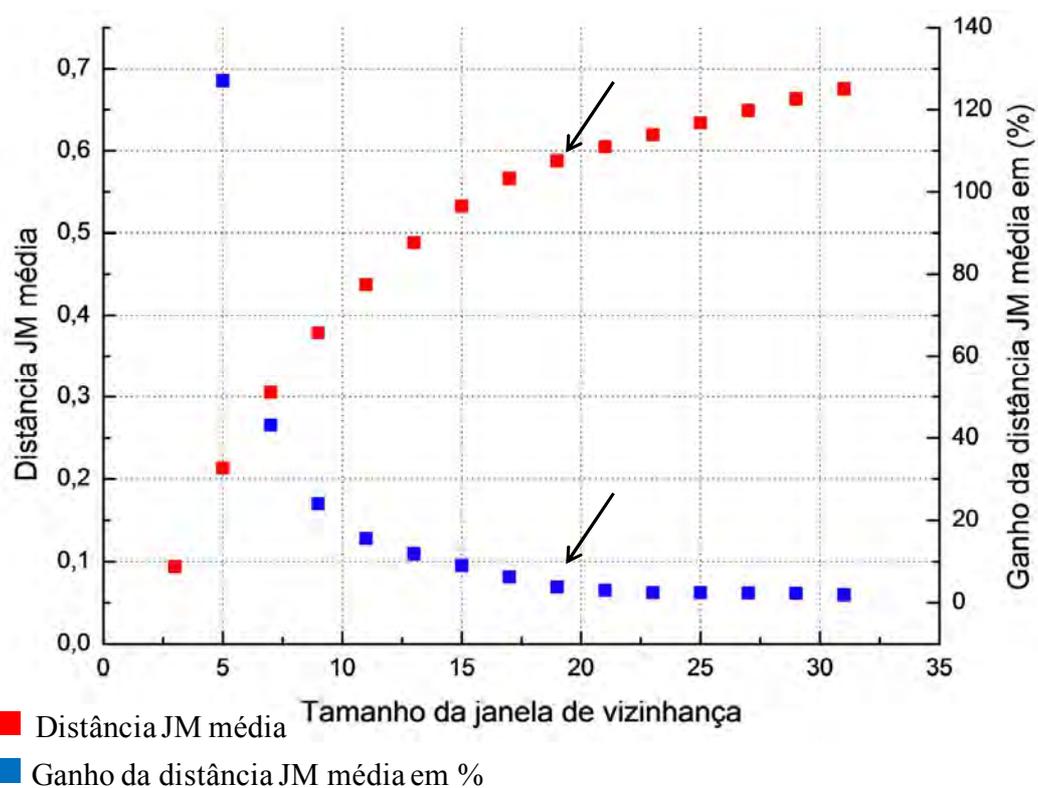


Figura B.5. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Coeficiente de Variação, banda HH.

Tabela B.6. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Coeficiente de Variação, banda HV.

Medida de textura e tamanho da janela de vizinhança	Distância JM média Banda HV	Ganho da distância JM média (%) Banda HV
Coeficiente de Variação 3	0,09	
Coeficiente de Variação 5	0,20	129,73
Coeficiente de Variação 7	0,29	44,81
Coeficiente de Variação 9	0,36	27,44
Coeficiente de Variação 11	0,43	18,02
Coeficiente de Variação 13	0,48	12,63
Coeficiente de Variação 15	0,53	8,64
Coeficiente de Variação 17	0,56	5,90
<b>Coeficiente de Variação 19</b>	<b>0,58</b>	<b>4,28</b>
Coeficiente de Variação 21	0,60	3,60
Coeficiente de Variação 23	0,62	3,08
Coeficiente de Variação 25	0,64	2,74
Coeficiente de Variação 27	0,65	2,60
Coeficiente de Variação 29	0,67	2,56
Coeficiente de Variação 31	0,69	2,52

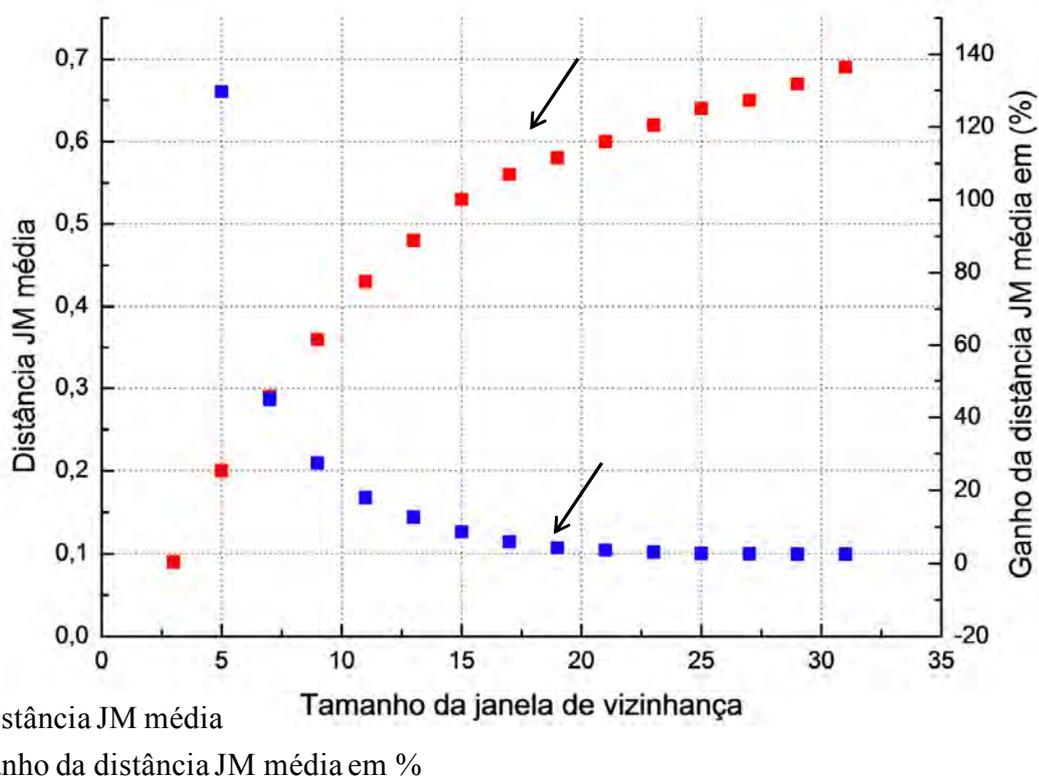


Figura B.6. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Coeficiente de Variação, banda HV.

Tabela B.7. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Dissimilaridade, banda HH.

Medida de textura e tamanho da janela de vizinhança	Distância JM média Banda HH	Ganho da distância JM média (%) Banda HH
Dissimilaridade 3	0,41	
Dissimilaridade 5	0,49	18,14
Dissimilaridade 7	0,59	21,92
Dissimilaridade 9	0,68	14,51
Dissimilaridade 11	0,74	9,28
Dissimilaridade 13	0,79	5,94
<b>Dissimilaridade 15</b>	<b>0,82</b>	<b>3,83</b>
Dissimilaridade 17	0,84	2,50
Dissimilaridade 19	0,85	1,59
Dissimilaridade 21	0,86	1,01
Dissimilaridade 23	0,86	0,82
Dissimilaridade 25	0,87	0,64
Dissimilaridade 27	0,87	0,54
Dissimilaridade 29	0,88	0,46
Dissimilaridade 31	0,88	0,36

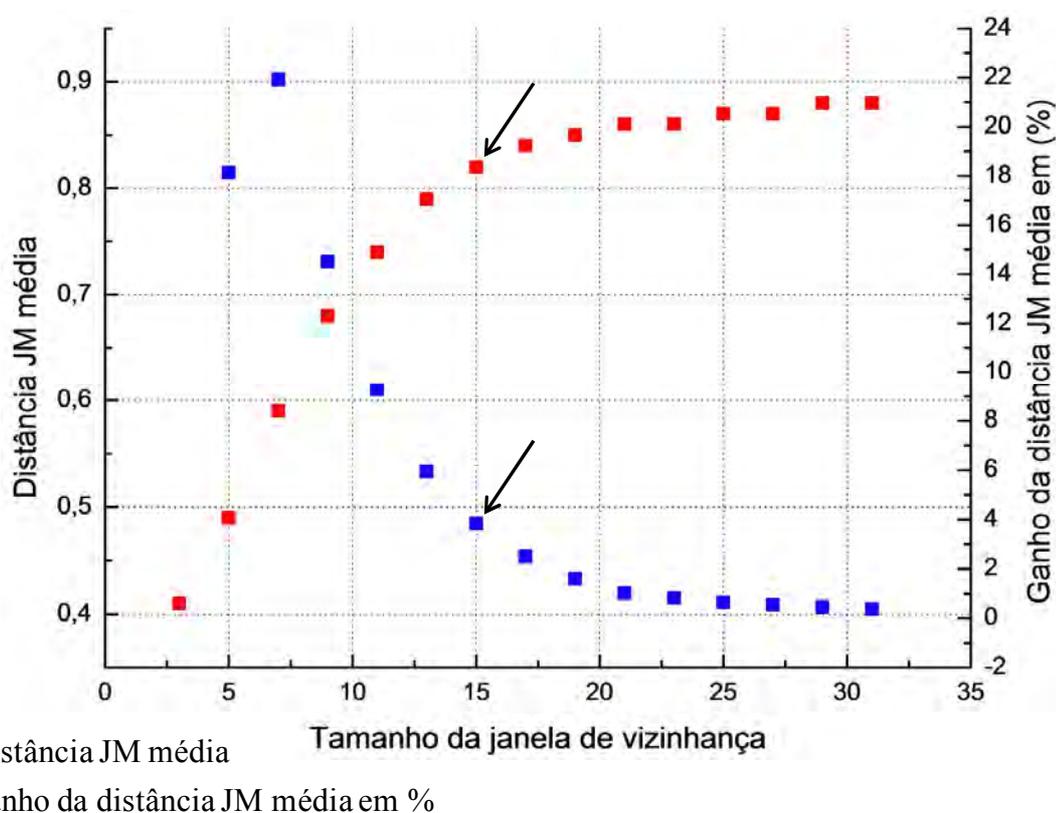


Figura B.7. . Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Dissimilaridade, banda HH.

Tabela B.8. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Dissimilaridade, banda HV.

Medida de textura e tamanho da janela de vizinhança	Distância JM média Banda HV	Ganho da distância JM média (%) Banda HV
Dissimilaridade 3	0,67	
Dissimilaridade 5	0,81	20,55
Dissimilaridade 7	0,89	10,04
Dissimilaridade 9	0,94	5,20
<b>Dissimilaridade 11</b>	<b>0,97</b>	<b>2,70</b>
Dissimilaridade 13	0,98	1,66
Dissimilaridade 15	0,99	1,15
Dissimilaridade 17	1,00	0,59
Dissimilaridade 19	1,00	0,00
Dissimilaridade 21	1,00	0,00
Dissimilaridade 23	1,00	0,00
Dissimilaridade 25	1,00	0,00
Dissimilaridade 27	1,00	0,00
Dissimilaridade 29	1,00	0,00
Dissimilaridade 31	1,00	0,00

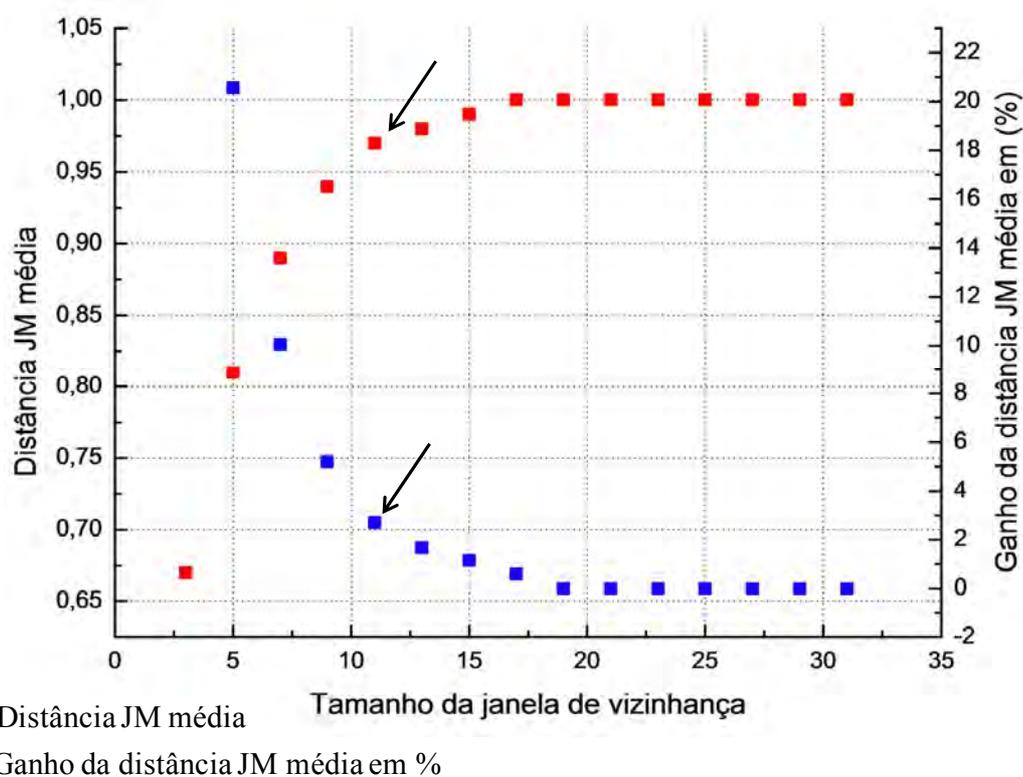


Figura B.8. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Dissimilaridade, banda HV.

Tabela B.9. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Entropia, banda HH.

Medida de textura e tamanho da janela de vizinhança	Distância JM média Banda HH	Ganho da distância JM média (%) Banda HH
Entropia 3	0,42	
Entropia 5	0,54	28,31
Entropia 7	0,65	19,22
Entropia 9	0,72	10,95
Entropia 11	0,76	5,90
<b>Entropia 13</b>	<b>0,78</b>	<b>2,70</b>
Entropia 15	0,79	0,76
Entropia 17	0,79	-0,19
Entropia 19	0,78	-0,65
Entropia 21	0,78	-0,93
Entropia 23	0,77	-1,19
Entropia 25	0,76	-1,31
Entropia 27	0,75	-1,24
Entropia 29	0,74	-1,07
Entropia 31	0,73	-0,92

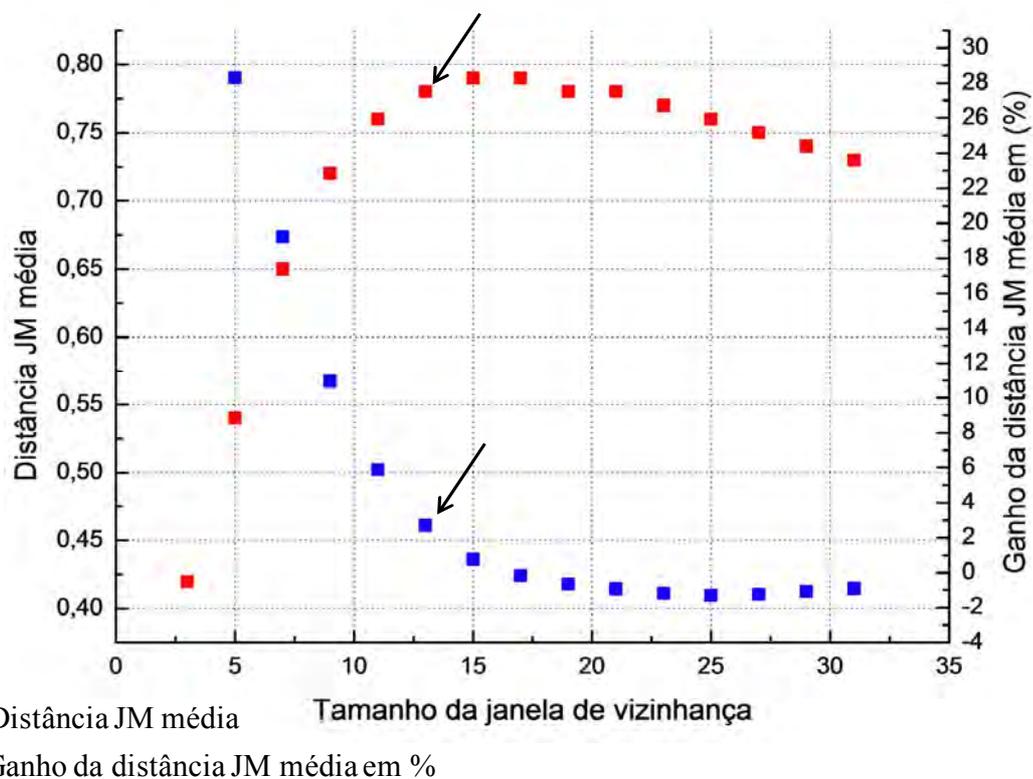


Figura B.9. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Entropia, banda HH.

Tabela B.10. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Entropia, banda HV.

Medida de textura e tamanho da janela de vizinhança	Distância JM média Banda HV	Ganho da distância JM média (%) Banda HV
Entropia 3	0,53	
Entropia 5	0,84	57,34
Entropia 7	0,93	10,10
<b>Entropia 9</b>	<b>0,97</b>	<b>4,20</b>
Entropia 11	0,98	1,37
Entropia 13	0,98	-0,01
Entropia 15	0,97	-0,67
Entropia 17	0,96	-1,06
Entropia 19	0,95	-1,22
Entropia 21	0,94	-1,37
Entropia 23	0,92	-1,42
Entropia 25	0,91	-1,38
Entropia 27	0,90	-1,28
Entropia 29	0,89	-1,17
Entropia 31	0,88	-1,05

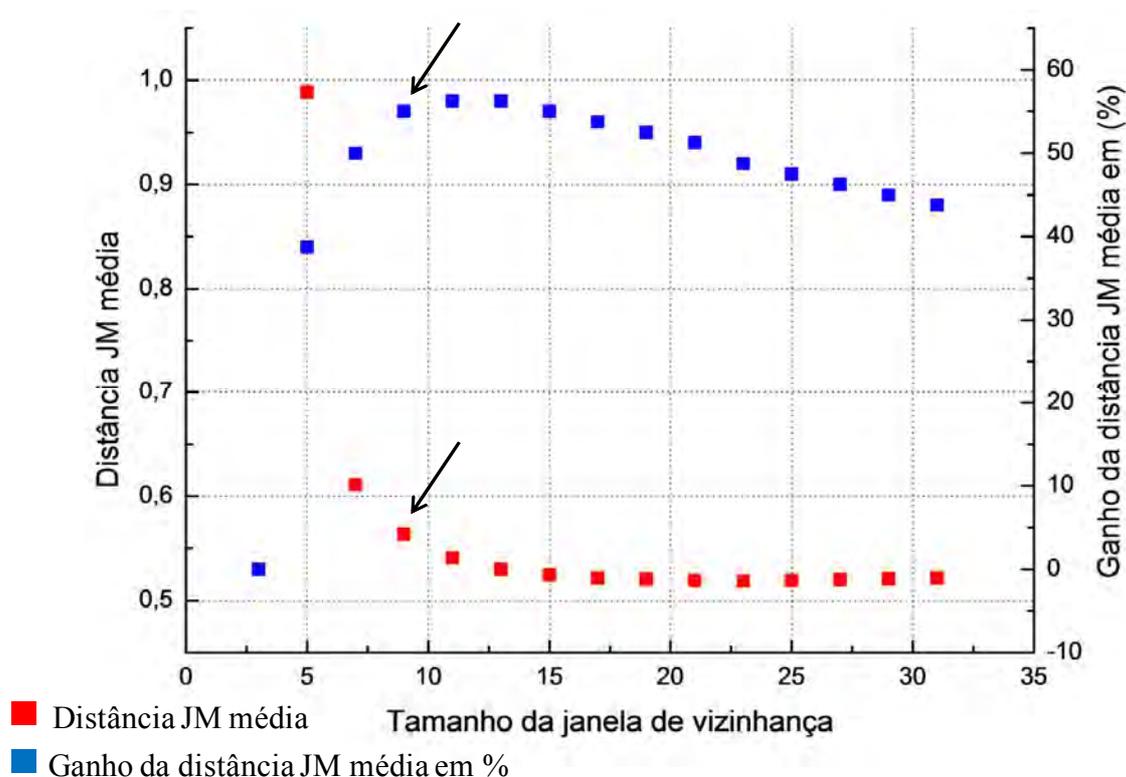


Figura B.10. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Entropia, banda HV.

Tabela B.11. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Homogeneidade, banda HH.

Medida de textura e tamanho da janela de vizinhança	Distância JM média Banda HH	Ganho da distância JM média (%) Banda HH
Homogeneidade 3	0,38	
Homogeneidade 5	0,47	24,30
Homogeneidade 7	0,58	23,80
Homogeneidade 9	0,69	17,64
Homogeneidade 11	0,76	10,71
Homogeneidade 13	0,81	6,68
<b>Homogeneidade 15</b>	<b>0,85</b>	<b>4,35</b>
Homogeneidade 17	0,87	2,99
Homogeneidade 19	0,89	2,14
Homogeneidade 21	0,90	1,69
Homogeneidade 23	0,92	1,36
Homogeneidade 25	0,93	1,06
Homogeneidade 27	0,93	0,89
Homogeneidade 29	0,94	0,70
Homogeneidade 31	0,95	0,52

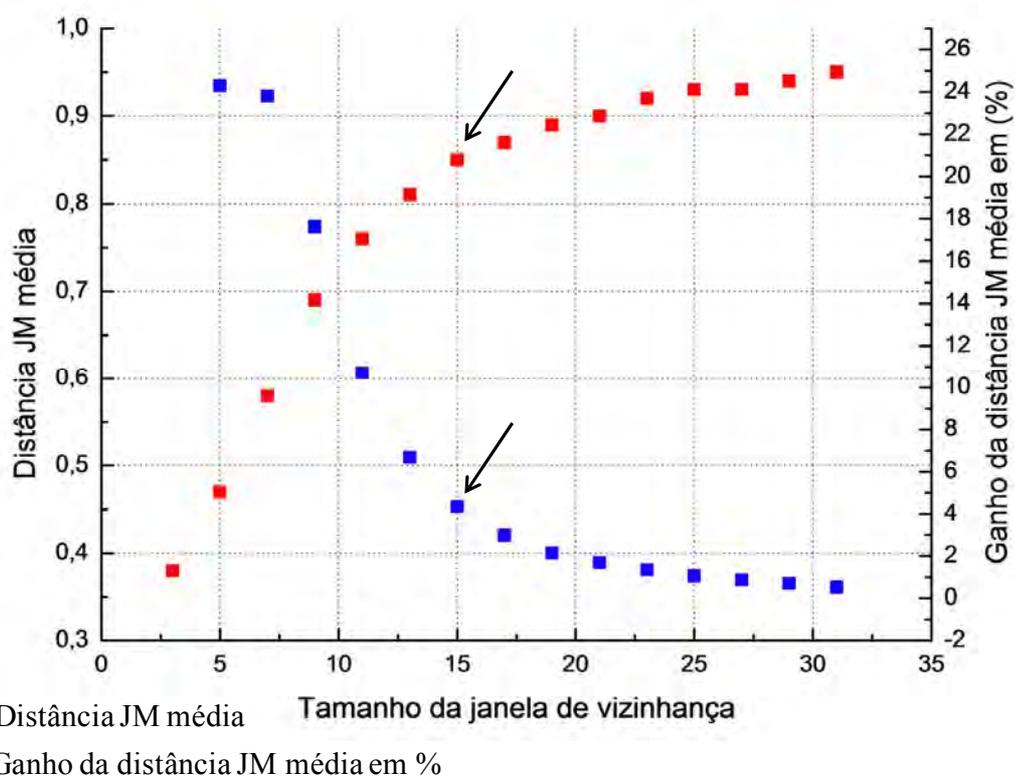


Figura B.11. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Homogeneidade, banda HH.

Tabela B.12. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Homogeneidade, banda HV.

Medida de textura e tamanho da janela de vizinhança	Distância JM média Banda HV	Ganho da distância JM média (%) Banda HV
Homogeneidade 3	0,57	
Homogeneidade 5	0,79	38,90
Homogeneidade 7	0,88	12,04
Homogeneidade 9	0,94	6,85
<b>Homogeneidade 11</b>	<b>0,98</b>	<b>4,20</b>
Homogeneidade 13	1,00	1,87
Homogeneidade 15	1,03	3,00
Homogeneidade 17	1,04	0,97
Homogeneidade 19	1,05	0,96
Homogeneidade 21	1,05	0,00
Homogeneidade 23	1,05	0,00
Homogeneidade 25	1,06	0,95
Homogeneidade 27	1,06	0,00
Homogeneidade 29	1,06	0,00
Homogeneidade 31	1,05	-0,94

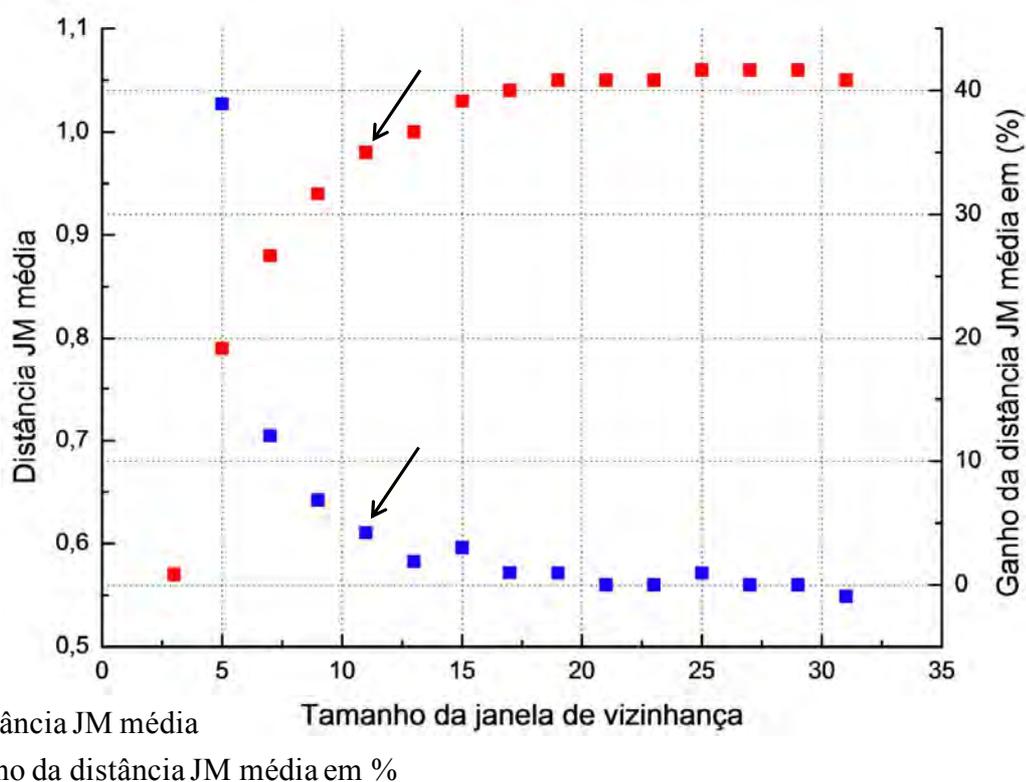


Figura B.12. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Homogeneidade, banda HV.

Tabela B.13. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Média, banda HH.

Medida de textura e tamanho da janela de vizinhança	Distância JM média Banda HH	Ganho da distância JM média (%) Banda HH
Média 3	0,80	
Média 5	0,89	11,76
Média 7	0,95	6,75
<b>Média 9</b>	<b>0,99</b>	<b>3,89</b>
Média 11	1,00	1,39
Média 13	1,02	2,00
Média 15	1,03	0,98
Média 17	1,03	0,00
Média 19	1,03	0,00
Média 21	1,03	0,00
Média 23	1,03	0,00
Média 25	1,02	-0,97
Média 27	1,01	-0,98
Média 29	1,01	0,00
Média 31	1,00	-0,99

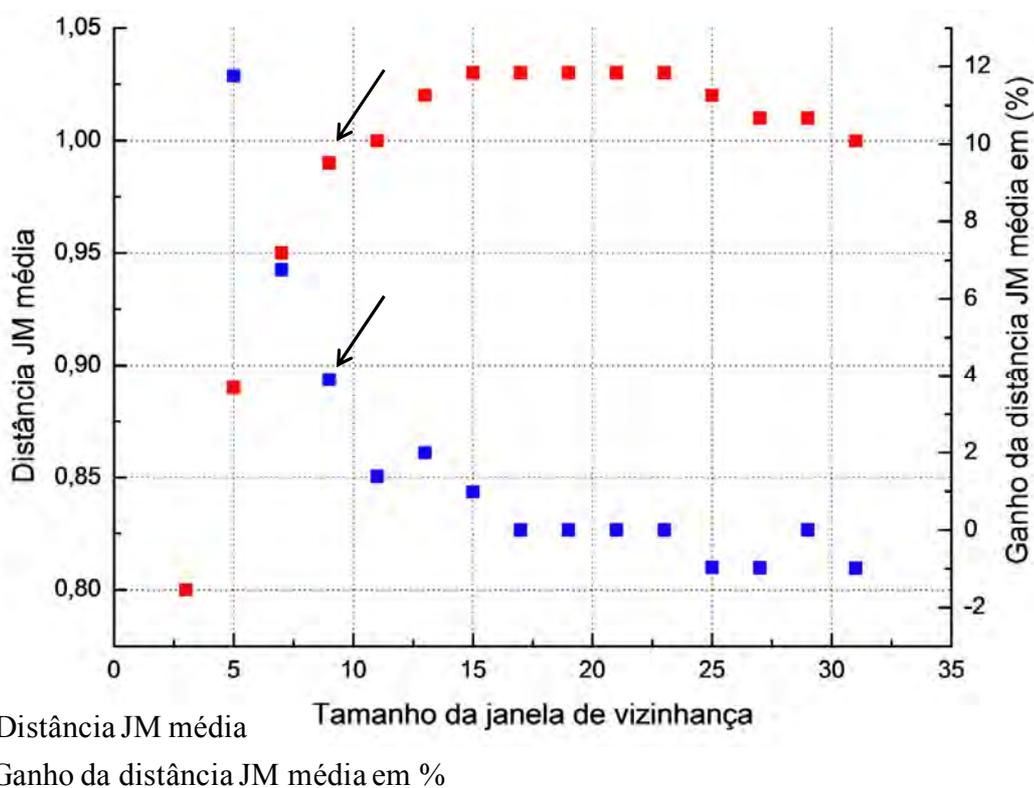


Figura B.13. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Média, banda HH.

Tabela B.14. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Média, banda HV.

Medida de textura e tamanho da janela de vizinhança	Distância JM média Banda HV	Ganho da distância JM média (%) Banda HV
Média 3	0,99	
Média 5	1,05	6,06
<b>Média 7</b>	<b>1,08</b>	<b>2,86</b>
Média 9	1,10	1,85
Média 11	1,10	0,00
Média 13	1,10	0,00
Média 15	1,10	0,00
Média 17	1,10	0,00
Média 19	1,09	-0,91
Média 21	1,08	-0,92
Média 23	1,08	0,00
Média 25	1,07	-0,93
Média 27	1,06	-0,93
Média 29	1,06	0,00
Média 31	1,05	-0,94

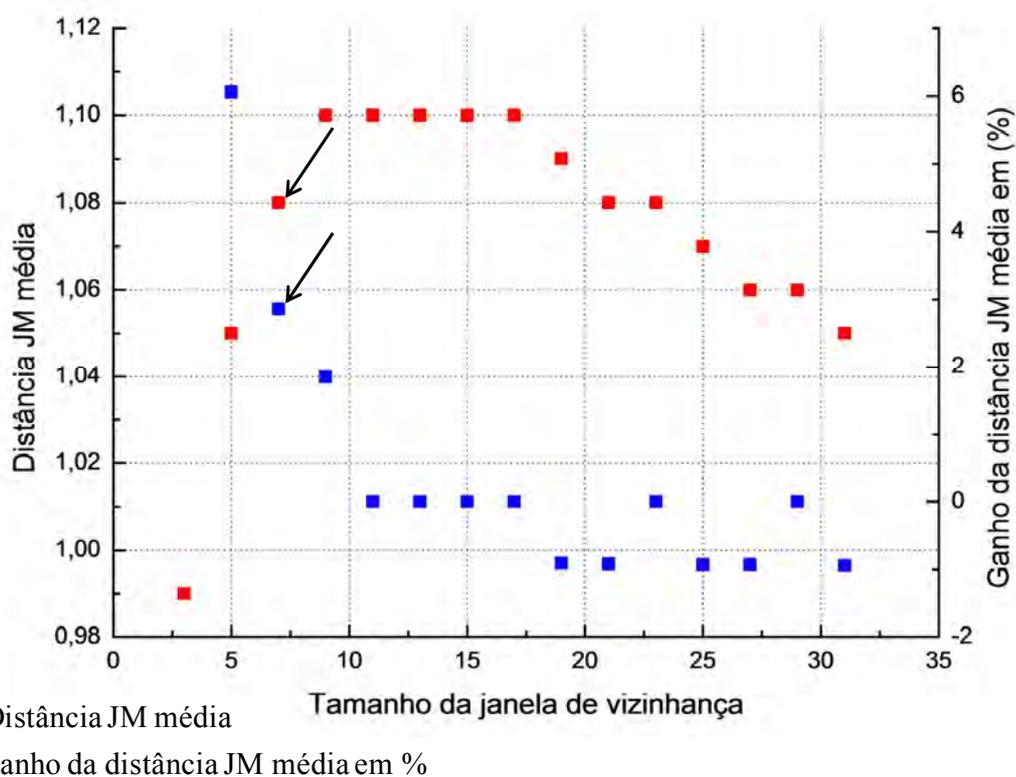


Figura B.14. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Média, banda HV.

Tabela B.15. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Segundo Momento, banda HH.

Medida de textura e tamanho da janela de vizinhança	Distância JM média Banda HH	Ganho da distância JM média (%) Banda HH
Segundo Momento 3	0,46	
Segundo Momento 5	0,52	14,06
Segundo Momento 7	0,61	16,96
Segundo Momento 9	0,67	10,50
Segundo Momento 11	0,72	6,92
<b>Segundo Momento 13</b>	<b>0,75</b>	<b>4,27</b>
Segundo Momento 15	0,77	2,53
Segundo Momento 17	0,78	1,66
Segundo Momento 19	0,79	1,00
Segundo Momento 21	0,79	0,57
Segundo Momento 23	0,79	0,16
Segundo Momento 25	0,76	-4,59
Segundo Momento 27	0,79	4,35
Segundo Momento 29	0,79	-0,36
Segundo Momento 31	0,78	-0,46

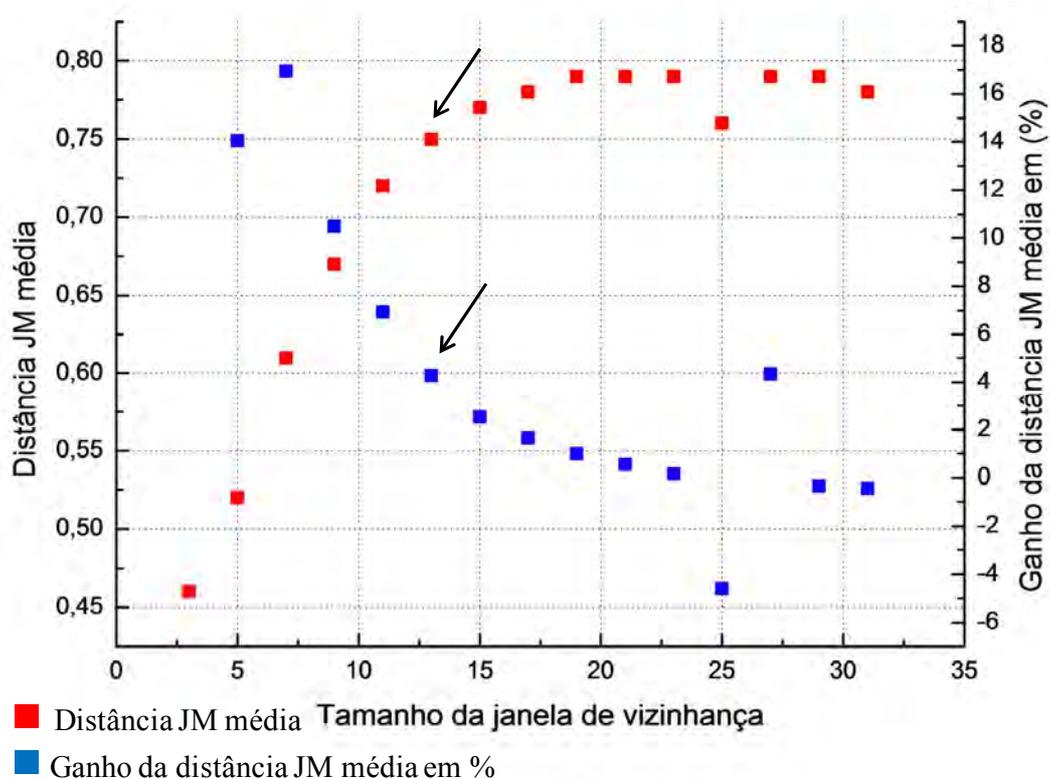


Figura B.15. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Segundo Momento, banda HH.

Tabela B.16. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Segundo Momento, banda HV.

Medida de textura e tamanho da janela de vizinhança	Distância JM média Banda HV	Ganho da distância JM média (%) Banda HV
Segundo Momento 3	0,56	
Segundo Momento 5	0,80	42,86
Segundo Momento 7	0,88	10,00
Segundo Momento 9	0,94	6,82
<b>Segundo Momento 11</b>	<b>0,98</b>	<b>4,26</b>
Segundo Momento 13	1,00	2,04
Segundo Momento 15	1,01	1,00
Segundo Momento 17	1,02	0,99
Segundo Momento 19	1,02	0,00
Segundo Momento 21	1,02	0,00
Segundo Momento 23	1,02	0,00
Segundo Momento 25	1,02	0,00
Segundo Momento 27	1,02	0,00
Segundo Momento 29	1,01	-0,98
Segundo Momento 31	1,00	-0,99

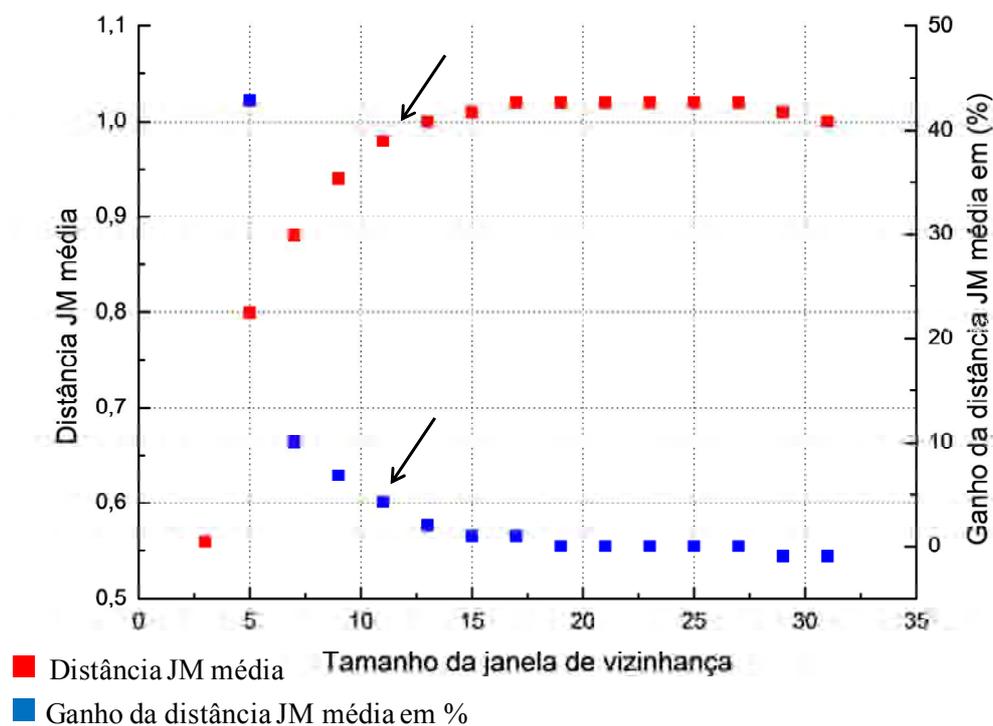


Figura B.16. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Segundo Momento, banda HV.

Tabela B.17. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Variância, banda HH.

Medida de textura e tamanho da janela de vizinhança	Distância JM média Banda HH	Ganho da distância JM média (%) Banda HH
Variância 3	0,41	
Variância 5	0,50	19,87
Variância 7	0,57	14,19
Variância 9	0,61	7,38
<b>Variância 11</b>	<b>0,62</b>	<b>2,21</b>
Variância 13	0,62	-0,49
Variância 15	0,62	-0,41
Variância 17	0,61	-0,90
Variância 19	0,57	-6,95
Variância 21	0,56	-0,66
Variância 23	0,56	-0,44
Variância 25	0,56	-0,53
Variância 27	0,56	-0,46
Variância 29	0,55	-0,71
Variância 31	0,55	-0,90

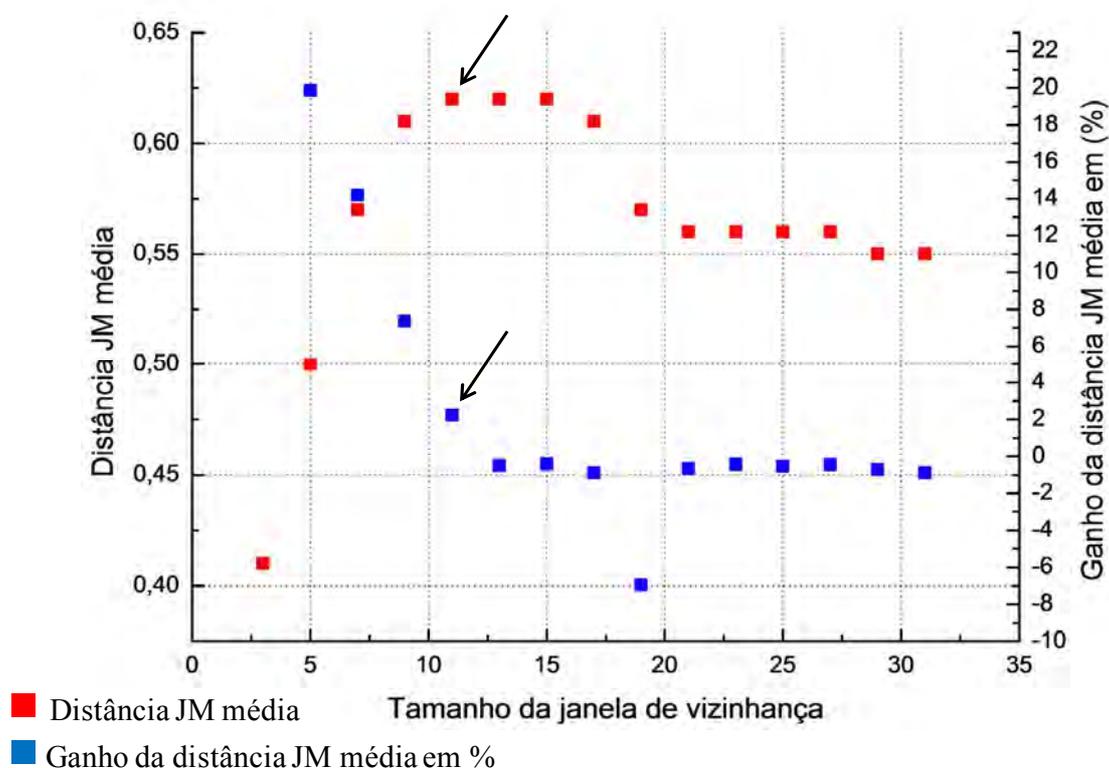


Figura B.17. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Variância, banda HH.

Tabela B.18. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Variância, banda HV.

Medida de textura e tamanho da janela de vizinhança	Distância JM média Banda HV	Ganho da distância JM média (%) Banda HV
Variância 3	0,68	
Variância 5	0,75	10,16
<b>Variância 7</b>	<b>0,79</b>	<b>4,23</b>
Variância 9	0,79	0,40
Variância 11	0,77	-2,03
Variância 13	0,75	-2,86
Variância 15	0,73	-2,63
Variância 17	0,71	-2,49
Variância 19	0,69	-2,55
Variância 21	0,68	-2,46
Variância 23	0,66	-2,32
Variância 25	0,65	-2,04
Variância 27	0,64	-1,73
Variância 29	0,63	-1,62
Variância 31	0,62	-1,59

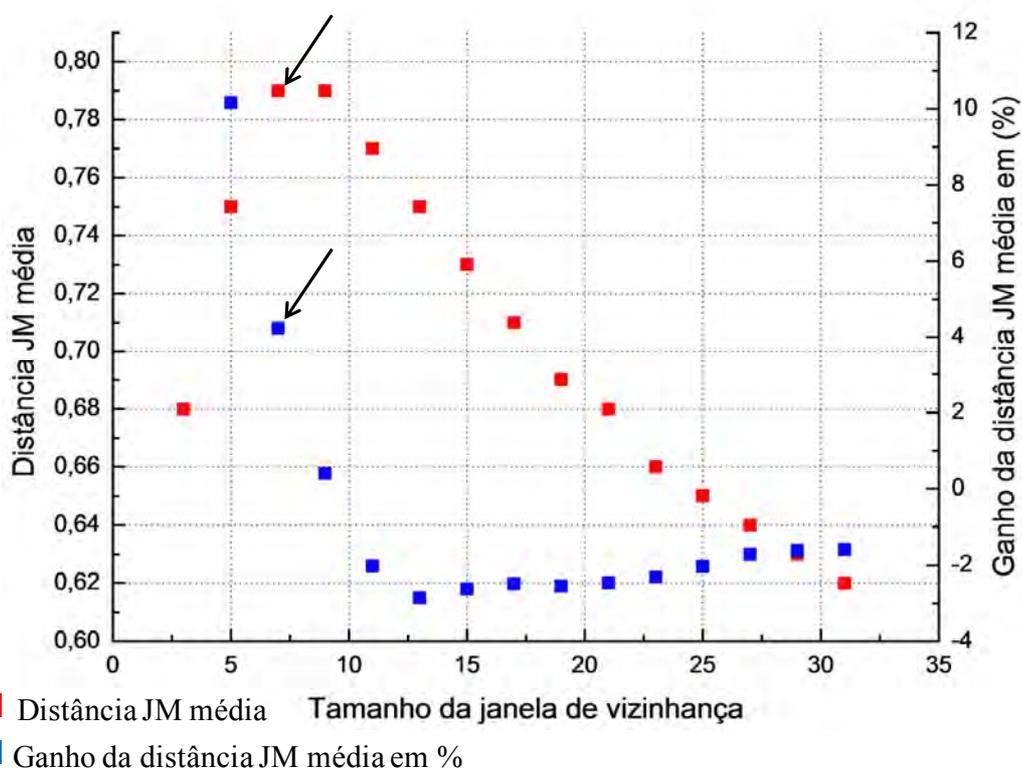


Figura B.18. Distância JM média e respectivos ganhos para diferentes tamanhos de janela para a medida de textura Variância, banda HV.



## **APÊNDICE C - MATRIZ DE CORRELAÇÃO DOS ATRIBUTOS ÓPTICOS E SAR**

Neste Apêndice é mostrada a matriz de correlação dos atributos ópticos e SAR descritos na Tabela 4.1 a exceção das bandas HH e HV e suas respectivas bandas  $\sigma^0$ . Nota-se que a correlação entre os pares de atributos foi calculada utilizando toda a cena dos atributos.

Apêndice C - Matriz de correlação dos atributos ópticos e SAR

Atributos	MED 7_HV	NL	PC:HH_HV	MED 9_HH	HOM_11_HV	SM_11_HV	DIS_11_HV	ENT_9_HV	CON_11_HV	COR 9_HH	COR_11_HV	HOM_15_HH	HV:HH	DIS_15_HH	VAR 7_HV	ENT_13_HH	CON_13_HH	SM_13_HH	VAR_11_HH	CV_19_HH	CV_19_HV	PC:TM	B5	B2	IMF_SL	B3	IMF_SM	B7	B1	IMF_VEG	B4	GEMI	NDVI	
MED 7_HV	1	0.94	0.88	0.82	-0.74	-0.73	0.86	0.83	0.79	-0.36	-0.48	-0.28	0.70	0.63	0.58	0.60	0.43	-0.54	0.21	-0.21	-0.32	0.74	-0.71	-0.75	-0.72	-0.69	0.70	-0.69	-0.66	-0.19	-0.34	0.00	0.63	
NL	0.94	1	0.96	0.80	-0.79	-0.74	0.79	0.72	0.74	-0.37	-0.47	-0.42	0.63	0.58	0.57	0.55	0.42	-0.60	0.23	-0.23	-0.34	0.72	-0.70	-0.74	-0.70	-0.68	0.68	-0.68	-0.65	-0.18	-0.33	-0.06	0.57	
PC:HH_HV	0.88	0.96	1	0.87	-0.73	-0.69	0.74	0.67	0.69	-0.38	-0.45	-0.44	0.44	0.63	0.54	0.59	0.52	-0.62	0.33	-0.20	-0.31	0.66	-0.64	-0.67	-0.64	-0.61	0.63	-0.62	-0.59	-0.17	-0.30	-0.06	0.52	
MED 9_HH	0.82	0.80	0.87	1	-0.58	-0.62	0.74	0.76	0.67	-0.37	-0.43	-0.26	0.31	0.77	0.46	0.73	0.64	-0.58	0.44	-0.12	-0.23	0.58	-0.56	-0.58	-0.56	-0.53	0.55	-0.54	-0.51	-0.15	-0.27	0.04	0.53	
HOM_11_HV	-0.74	-0.79	-0.73	-0.58	1	0.84	-0.77	-0.62	-0.73	0.40	0.52	0.61	-0.60	-0.44	-0.49	-0.39	-0.32	0.65	-0.16	0.31	0.37	-0.70	0.69	0.71	0.69	0.66	-0.66	0.67	0.63	0.16	0.30	0.09	-0.53	
SM_11_HV	-0.73	-0.74	-0.69	-0.62	0.84	1	-0.72	-0.76	-0.63	0.53	0.67	0.45	-0.55	-0.51	-0.45	-0.52	-0.35	0.68	-0.20	0.21	0.23	-0.69	0.68	0.68	0.72	0.68	-0.59	0.70	0.64	0.01	0.17	-0.07	-0.61	
DIS_11_HV	0.86	0.79	0.74	0.74	-0.77	-0.72	1	0.87	0.96	-0.35	-0.54	-0.20	0.59	0.65	0.65	0.66	0.46	-0.53	0.27	-0.07	-0.14	0.68	-0.66	-0.69	-0.65	-0.62	0.66	-0.63	-0.60	-0.22	-0.35	-0.02	0.57	
ENT 9_HV	0.83	0.72	0.67	0.76	-0.62	-0.76	0.87	1	0.77	-0.39	-0.58	-0.07	0.54	0.66	0.61	0.71	0.45	-0.52	0.29	0.00	-0.05	0.62	-0.61	-0.63	-0.62	-0.59	0.58	-0.60	-0.56	-0.11	-0.24	0.09	0.58	
CON_11_HV	0.79	0.74	0.69	0.67	-0.73	-0.63	0.96	0.77	1	-0.30	-0.49	-0.25	0.55	0.58	0.70	0.59	0.44	-0.50	0.29	-0.01	-0.08	0.65	-0.61	-0.63	-0.58	-0.56	0.62	-0.56	-0.54	-0.25	-0.37	-0.10	0.47	
COR 9_HH	-0.36	-0.37	-0.38	-0.37	0.40	0.53	-0.35	-0.39	-0.30	1	0.38	0.25	-0.21	-0.33	-0.23	-0.36	-0.25	0.43	-0.19	0.01	0.04	-0.33	0.33	0.33	0.35	0.33	-0.29	0.34	0.31	0.00	0.08	-0.01	-0.28	
COR_11_HV	-0.48	-0.47	-0.45	-0.43	0.52	0.67	-0.54	-0.58	-0.49	0.38	1	0.21	-0.34	-0.36	-0.40	-0.40	-0.27	0.41	-0.20	0.01	0.00	-0.45	0.45	0.44	0.47	0.45	-0.38	0.48	0.43	-0.02	0.09	-0.07	-0.41	
HOM_15_HH	-0.28	-0.42	-0.44	-0.26	0.61	0.45	-0.20	-0.07	-0.25	0.25	0.21	1	-0.22	-0.24	-0.20	-0.14	-0.30	0.66	-0.21	0.29	0.36	-0.35	0.34	0.34	0.33	0.30	-0.35	0.31	0.29	0.14	0.20	0.21	-0.15	
HV:HH	0.70	0.63	0.44	0.31	-0.60	-0.55	0.59	0.54	0.55	-0.21	-0.34	-0.22	1	0.27	0.41	0.25	0.11	-0.31	-0.02	-0.18	-0.26	0.59	-0.57	-0.60	-0.58	-0.56	0.55	-0.56	-0.53	-0.11	-0.23	-0.04	0.47	
DIS_15_HH	0.63	0.58	0.63	0.77	-0.44	-0.51	0.65	0.66	0.58	-0.33	-0.36	-0.24	0.27	1	0.41	0.89	0.83	-0.67	0.56	0.14	-0.03	0.46	-0.45	-0.45	-0.43	-0.39	0.47	-0.41	-0.39	-0.19	-0.27	0.00	0.40	
VAR 7_HV	0.58	0.57	0.54	0.46	-0.49	-0.45	0.65	0.61	0.70	-0.23	-0.40	-0.20	0.41	0.41	1	0.49	0.34	-0.43	0.37	0.19	0.16	0.42	-0.41	-0.41	-0.38	-0.36	0.43	-0.37	-0.35	-0.19	-0.26	-0.19	0.23	
ENT_13_HH	0.60	0.55	0.59	0.73	-0.39	-0.52	0.66	0.71	0.59	-0.36	-0.40	-0.14	0.25	0.89	0.49	1	0.76	-0.71	0.63	0.30	0.15	0.42	-0.42	-0.41	-0.39	-0.36	0.43	-0.38	-0.35	-0.19	-0.26	-0.02	0.35	
CON_13_HH	0.43	0.42	0.52	0.64	-0.32	-0.35	0.46	0.45	0.44	-0.25	-0.27	-0.30	0.11	0.83	0.34	0.76	1	-0.55	0.80	0.24	0.03	0.30	-0.30	-0.29	-0.28	-0.24	0.32	-0.27	-0.24	-0.16	-0.21	-0.05	0.23	
SM_13_HH	-0.54	-0.60	-0.62	-0.58	0.65	0.68	-0.53	-0.52	-0.50	0.43	0.41	0.66	-0.31	-0.67	-0.43	-0.71	-0.55	1	-0.45	-0.01	0.08	-0.47	0.47	0.46	0.46	0.42	-0.47	0.44	0.40	0.16	0.24	0.13	-0.31	
VAR_11_HH	0.21	0.23	0.33	0.44	-0.16	-0.20	0.27	0.29	0.29	-0.19	-0.20	-0.21	-0.02	0.56	0.37	0.63	0.80	-0.45	1	0.45	0.25	0.14	-0.14	-0.11	-0.11	-0.08	0.16	-0.11	-0.09	-0.12	-0.13	-0.12	0.03	
CV_19_HH	-0.21	-0.23	-0.20	-0.12	0.31	0.21	-0.07	0.00	-0.01	0.01	0.01	0.29	-0.18	0.14	0.19	0.30	0.24	-0.01	0.45	1	0.85	-0.21	0.20	0.24	0.24	0.25	-0.16	0.23	0.23	-0.05	0.01	-0.23	-0.35	
CV_19_HV	-0.32	-0.34	-0.31	-0.23	0.37	0.23	-0.14	-0.05	-0.08	0.04	0.00	0.36	-0.26	-0.03	0.16	0.15	0.03	0.08	0.25	0.85	1	-0.32	0.30	0.34	0.33	0.33	-0.28	0.32	0.31	0.01	0.09	-0.17	-0.40	
PC:TM	0.74	0.72	0.66	0.58	-0.70	-0.69	0.68	0.62	0.63	-0.33	-0.45	-0.35	0.59	0.46	0.42	0.30	-0.47	0.14	-0.21	-0.32	1	-0.98	-0.94	-0.94	-0.92	-0.94	-0.94	-0.89	-0.29	-0.49	-0.15	0.73		
B5	-0.71	-0.70	-0.64	-0.56	0.69	0.68	-0.66	-0.61	-0.61	0.33	0.45	0.34	-0.57	-0.45	-0.41	-0.42	-0.30	0.47	-0.14	0.20	0.30	-0.98	1	0.90	0.96	0.88	-0.93	0.95	0.88	0.88	0.25	0.45	0.13	-0.71
B2	-0.75	-0.74	-0.67	-0.58	0.71	0.68	-0.69	-0.63	-0.63	0.33	0.44	0.34	-0.60	-0.45	-0.41	-0.41	-0.29	0.46	-0.11	0.24	0.34	-0.94	0.90	1	0.88	0.93	-0.85	0.88	0.89	0.21	0.40	0.08	-0.75	
IMF_SL	-0.72	-0.70	-0.64	-0.56	0.69	0.72	-0.65	-0.62	-0.58	0.35	0.47	0.33	-0.58	-0.43	-0.38	-0.39	-0.28	0.46	-0.11	0.24	0.33	-0.94	0.96	0.88	1	0.93	-0.82	0.97	0.86	-0.01	0.21	-0.04	-0.78	
B3	-0.69	-0.68	-0.61	-0.53	0.66	0.68	-0.62	-0.59	-0.56	0.33	0.45	0.30	-0.56	-0.39	-0.36	-0.36	-0.24	0.42	-0.08	0.25	0.33	-0.92	0.88	0.93	0.93	1	-0.75	0.92	0.91	-0.03	0.19	-0.07	-0.83	
IMF_SM	0.70	0.68	0.63	0.55	-0.66	-0.59	0.66	0.58	0.62	-0.29	-0.38	-0.35	0.55	0.47	0.43	0.43	0.32	-0.47	0.16	-0.16	-0.28	0.94	-0.93	-0.85	-0.82	-0.75	1	-0.81	-0.74	-0.57	-0.73	-0.34	0.56	
B7	-0.69	-0.68	-0.62	-0.54	0.67	0.70	-0.63	-0.60	-0.56	0.34	0.48	0.31	-0.56	-0.41	-0.37	-0.38	-0.27	0.44	-0.11	0.23	0.32	-0.94	0.95	0.88	0.97	0.92	-0.81	1	0.86	0.02	0.24	-0.02	-0.77	
B1	-0.66	-0.65	-0.59	-0.51	0.63	0.64	-0.60	-0.56	-0.54	0.31	0.43	0.29	-0.53	-0.39	-0.35	-0.35	-0.24	0.40	-0.09	0.23	0.31	-0.89	0.85	0.89	0.86	0.91	-0.74	0.86	1	0.06	0.24	-0.03	-0.75	
IMF_VEG	-0.19	-0.18	-0.17	-0.15	0.16	0.01	-0.22	-0.11	-0.25	0.00	-0.02	0.14	-0.11	-0.19	-0.19	-0.19	-0.16	0.16	-0.12	-0.05	0.01	-0.29	0.25	0.21	-0.01	-0.03	-0.57	0.02	0.06	1	0.97	0.64	0.14	
B4	-0.34	-0.33	-0.30	-0.27	0.30	0.17	-0.35	-0.24	-0.37	0.08	0.09	0.20	-0.23	-0.27	-0.26	-0.26	-0.21	0.24	-0.13	0.01	0.09	-0.49	0.45	0.40	0.21	0.19	-0.73	0.24	0.24	0.97	1	0.61	-0.04	
GEMI	0.00	-0.06	-0.06	0.04	0.09	-0.07	-0.02	0.09	-0.10	-0.01	-0.07	0.21	-0.04	0.00	-0.19	-0.02	-0.05	0.13	-0.12	-0.23	-0.17	-0.15	0.13	0.08	-0.04	-0.07	-0.34	-0.02	-0.03	0.64	0.61	1	0.50	
NDVI	0.63	0.57	0.52	0.53	-0.53	-0.61	0.57	0.58	0.47	-0.28	-0.41	-0.15	0.47	0.40	0.23	0.35	0.23	-0.31	0.03	-0.35	-0.40	0.73	-0.71	-0.75	-0.78	-0.83	0.56	-0.77	-0.75	0.14	-0.04	0.50	1	

## APÊNDICE D – GRÁFICOS DE MÉDIA E DESVIO PADRÃO DOS ATRIBUTOS SAR E ÓPTICOS

Neste apêndice são mostrados os gráficos de média e desvio padrão dos atributos SAR e ópticos. Os valores médios dos níveis de cinza de todas as classes foram normalizados para facilitar a visualização e a análise dos mesmos. Nos atributos ópticos, os valores médios dos níveis de cinza foram normalizados para o intervalo de 0 a 255. O mesmo foi feito para os atributos SAR, entretanto os valores médios foram normalizados para o intervalo de 0 a 65535. Nestes gráficos são mostrados também, os valores máximos e mínimos dos níveis de cinza de cada atributo antes das normalizações. A organização dos gráficos de média e desvio padrão dos atributos SAR e ópticos seguirão a ordem decrescente dos valores das distâncias JM médias.

### D.1. Gráfico de média e desvio padrão dos atributos SAR

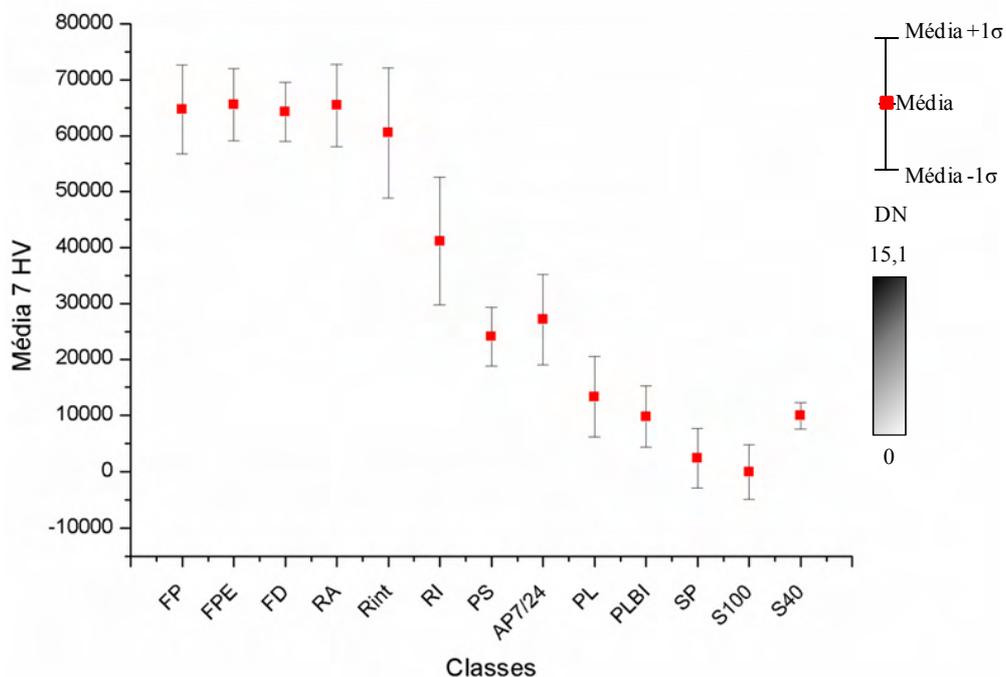


Figura D1.1 - Gráfico de média e desvio padrão da medida de textura Média extraída da banda HV.

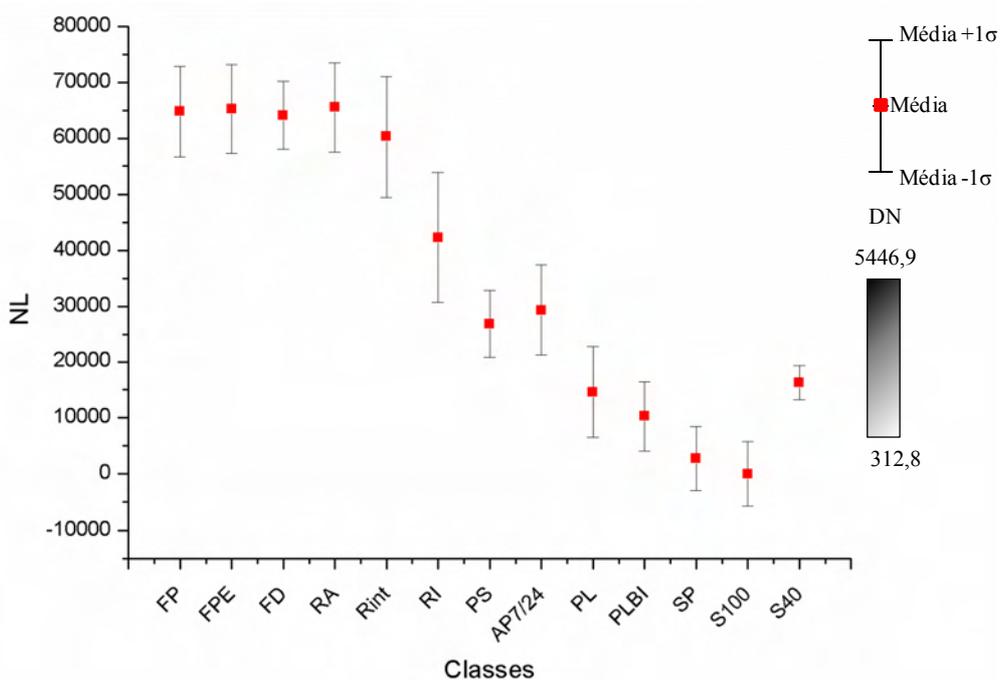


Figura D1.2 - Gráfico de média e desvio padrão do índice NL.

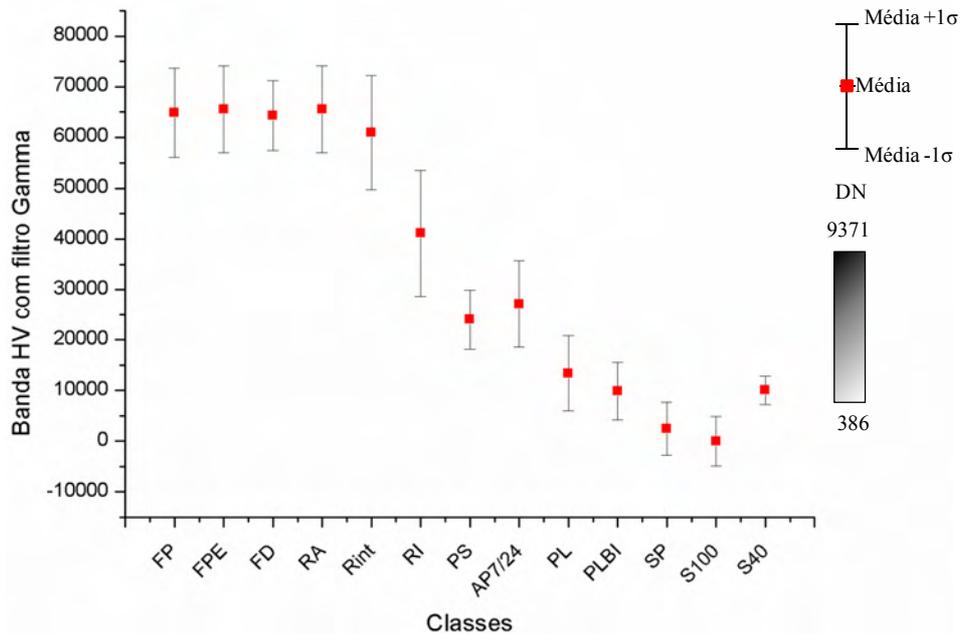


Figura D1.3- Gráfico de média e desvio padrão da banda HV com filtro *Gama*.

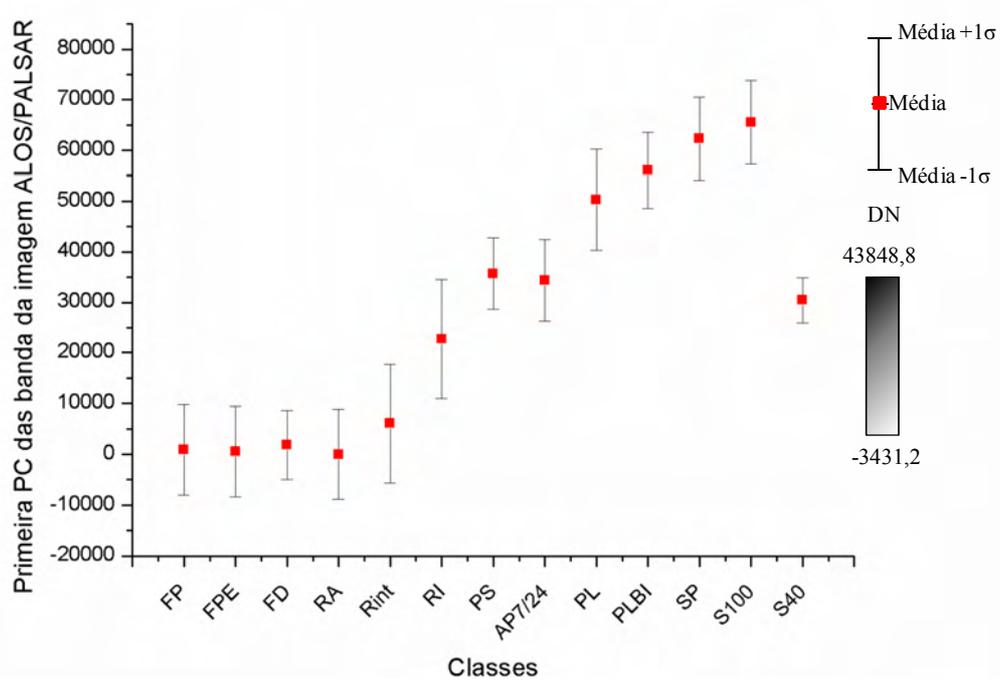


Figura D1.4 - Gráfico de média e desvio padrão da primeira PC das bandas HH e HV.

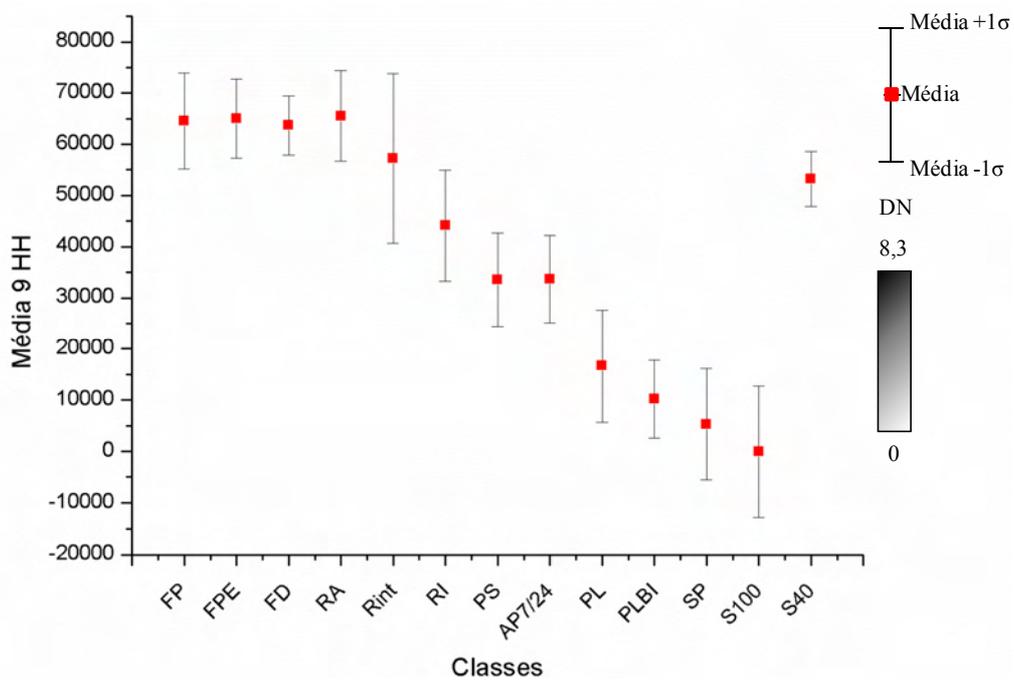


Figura D1.5 - Gráfico de média e desvio padrão da medida de textura Média extraída da banda HH.

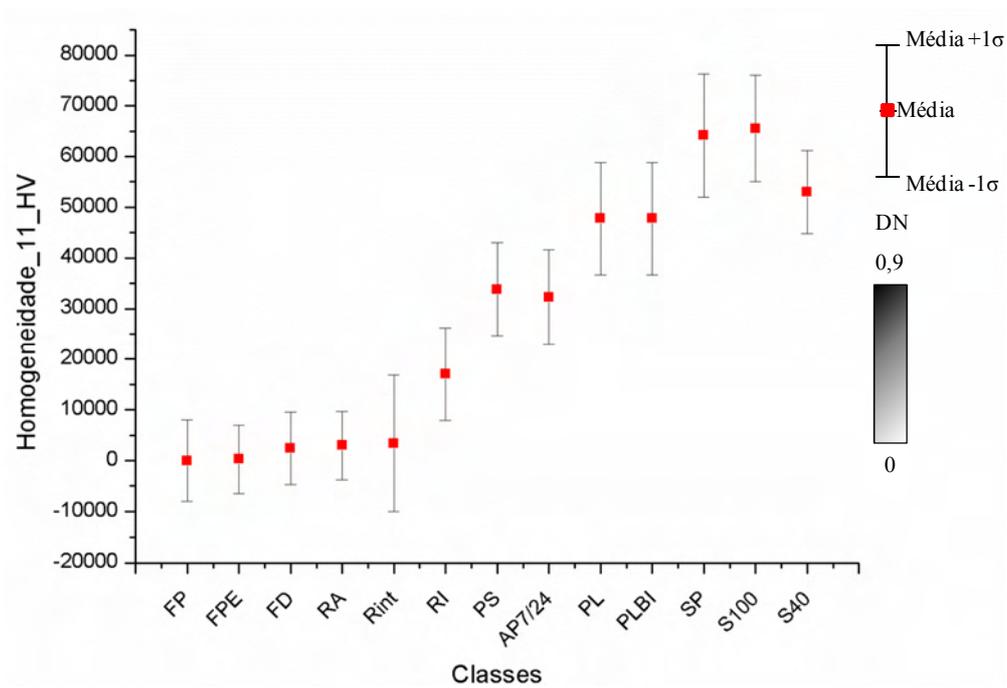


Figura D1.6 - Gráfico de média e desvio padrão da medida de textura Homogeneidade extraída da banda HV.

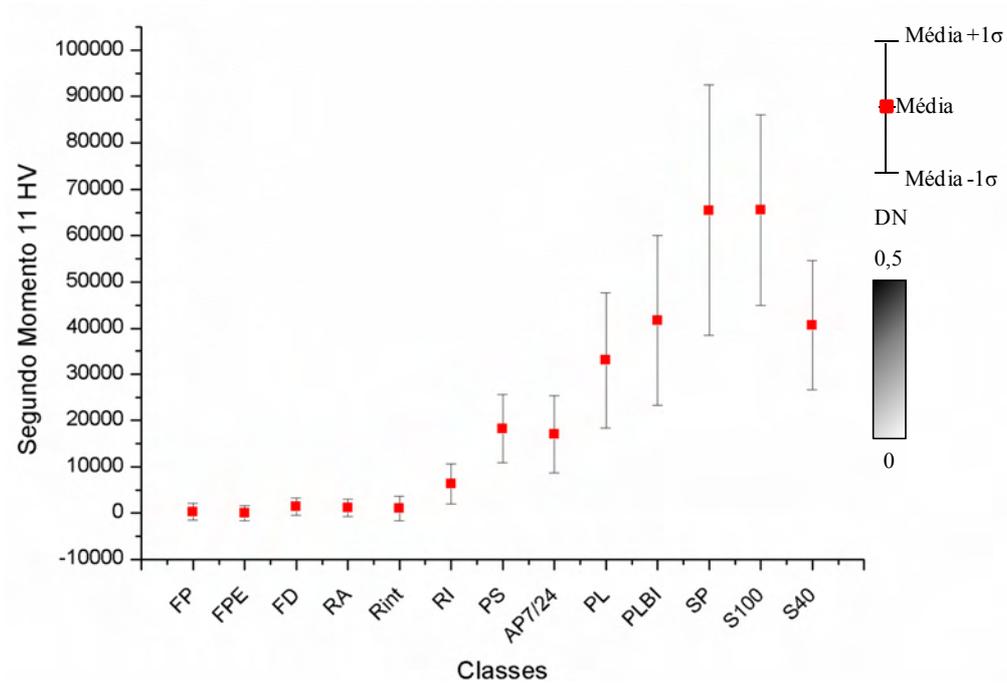


Figura D1.7 - Gráfico de média e desvio padrão da medida de textura Segundo Momento extraída da banda HV.

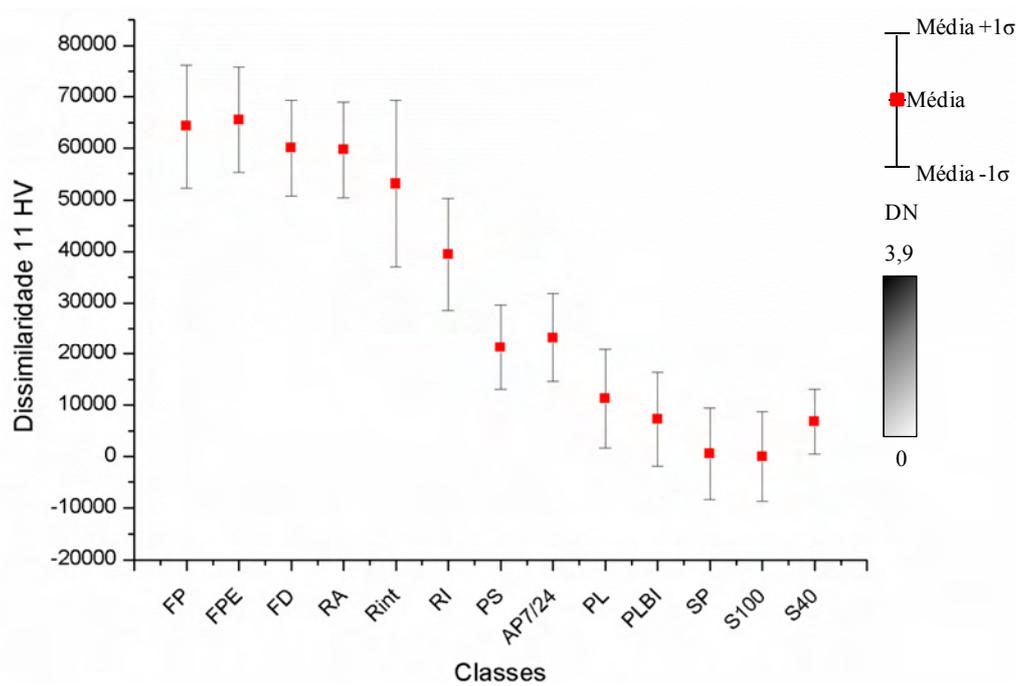


Figura D1.8 - Gráfico de média e desvio padrão da medida de textura Dissimilaridade extraída da banda HV.

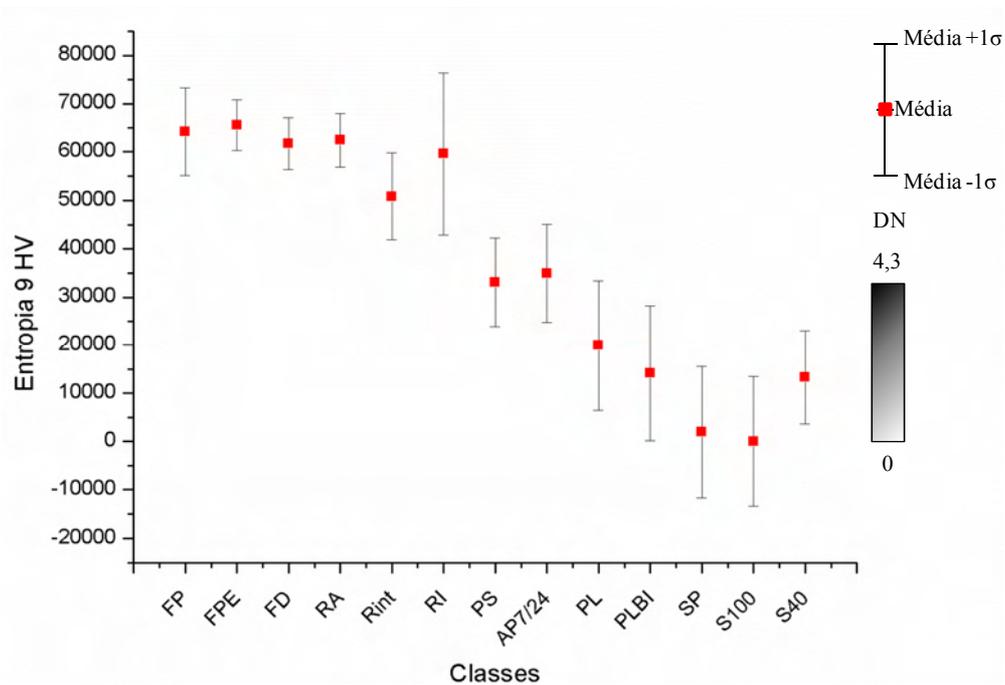


Figura D1.9 - Gráfico de média e desvio padrão da medida de textura Entropia extraída da banda HV.

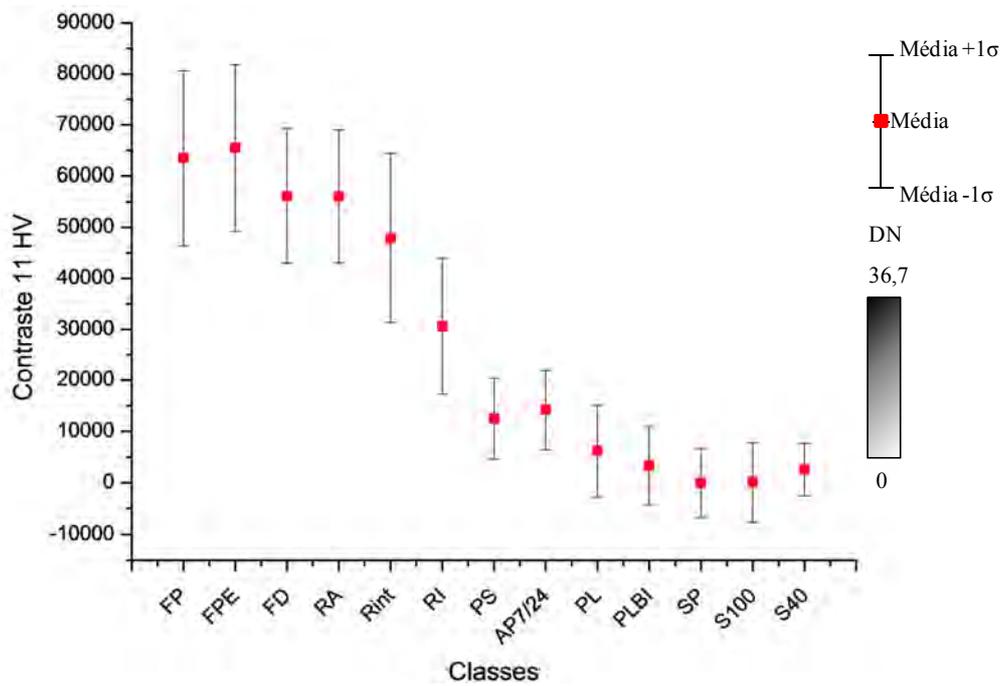


Figura D1.10 - Gráfico de média e desvio padrão da medida de textura Contraste extraída da banda HV.

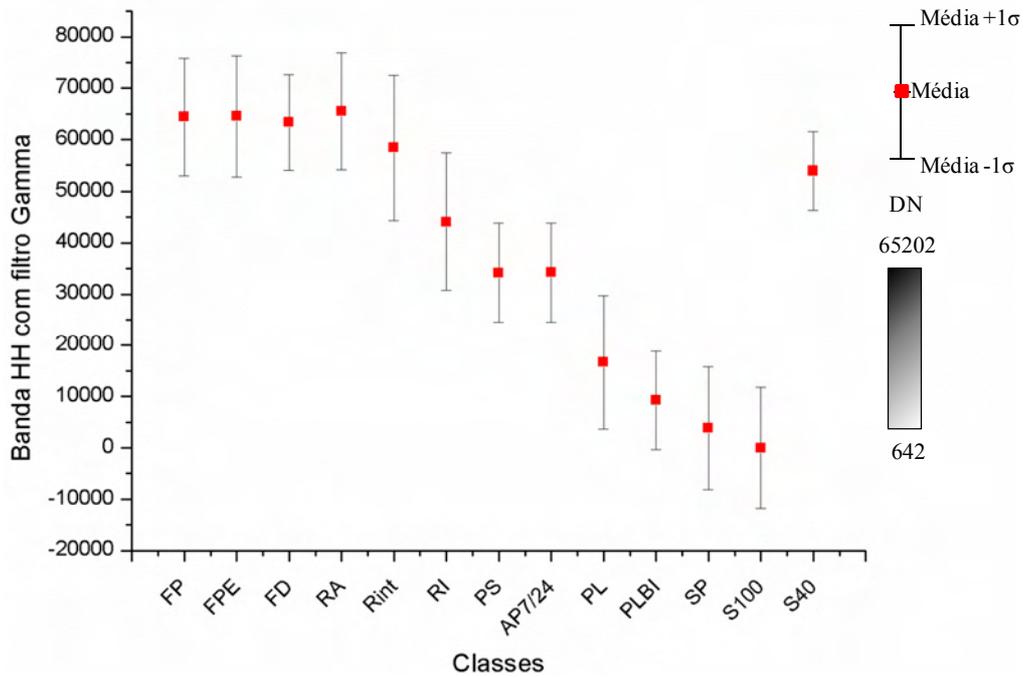


Figura D1.11 - Gráfico de média e desvio padrão da banda HH com filtro *Gama*.

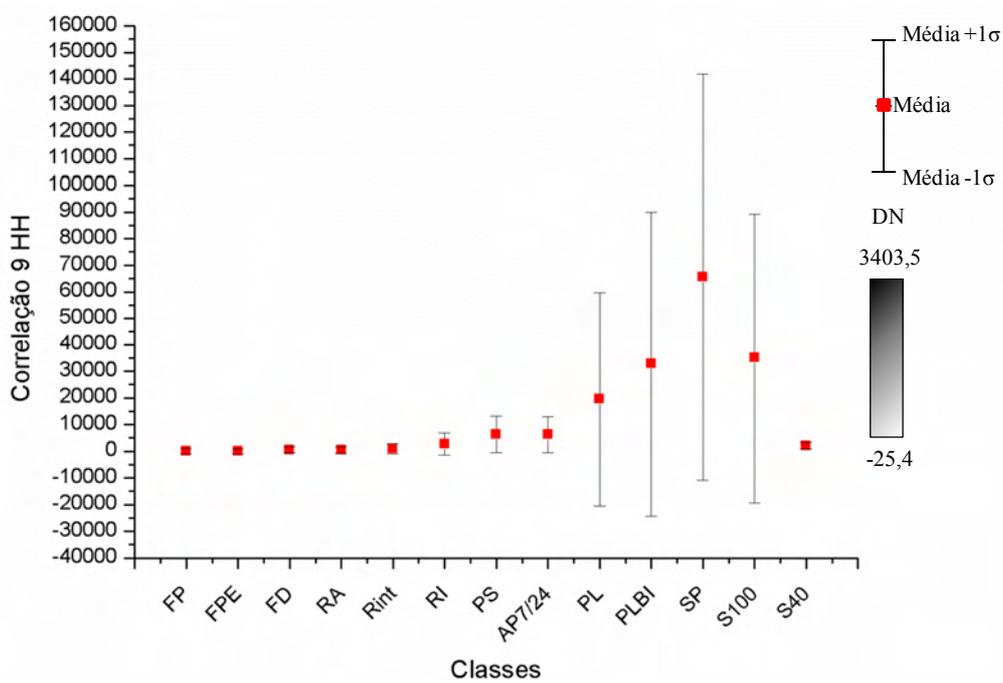


Figura D1.12 - Gráfico de média e desvio padrão da medida de textura Correlação extraída da banda HH.

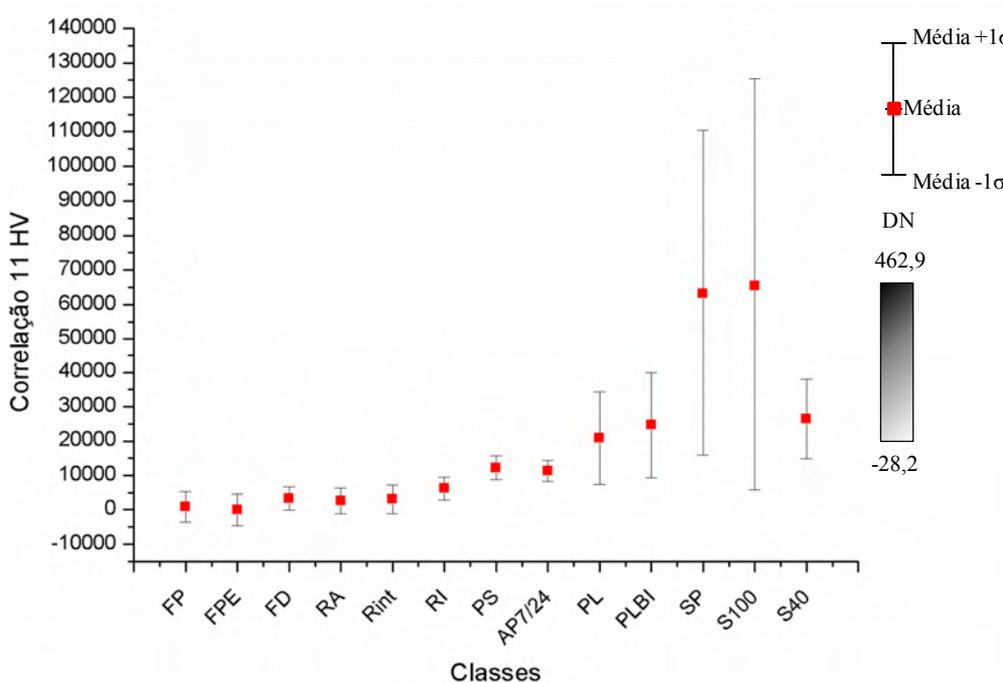


Figura D1.13 - Gráfico de média e desvio padrão da medida de textura Correlação extraída da banda HV.

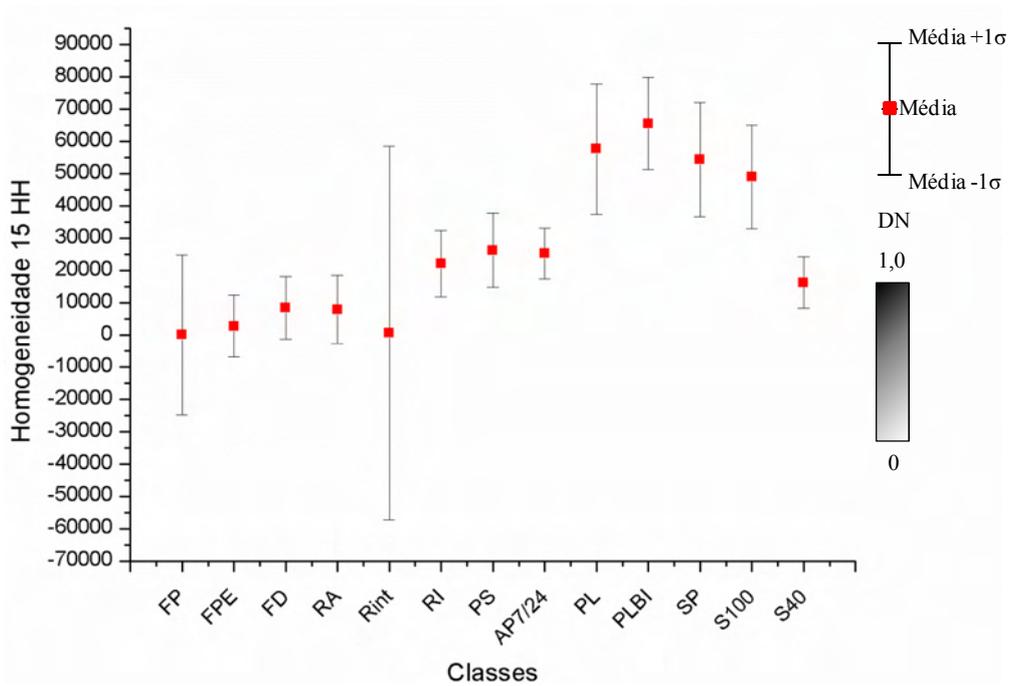


Figura D1.14 - Gráfico de média e desvio padrão da medida de textura Homogeneidade extraída da banda HH.

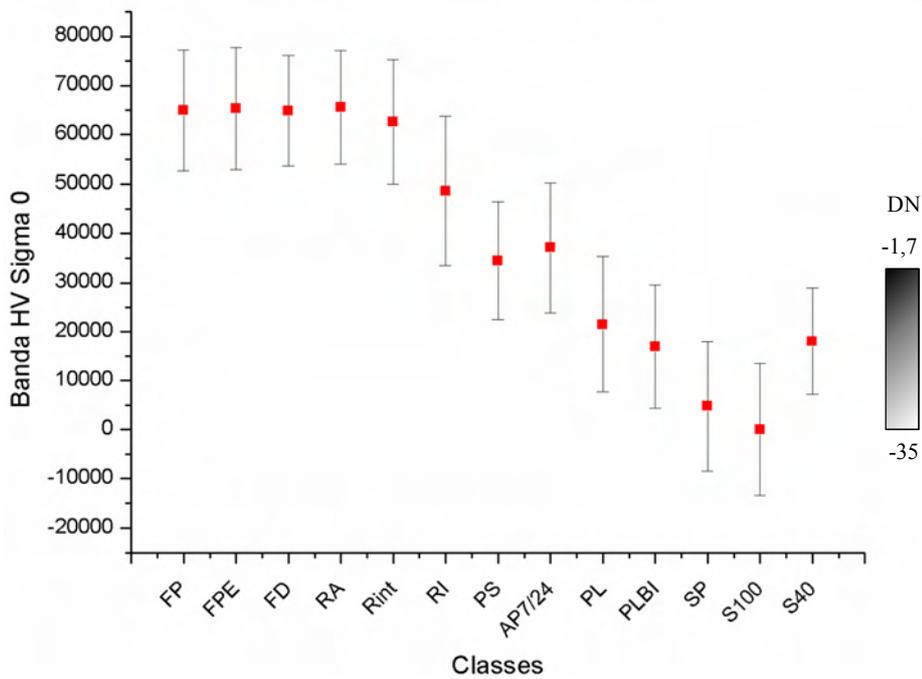


Figura D1.15- Gráfico de média e desvio padrão da banda HV em  $\sigma^0$ .

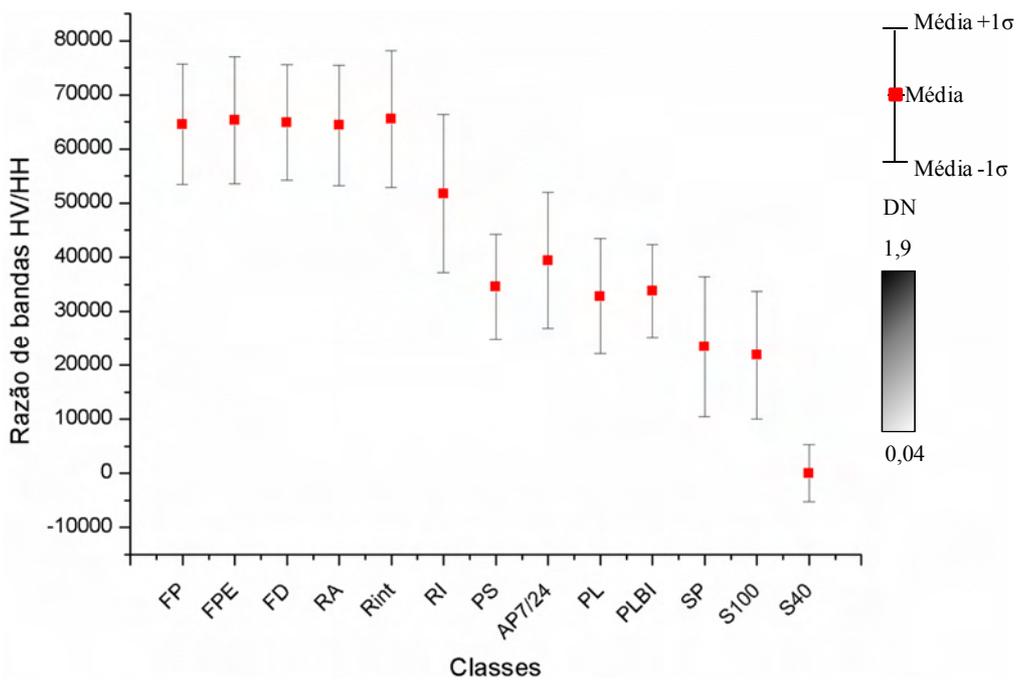


Figura D1.16 - Gráfico de média e desvio padrão da razão de bandas HV/HH.

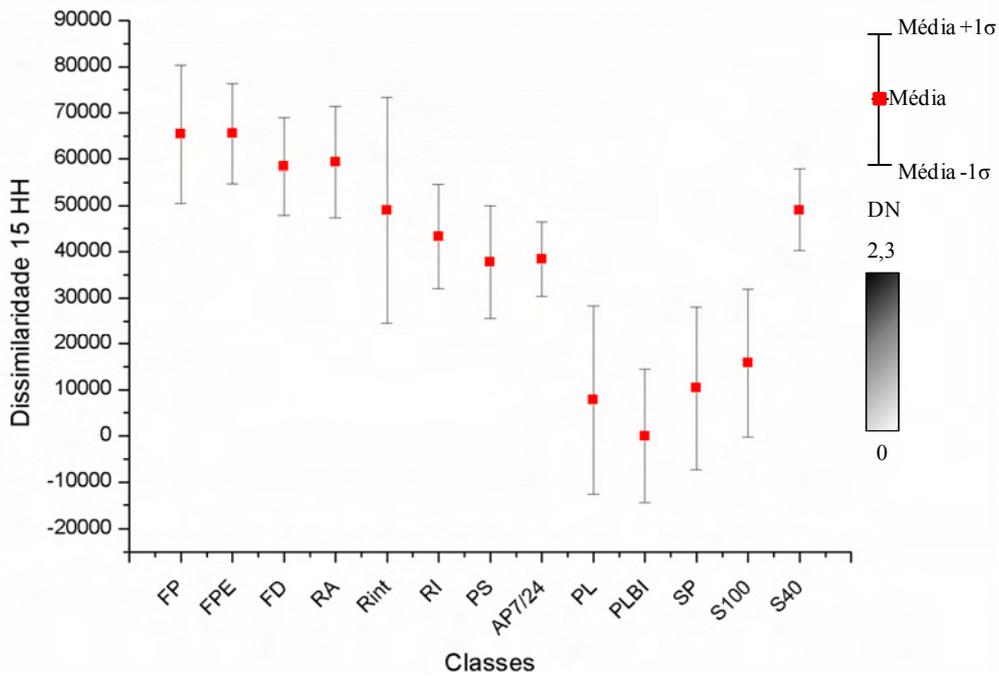


Figura D1.17 - Gráfico de média e desvio padrão da medida de textura Dissimilaridade extraída da banda HH.

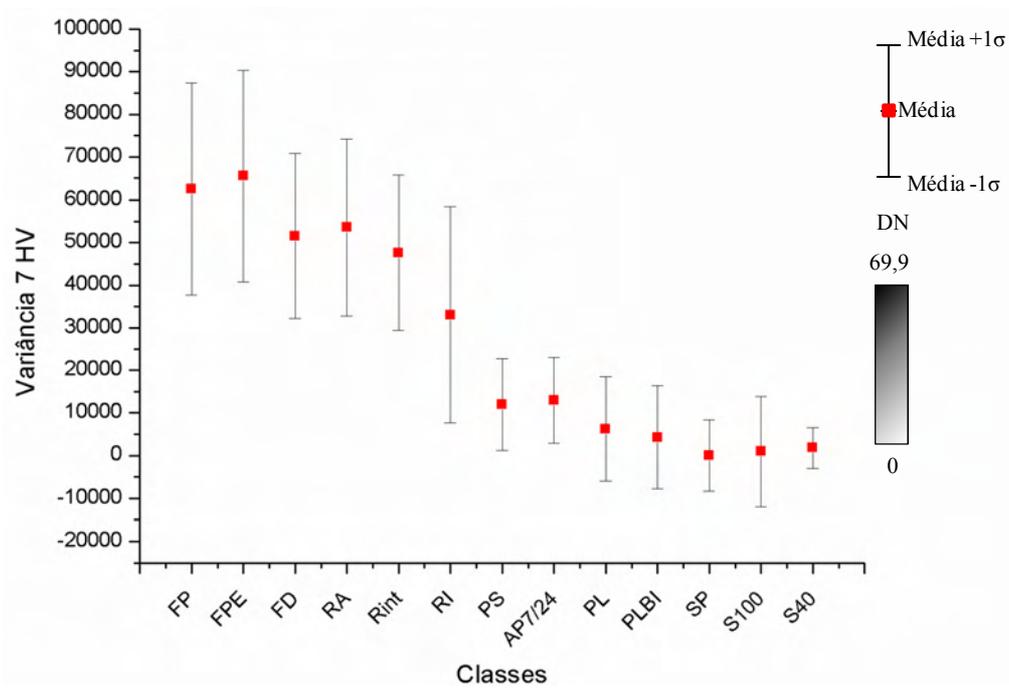


Figura D1.18 - Gráfico de média e desvio padrão da medida de textura Variância extraída da banda HV.

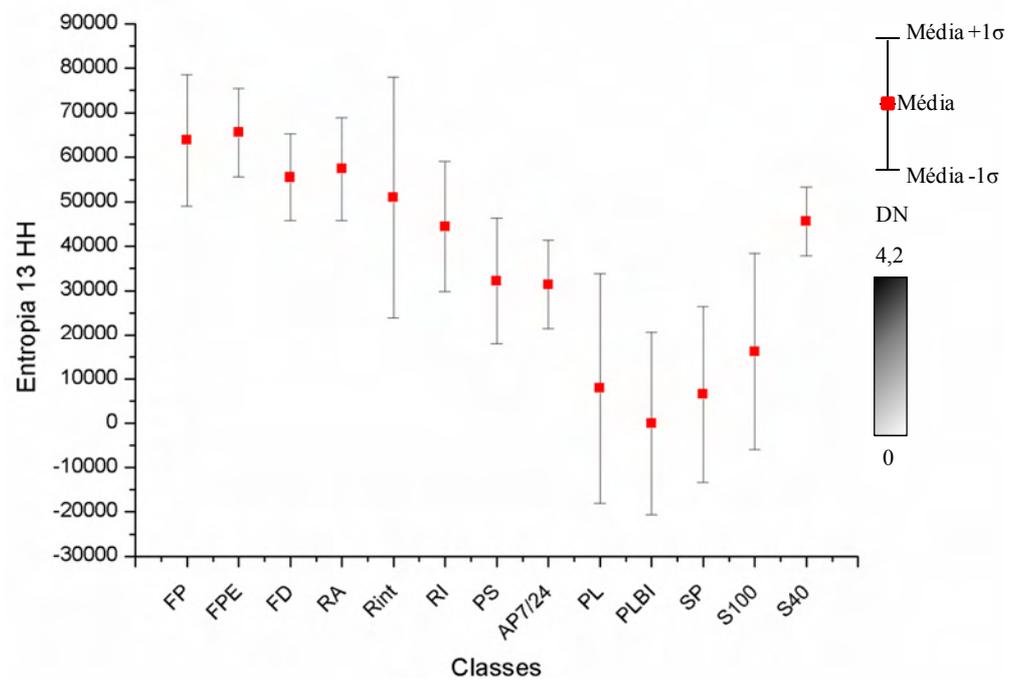


Figura D1.19 - Gráfico de média e desvio padrão da medida de textura Entropia extraída da banda HH.

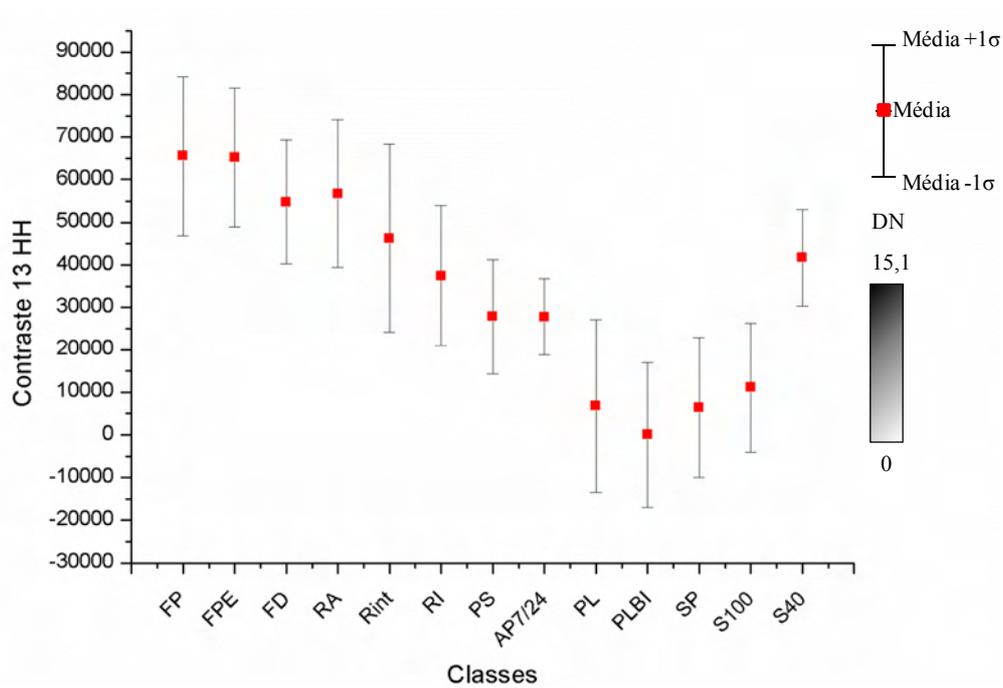


Figura D1.20 - Gráfico de média e desvio padrão da medida de textura Contraste extraída da banda HH.

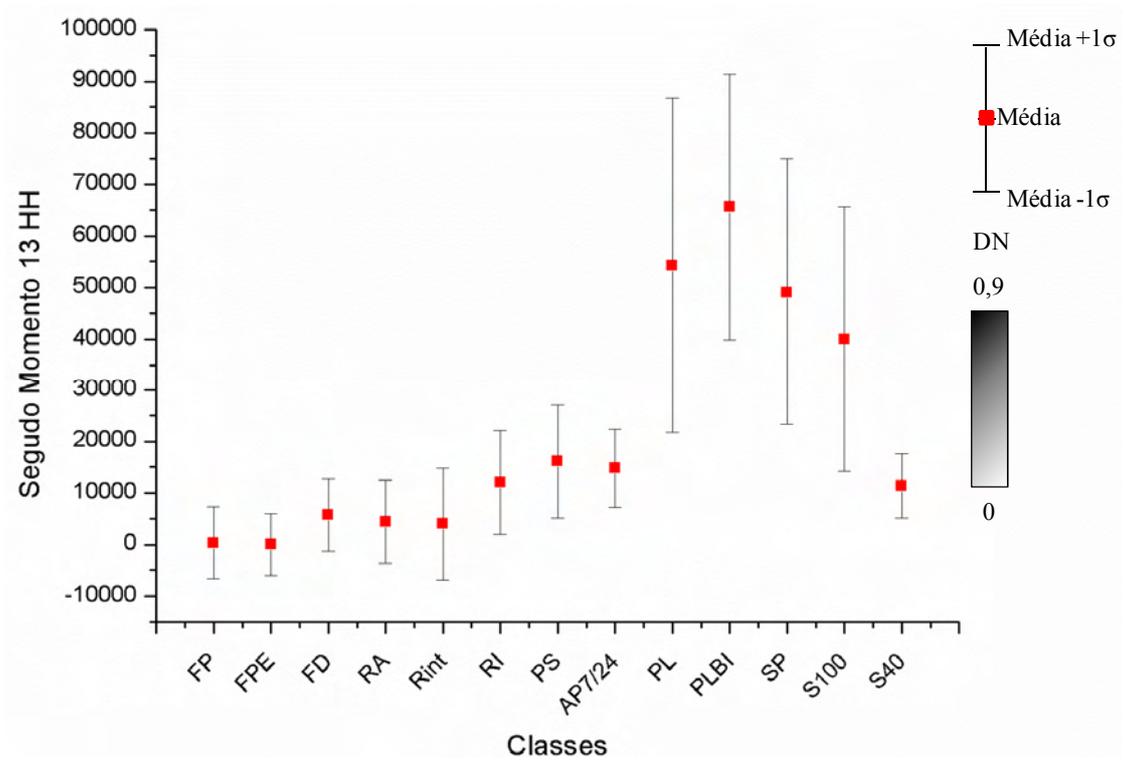


Figura D1.21 - Gráfico de média e desvio padrão da medida de textura Segundo Momento extraída da banda HH.

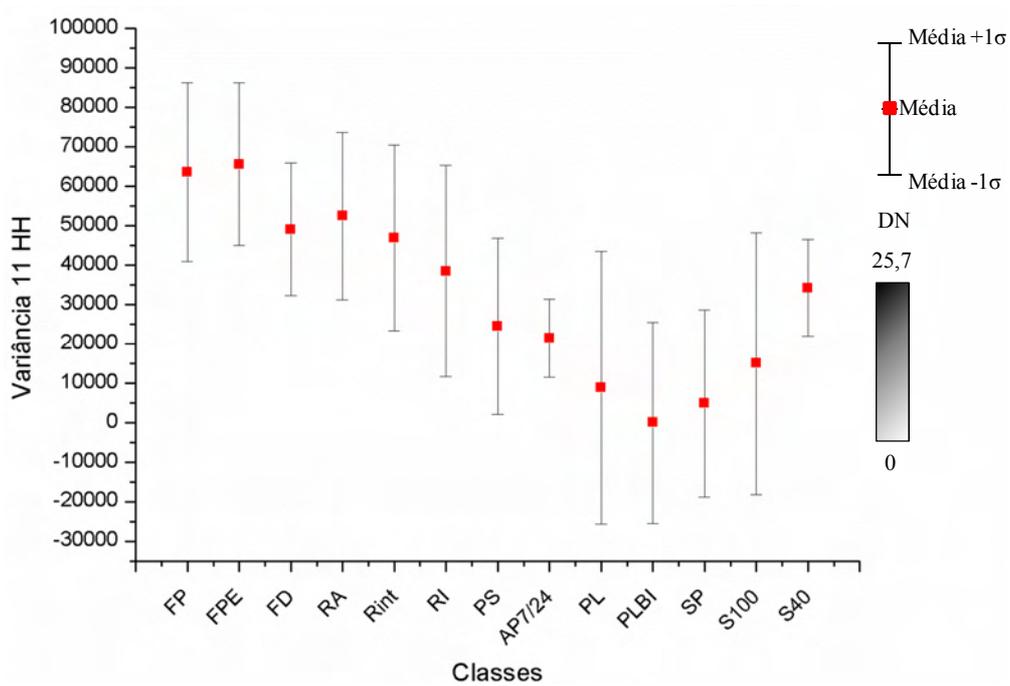


Figura D1.22 - Gráfico de média e desvio padrão da medida de textura Variância extraída da banda HH.

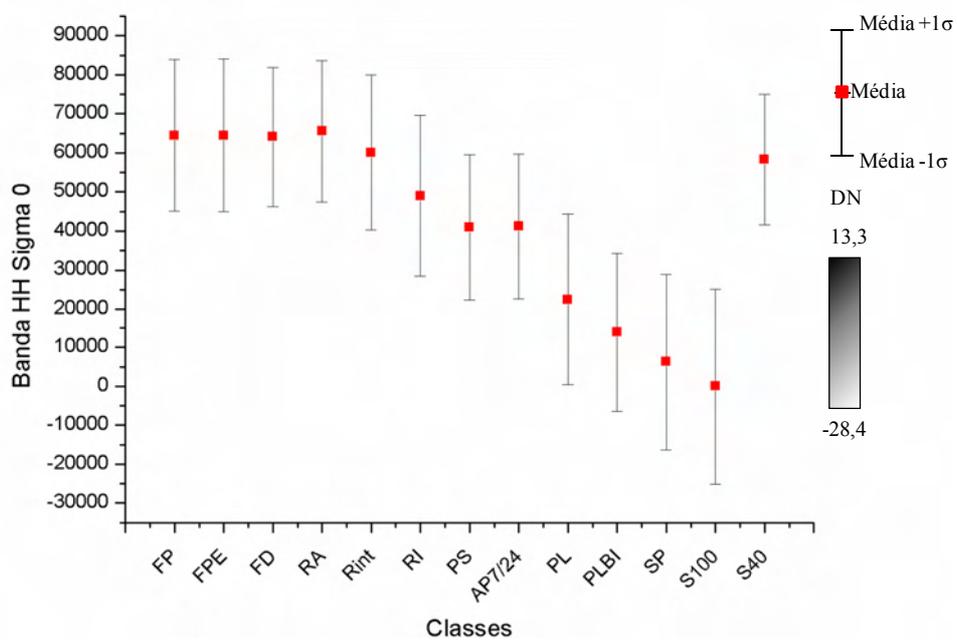


Figura D1.23- Gráfico de média e desvio padrão da banda HH em  $\sigma^0$ .

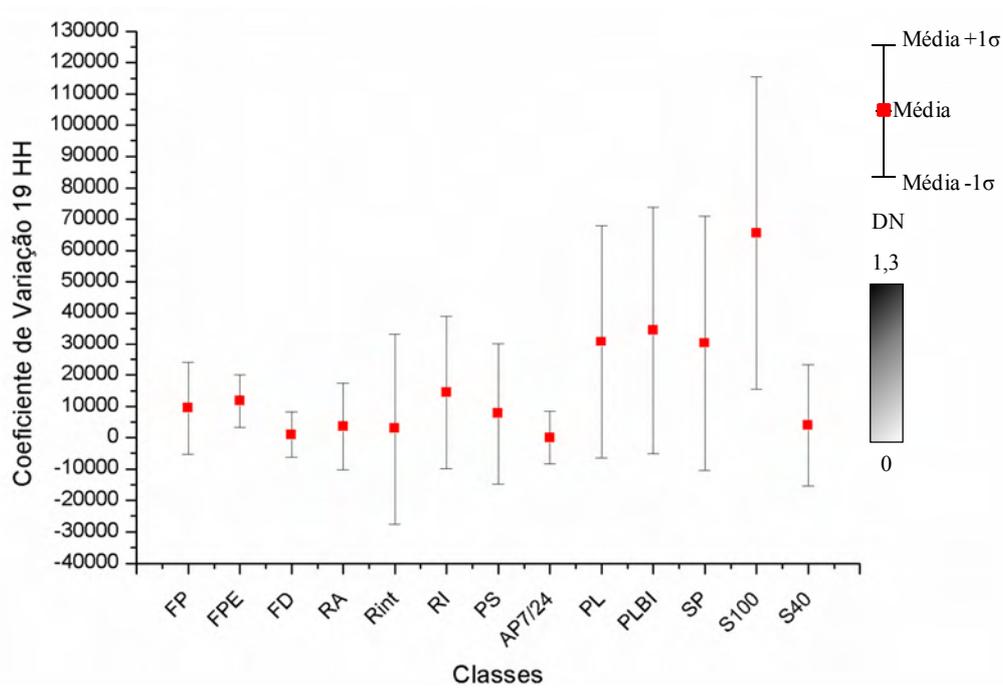


Figura D1.24 - Gráfico de média e desvio padrão da medida de textura Coeficiente de Variação extraída da banda HH.

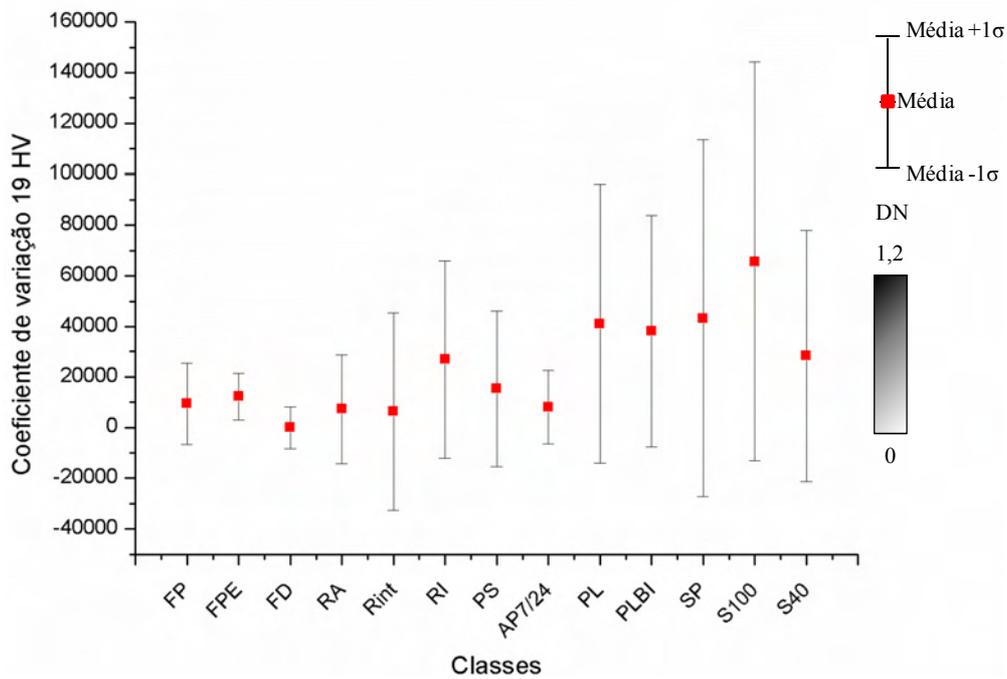


Figura D1.25 - Gráfico de média e desvio padrão da medida de textura Coeficiente de Variação extraída da banda HV.

## D.2. Gráfico de média e desvio padrão dos atributos ópticos

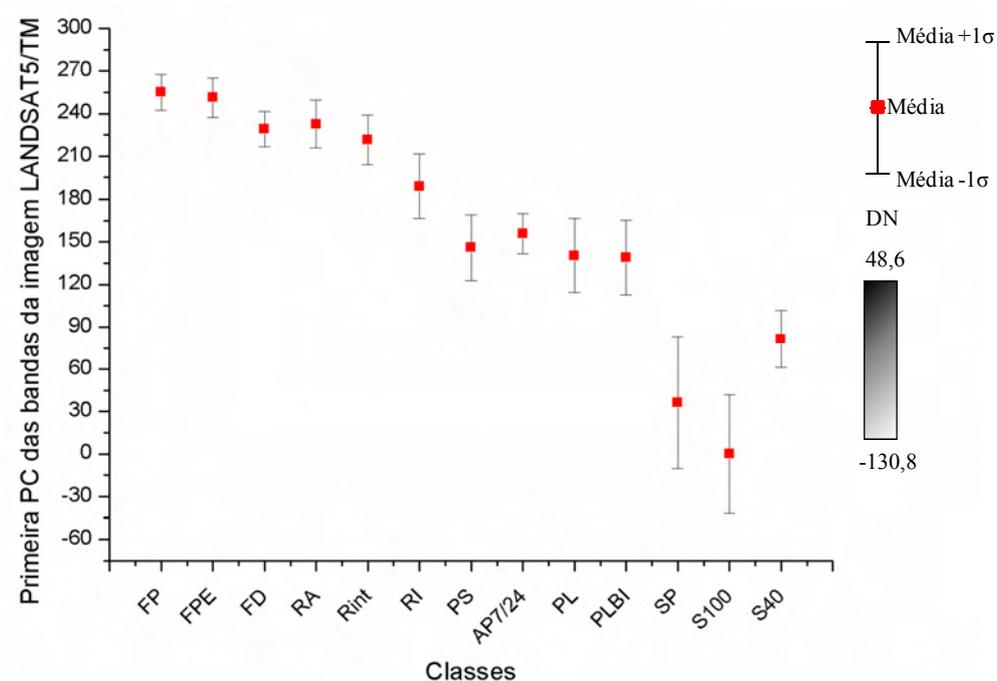


Figura D2.1 - Gráfico de média e desvio padrão da primeira PC extraída das bandas da imagem LANDSAT5/TM.

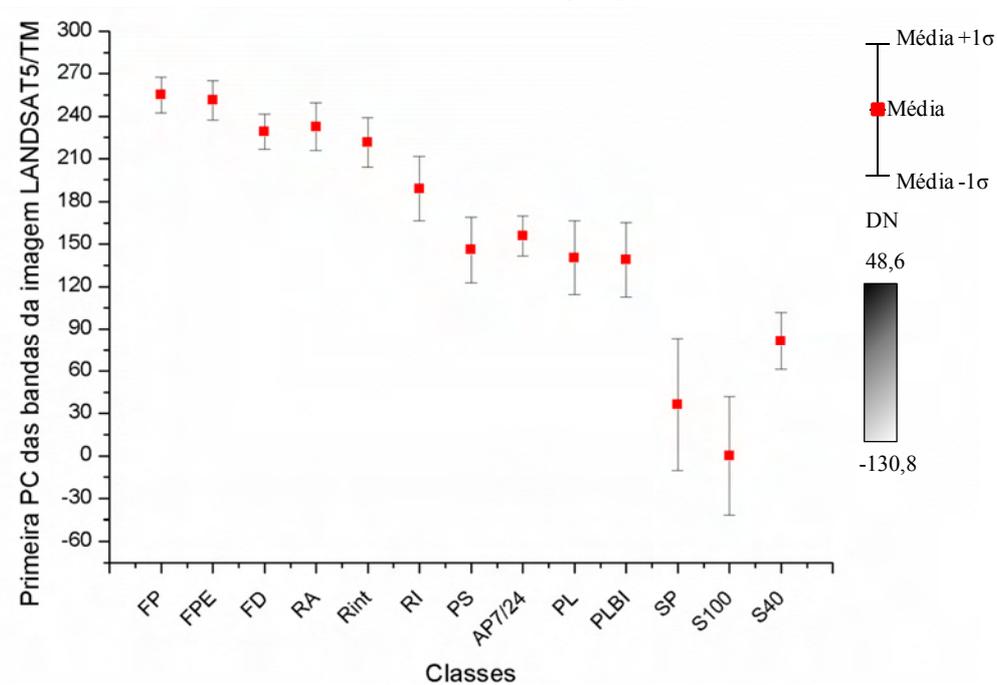


Figura D2.2 - Gráfico de média e desvio padrão da banda 5 da imagem LANDSAT5/TM.

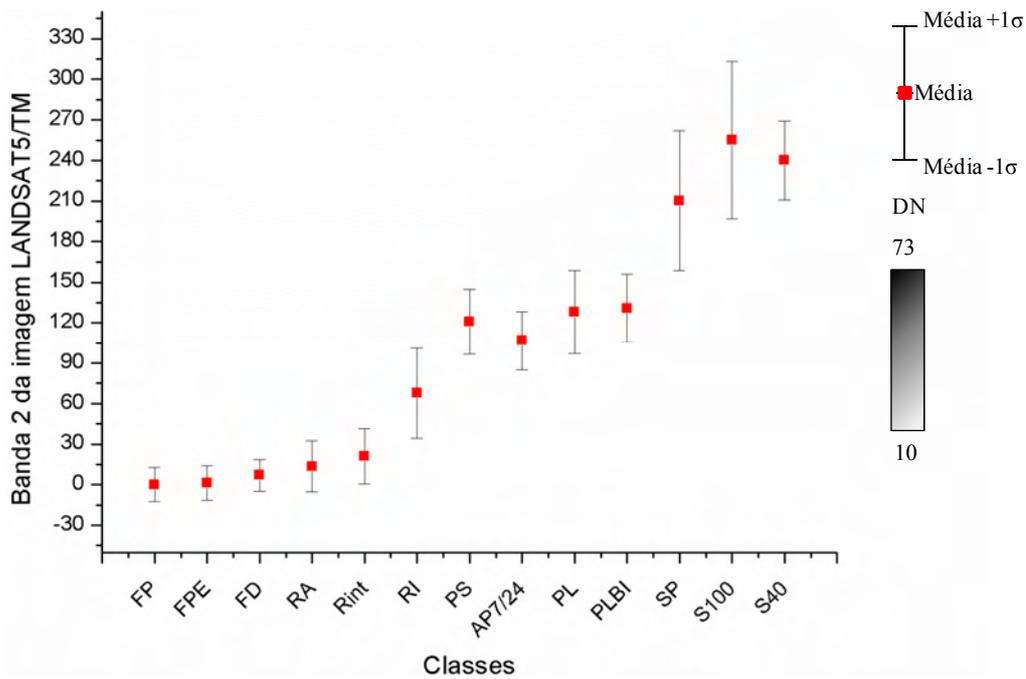


Figura D2.3 - Gráfico de média e desvio padrão da banda 2 da imagem LANDSAT5/TM.

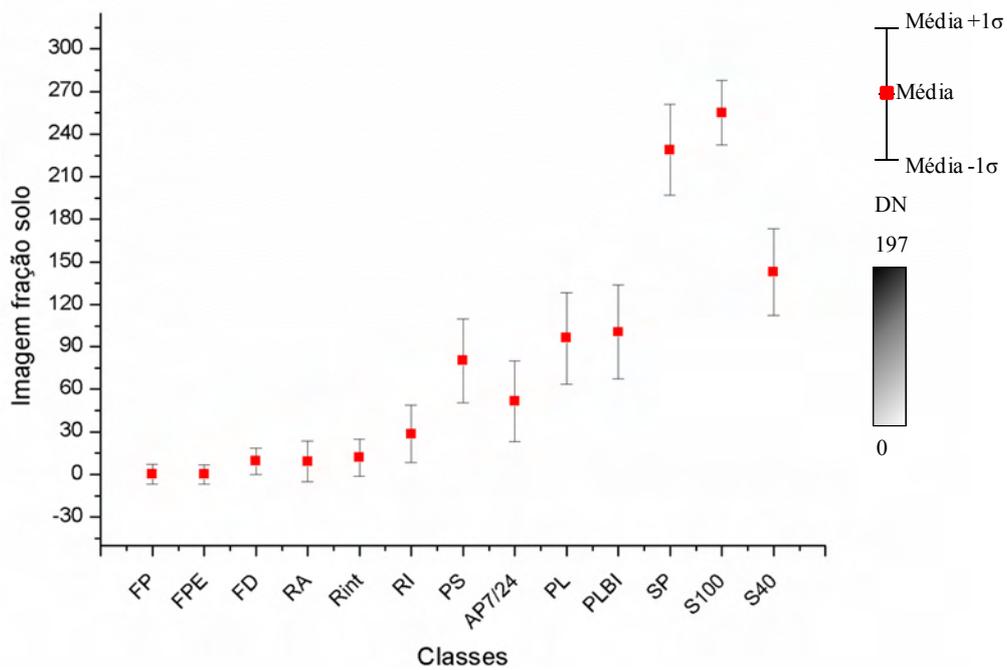


Figura D2.4 - Gráfico de média e desvio padrão da imagem fração solo.

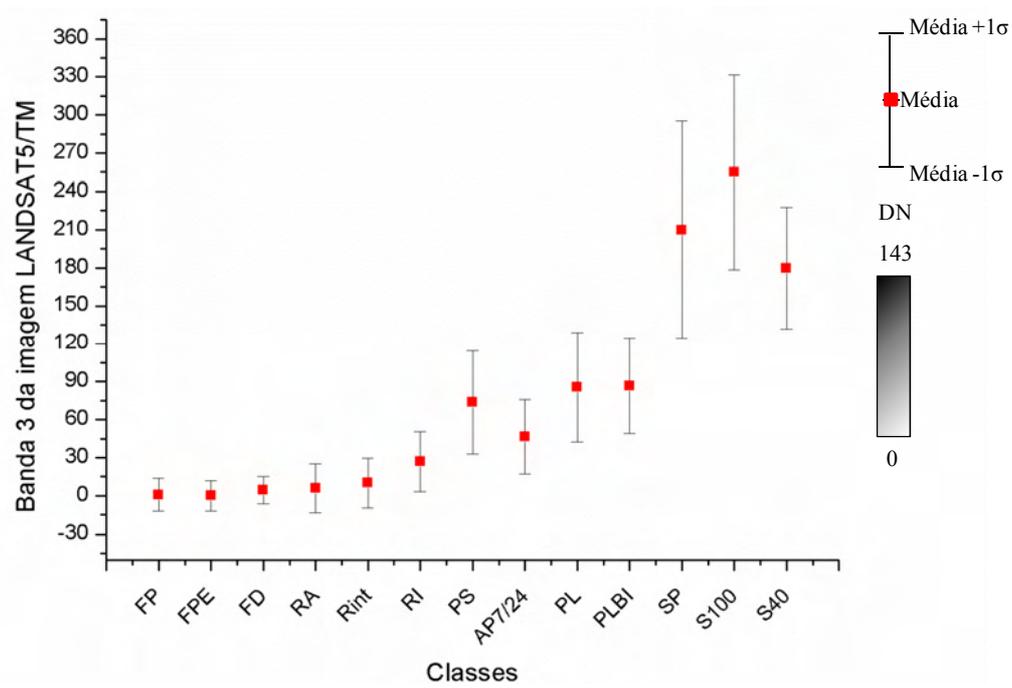


Figura D2.5 - Gráfico de média e desvio padrão da banda 3 da imagem LANDSAT5/TM.

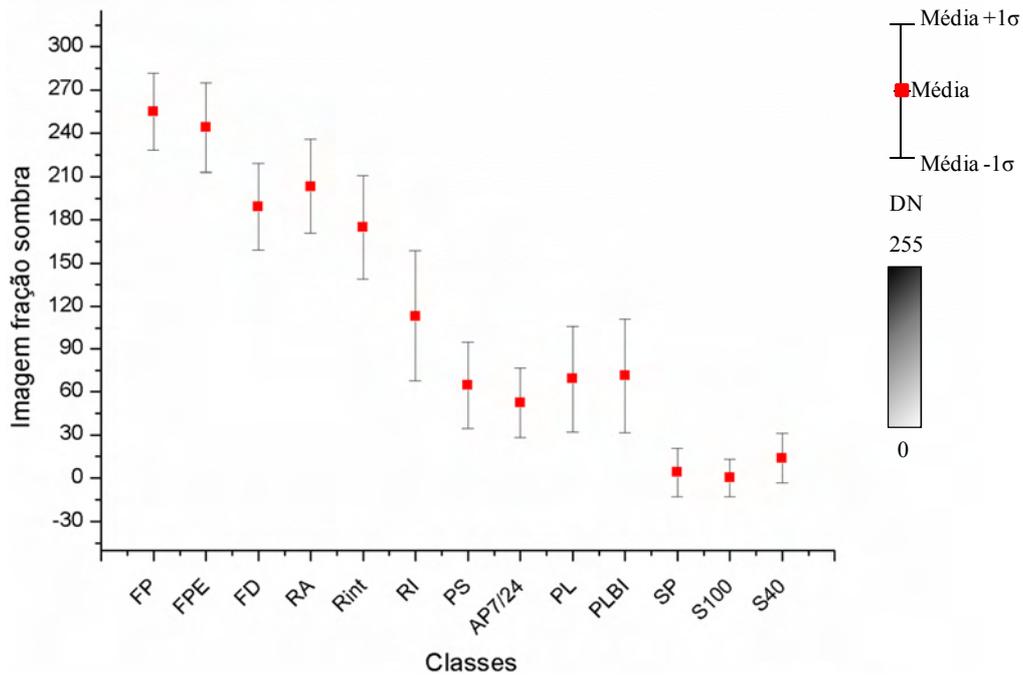


Figura D2.6 - Gráfico de média e desvio padrão da imagem fração sombra.

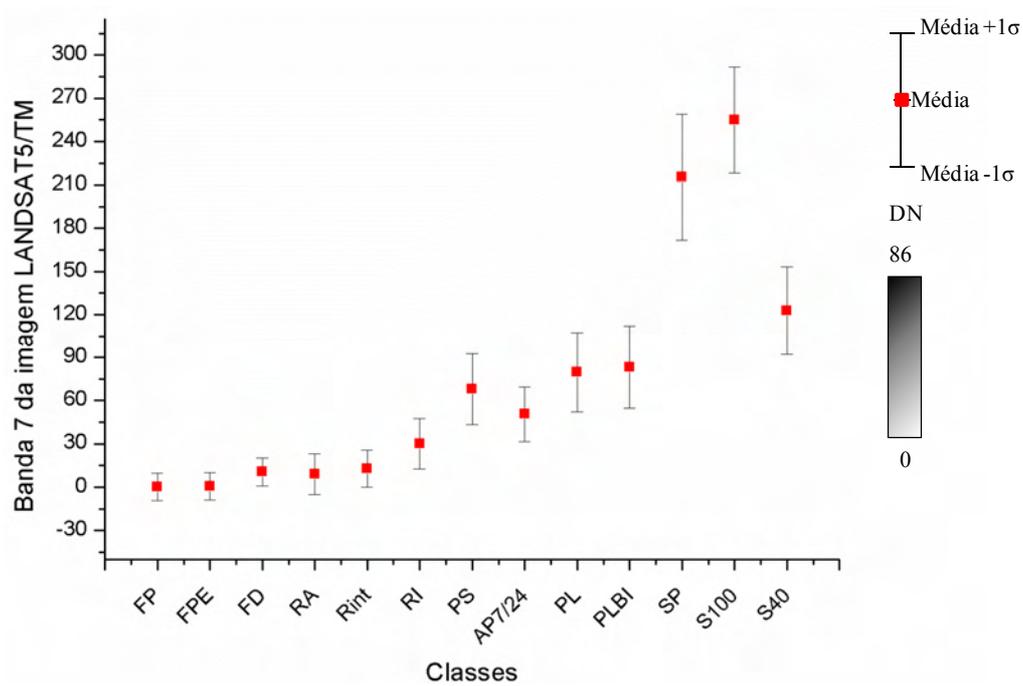


Figura D2.7- Gráfico de média e desvio padrão da banda 7 da imagem LANDSAT5/TM.

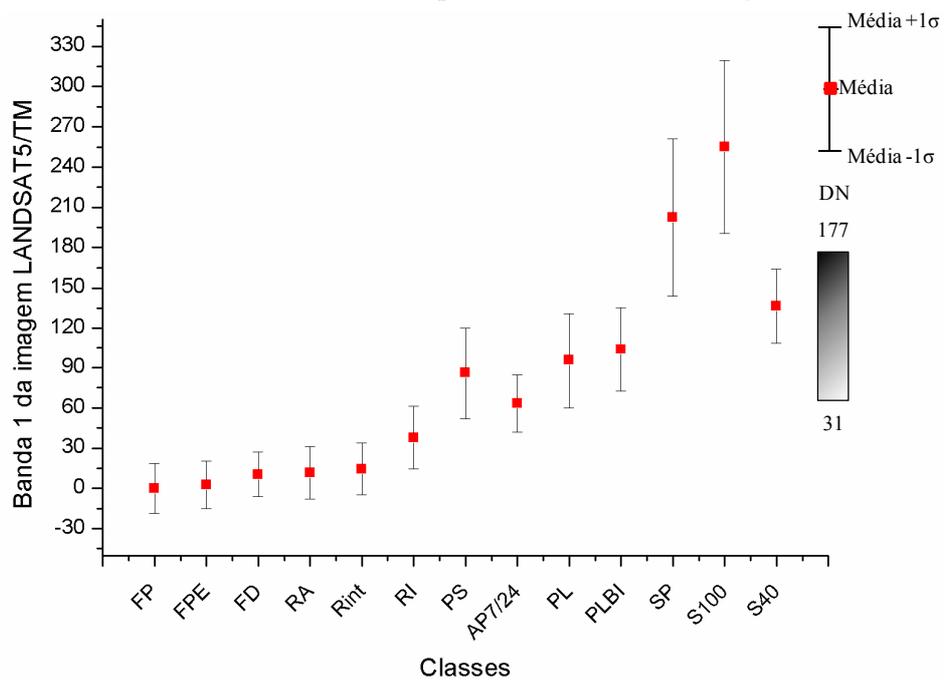


Figura D2.8 - Gráfico de média e desvio padrão da banda 1 da imagem LANDSAT5/TM.

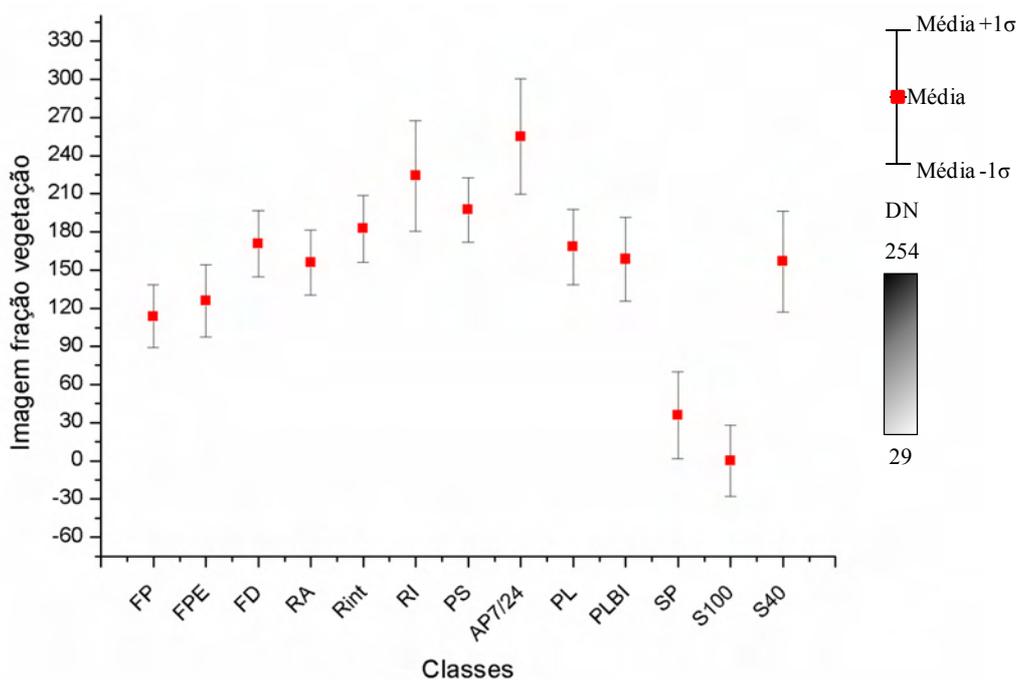


Figura D2.9- Gráfico de média e desvio padrão da imagem fração vegetação.

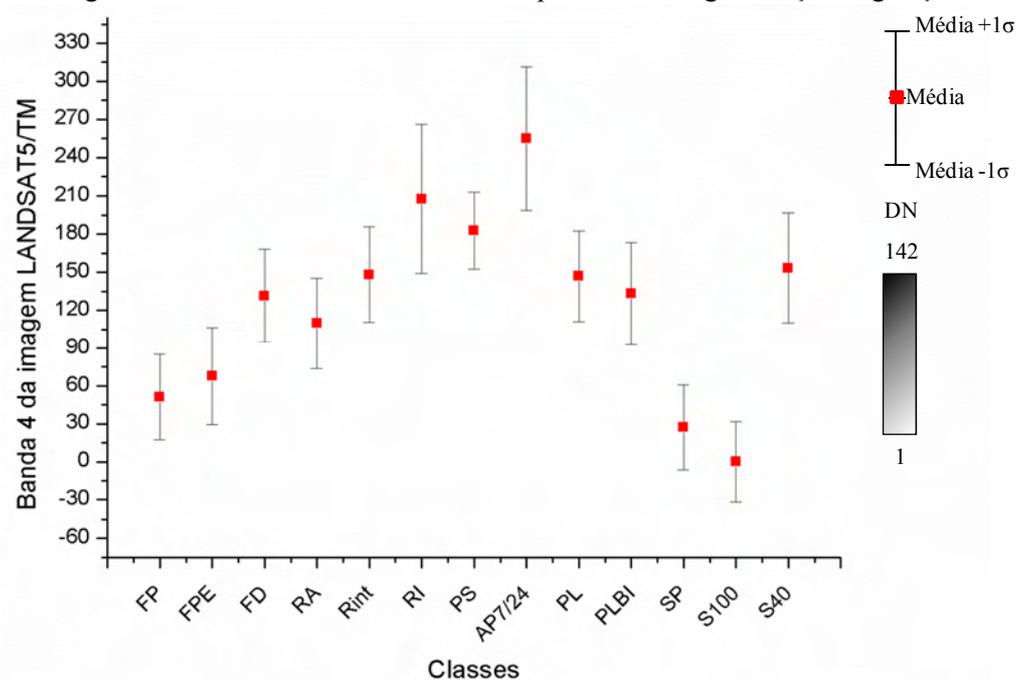


Figura D2.10- Gráfico de média e desvio padrão da banda 4 da imagem LANDSAT5/TM.

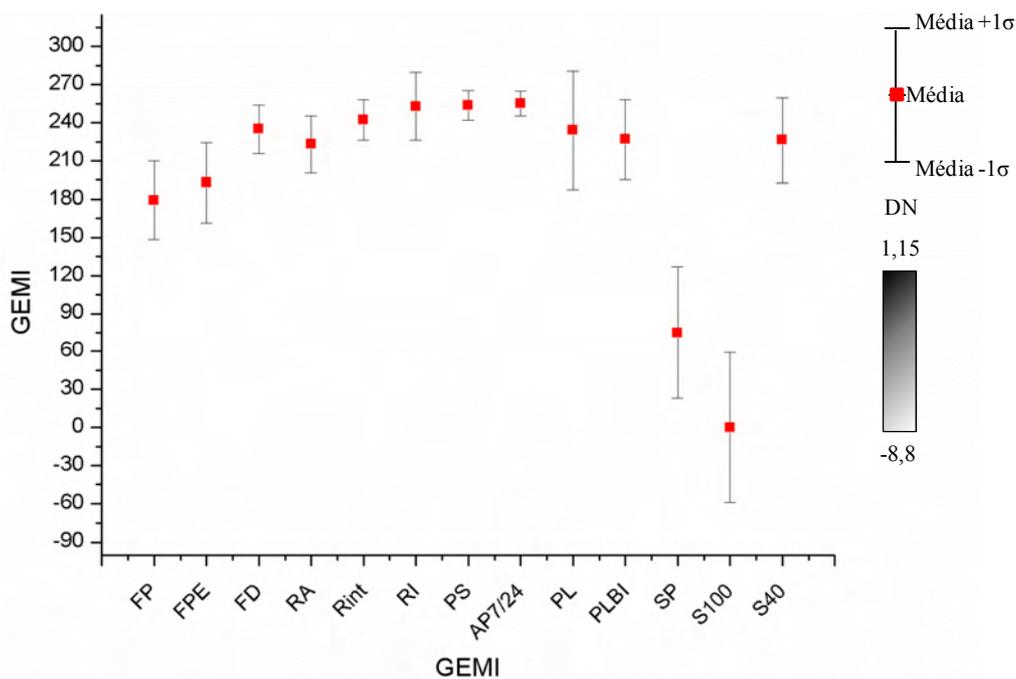


Figura D2.11- Gráfico de média e desvio padrão do índice GEMI.

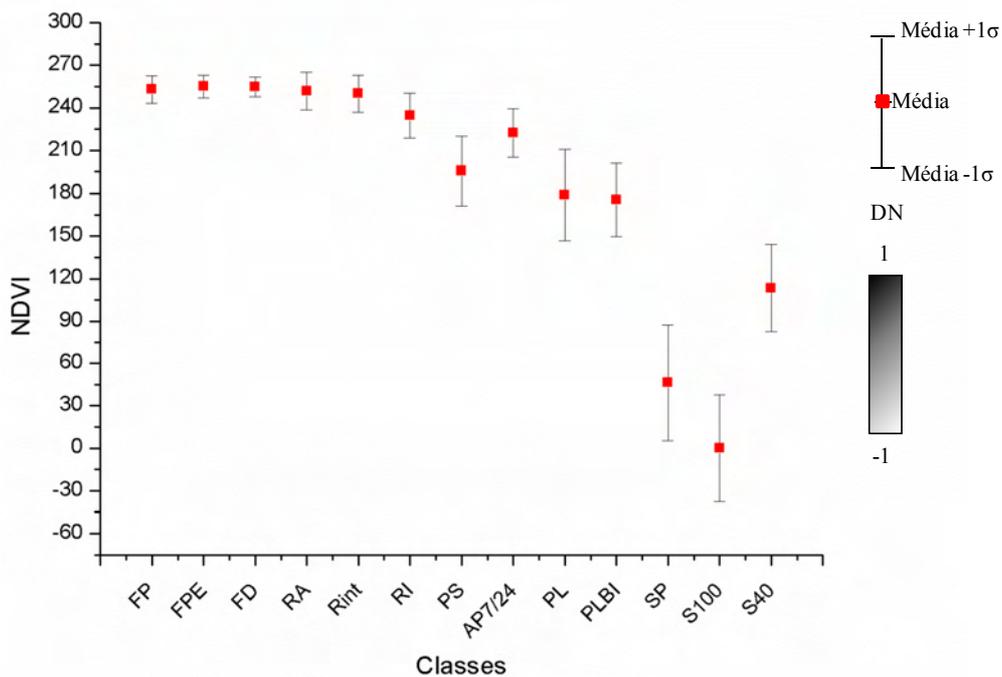


Figura D2.12- Gráfico de média e desvio padrão do índice de vegetação NDVI.



## APÊNDICE E – GRÁFICOS UTILIZADOS NA ANÁLISE EXPLORATÓRIA DOS ATRIBUTOS.

No apêndice E são mostrados os gráficos utilizados na análise exploratória dos atributos que participaram dos processos de fusões. Os gráficos de média e desvio padrão também são normalizados conforme descrito no Apêndice D. Para facilitar as análises dos atributos, nestes gráficos, são destacados pelas elipses os agrupamentos das classes de interesse possíveis de serem agrupadas em uma análise visual. Neste apêndice também são mostrados os gráficos formados por pares de atributos utilizados nas análises dos atributos.

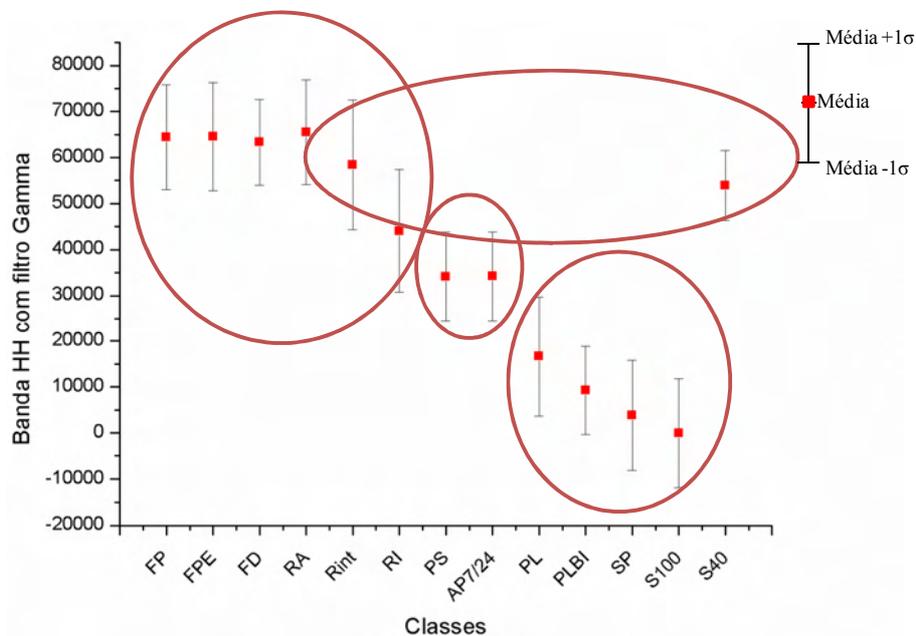


Figura E.1 - Gráfico de média e desvio padrão da banda HH com filtro *Gama* 5x5. Tomando como base este atributo é possível de separar, visualmente, 4 classes.

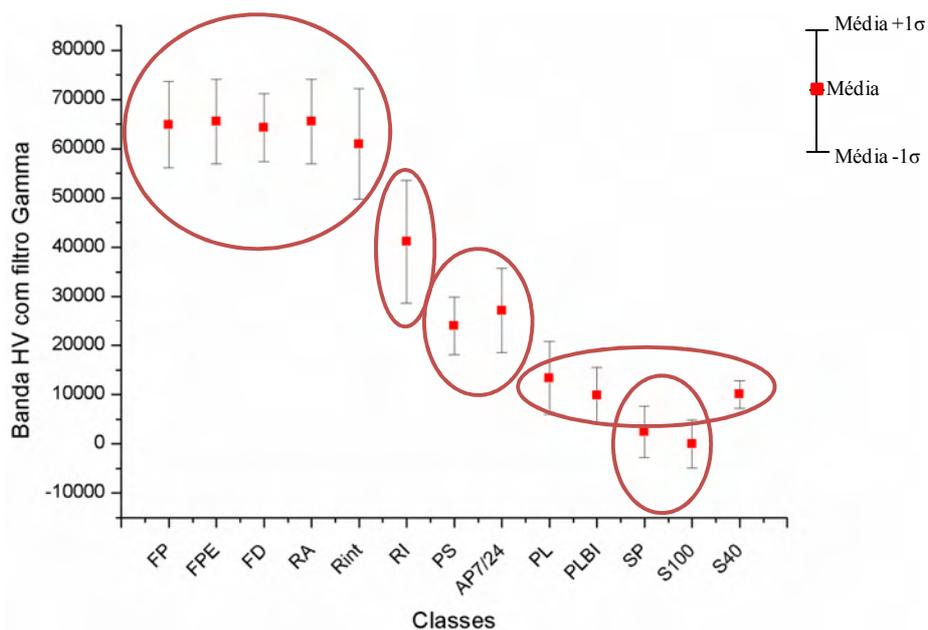


Figura E.2 - Gráfico de média e desvio padrão da banda HV com filtro Gama 5x5. Tomando como base este atributo é possível de separar, visualmente, de 4 a 5 classes.

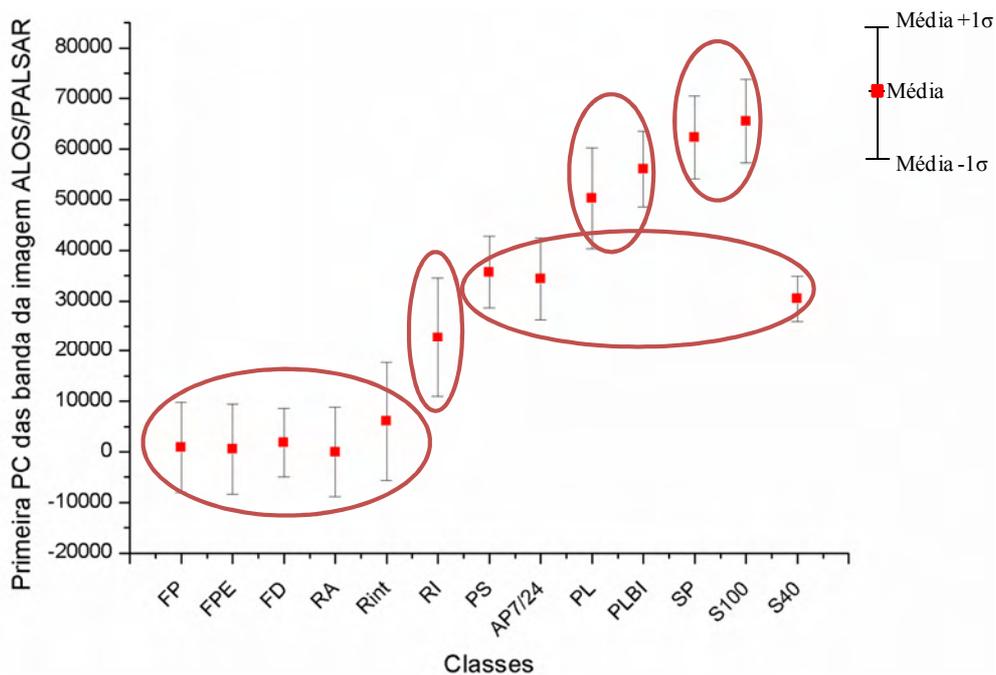


Figura E.3 - Gráfico de média e desvio padrão da primeira PC das bandas da imagem ALOS/PALSAR. Tomando como base este atributo é possível de separar, visualmente, 5 classes.

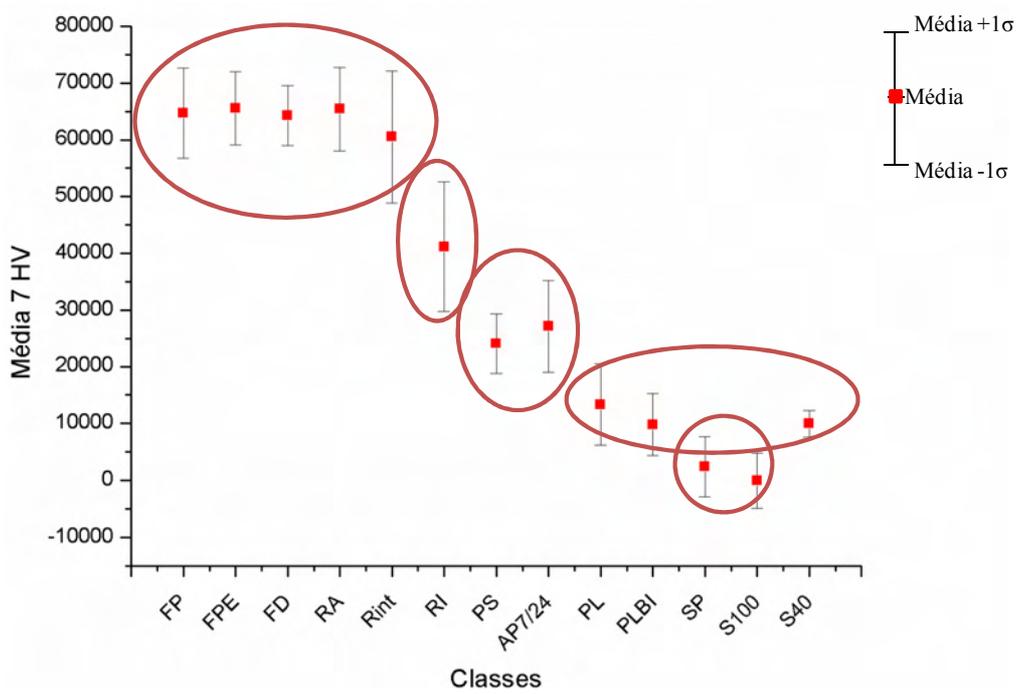


Figura E.4 - Gráfico de média e desvio padrão da medida de textura média\_7\_HV. Tomando como base este atributo é possível de separar, visualmente, de 4 a 5 classes.

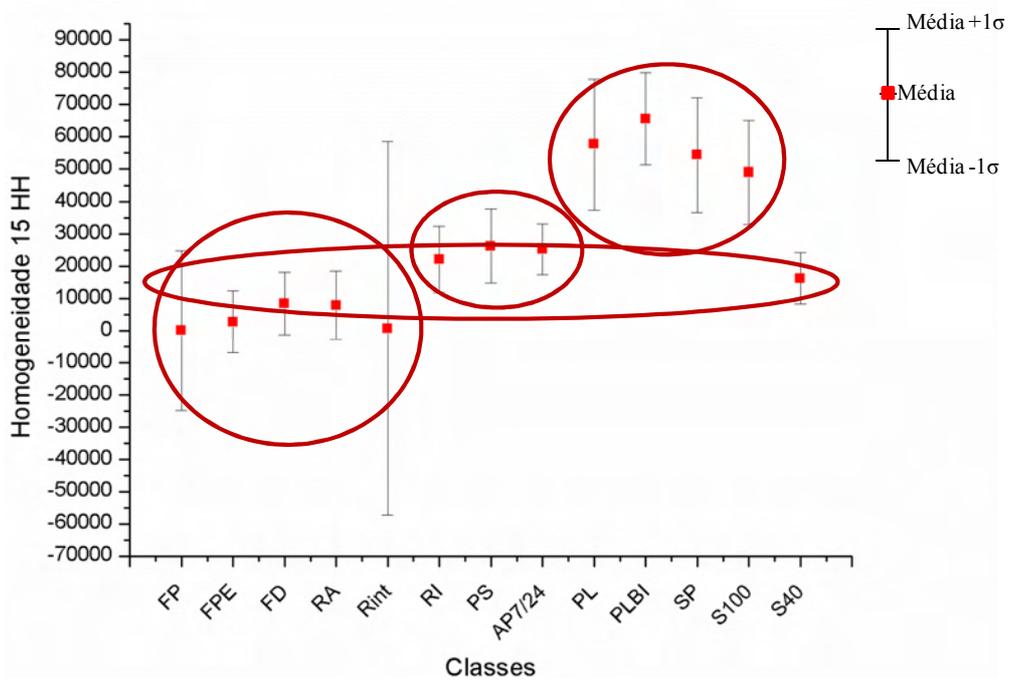


Figura E.5 - Gráfico de média e desvio padrão da medida de textura homogeneidade\_15\_HV. Tomando como base este atributo é possível de separar, visualmente, 3 classes.

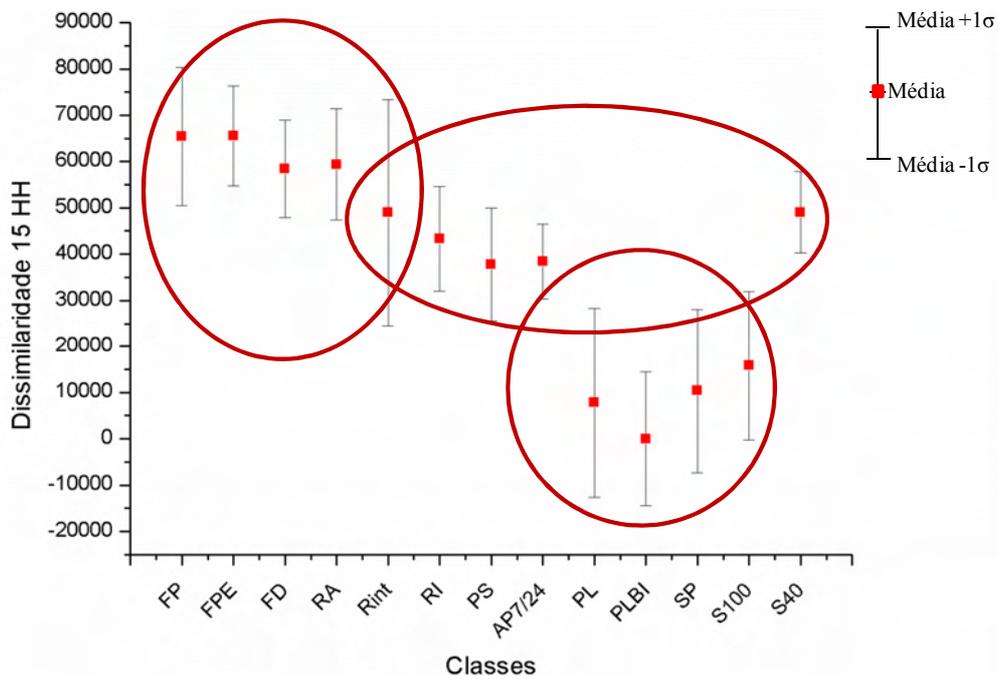


Figura E.6- Gráfico de média e desvio padrão da medida de textura dissimilaridade\_15\_HV. Tomando como base este atributo é possível de separar, visualmente, 3 classes.

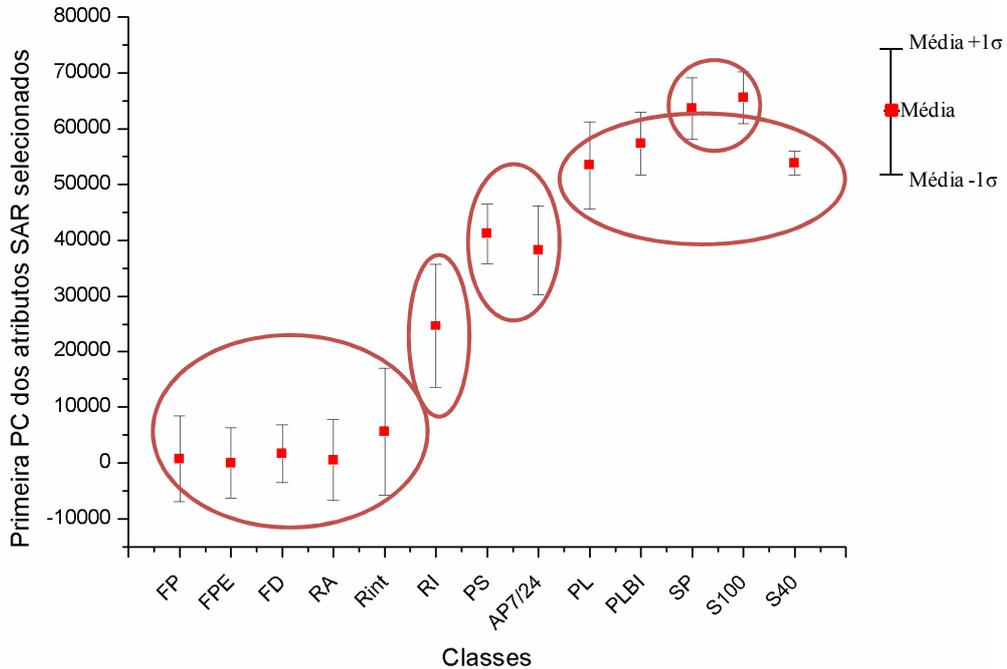


Figura E.7 - Gráfico de média e desvio padrão da primeira PC dos atributos SAR selecionados. Tomando como base este atributo é possível de separar, visualmente, de 4 a 5 classes.

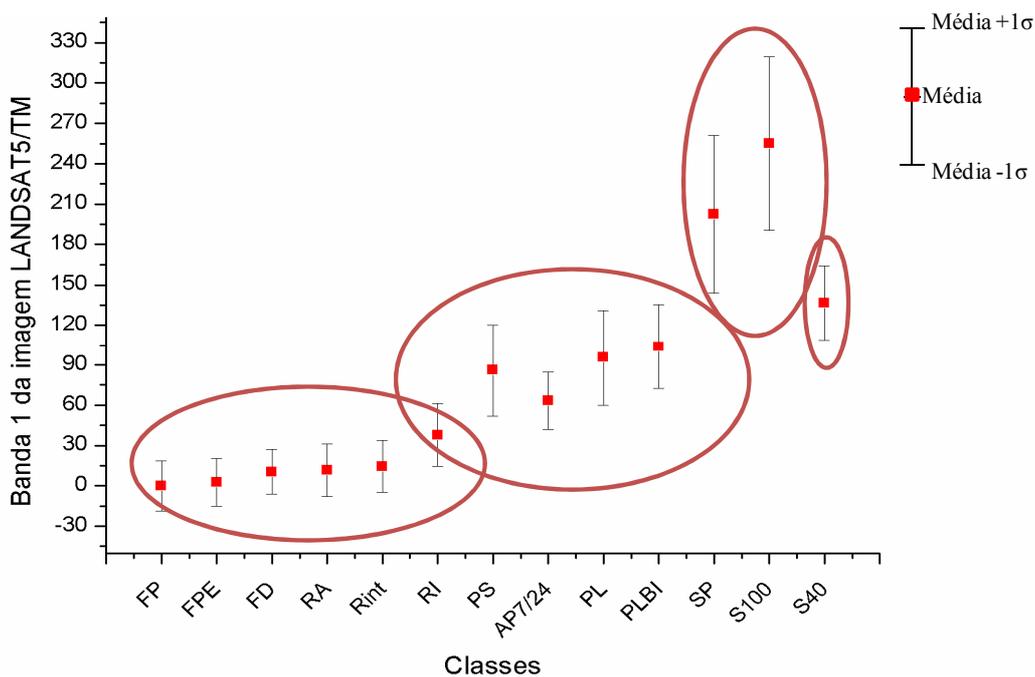


Figura E.8 - Gráfico de média e desvio padrão da banda 1 da imagem LANDSAT5/TM. Tomando como base este atributo é possível de separar, visualmente, de 3 a 4 classes.

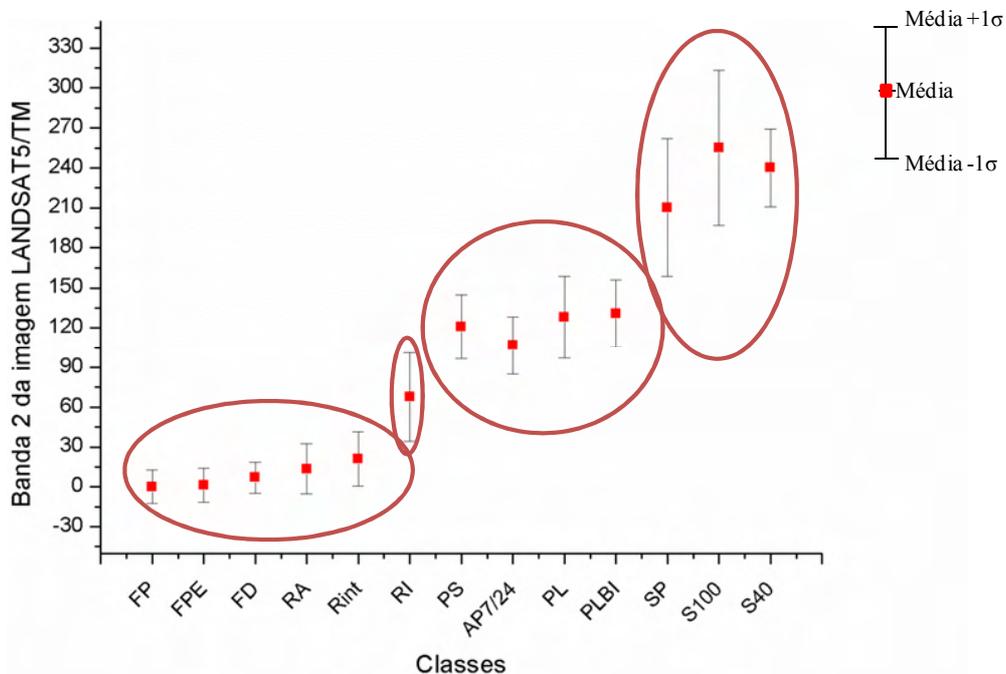


Figura E.9 - Gráfico de média e desvio padrão da banda 2 da imagem LANDSAT5/TM. Tomando como base este atributo é possível de separar, visualmente, 4 classes.

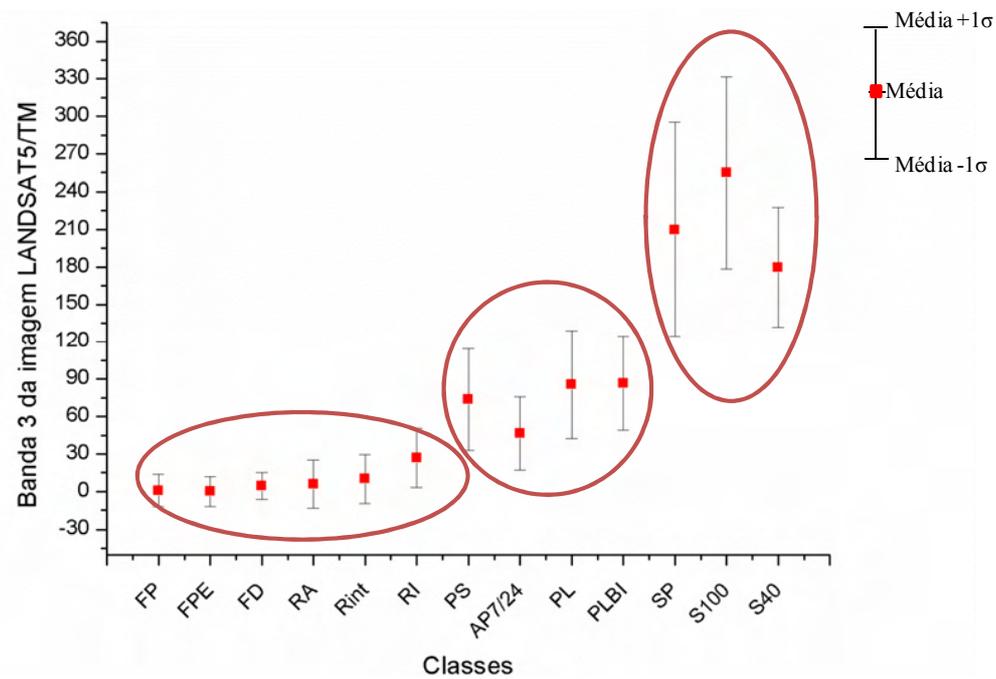


Figura E.10 - Gráfico de média e desvio padrão da banda 3 da imagem LANDSAT5/TM. Tomando como base este atributo é possível de separar, visualmente, 3 classes.

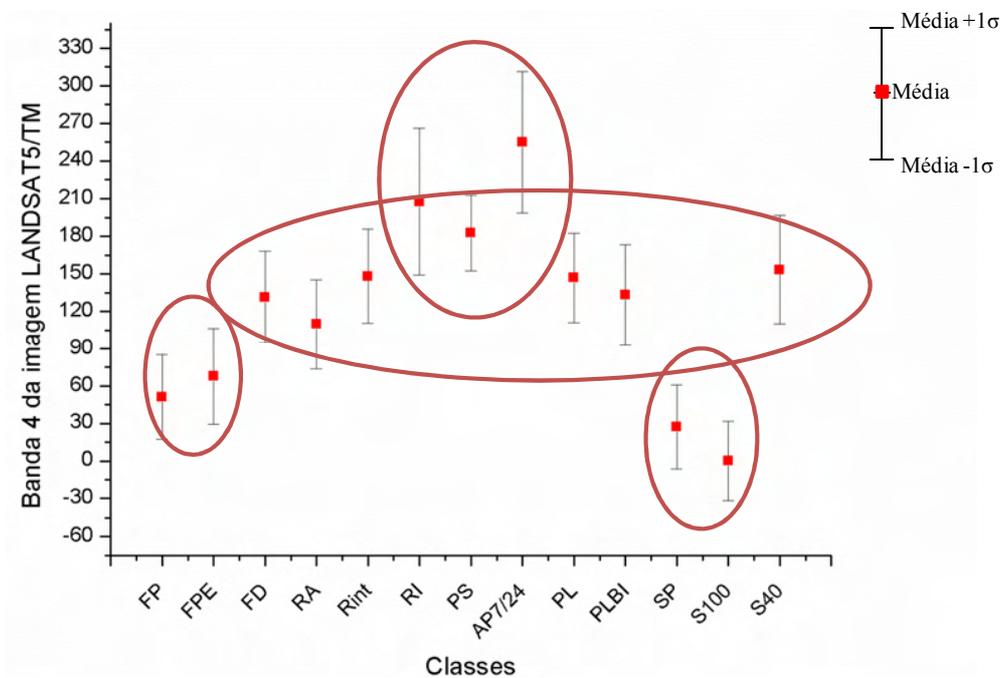


Figura E.11 - Gráfico de média e desvio padrão da banda 4 da imagem LANDSAT5/TM. Tomando como base este atributo é possível de separar, visualmente, 4 classes.

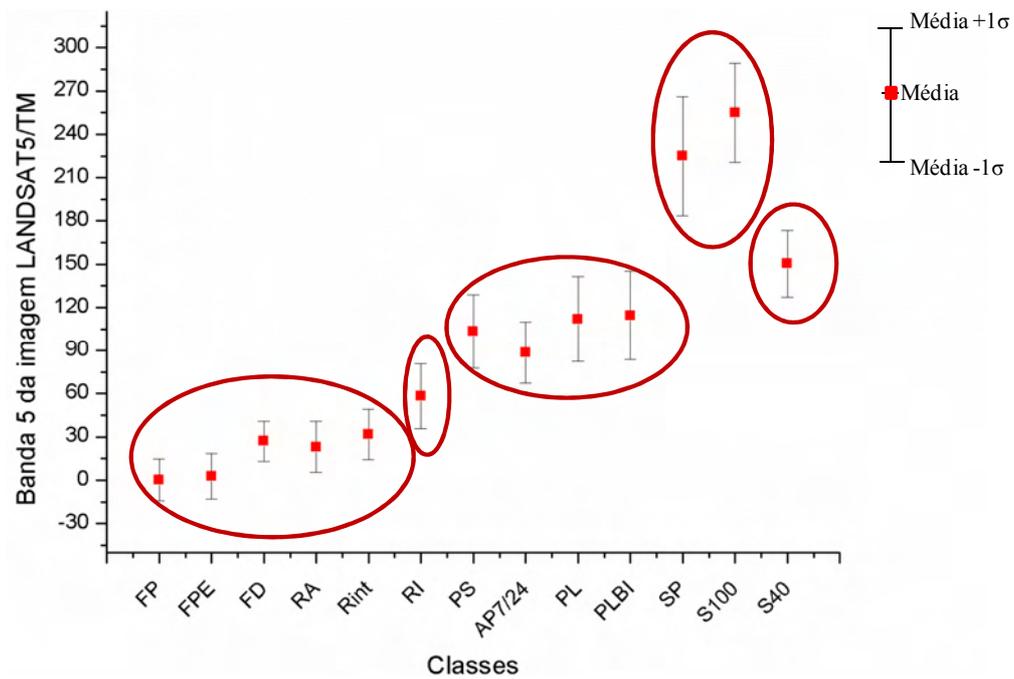


Figura E.12 - Gráfico de média e desvio padrão da banda 5 da imagem LANDSAT5/TM. Tomando como base este atributo é possível de separar, visualmente, 5 classes.

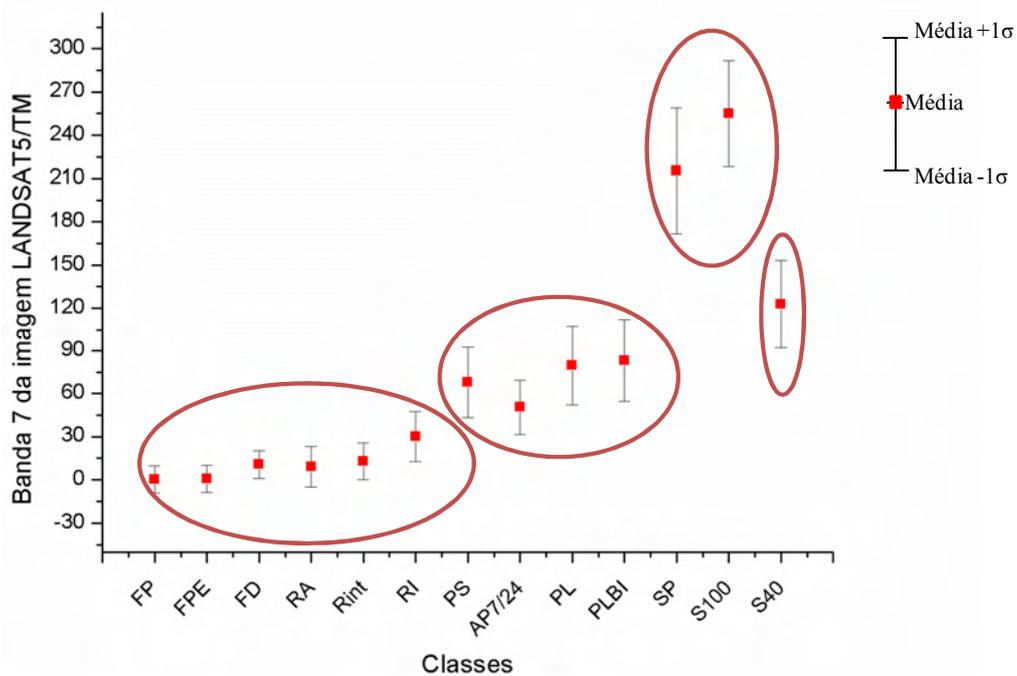


Figura E.13 - Gráfico de média e desvio padrão da banda 7 da imagem LANDSAT5/TM. Tomando como base este atributo é possível de separar, visualmente, 4 classes.

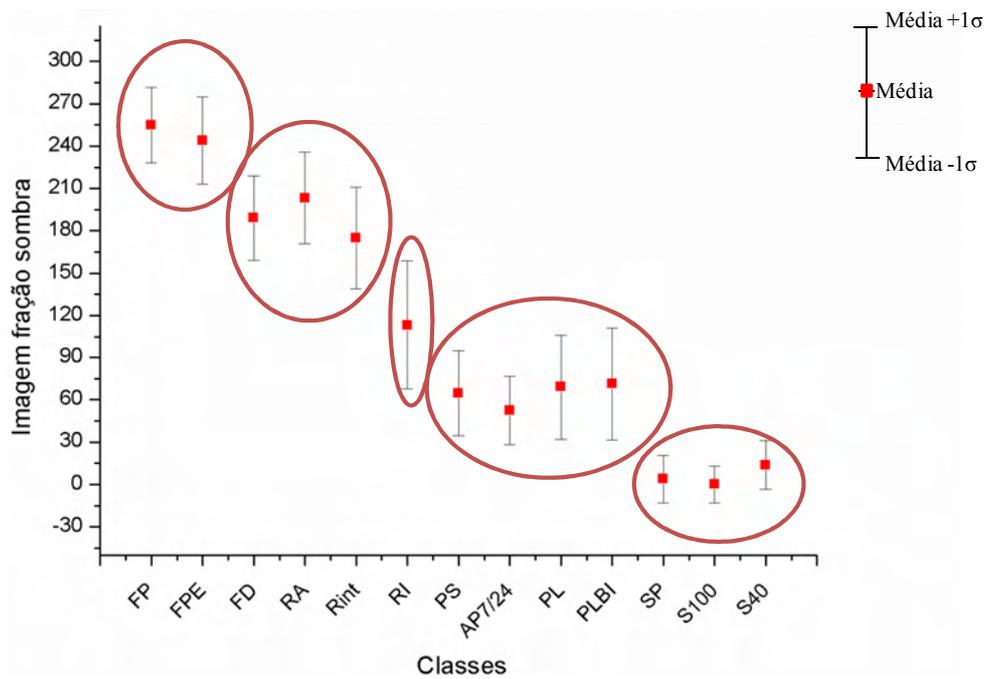


Figura E.14 - Gráfico de média e desvio padrão da imagem fração sombra Tomando como base este atributo é possível de separar, visualmente, 5 classes.

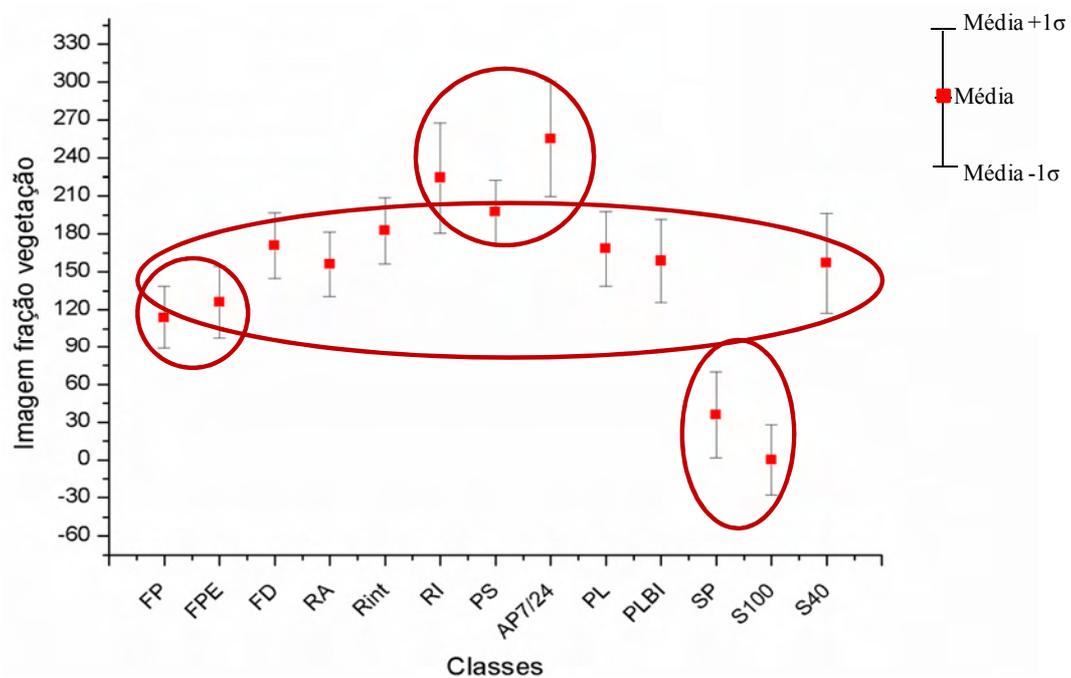


Figura E.15 - Gráfico de média e desvio padrão da imagem fração vegetação. Tomando como base este atributo é possível de separar, visualmente, de 3 classes.

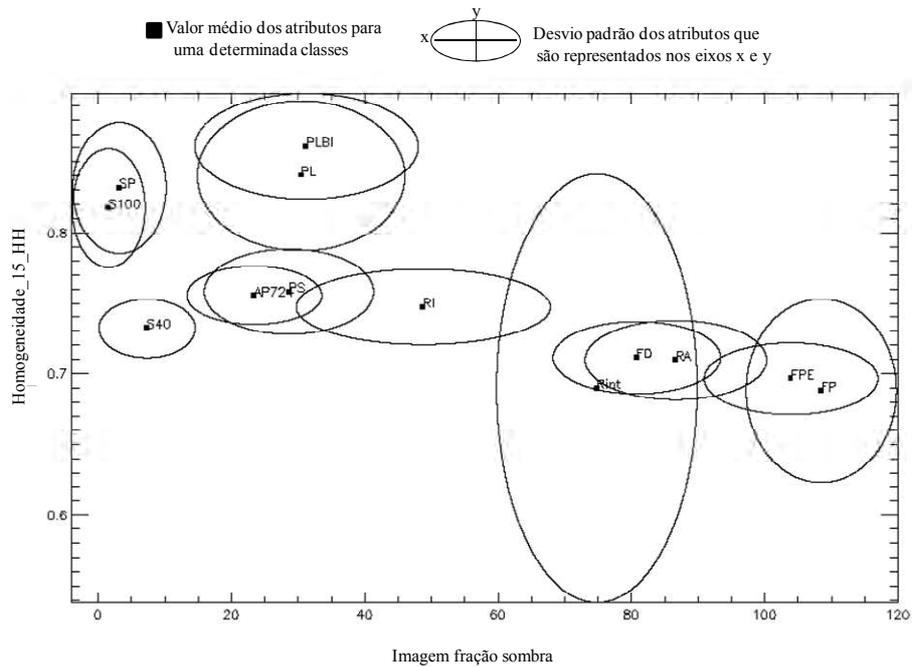


Figura E.16 - Gráfico dos pares dos atributos homogeneidade\_15\_HH e da imagem fração sombra. Tomando como base estes 2 atributos é possível de separar, visualmente, 7 classes.

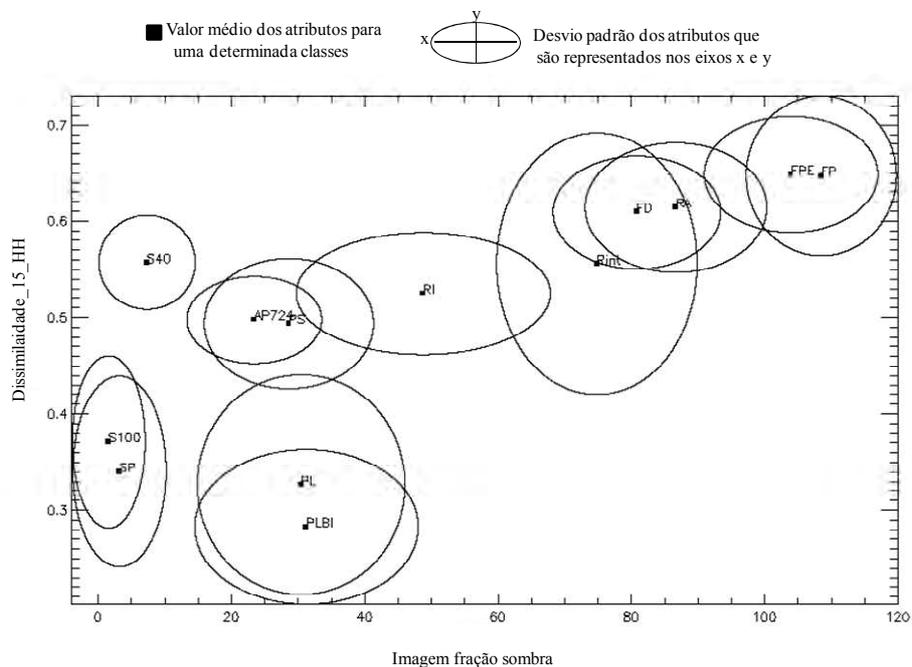


Figura E.17 - Gráfico dos pares dos atributos dissimilaridade\_15\_HH e da imagem fração sombra. Tomando como base estes 2 atributos é possível de separar, visualmente, 7 classes.

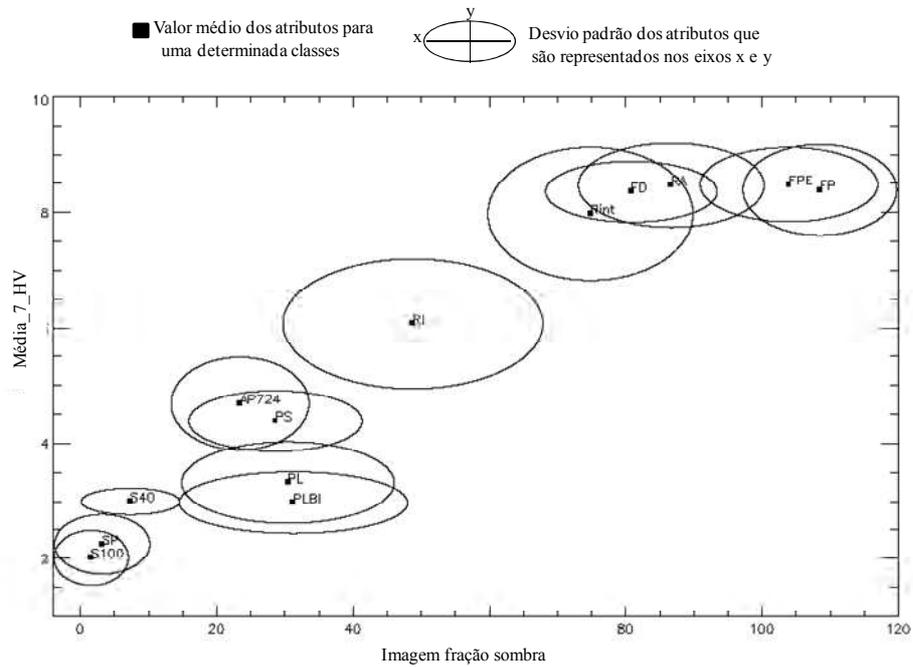


Figura E.18 - Gráfico dos pares dos atributos média\_7\_HV e da imagem fração sombra. Tomando como base estes 2 atributos é possível de separar, visualmente, 7 classes.

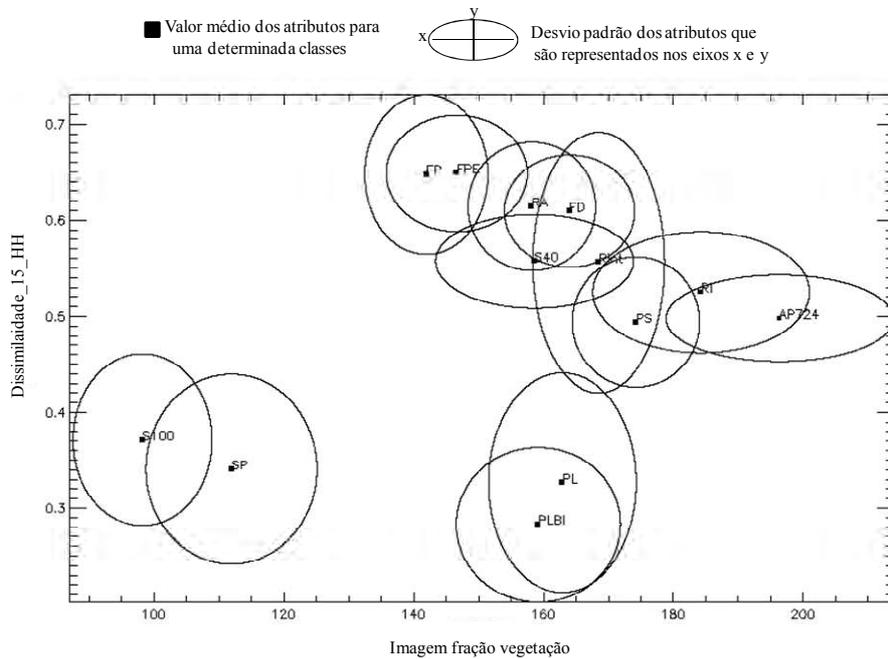


Figura E.19 - Gráfico dos pares dos atributos dissimilaridade\_15\_HH e da imagem fração vegetação. Tomando como base estes 2 atributos é possível de separar, visualmente, 5 classes.

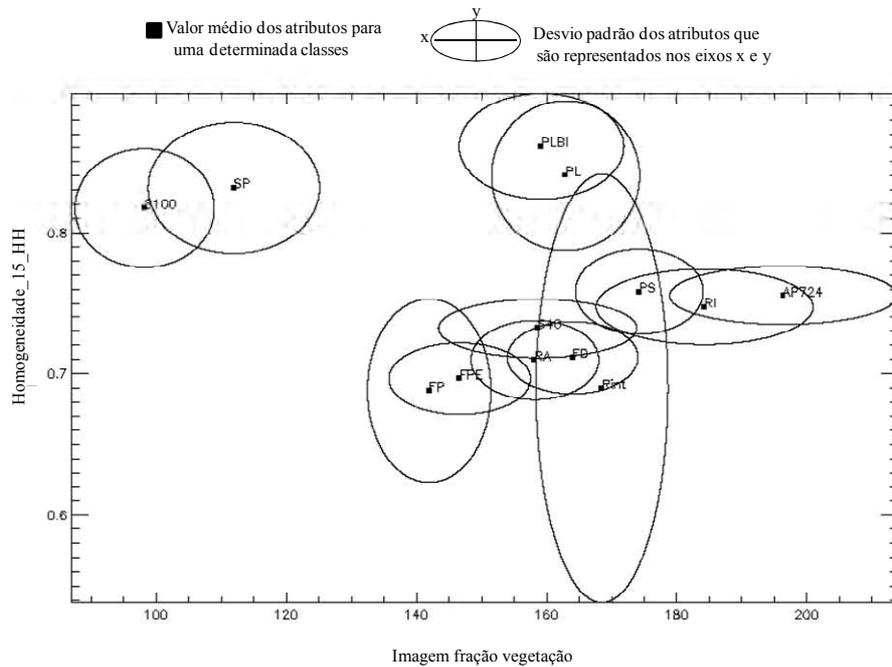


Figura E.20 - Gráfico dos pares dos atributos homogeneidade\_15\_HH e da imagem fração vegetação. Tomando como base estes 2 atributos é possível de separar, visualmente, 5 classes.

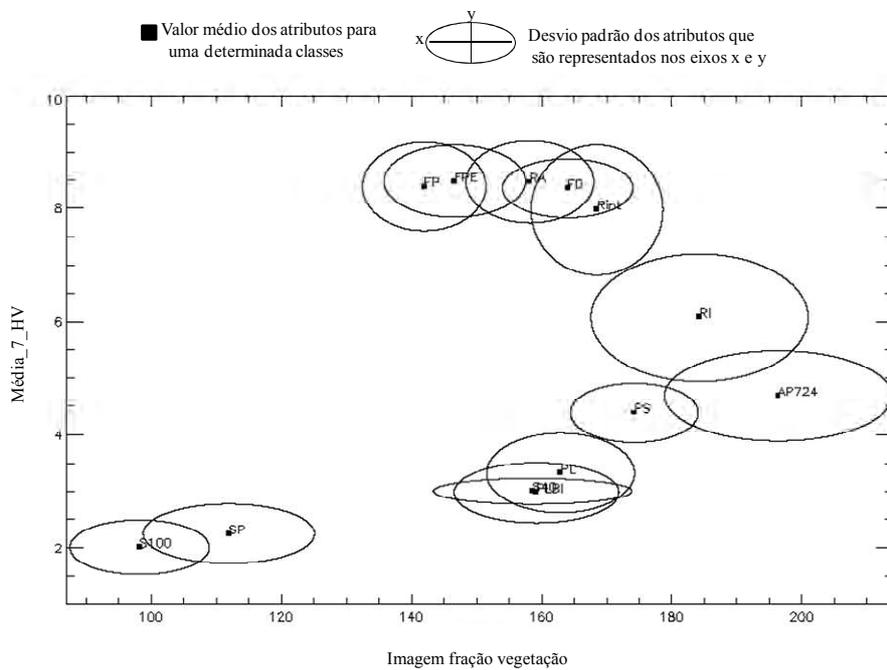


Figura E.21 - Gráfico dos pares dos atributos média\_7\_HV e da imagem fração vegetação. Tomando como base estes 2 atributos é possível de separar, visualmente, 7 classes.

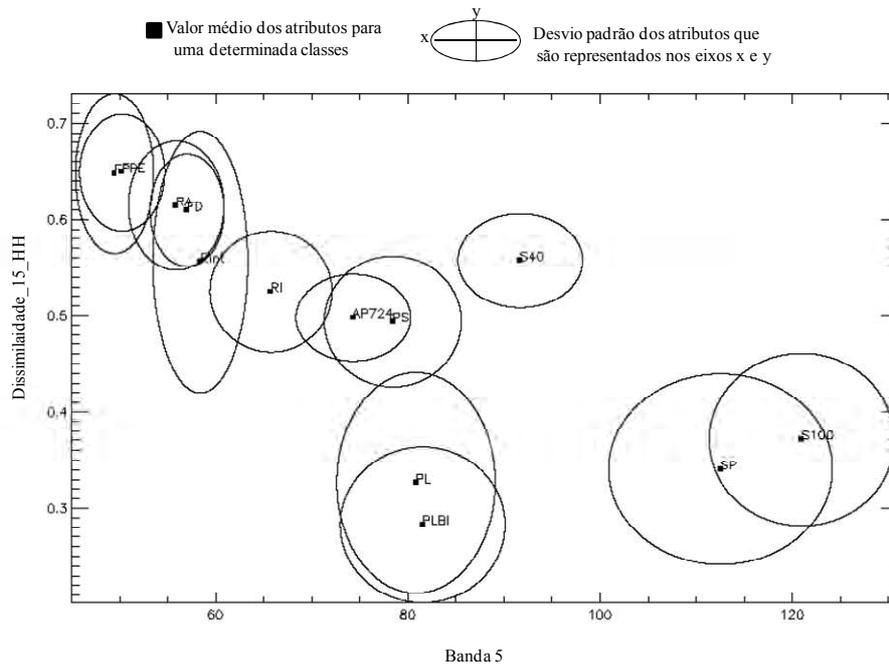


Figura E.22 - Gráfico dos pares dos atributos dissimilaridade\_15\_HH e banda 5. Tomando como base estes 2 atributos é possível de separar, visualmente, 7 classes.

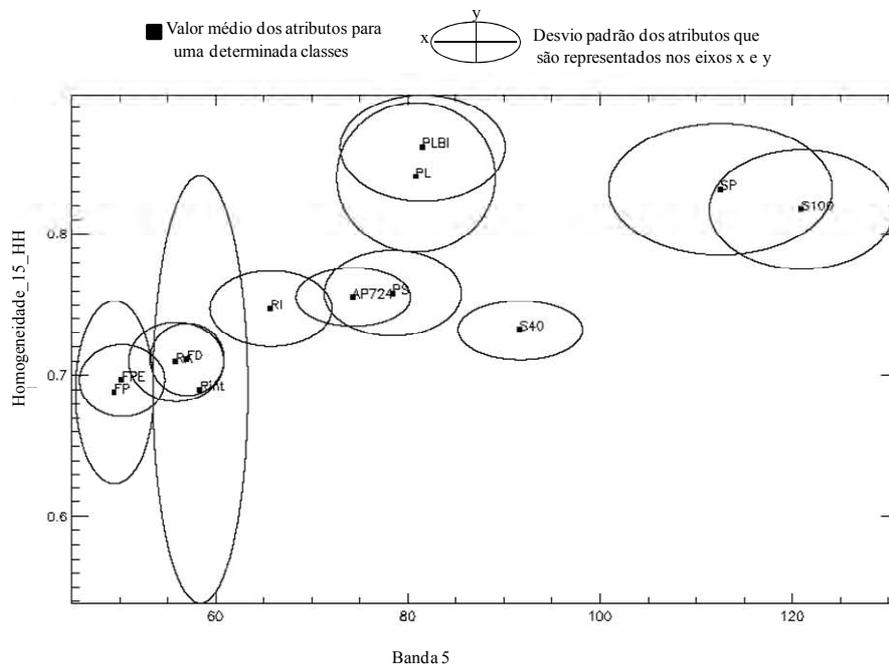


Figura E.23 - Gráfico dos pares dos atributos homogeneidade\_15\_HH e banda 5. Tomando como base estes 2 atributos é possível de separar, visualmente, 7 classes.

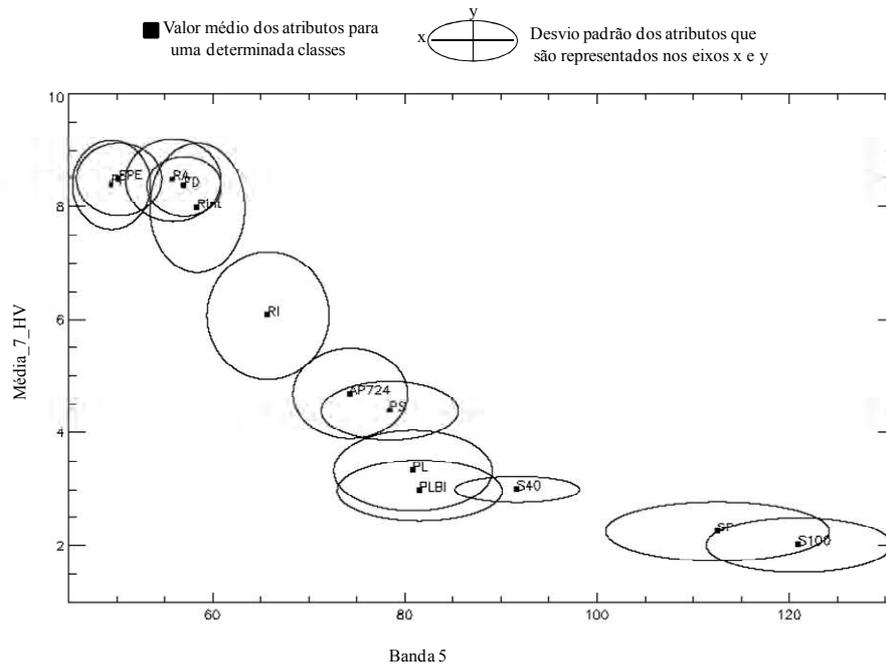


Figura E.24 - Gráfico dos pares dos atributos média\_7\_HV e banda 5. Tomando como base estes 2 atributos é possível de separar, visualmente, 7 classes.

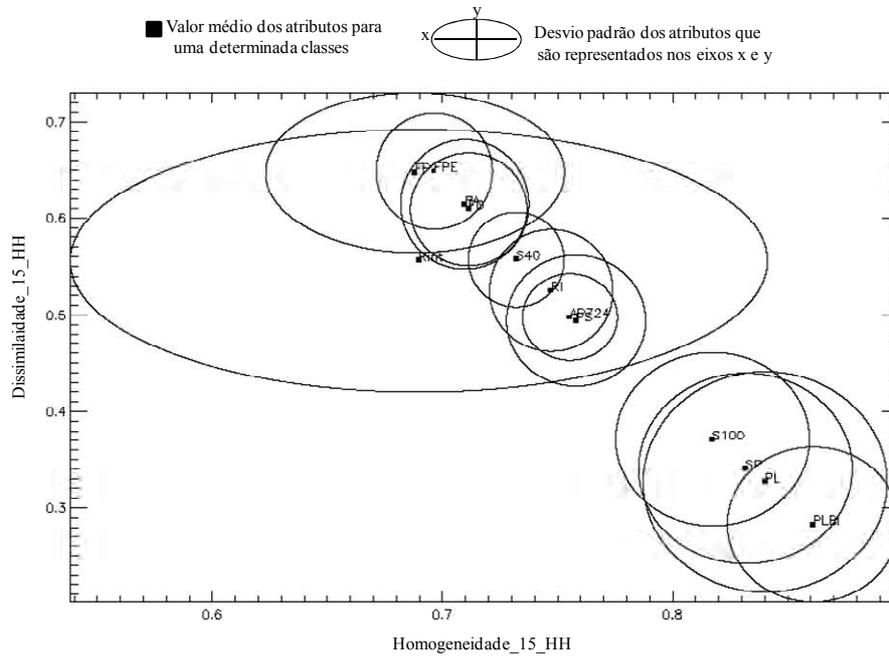


Figura E.25 - Gráfico dos pares dos atributos dissimilaridade\_15\_HH e homogeneidade\_15\_HH. Tomando como base estes 2 atributos é possível de separar, visualmente, 2 classes.

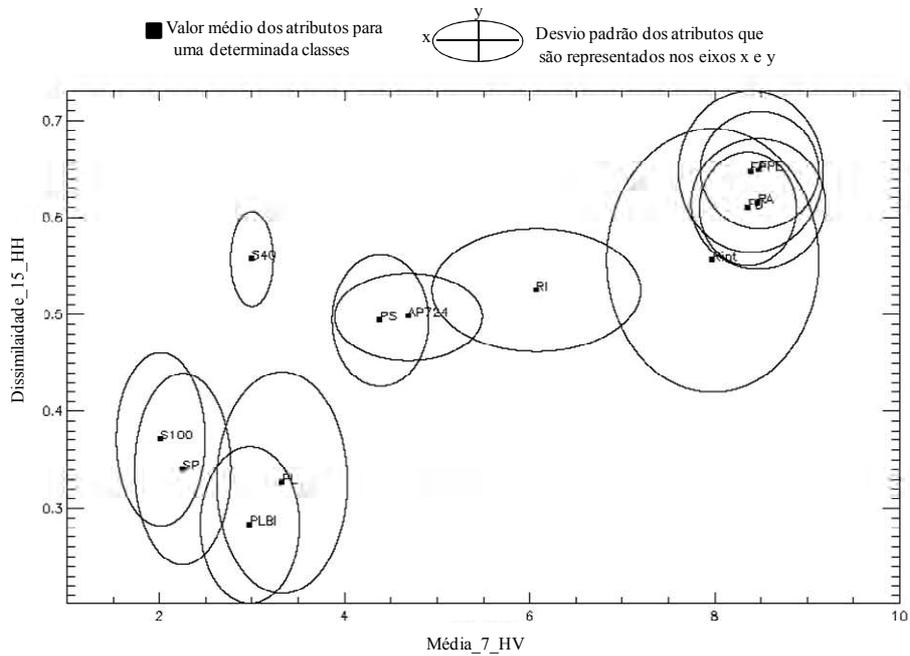


Figura E.26 - Gráfico dos pares dos atributos dissimilaridade\_15\_HH e média\_7\_HV. Tomando como estes 2 atributos é possível de separar, visualmente, 6 classes.

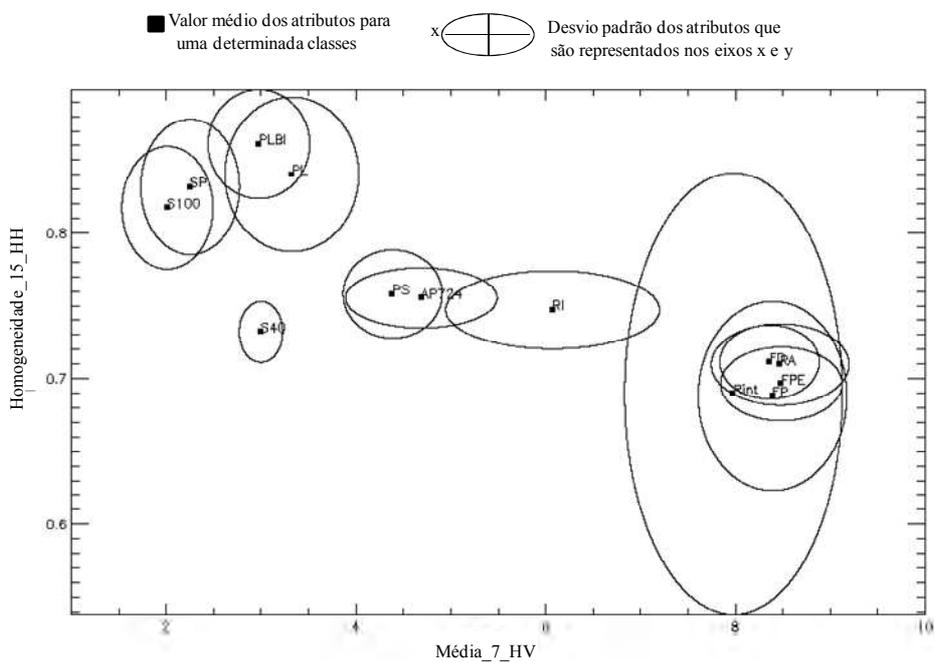


Figura E.27 - Gráfico dos pares dos atributos homogeneidade\_15\_HH e média\_7\_HV. Tomando como base estes 2 atributos é possível de separar, visualmente, 6 classes.

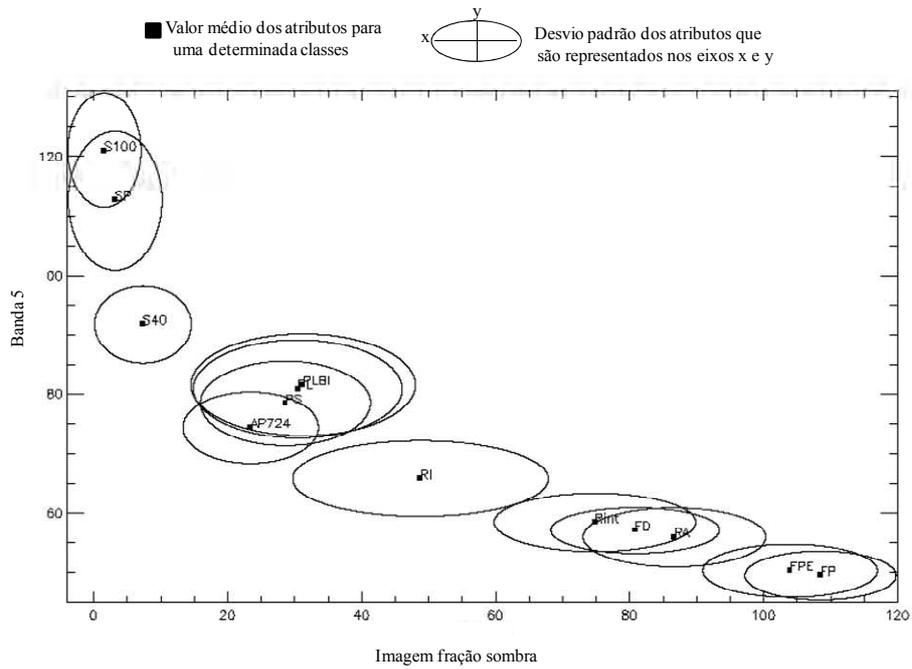


Figura E.28 - Gráfico dos pares dos atributos banda 5 e a imagem fração sombra. Tomando como base estes 2 atributos é possível de separar, visualmente, 6 classes.

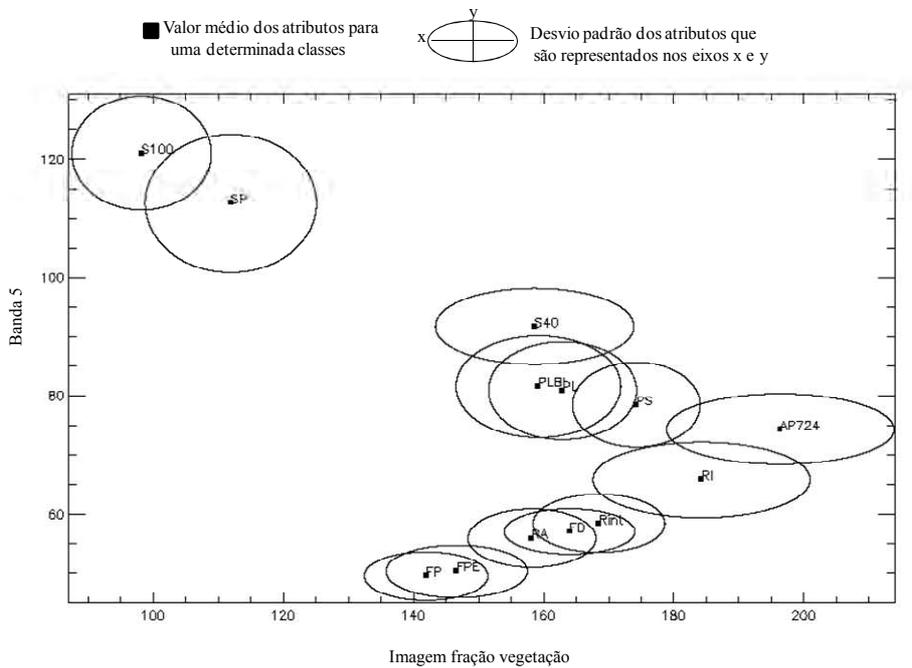


Figura E.29 - Gráfico dos pares dos atributos banda 5 e a imagem fração vegetação. Tomando como base estes 2 atributos é possível de separar, visualmente, 8 classes.

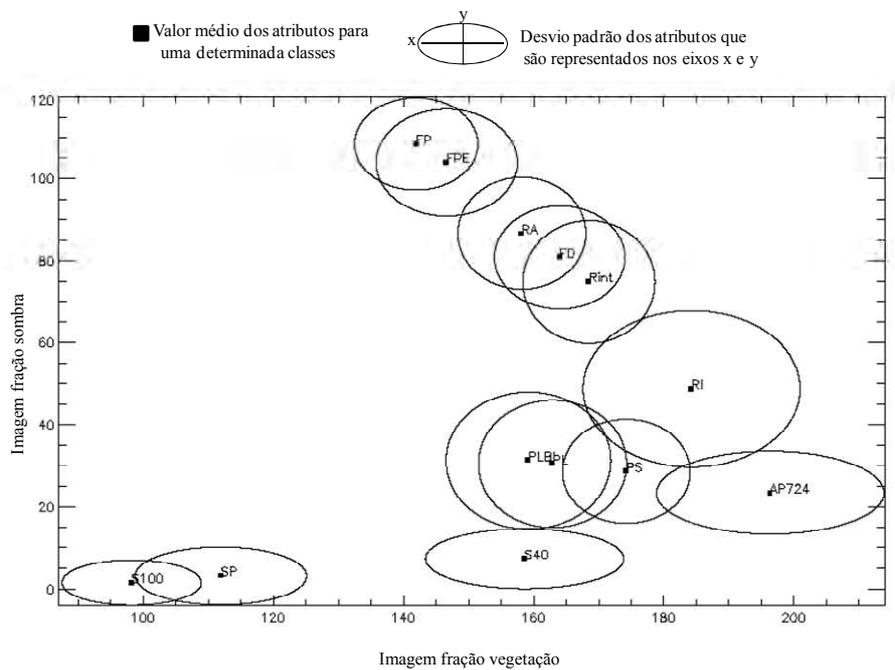
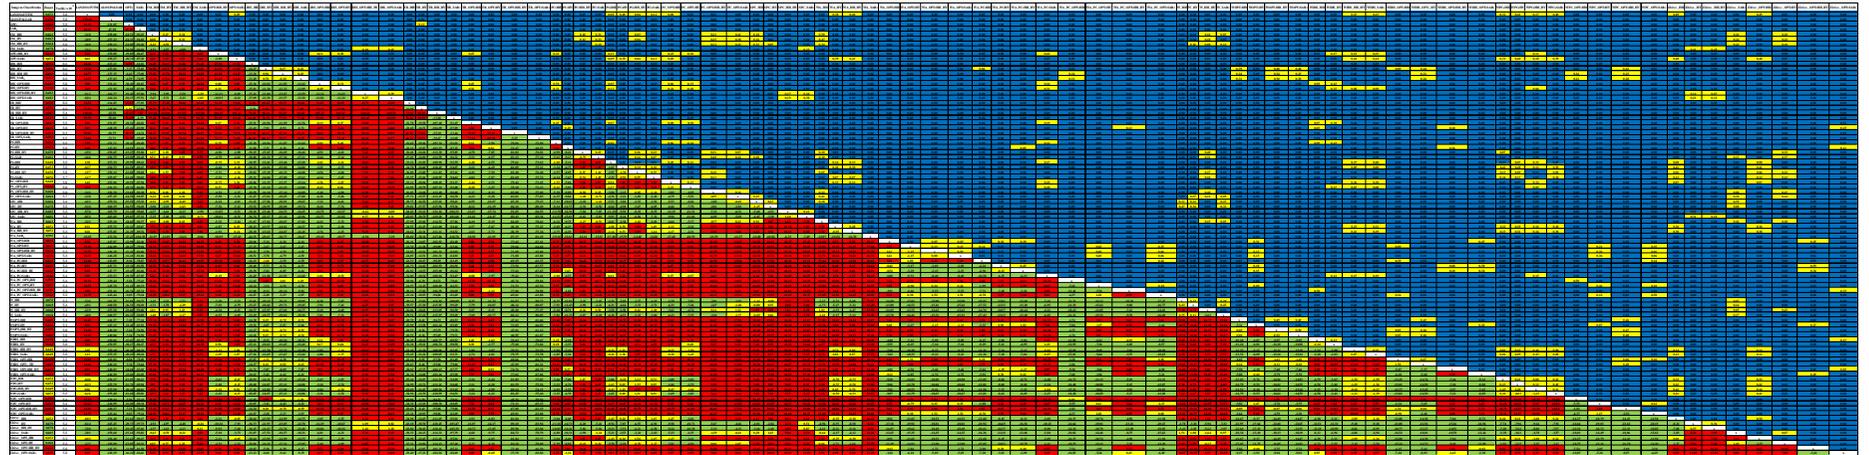


Figura E.30 - Gráfico dos pares dos atributos imagem fração vegetação e imagem fração sombra. Tomando como base estes 2 atributos é possível de separar, visualmente, 8 classes.

**APÊNDICE F – TESTES DE HIPÓTESE Z ENTRE OS PARES DE *KAPPAS*  
DAS IMAGENS CLASSIFICADAS.**

No Apêndice F são mostrados os valores da estatística  $z$  (triângulo inferior) e valores- $p$  (triângulo superior) dos testes de hipótese entre os pares de classificações. Os valores- $p$  acima de 0,05 indicam que a hipótese de igualdade de classificações é aceita a este nível de significância. Valores- $p$  abaixo de 0,05 e valores  $z$  positivos (negativos) indicam que o valor de *Kappa* da classificação indicada na coluna (linha) é superior ao valor de *Kappa* da respectiva linha (resp. coluna) ao nível de significância  $p/2$ .

Apêndice C - Testes de hipótese z entre os pares de *Kappas* das imagens classificadas



Valor- <i>p</i> maior que 0,05	<i>Kappas</i> Iguais
Valor- <i>p</i> menor que 0,05	<i>Kappas</i> Diferentes
<i>Kappa</i> da classificação da imagem da linha melhor que o <i>Kappa</i> da classificação da imagem na coluna	
<i>Kappa</i> da classificação da imagem da linha pior que o <i>Kappa</i> da classificação da imagem na coluna	

## APÊNDICE G - REPRESENTAÇÃO DAS MATRIZES DE CONFUSÃO DAS CLASSIFICAÇÕES COM 8 CLASSES DE INTERESSE.

Neste apêndice são mostradas as figuras que representam as matrizes de confusão das classificações selecionadas e das imagens originais com 8 classes de interesse. Nestes gráficos as circunferências são proporcional às porcentagens das amostras de validação classificadas em uma determinada classe, dentro de cada circunferência também é mostrado este valor. Valores inferiores a 5% não são mostrados nestas matrizes. As classes que apresentam notável confusão são destacadas por retângulos nas matrizes. Um exemplo da confusão entre as classes é ilustrado numa região selecionada da imagem.

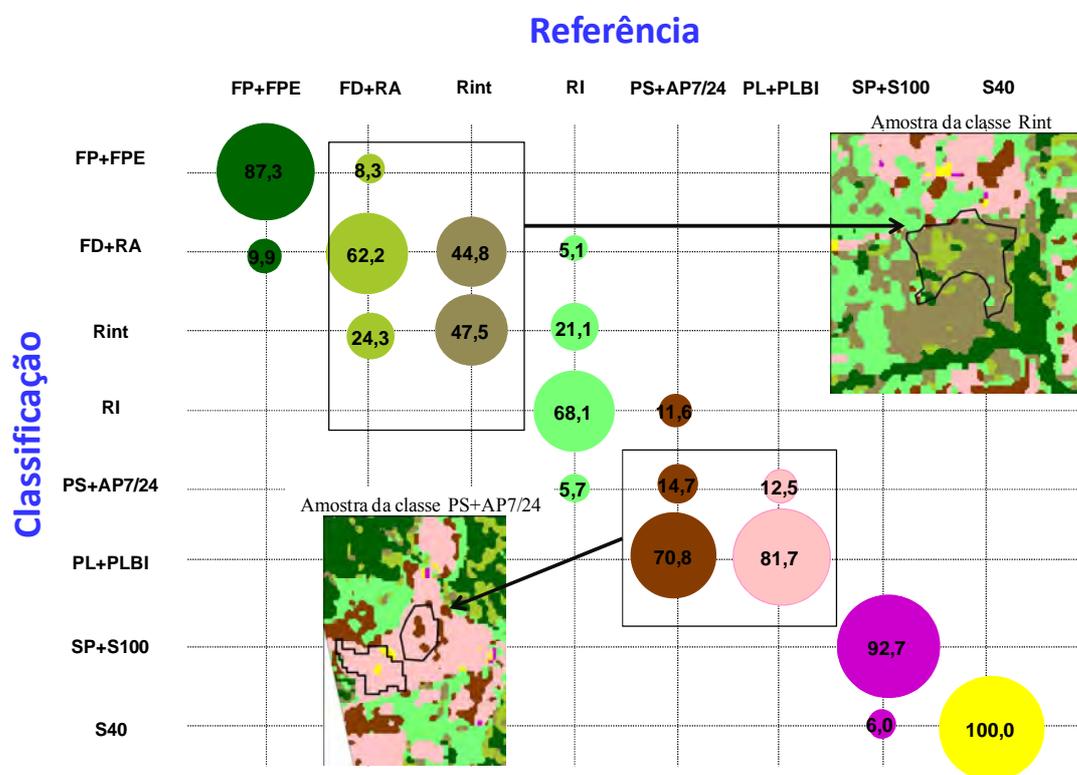


Figura G.1. Matriz de confusão da classificação da imagem LANDSAT5/TM.

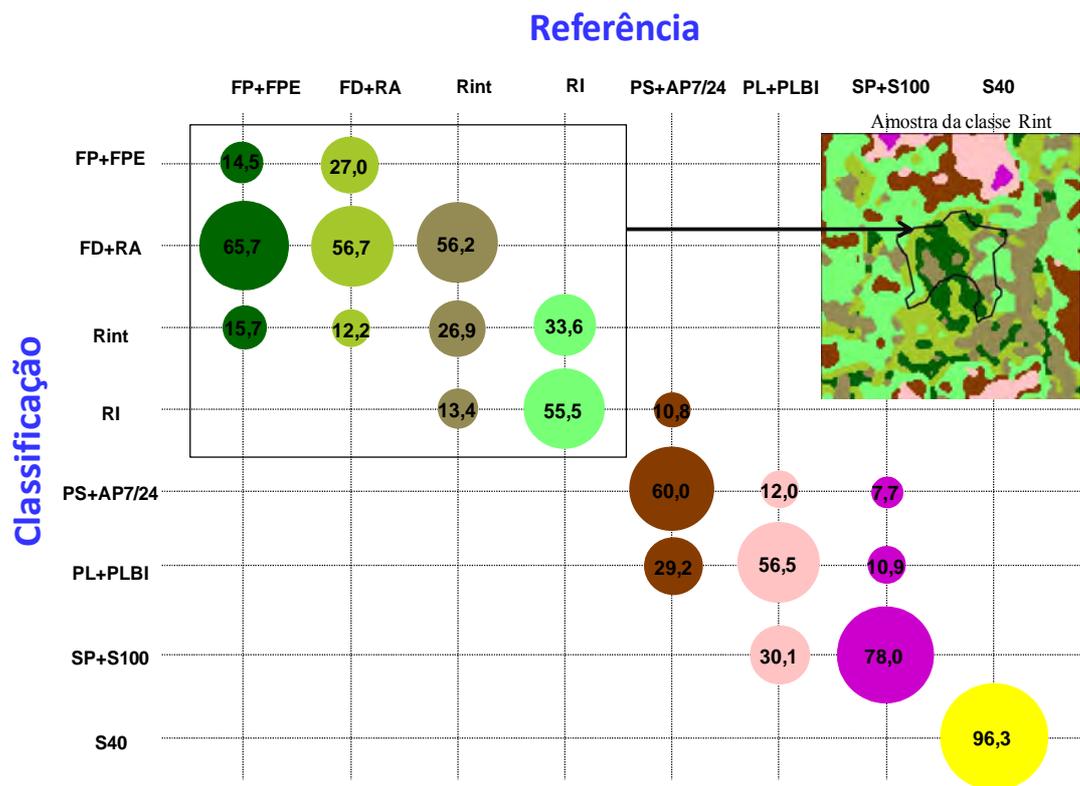


Figura G.2. Matriz de confusão da classificação da imagem ALOS/PALSAR.

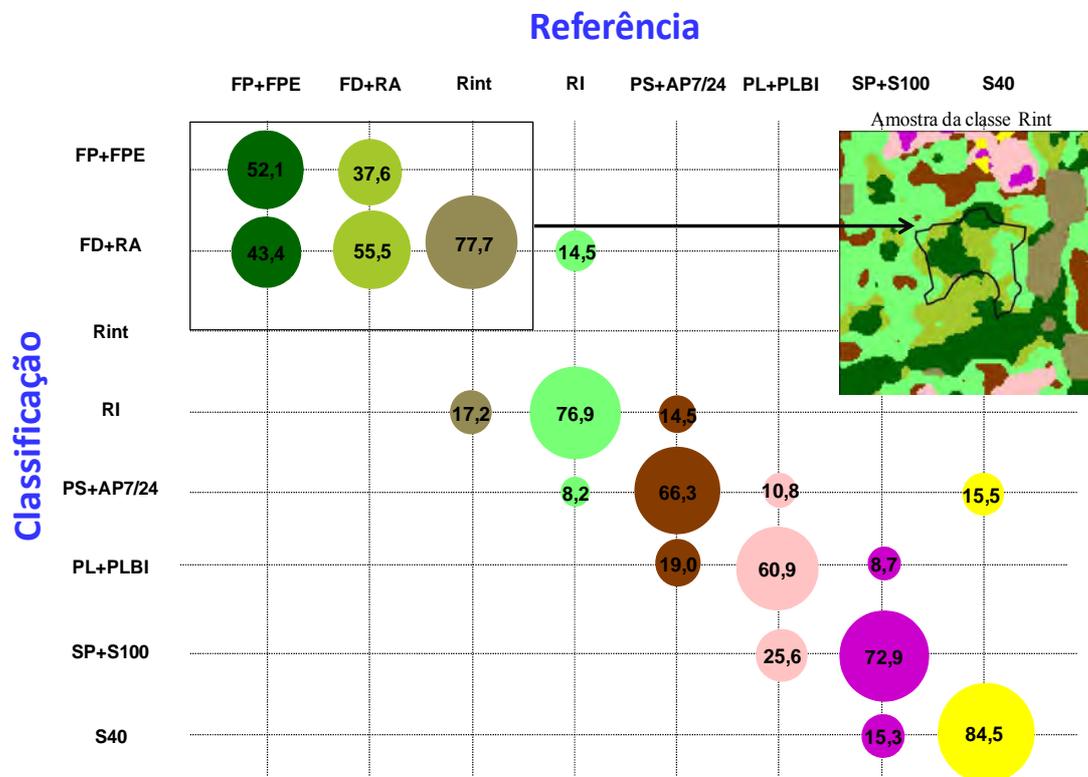


Figura G.3. Matriz de confusão da classificação dos atributos SAR<sub>3</sub>.

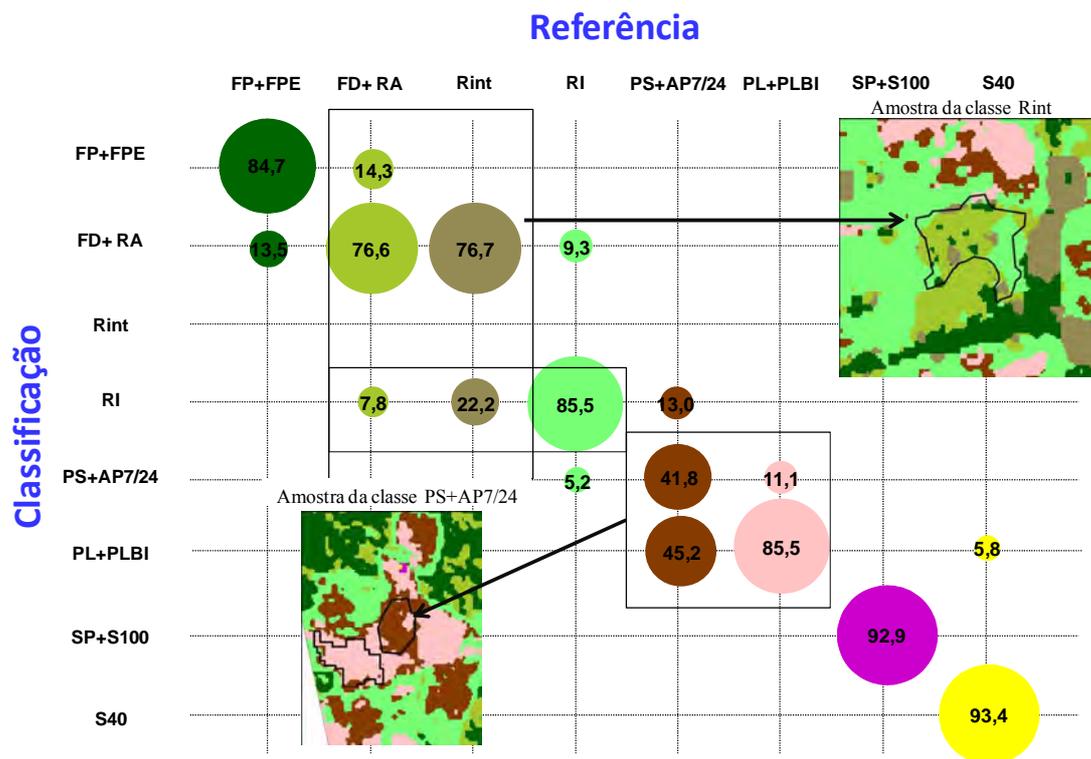


Figura G.4. Matriz de confusão da classificação da combinação TM\_SAR<sub>3</sub>.

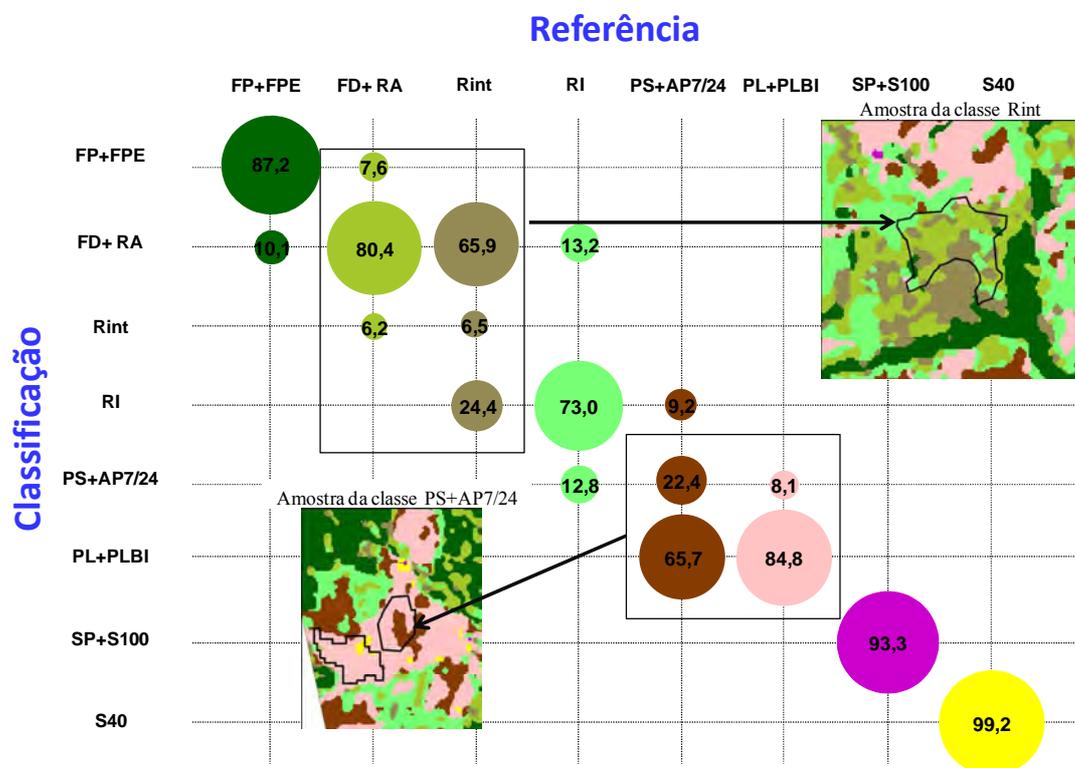


Figura G.5. Matriz de confusão da classificação da imagem WA\_SAR<sub>3</sub>.

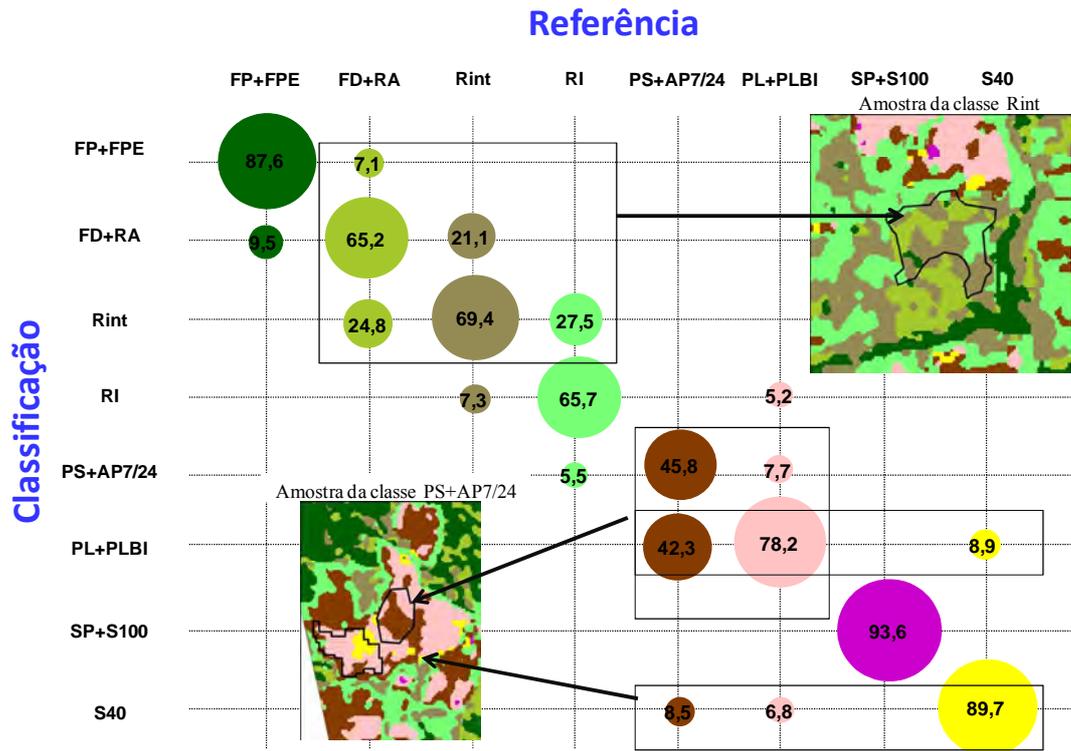


Figura G.6. Matriz de confusão da classificação da imagem SPC\_HH\_HV.

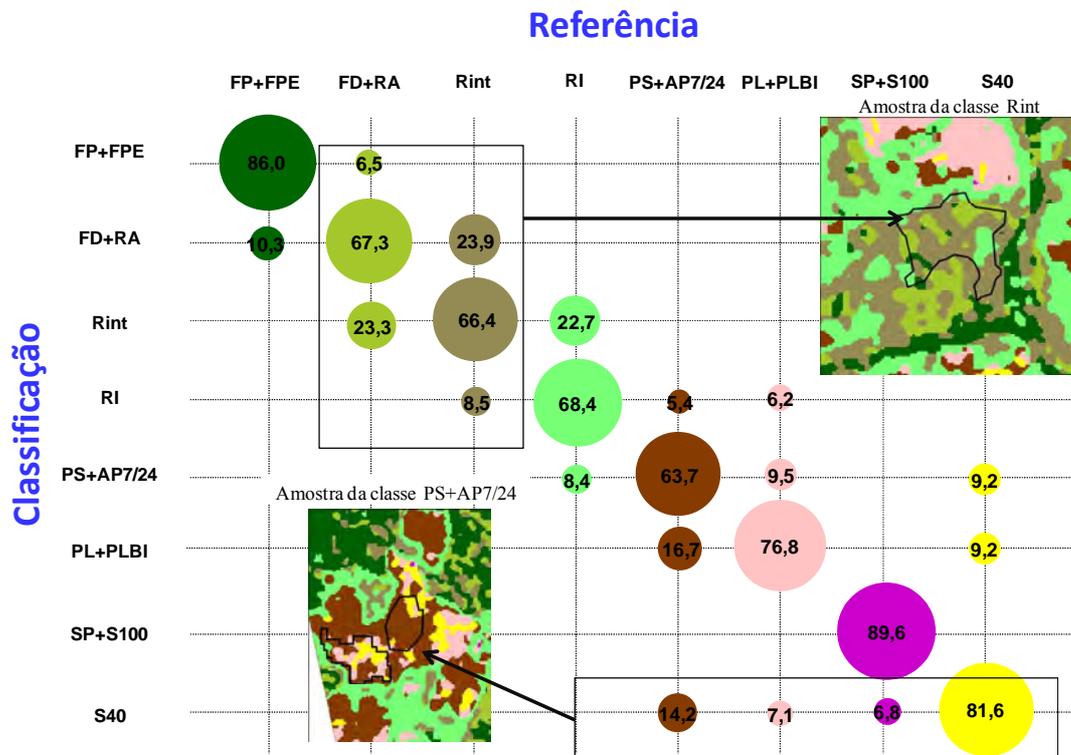


Figura G.7. Matriz de confusão da classificação da imagem IHS\_OPT3HH\_HV.

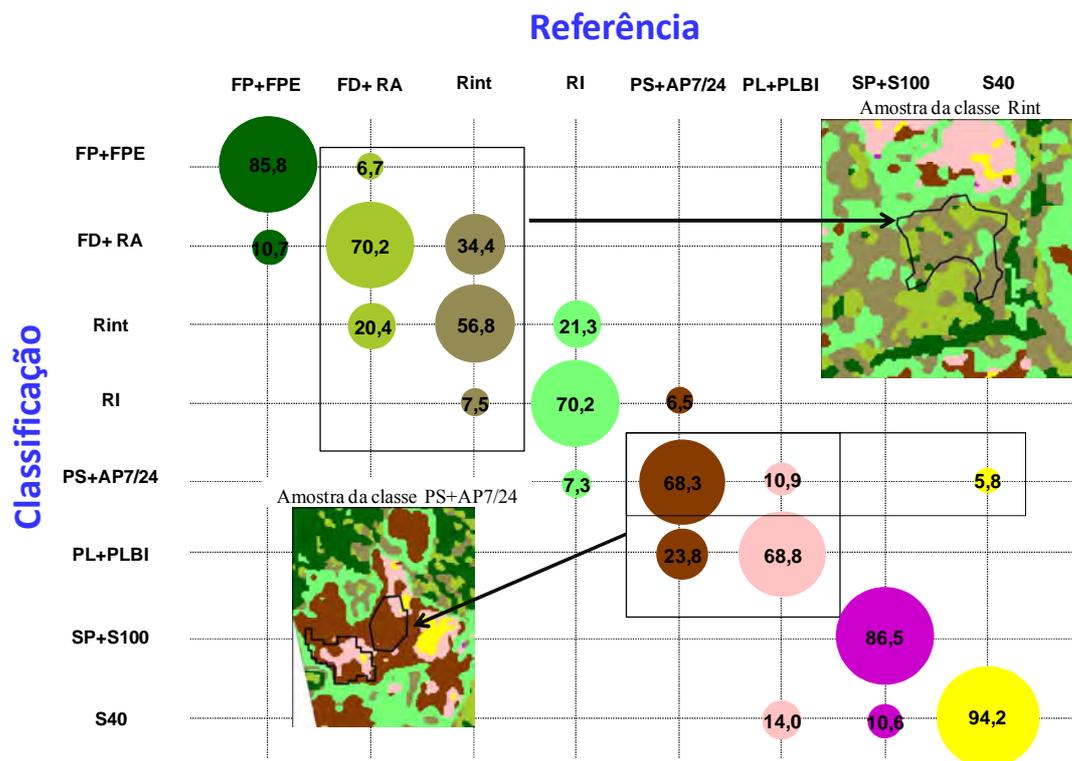


Figura G.8. Matriz de confusão da classificação da imagem IHS\_OPT<sub>3</sub>SAR<sub>3</sub>.

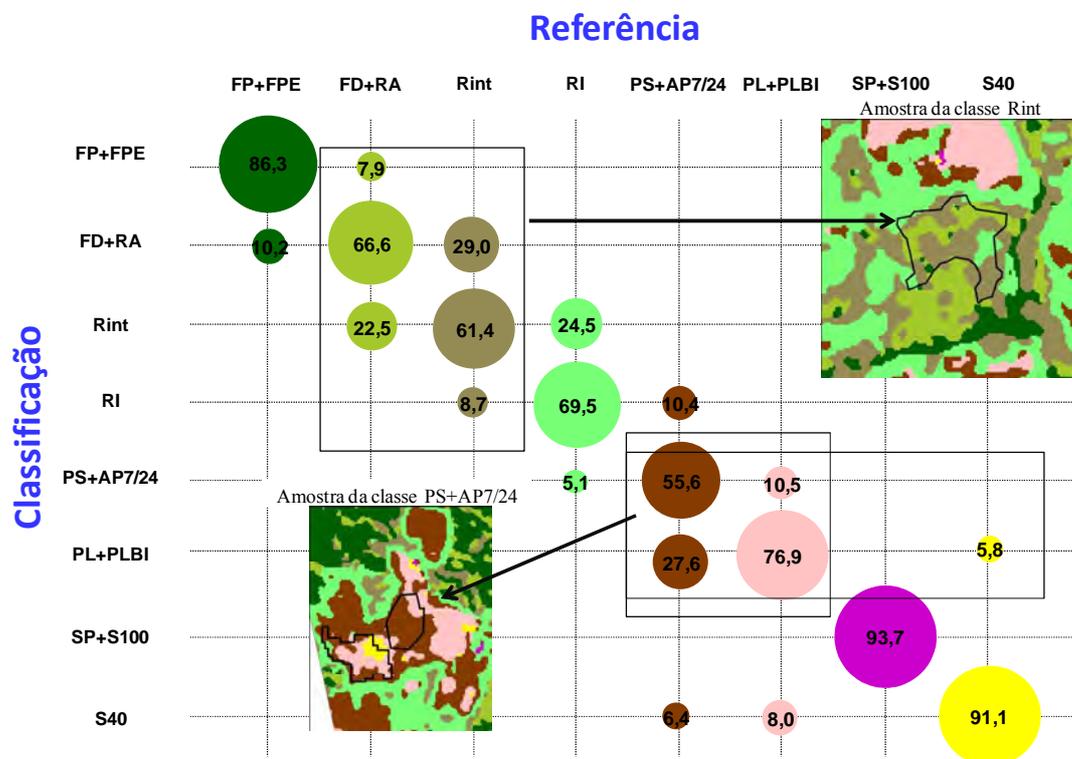


Figura G.9. Matriz de confusão da classificação da imagem SPC\_SAR<sub>3</sub>.

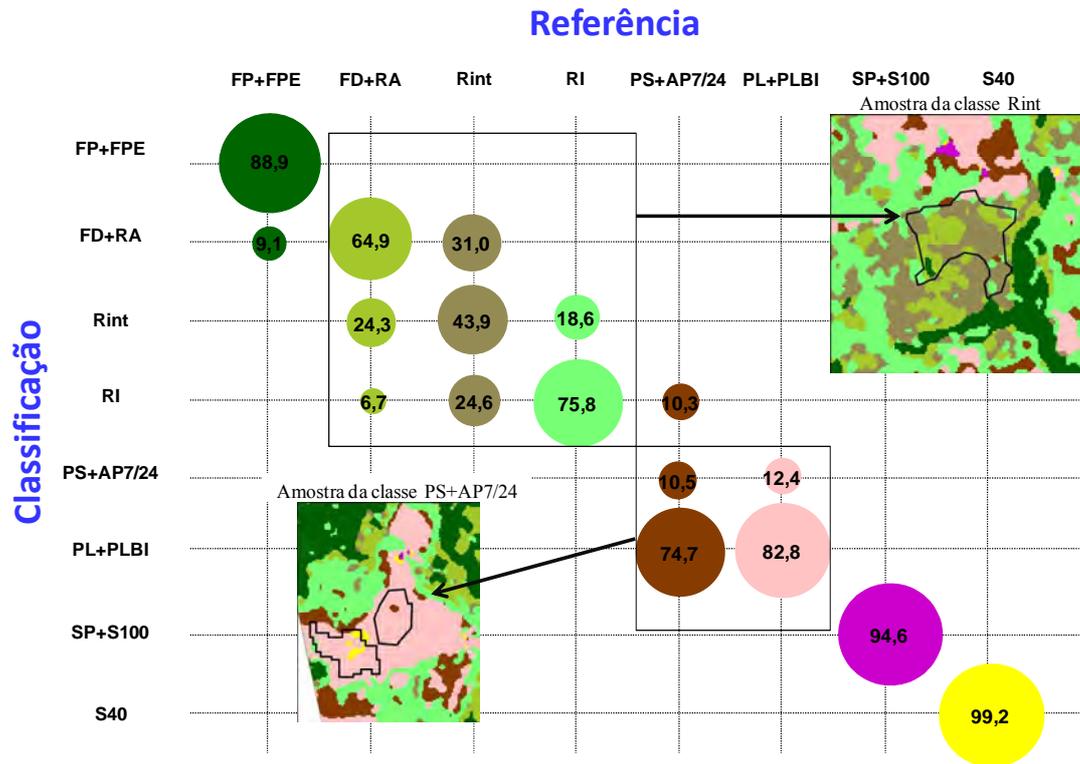


Figura G.10. Matriz de confusão da classificação da imagem Ehlers\_HV.

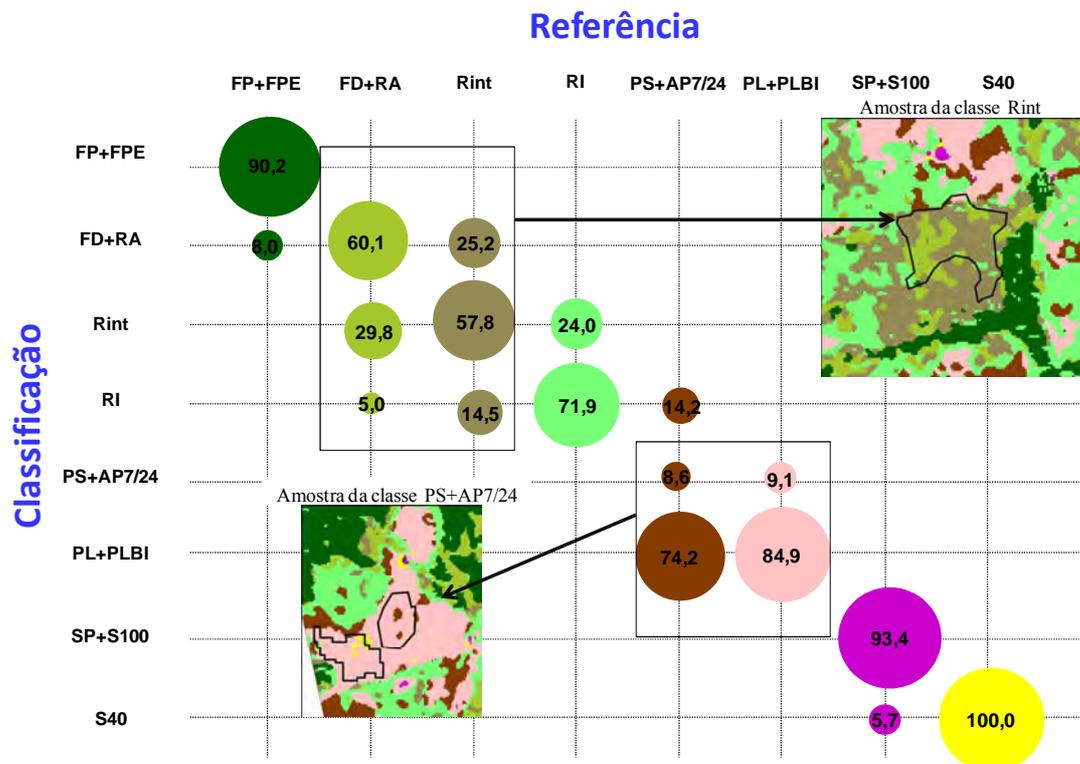


Figura G.11. Matriz de confusão da classificação da imagem Ehlers\_HH\_HV.

## APÊNDICE H - REPRESENTAÇÃO DAS MATRIZES DE CONFUSÃO DAS CLASSIFICAÇÕES COM 6 CLASSES DE INTERESSE

Neste apêndice são mostradas as figuras que representam as matrizes de confusão das classificações selecionadas e das imagens originais com 6 classes de interesse. Nestes gráficos as circunferências são proporcional às porcentagens das amostras de validação classificadas em uma determinada classe, dentro de cada circunferência também é mostrado este valor. Valores inferiores a 5% não são mostrados nestas matrizes. As classes que apresentam notável confusão são destacadas por retângulos nas matrizes.

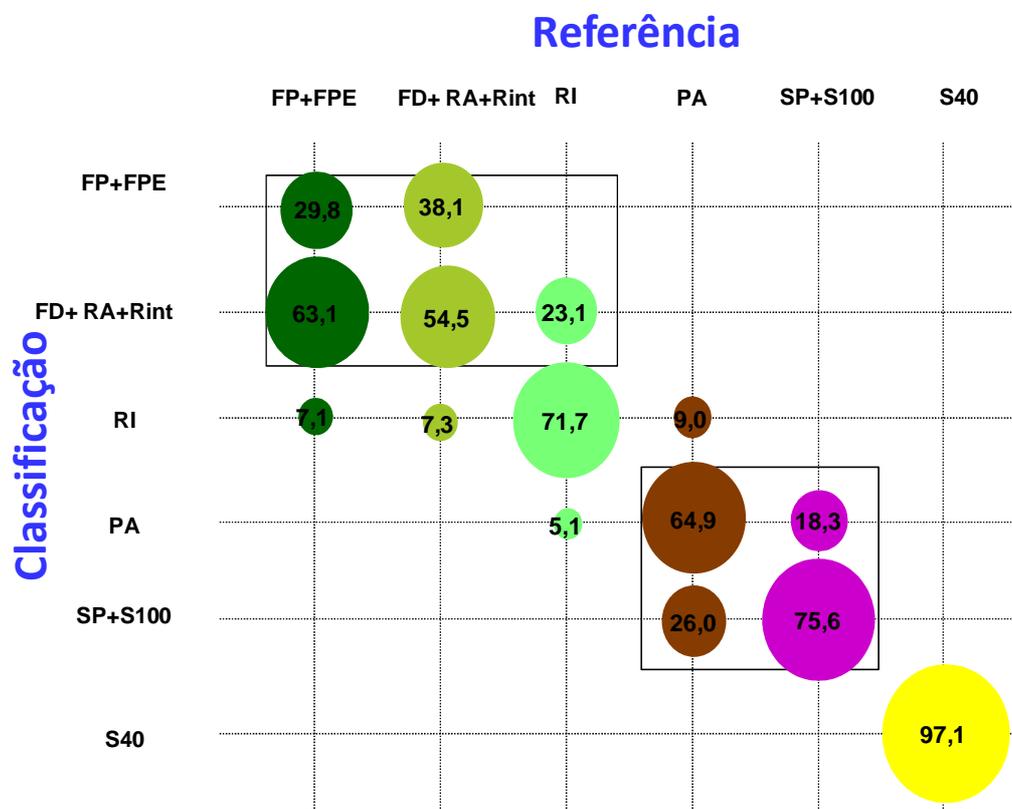


Figura H.1. Matriz de confusão da classificação da imagem ALOS/PALSAR.

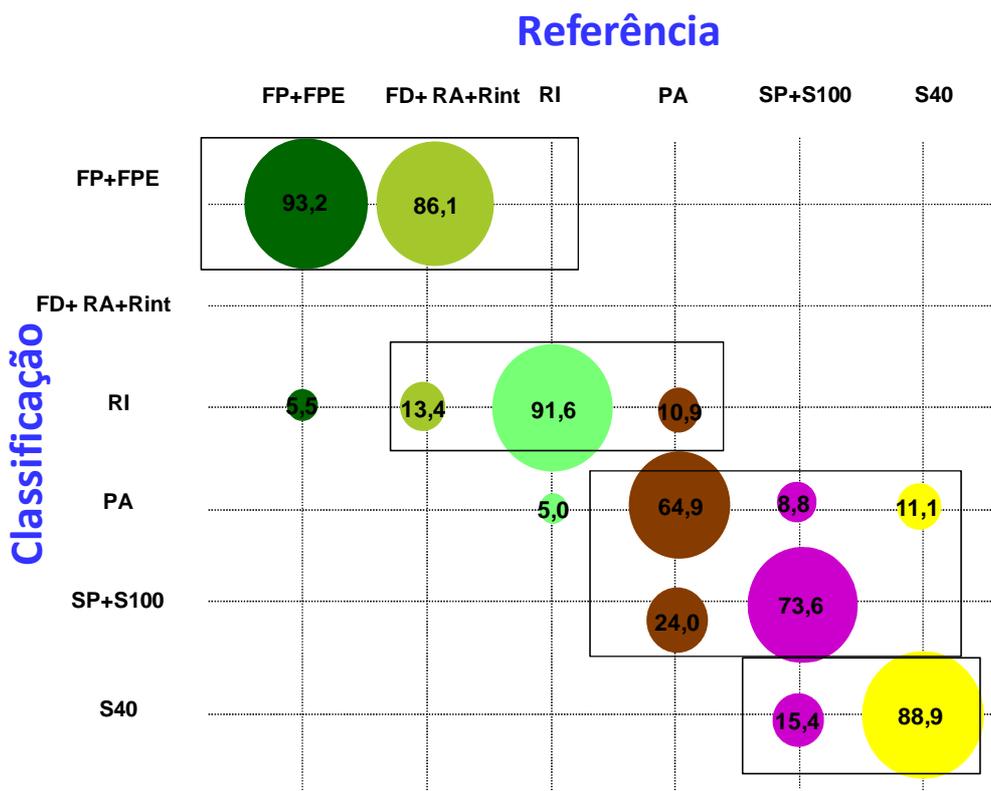


Figura H.2. Matriz de confusão da classificação dos atributos SAR<sub>3</sub>.

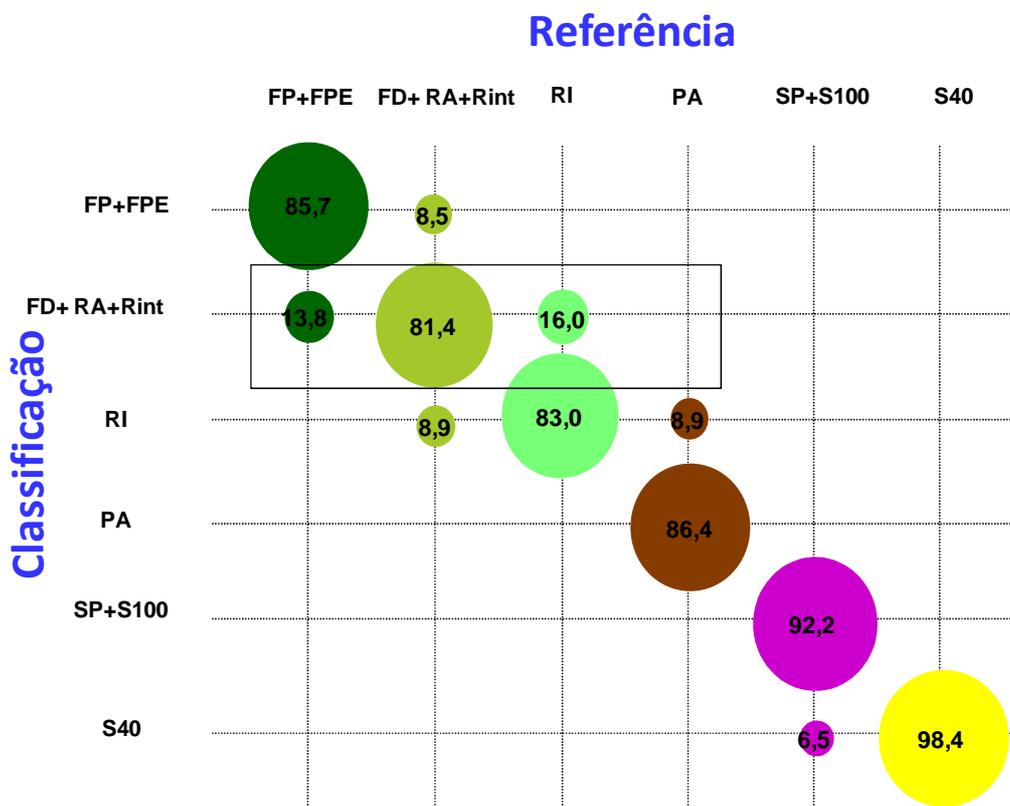


Figura H.3. Matriz de confusão da classificação da imagem LANDSAT5/TM.

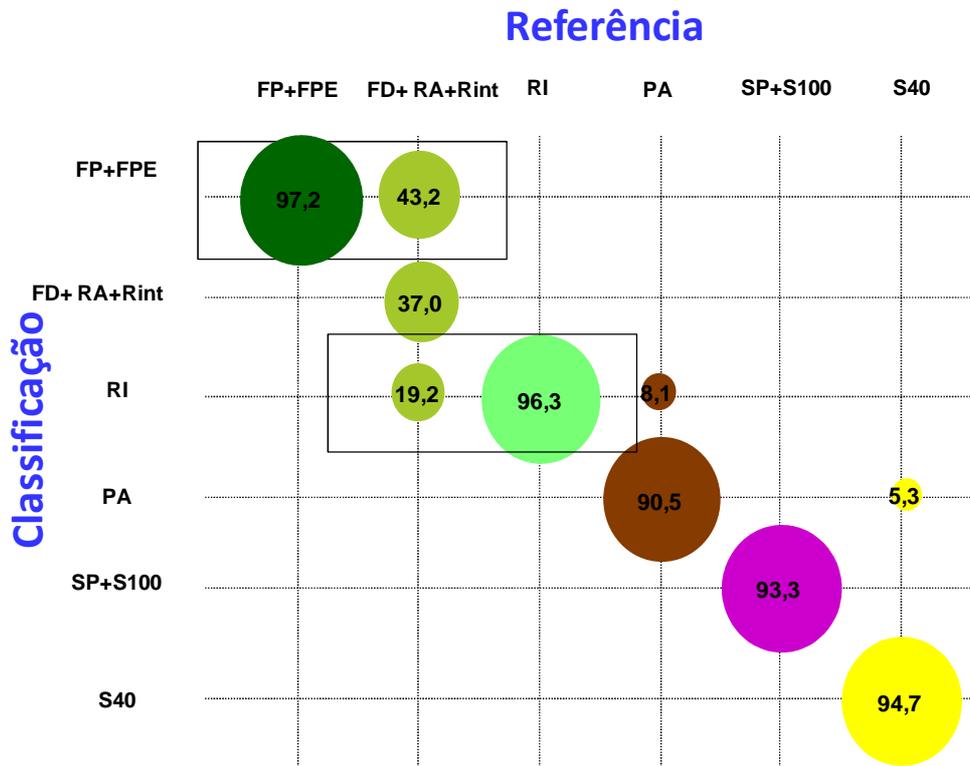


Figura H.4. Matriz de confusão da classificação da imagem *TM\_SAR<sub>3</sub>*.

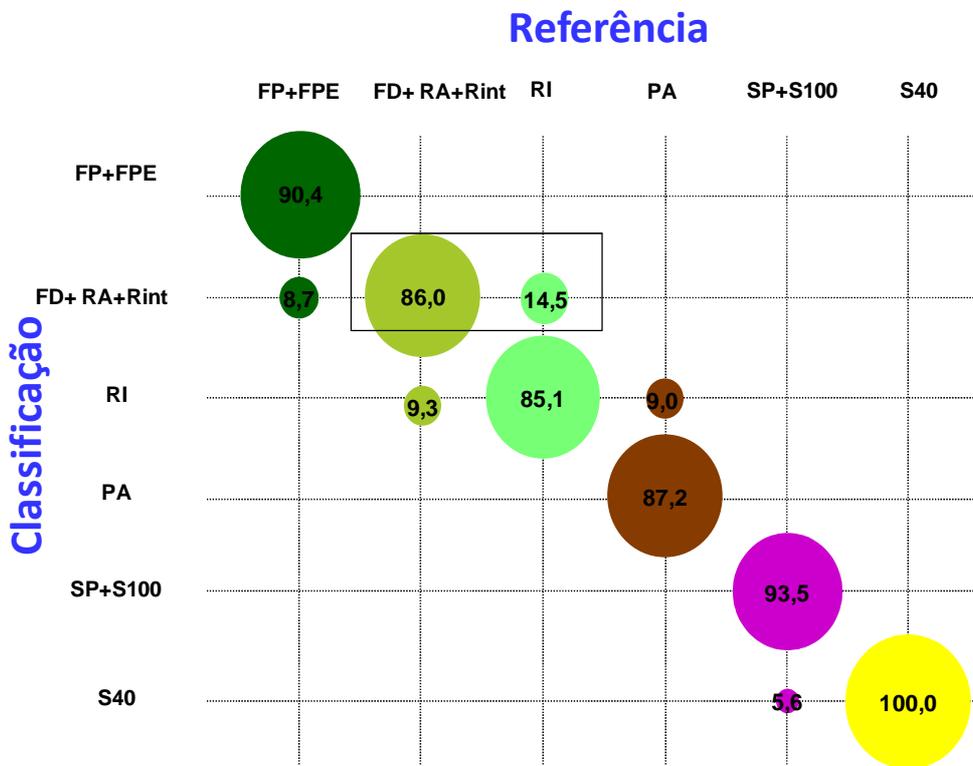


Figura H.5. Matriz de confusão da classificação da imagem *Ehlers\_HH\_HV*.

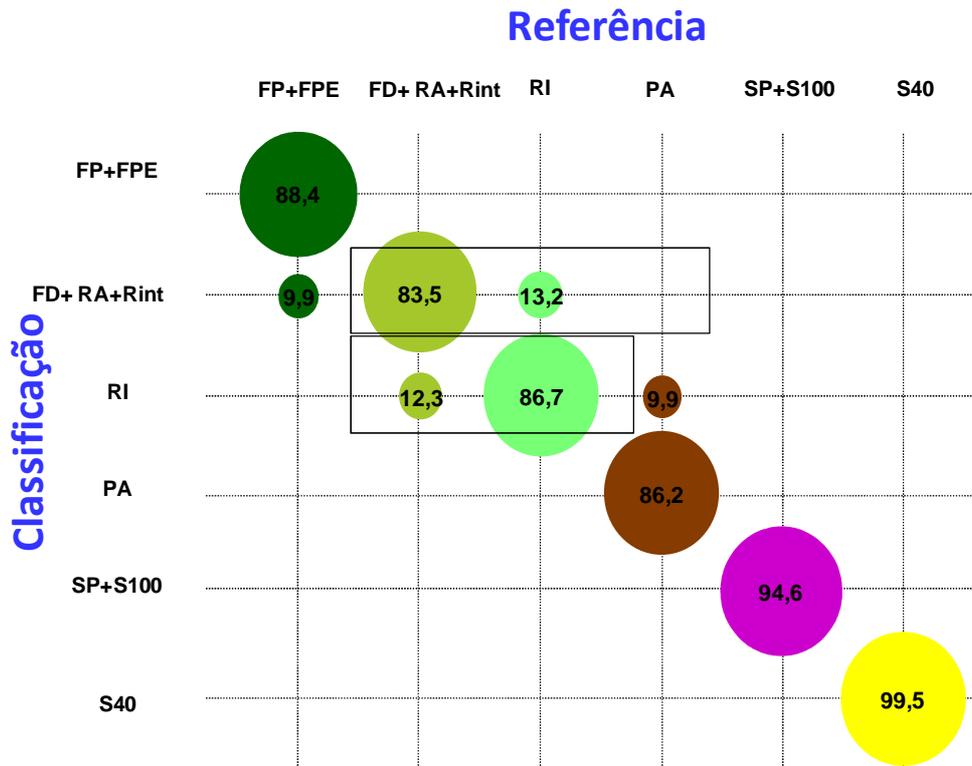


Figura H.6. Matriz de confusão da classificação da imagem *Ehlers\_HV*.

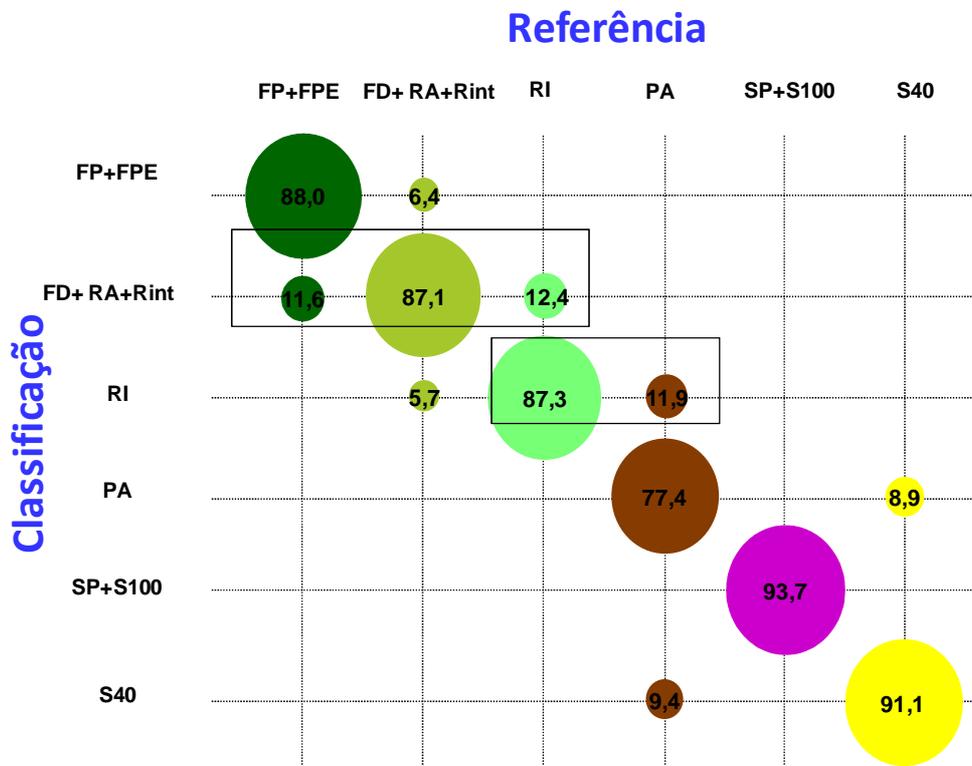


Figura H.7. Matriz de confusão da classificação da imagem *SPC\_HH\_HV*.

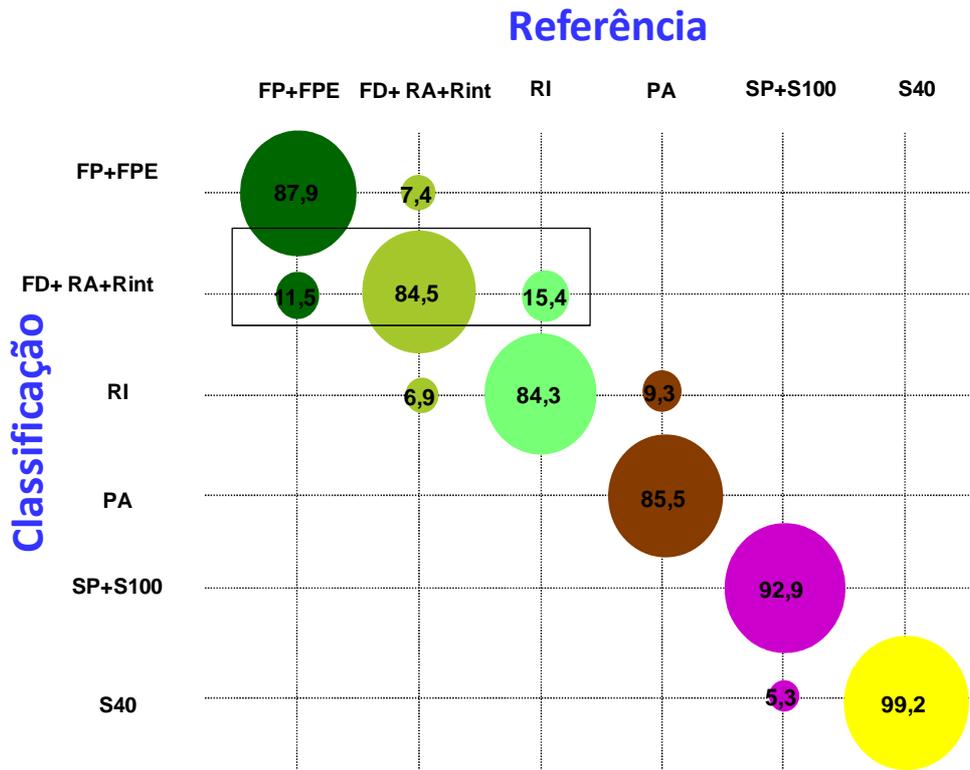


Figura H.8. Matriz de confusão da classificação da imagem WA\_SAR<sub>3</sub>.

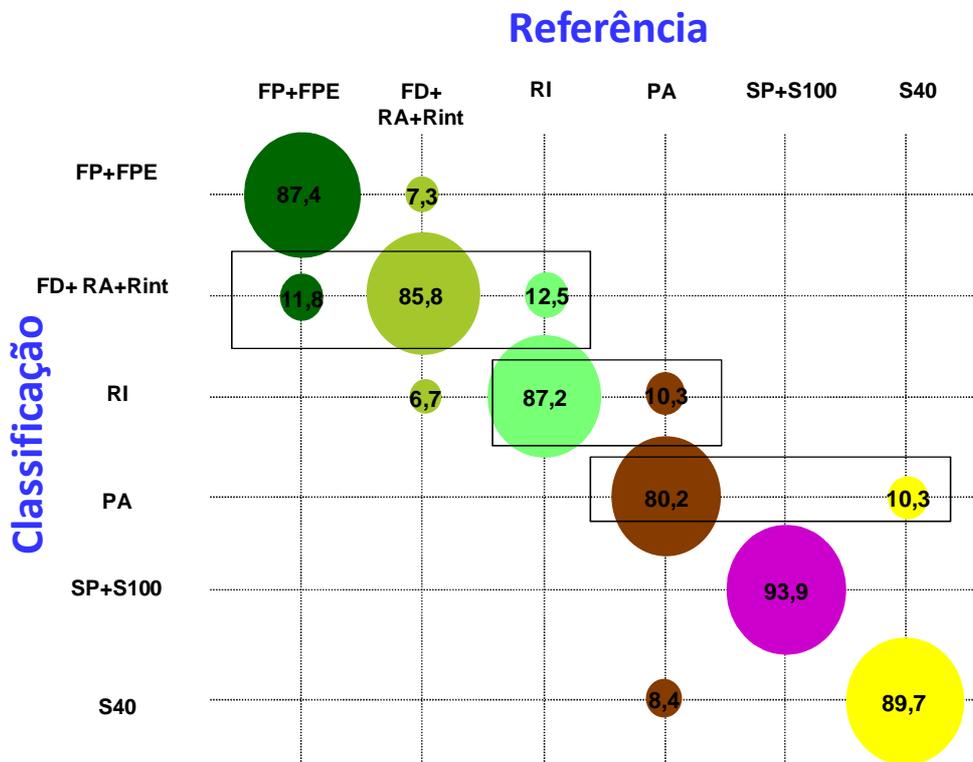


Figura H.9. Matriz de confusão da classificação da imagem SPC\_SAR<sub>3</sub>.

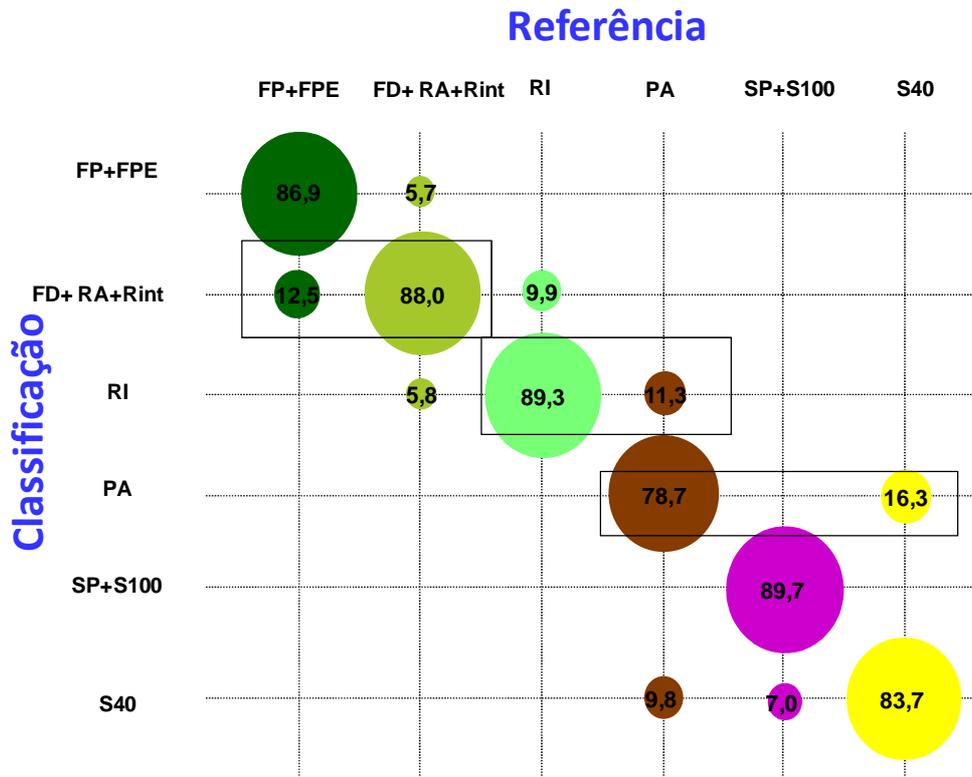


Figura H.10. Matriz de confusão da classificação da imagem IHS\_OPT<sub>3</sub>HH\_HV.

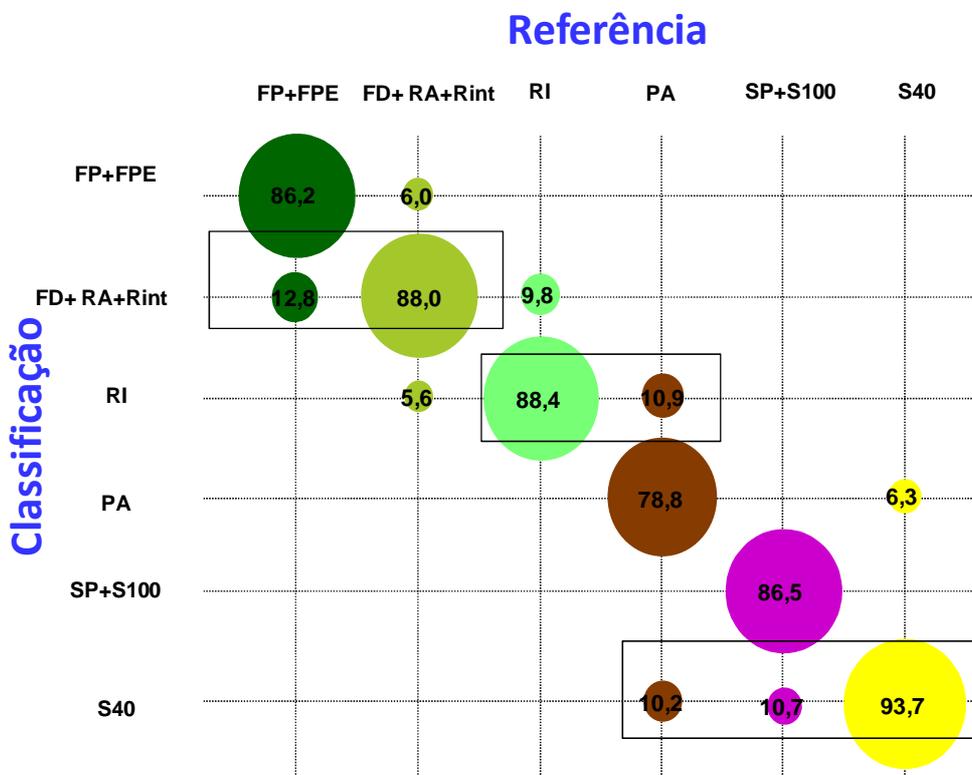


Figura H.11. Matriz de confusão da classificação da imagem IHS\_OPT<sub>3</sub>SAR<sub>3</sub>.