



Ministério da
Ciência e Tecnologia



INPE-16237-TDI/1553

**GERAÇÃO E AVALIAÇÃO DE PRODUTOS
INTERFEROMÉTRICOS DOS DADOS ALOS/PALSAR
FDB E PLR PARA FINS DE CLASSIFICAÇÃO DA
COBERTURA DA TERRA NA REGIÃO AMAZÔNIA**

Daniel Luís Andrade e Silva

Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto,
orientada pelos Drs. Corina da Costa Freitas e Luciano Vieira Dutra, aprovada em
25 de maio de 2009.

Registro do documento original:

<<http://urlib.net/sid.inpe.br/mtc-m18@80/2009/06.01.20.48>>

INPE
São José dos Campos
2009

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) 3945-6911/6923

Fax: (012) 3945-6919

E-mail: pubtc@sid.inpe.br

CONSELHO DE EDITORAÇÃO:**Presidente:**

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

Membros:

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

Dr. Haroldo Fraga de Campos Velho - Centro de Tecnologias Especiais (CTE)

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

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

Dr. Ralf Gielow - Centro de Previsão de Tempo e Estudos Climáticos (CPT)

Dr. Wilson Yamaguti - Coordenação Engenharia e Tecnologia Espacial (ETE)

BIBLIOTECA DIGITAL:

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

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

Jefferson Andrade Ancelmo - Serviço de Informação e Documentação (SID)

Simone A. Del-Ducca Barbedo - Serviço de Informação e Documentação (SID)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

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

Marilúcia Santos Melo Cid - Serviço de Informação e Documentação (SID)

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

EDITORAÇÃO ELETRÔNICA:

Viveca Sant´Ana Lemos - Serviço de Informação e Documentação (SID)



Ministério da
Ciência e Tecnologia



INPE-16237-TDI/1553

**GERAÇÃO E AVALIAÇÃO DE PRODUTOS
INTERFEROMÉTRICOS DOS DADOS ALOS/PALSAR
FDB E PLR PARA FINS DE CLASSIFICAÇÃO DA
COBERTURA DA TERRA NA REGIÃO AMAZÔNIA**

Daniel Luís Andrade e Silva

Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto,
orientada pelos Drs. Corina da Costa Freitas e Luciano Vieira Dutra, aprovada em
25 de maio de 2009.

Registro do documento original:

<<http://urlib.net/sid.inpe.br/mtc-m18@80/2009/06.01.20.48>>

INPE
São José dos Campos
2009

Dados Internacionais de Catalogação na Publicação (CIP)

Silva, Daniel Luís Andrade e.
Si32g Geração e avaliação de produtos interferométricos dos dados
ALOS/PALSAR FDB e PLR para fins de classificação da cobertura da terra na região Amazônia / Daniel Luís Andrade e Silva.
– São José dos Campos : INPE, 2009.
159p. ; (INPE-16237-TDI/1553)

Dissertação (Mestrado em Sensoriamento remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009.

Orientadores : Drs. Corina da Costa Freitas e Luciano Vieira Dutra.

1. Interferometria-SAR. 2. ALOS/PALSAR. 3. Coerência interferométrica. 4. Classificação de cobertura da terra. 5. Tapajós. I.Título.

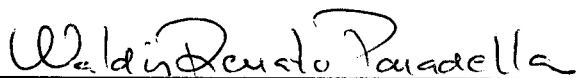
CDU 004.93'1:528.854(811)

Copyright © 2009 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 da Editora, com exceção de qualquer material fornecido especificamente no propósito de ser entrado e executado num sistema computacional, para o uso exclusivo do leitor da obra.

Copyright © 2009 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 the Publisher, 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.

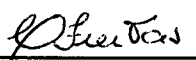
Aprovado (a) pela Banca Examinadora
em cumprimento ao requisito exigido para
obtenção do Título de Mestre em
Sensoriamento Remoto

Dr. Waldir Renato Paradella



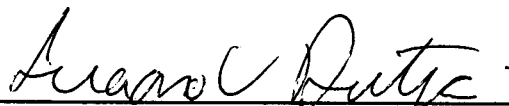
Presidente / INPE / SJCampos - SP

Dra. Corina da Costa Freitas



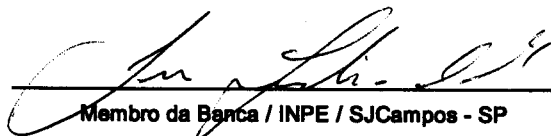
Orientador(a) / INPE / SJCampos - SP

Dr. Luciano Vieira Dutra



Orientador(a) / INPE / SJCampos - SP

Dr. José Cláudio Mura



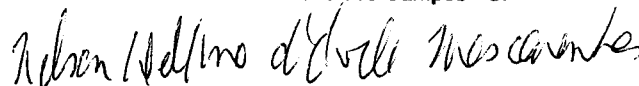
Membro da Banca / INPE / SJCampos - SP

Dr. Yosio Edemir Shimabukuro



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

Dr. Nelson Delfino D'Ávila Mascarenhas



Convidado(a) / UFSCAR / São Carlos - SP

Aluno (a): Daniel Luís Andrade e Silva

São José dos Campos, 25 de maio de 2009

AGRADECIMENTOS

A Deus, por esta gratificante etapa concluída.

À minha querida mãe, Ana Maria Andrade e Silva, por toda uma vida de incentivos.

Aos orientadores Dra. Corina da Costa Freitas e Dr. Luciano Vieira Dutra pela orientação e pela confiança depositada.

Ao Instituto Militar de Engenharia (IME) e à Diretoria de Serviço Geográfico (DSG) pela grande oportunidade que me foi dada de cursar o Mestrado em Sensoriamento Remoto no INPE.

À Agência Nacional de Exploração Japonesa (JAXA) pelo fornecimento das imagens ALOS/PALSAR pelo projeto ALOS-SCIENCE 108.

Aos colegas da “Senzala” pelo companheirismo e pelas inúmeras dúvidas esclarecidas.

Ao pesquisador José Cláudio Mura pelas inúmeras contribuições e pela constante disposição.

À Creaso/Sarmap, pela cessão da licença do software *SARscape*.

Aos colegas da turma SERE – 2007 e de outras turmas contemporâneas por proporcionarem um ambiente de amizade e camaradagem.

RESUMO

Os radares imageadores representam uma das opções do Sensoriamento Remoto no levantamento de recursos naturais e monitoramento do planeta. Entre esses radares está o PALSAR, um dos sensores do satélite japonês ALOS, que permite a realização da técnica de interferometria de passagens repetidas. Empregando-se essa técnica podem ser gerados produtos conhecidos como interferogramas e imagens de coerência interferométrica, os quais possuem como aplicações, respectivamente, a geração de modelos digitais de elevação e a classificação da cobertura da terra. Dentro desse contexto, o objetivo do presente trabalho é gerar e avaliar a qualidade desses produtos interferométricos a partir de imagens complexas do ALOS/PALSAR em diferentes polarizações da Floresta Nacional do Tapajós, adquiridas num intervalo de tempo de quarenta e seis dias. Para o desenvolvimento do trabalho, primeiramente foram realizados processamentos interferométricos a fim de se gerar os produtos desejados, cujas avaliações de qualidade consistiram em testar a potencialidade dos mesmos para classificar cobertura da terra. A avaliação dos interferogramas foi feita visualmente com auxílio das imagens de coerência interferométrica, enquanto estas foram utilizadas tanto isoladamente como em conjunto com imagens-Amplitude para classificações de cobertura da terra usando dois diferentes métodos de classificação supervisionada (máxima verossimilhança acrescida do algoritmo ICM e máquinas de vetores-suporte). Anteriormente às classificações, foram feitas análises exploratórias a fim de se observar o comportamento da coerência interferométrica em cada uma das classes de cobertura da terra e verificar a separabilidade entre elas com base na distância estatística JM (Jeffreys-Matusita). Os resultados obtidos com as classificações foram comparados utilizando-se como parâmetro o coeficiente de concordância *kappa*, que quando analisado com seu desvio-padrão possibilitou fazer testes estatísticos que permitiram verificar a igualdade da acurácia das classificações dado o nível de significância de 0,05. Os resultados das análises e comparações mostraram que a utilização de imagens de coerência interferométrica produz bons resultados de classificação ($k > 0,4$) somente quando realizada em conjunto com imagens-Amplitude. A partir das conclusões dos resultados obtidos, foi possível também estabelecer um comparativo entre as potencialidades interferométricas do ALOS/PALSAR e de outros radares imageadores com diferentes capacidades polarimétricas, tempos de revisita e frequência. Espera-se que este trabalho possa representar uma contribuição aos estudos e pesquisas atuais envolvendo radares imageadores polarimétricos, especialmente os que operam em banda L.

GENERATION AND EVALUATION OF FBD AND PLR ALOS/PALSAR DATA INTERFEROMETRIC PRODUCTS FOR LAND COVER CLASSIFICATION IN AMAZON

ABSTRACT

Imagery radars are options of Remote Sensing in the research of natural resources and monitoring of the planet. Among these radars is the ALOS/PALSAR which belongs to the family of Japanese satellites for observing the continents. One application of this radar is repeat pass interferometry. Employing this technique can be generated products as interferograms and interferometric coherence images, whose applications are, respectively, generation of digital elevation models and land cover classification. In this context, the purpose of this work is to generate and evaluate the quality of interferometric products from ALOS/PALSAR SLC images in different polarizations of Tapajos National Forest, acquired in the time interval of forty-six days. For the development of this work, were initially performed interferometric processing to generate the desired products, whose evaluations of quality consisted of test their potential in land cover classifications. The evaluation of interferograms was made visually based on the interferometric coherence images while these images were used singly and combined with Amplitude images in land cover classifications using two different methods of supervised classification (maximum likelihood added by ICM algorithm and support vectors machine). Before the classifications, exploratory analysis were made for observing the behavior of interferometric coherence in each of the classes of land cover and verification of the separability among them based on JM (Jeffreys-Matusita) statistics distance. The results of classifications were compared using as parameter the Kappa coefficient, that enabled statistical tests to verify the equality of accuracy in classifications by the significance level 0,05. The results of the tests and comparisons showed that interferometric coherence images produces good results for classification ($k > 0,4$) only when combined with Amplitude images. From the conclusions of results, it was also possible establish a comparison between the interferometric potentiality of ALOS/PALSAR and other imagery radars with different polarimetric capabilities, revisits time and frequency. It is hoped that this work can represent a contribution to current studies and researches involving imagery polarimetric radars, especially those operating in L band.

SUMÁRIO

Pág.

LISTA DE FIGURAS

LISTA DE TABELAS

1 INTRODUÇÃO.....	19
1.1 Contextualização e Motivação do trabalho.....	19
1.2 Objetivos do trabalho.....	20
1.3 Contribuição do trabalho.....	21
1.4 Organização do trabalho.....	22
2 FUNDAMENTAÇÃO TEÓRICA.....	23
2.1 Imagens SAR.....	23
2.1.1 Ruído <i>speckle</i>	24
2.1.2 Geometria de aquisição e distorções geométricas.....	25
2.2 Parâmetros que definem a interação das microondas com alvos florestais.....	26
2.3 Interferometria-SAR (InSAR).....	28
2.3.1 Descrição e aplicações.....	28
2.3.2 Processamentos e produtos interferométricos.....	31
2.3.2.1 Co-registros.....	31
2.3.2.2 Interferogramas.....	32
2.3.2.3 Imagens de coerência interferométrica.....	35
2.4 Classificação de imagens SAR.....	40
2.4.1 Classificadores por máxima verossimilhança (MaxVer).....	41
2.4.2 Classificadores por máquinas de vetor-suporte.....	42
2.4.3 Avaliação de classificações.....	43
2.5 O satélite ALOS e o sensor PALSAR.....	47
3 MATERIAIS E MÉTODOS.....	51
3.1 Área de estudo	51
3.2. Imagens ALOS/PALSAR utilizadas.....	52
3.3 Dados auxiliares utilizados.....	55
3.4 <i>Softwares</i> utilizados.....	57
3.5 Procedimentos metodológicos.....	58
3.5.1 Pré-processamentos.....	59
3.5.2 Geração e calibração dos produtos interferométricos.....	63
3.5.3 Conversões <i>slant to ground range</i> e definição de amostras de treinamento e teste.....	65
3.5.4 Classificações supervisionadas.....	72
4 RESULTADOS E DISCUSSÕES.....	79
4.1 Avaliação visual dos interferogramas.....	79

4.2 Análises exploratórias	83
4.2.1 Dados FBD.....	83
4.2.2 Dados PLR.....	91
4.3 Classificações supervisionadas	101
4.3.1 Classificações (MaxVer + ICM).....	103
4.3.1.1 Dados FBD.....	103
4.3.1.2 Dados PLR.....	111
4.3.2 Classificações SVM.....	121
4.3.2.1 Dados FBD.....	121
4.3.2.2 Dados PLR.....	128
4.3.3 Discussões acerca dos resultados das classificações.....	137
5 CONSIDERAÇÕES FINAIS.....	141
5.1 Conclusões do trabalho.....	141
5.2 Sugestões para trabalhos futuros.....	144
REFERÊNCIAS BIBLIOGRÁFICAS.....	145
APÊNDICE A – MATRIZES DE CONFUSÃO.....	153

LISTA DE FIGURAS

	<u>Pág.</u>
2.1 – Soma vetorial das contribuições em amplitude e fase de cada difusor ao sinal SAR retroespalhado.....	23
2.2 – Geometria de aquisição de imagens pelos radares.....	25
2.3 – Conversão de imagem em <i>slant range</i> para <i>ground range</i>	27
2.4 - Modos de aquisição do par interferométrico: (a) uma passagem; (b) duas passagens.....	31
2.5 – Interferogramas dobrados: (a) terreno qualquer; (b) terreno plano.....	34
2.6 - Desdobramentos de fase: (a) unidimensional; (b), (c) bidimensional.....	36
2.7 - (a): Imagem de coerência ERS-1/2 (14 e 15/04/1996); (b) imagem óptica TM (R3G4B5) de 18/03/1996.....	39
2.8 - Satélite ALOS.....	48
2.9 - Design geral do ALOS.....	48
3.1 - Localização geográfica da área de estudo.....	51
3.2 - Esquematização das linhas-base normais estimadas e articulação geométrica das imagens: (a) FBD; (b) PLR.....	54
3.3 – Área de estudo: (a) imagem TM: composição (R5G4B3), data 21/06/2007; (b) imagem SPOT/HRVIR: composição (R2G3B1), data 30/06/2007; (c) imagem FBD: polarização HH, data 13/06/2007; (d) imagem PLR: polarização HH, data 23/04/2007.....	56
3.4 - Fluxograma geral do trabalho.....	58
3.5 – Fluxograma da primeira etapa (Pré-processamentos).....	59
3.6 – Fluxograma da segunda etapa (geração e calibração de produtos interferométricos).....	63
3.7 – Fluxograma da terceira etapa (conversões <i>slant to ground range</i> e definição de amostras de treinamento e teste)	66
3.8 – Dados FBD: Imagens-Amplitude em <i>ground range</i> filtradas: (a) A_{HH1} (13/06/2007); (b) A_{HV1} (13/06/2007); (c) A_{HH2} (29/07/2007); (d) A_{HV2} (29/07/2007).....	67
3.9 – Dados PLR: Imagens-Amplitude em <i>ground range</i> filtradas: (a) A_{HH1} (08/03/2007); (b) A_{HV1} (08/03/2007); (c) A_{VV1} (08/03/2007); (d) A_{HH2} (23/04/2007); (e) A_{HV2} (23/04/2007); (f) A_{VV2} (23/04/2007).....	69
3.10 - Feições representativas das classes de estudo utilizadas: (a) Floresta primária; (b) Floresta modificada; (c) Agricultura; (d) Pastagem; (e) Solo exposto	70
3.11 - Amostras de treinamento e teste	71
3.12 - Fluxograma da última etapa (classificações, análises, comparações e avaliação dos produtos gerados).....	73
4.1 – Composições RGB de interferogramas dobrados: (a) HH1_HH2 (FBD); (b) HH1_HH2 (PLR).....	79
4.2 – Composições RGB de interferogramas removidos de fase plana: (a) e (b) HH1_HH2 (FBD); (c) e (d) HH1_HH2 (PLR).....	80

4.3 – Composições RGB de interferogramas desdobrados: (a) e (b) HH1_HH2 (FBD); (c) e (d) HH1_HH2 (PLR).....	82
4.4 – Dados FBD: imagens de coerência calibradas e seus respectivos histogramas: (a) γ_{HH1_HH2} ; (b) γ_{HV1_HV2}	84
4.5 – Dados FBD: histogramas de coerência para as cinco classes de estudo.....	85
4.6 – Dados FBD: resumo estatístico das classes na imagem de coerência γ_{HH1_HH2}	86
4.7 – Dados FBD: resumo estatístico das classes na imagem de coerência γ_{HV1_HV2}	87
4.8 – Dados FBD: distribuições gaussianas das cinco classes de estudo.....	88
4.9 – Dados PLR: Imagens de coerência calibradas e seus respectivos histogramas: (a) γ_{HH1_HH2} ; (b) γ_{HV1_HV2} ; (c) γ_{VV1_VV2}	92
4.10 – Dados PLR: Histogramas de coerência para as cinco classes de estudo.....	93
4.11 – Dados PLR: resumo estatístico das classes na imagem de coerência γ_{HH1_HH2} ...	95
4.12 – Dados PLR: resumo estatístico das classes na imagem de coerência γ_{HV1_HV2} ...	95
4.13 - Dados PLR: resumo estatístico das classes na imagem de coerência γ_{VV1_VV2}	95
4.14 – Dados PLR: distribuições gaussianas das cinco classes de estudo.....	98
4.15- Dados FBD: intervalos de confiança de 95% para os coeficientes <i>Kappa</i> das classificações (MaxVer + ICM) das composições univariadas.....	103
4.16 – Dados FBD: resultado da melhor entre as classificações (MaxVer + ICM) das composições univariadas (A_{HV2}), com $\hat{k} = 0,58196$	107
4.17 - Dados FBD: intervalos de confiança de 95% para os coeficientes <i>Kappa</i> das classificações (MaxVer + ICM) das composições bivariadas.....	107
4.18 – Dados FBD: resultados das duas melhores entre as classificações (MaxVer + ICM) das composições bivariadas: (a) ($A_{HV2} + \gamma_{HV1_HV2}$), com $\hat{k} = 0,63724$; (b) ($A_{HH2} + A_{HV2}$), com $\hat{k} = 0,60780$	108
4.19 - Dados FBD: intervalos de confiança de 95% para os coeficientes <i>Kappa</i> das classificações (MaxVer + ICM) das composições multivariadas.....	110
4.20 – Dados FBD: resultado da melhor entre as classificações (MaxVer + ICM) das composições multivariadas ($A_{HH2} + A_{HV2} + \gamma_{HV1_HV2}$), com $\hat{k} = 0,65908$	111
4.21 - Dados PLR: intervalos de confiança de 95% para os coeficientes <i>Kappa</i> das classificações (MaxVer + ICM) das composições univariadas.....	112
4.22 – Dados PLR: resultados das duas melhores entre as classificações (MaxVer + ICM) das composições univariadas: (a) (A_{HH2}), com $\hat{k} = 0,59742$; (b) (A_{HV1}), com $\hat{k} = 0,57509$	114
4.23 - Dados PLR: intervalos de confiança de 95% para os coeficientes <i>Kappa</i> das classificações (MaxVer + ICM) das composições bivariadas.....	116
4.24 – Dados PLR: resultados das duas melhores entre as classificações (MaxVer + ICM) das composições bivariadas: (a) ($A_{HH2} + \gamma_{VV1_VV2}$), com $\hat{k} = 0,73960$; (b) ($\gamma_{HH1_HH2} + A_{HV1}$), com $\hat{k} = 0,72516$	117
4.25 - Dados PLR: intervalos de confiança de 95% para os coeficientes <i>Kappa</i>	

	das classificações (MaxVer + ICM) das composições multivariadas.....	119
4.26 –	Dados PLR: resultado da melhor entre as classificações (MaxVer + ICM) das composições multivariadas ($A_{HH2} + A_{HV2} + A_{VV2} + \gamma_{HV1_HV2}$), com $\hat{k} = 0,76293$	120
4.27 -	Dados FBD: intervalos de confiança de 95% para os coeficientes <i>Kappa</i> das classificações SVM das composições univariadas.....	121
4.28 –	Dados FBD: resultados das duas melhores entre as classificações SVM das composições univariadas: (a) (A_{HH2}), com $\hat{k} = 0,48062$; (b) (A_{HV2}), com $\hat{k} = 0,46026$	123
4.29 -	Dados FBD: intervalos de confiança de 95% para os coeficientes <i>Kappa</i> das classificações SVM das composições bivariadas.....	124
4.30 –	Dados FBD: resultado da melhor entre as classificações SVM das composições bivariadas ($A_{HH2} + A_{HV2}$), com $\hat{k} = 0,59301$	125
4.31 -	Dados FBD: intervalos de confiança de 95% para os coeficientes <i>Kappa</i> das classificações SVM das composições multivariadas.....	126
4.32 –	Dados FBD: resultado da melhor entre as classificações SVM das composições multivariadas ($A_{HH2} + A_{HV2} + \gamma_{HV1_HV2}$), com $\hat{k} = 0,627815$	128
4.33 -	Dados PLR: intervalos de confiança de 95% para os coeficientes <i>Kappa</i> das classificações SVM das composições univariadas.....	129
4.34-	Dados PLR: resultado da melhor entre as classificações SVM das composições univariadas (A_{HV1}), com $\hat{k} = 0,60744$	130
4.35 -	PLR: intervalos de confiança de 95% para os coeficientes <i>Kappa</i> das classificações SVM das composições bivariadas.....	132
4.36 -	Dados PLR: resultados das duas melhores entre as classificações SVM das composições bivariadas: (a) ($A_{HV1} + \gamma_{HH1_HH2}$), com $\hat{k} = 0,68905$ (b) ($A_{HV2} + \gamma_{HH1_HH2}$), com $\hat{k} = 0,67302$	133
4.37 -	Dados PLR: intervalos de confiança de 95% para os coeficientes <i>Kappa</i> das classificações SVM das composições multivariadas.....	135
4.38 -	Dados PLR: resultados das duas melhores entre as classificações SVM das composições multivariadas: (a) ($A_{HH2} + A_{HV2} + A_{VV2} + \gamma_{HV1_HV2}$), com $\hat{k} = 0,77804$; (b) ($A_{HH2} + A_{HV2} + A_{VV2} + \gamma_{HH1_HH2}$), com $\hat{k} = 0,77445$	136

LISTA DE TABELAS

	<u>Pág.</u>
2.1 – Conceitos de \hat{k}	46
3.1 – Principais características das imagens SAR utilizadas.....	53
3.2 – Informações geométricas dos pares interferométricos.....	54
3.3 – Datas e composições RGB das imagens ópticas auxiliares.....	55
3.4 – Parâmetros dos co-registros.....	61
3.5 – Polinômios dos co-registros.....	62
3.6 – Fatores de calibração das imagens de coerência interferométrica.....	65
3.7 – Parâmetros de conversão <i>slant to ground range</i>	67
3.8 – Quantidade de pixels das amostras de treinamento e teste.....	72
3.9 – Combinações entre os atributos Amplitude e Coerência interferométrica para os dados FBD e PLR.....	74
3.10 – Composições univariadas, bivariadas e multivariadas para as classificações supervisionadas.....	75
3.11 – Dados FBD: Valores-p dos testes de normalidade das classes.....	76
3.12 – Dados PLR: Valores-p dos testes de normalidade das classes.....	77
4.1 – Dados FBD: Médias e desvios-padrão de cada histograma (γ_{HH1_HH2}).....	86
4.2 – Dados FBD: Médias e desvios-padrão de cada histograma (γ_{HV1_HV2}).....	86
4.3 – Dados FBD: distâncias estatísticas JM entre as classes para apenas um atributo..	89
4.4 – Dados PLR: Média e desvio-padrão de cada histograma (γ_{HH1_HH2}).....	94
4.5 – Dados PLR: Média e desvio-padrão de cada histograma (γ_{HV1_HV2}).....	94
4.6 – Dados PLR: Média e desvio-padrão de cada histograma (γ_{VV1_VV2}).....	94
4.7 – Dados PLR: distâncias estatísticas JM entre as classes para apenas um atributo..	99
4.8 – Dados FBD: resultados das avaliações das classificações (MaxVer + ICM) para as composições univariadas.....	103
4.9 - Dados FBD: resultados das avaliações das classificações (MaxVer + ICM) para as composições bivariadas.....	106
4.10 - Dados FBD: resultados das avaliações das classificações (MaxVer +ICM) para as composições multivariadas.....	109
4.11 - Dados PLR: resultados das avaliações das classificações (MaxVer +ICM) para as composições univariadas.....	112
4.12 - Dados PLR: resultados das avaliações das classificações (MaxVer +ICM) para as composições bivariadas.....	115
4.13 - Dados PLR: resultados das avaliações das classificações (MaxVer +ICM) para as composições multivariadas.....	118
4.14 - Dados FBD: resultados das avaliações das classificações SVM para as composições univariadas.....	121

4.15 - Dados FBD: resultados das avaliações das classificações SVM para as composições bivariadas.....	124
4.16 - Dados FBD: resultados das avaliações das classificações SVM para as composições multivariadas.....	126
4.17 - Dados PLR: resultados das avaliações das classificações SVM para as composições univariadas.....	128
4.18 - Dados PLR: resultados das avaliações das classificações SVM para as composições bivariadas.....	131
4.19 - Dados PLR: resultados das avaliações das classificações SVM para as composições multivariadas.....	134
4.20 - Resumo dos melhores resultados das classificações realizadas.....	139

1 INTRODUÇÃO

1.1 Contextualização e Motivação do trabalho

Em virtude de apresentarem, em relação aos sensores ópticos, vantagens operacionais tais como o fato de não dependerem da reflexão da iluminação solar e das condições atmosféricas além de possibilitar penetrabilidade das microondas na vegetação, os radares imageadores representam uma das opções do Sensoriamento Remoto no levantamento de recursos naturais e monitoramento do planeta. A análise do cenário de programas espaciais revela uma presença cada vez maior de missões com radares imageadores (PARADELLA, 2005). Entre essas missões, uma das mais recentes foi a responsável pelo lançamento do satélite *Advanced Land Observing Satellite* (ALOS) em 24 de janeiro de 2006.

O ALOS sucede os satélites JERS-1 (*Japanese Earth Resources Satellite-1*) na família dos satélites japoneses de observação dos continentes, possuindo tecnologia aprimorada para ser usado para Cartografia e para o monitoramento e exploração de recursos naturais (JAXA, 2008). Possui três instrumentos imageadores, entre os quais está o *Phased Array type L-band Synthetic Aperture Radar* (PALSAR), que é um radar de abertura sintética que opera em banda L, em diferentes polarizações e que possibilita interferometria de dupla passagem.

Empregando-se a técnica de Interferometria-SAR são obtidos os chamados produtos interferométricos, entre os quais estão interferogramas e imagens de coerência interferométrica, cujas finalidades podem ser respectivamente geração de modelos digitais de elevação interferométricos e uso em classificações de cobertura da terra. O potencial de utilização da interferometria de passagens repetidas apresenta como limitação, em relação à interferometria de passagem única, a ocorrência de descorrelação temporal entre as imagens adquiridas, que é diretamente proporcional ao intervalo de tempo entre as aquisições e que pode comprometer a utilização dos produtos interferométricos para os seus respectivos fins, em virtude da perda de coerência dos sinais retroespalhados pelos alvos entre as duas aquisições.

Dentro de todo esse contexto, em que é considerado o caráter recente e inovador de estudos envolvendo imageamento com o satélite ALOS, em especial no que diz respeito à técnica de Interferometria-SAR sob diferentes polarizações, o presente trabalho trata da avaliação da qualidade de produtos interferométricos gerados a partir de imagens complexas ALOS/PALSAR no tocante à classificação de cobertura da terra, partindo-se da hipótese de que a qualidade de tais produtos para as suas respectivas aplicações não é afetada pela decorrelação temporal causada pelo intervalo de quarenta e seis dias entre as aquisições das imagens.

1.2 Objetivos do trabalho

O objetivo geral desse trabalho é gerar produtos interferométricos a partir de pares de imagens complexas ALOS/PALSAR em polarização dual (FBD – *fine beam dual*) e total (PLR – *polarimetric – quad pol*) adquiridas em passagens repetidas com intervalo de tempo de quarenta e seis dias e avaliar a qualidade dos mesmos para fins de classificação de cobertura da terra na região amazônica.

Os objetivos específicos são:

- verificar a possibilidade de utilização dos interferogramas gerados para gerar modelos digitais de elevação a partir de avaliações visuais.
- analisar o comportamento da coerência interferométrica em cada uma das classes de estudo.
- comparar, nas imagens de coerência e nas imagens-Amplitude geradas, as separabilidades entre as classes de estudo com base na distância estatística JM entre elas.
- avaliar o desempenho das imagens de coerência interferométrica e das imagens-Amplitude geradas para classificar cobertura da terra.
- comparar as potencialidades interferométricas do ALOS/PALSAR com as de outros radares.

Feitas as avaliações visuais dos interferogramas e avaliados os desempenhos das imagens de coerência interferométrica nas classificações de cobertura da terra, poder-se-á então atestar sobre a qualidade dos produtos interferométricos gerados.

1.3 Contribuição do trabalho

O presente trabalho possui um caráter inovador, haja vista que são recentes os trabalhos envolvendo a utilização de imagens ALOS/PALSAR para processamentos interferométricos considerando diferentes polarizações, sendo sua maior contribuição relacionada à abordagem simultânea de todas as polarizações analisadas. Sendo assim, espera-se que esse trabalho possa contribuir com as pesquisas atuais que envolvam estudos e aplicações de radares polarimétricos imageadores nas Geociências, em especial em estudos florestais e aplicações topográficas, ilustrando assim a integração existente entre o Sensoriamento Remoto e outras áreas do conhecimento científico.

Como existem outros trabalhos (TAKEUCHI e OGURO, 2003; GABOARDI, 2002) envolvendo produtos interferométricos de outros radares (JERS-1 e ERS-1/2) que operam em frequências e tempos de revisita diferentes, é possível comparar, para fins de classificação de cobertura da terra de áreas florestadas, os efeitos da decorrelação temporal nas imagens utilizadas nesse trabalho com os efeitos nas imagens dos radares citados anteriormente.

As conclusões acerca das potencialidades interferométricas do PALSAR em regiões florestais, no caso específico deste trabalho a FLONA do Tapajós, poderão servir como base a previsões relacionadas às aplicações interferométricas de futuros radares que venham a ser desenvolvidos.

1.4 Organização do trabalho

Esta dissertação está organizada em cinco capítulos. O Capítulo 2 apresenta toda a fundamentação teórica com os conceitos e as teorias que apóiam o trabalho, especialmente relacionados às características gerais das imagens SAR, à interação das microondas com alvos florestais, à técnica de Interferometria-SAR e aos procedimentos

e avaliação de classificação, além de uma descrição simplificada do sistema imageador ALOS/PALSAR.

No Capítulo 3 é descrita toda a metodologia empregada no trabalho, no tocante à área de estudo, às imagens e aos *softwares* utilizados bem como aos procedimentos metodológicos realizados envolvendo pré-processamentos (recortes, co-registros e filtragens), processamentos interferométricos, as classificações supervisionadas e outros processamentos necessários (conversões de dados e calibrações).

Os resultados obtidos com os processamentos interferométricos e as classificações realizadas, juntamente com suas análises e discussões são mostrados no Capítulo 4.

Finalmente, no Capítulo 5 são feitas as considerações finais, onde são apresentadas as conclusões e algumas sugestões para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Imagens SAR

Cada célula de resolução numa cena imageada possui inúmeros difusores que interagem com o sinal recebido. Cada um destes difusores faz retornar à antena um sinal de amplitude e fase arbitrárias, que irão se somar vetorialmente formando uma amplitude e uma fase resultantes, conforme ilustrado na Figura 2.1. Com isso fica mostrada a natureza coerente do sinal resultante.




Figura 2.1 – Soma vetorial das contribuições em amplitude e fase de cada difusor ao sinal SAR retroespalhado.

Fonte: Almeida (2008).

Cada sinal resultante recebido pelo SAR pode ser armazenado na forma de um número complexo, sendo o argumento desse número igual ao valor nominal da fase do sinal resultante e as partes real e imaginária representando respectivamente as componentes do sinal em fase (I) e em quadratura de fase (Q). O resultado do processamento desses sinais é uma imagem complexa que recebe o nome de imagem SLC (*Single Look Complex*). O valor de nível de cinza de cada pixel dessa imagem é correspondente ao valor da potência retroespalhada pelos difusores da célula de resolução na cena, sendo que um maior retroespalhamento representa um maior nível de cinza.

A partir de conversões das imagens SLC são geradas imagens-Amplitude (A) e Intensidade (I) de um *look*, conforme as Equações 2.1 e 2.2 (HENDERSON e LEWIS, 1998):

$$A = \sqrt{U_I^2 + U_Q^2} \quad (2.1)$$

$$I = U_I^2 + U_Q^2 \quad (2.2)$$

onde U_I e U_Q representam respectivamente os valores dos pixels nas componentes I e Q.

2.1.1 Ruído *speckle*

Quando uma imagem SAR é obtida através de um *look*, a diferença de níveis de cinza entre pixels adjacentes pode ser muito grande evidenciando o ruído *speckle* na imagem comprometendo assim sua interpretação. Este ruído é consequência da natureza coerente dos sinais resultantes, conforme foi mostrado na Figura 2.1.

O ruído *speckle* deixa um aspecto de “sal e pimenta” nas imagens SAR e prejudica sua interpretação (JENSEN, 2000). Ele não pode ser eliminado, pois é intrínseco ao sistema imageador. Por isso, existem basicamente dois métodos para reduzir seu efeito: técnica *multi-look* e filtragem espacial.

A técnica *multi-look* consiste em dividir o intervalo da abertura sintética em sub-intervalos e para cada intervalo gerar uma imagem. Soma-se as imagens geradas em cada sub-intervalo para gerar uma imagem final com nível de ruído *speckle* atenuado. O inconveniente apresentado por essa técnica é a perda de resolução azimutal. Um maior número de *looks* possibilita uma imagem resultante menos ruidosa, porém com pior resolução azimutal. Dessa forma, a resolução azimutal (ρ_a) de uma imagem SAR gerada com um processamento de n *looks* é dada pela Equação 2.3 (FREITAS et al., 1999):

$$\rho_a = nR_a \quad (2.3)$$

onde n é o número de *looks* e R_a é a resolução azimutal da imagem com um *look*.

Além de formatos complexos, as imagens *multi-look* podem ser representadas na forma de imagens-Amplitude (A) ou Intensidade (I). Uma imagem-Intensidade de “ n ” *looks* é

a média das intensidades de “n” imagens de um *look* enquanto a imagem-Amplitude de “n” *looks* é a raiz quadrada da média das intensidades de “n” imagens de um *look*.

Além da técnica *multi-look*, diversos filtros espaciais redutores de *speckle* foram propostos a fim de aumentar a razão sinal/ruído (SNR - *signal noise ration*) das imagens SAR. Um exemplo desses filtros é o *Gama*, um filtro adaptativo que altera a imagem ruidosa com base nas estatísticas extraídas localmente em cada pixel, preservando o valor médio e as bordas das imagens. De acordo com CCRS (2007), esse filtro é apropriado para imagens que possuam distribuições estatísticas *Gama* ou derivadas, como por exemplo, raiz da *Gama*, que nas imagens-Amplitude estão associadas a regiões homogêneas tais como áreas agrícolas.

Vários trabalhos (VIEIRA, 1996; FRERY et al. 1997; CORREIA, 1999; FREITAS et al., 2005) abordam as distribuições estatísticas associadas às imagens SAR considerando dados em amplitude, intensidade e complexos para regiões homogêneas, heterogêneas e extremamente heterogêneas.

2.1.2 Geometria de aquisição e distorções geométricas

A seguir, são definidos termos relacionados à geometria de aquisição das imagens SAR, ilustrada na Figura 2.2.

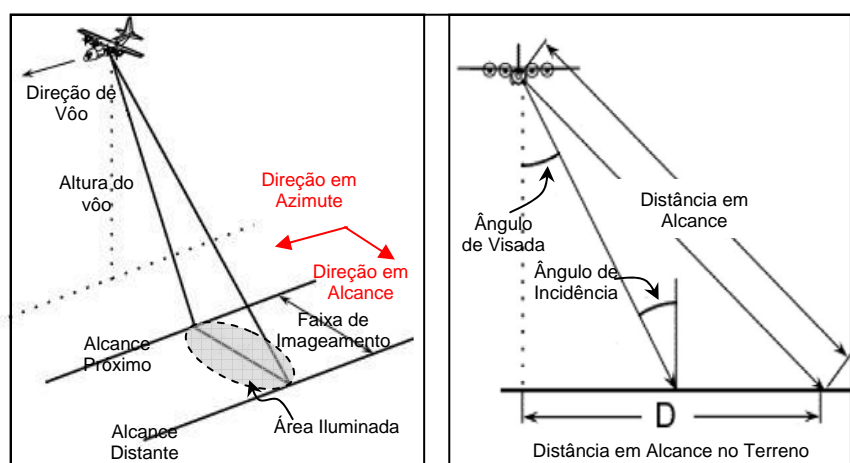


Figura 2.2 - Geometria de aquisição de imagens pelos radares
Fonte: Almeida (2008).

A direção da linha de vôo é chamada de azimutal (em azimute) e a direção ortogonal ou transversal é denominada alcance (*range*). A região mais próxima da plataforma na qual inicialmente a frente de onda incide é chamada alcance próximo (*near range*) e a região mais afastada é denominada alcance distante (*far range*). Estes dois extremos limitam a faixa de imageamento.

O alcance inclinado (*slant range*) de um ponto é a distância inclinada deste ao sensor. Já o alcance no terreno (*ground range*) é o afastamento desse mesmo ponto em relação à projeção da plataforma no solo. O ângulo medido a partir do nadir até um ponto considerado é o ângulo de visada e o ângulo formado pela direção perpendicular à superfície terrestre no mesmo ponto considerado e o feixe incidente do sinal de onda emitido é denominado ângulo de incidência.

Uma observação importante a ser feita em relação ao mecanismo de imageamento com radares diz respeito à geometria de visada lateral, que deve ser sempre utilizada porque se a antena transmissora dos sinais de ondas fosse apontada para nadir, alvos à direita e à esquerda da plataforma afastados igualmente em relação ao sensor não seriam distinguidos, pois seus sinais refletidos retornariam à antena receptora juntos.

A geometria de visada lateral proporciona a aquisição das imagens por uma perspectiva inclinada (*slant range*), causando uma distorção geométrica em virtude do espaçamento dos pixels na faixa imageada em *slant range* não ser o mesmo observado na faixa imageada em *ground range*, havendo compressões nos pixels em *near range*.

A conversão de *slant* para *ground range* consiste em projetar os pixels no solo e depois reamostrá-los com um espaçamento uniforme. Essa conversão devolve aos alvos seu formato original, mas também altera sua estatística (IEAv, 2002). A Figura 2.3 ilustra uma conversão de imagem em *slant range* para *ground range*.

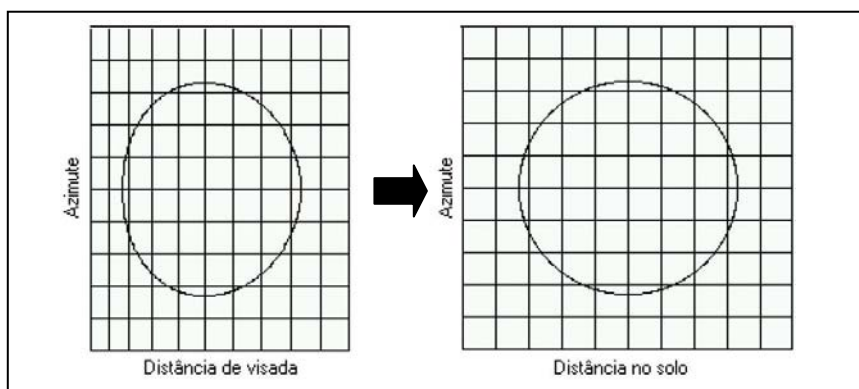


Figura 2.3 – Conversão de imagem em *slant range* para *ground range*

Fonte: Almeida (2008).

Além das distorções geométricas devidas à geometria de visada lateral, existem as distorções decorrentes de variações no movimento da plataforma de imageamento, que podem causar rotação e translação entre as imagens adquiridas em passagens repetidas.

2.2 Parâmetros que definem a interação das microondas com alvos florestais

O registro de uma cobertura florestal em uma imagem SAR é obtido pelo processamento dos sinais resultantes após a interação da energia eletromagnética com os constituintes da floresta (folhas, galhos, troncos e solo). A magnitude do retroespalhamento depende de características dos elementos florestais tais como tamanho, estrutura, densidade, propriedades dielétricas e também de parâmetros de configuração do sistema SAR, como comprimento de onda e polarização incidente.

Le Toan et al. (2002) afirmam que os componentes vegetais que agem como principais fontes de espalhamento são da mesma ordem de magnitude dos comprimentos de onda com os quais interagem. Componentes vegetais menores que os comprimentos de onda incidentes funcionam como atenuadores do retroespalhamento (DOBSON, 2000).

Por isso, pequenos comprimentos de onda (bandas X e C) permitem obter informações sobre as camadas superficiais do dossel vegetal pelo retroespalhamento produzido nas folhas e pequenos galhos. Já comprimentos de onda maiores (bandas L e P) têm uma penetrabilidade maior no dossel vegetal e o retroespalhamento é causado pelos galhos e

tronco (DOBSON, 2000). Dependendo do tipo e condições do dossel, as bandas L e P fornecem informações do solo sob a floresta.

As imagens SAR podem ser obtidas de forma co-polarizada (sinais transmitidos e recebidos na mesma polarização - HH e VV) ou em polarização cruzada (sinais transmitidos e recebidos em diferentes polarizações - HV e VH). No caso de co-polarizações, as microondas interagem com alvos com orientação similar a do pulso emitido. Portanto, os troncos das árvores interagem mais fortemente com a polarização VV, enquanto os galhos (quando orientados horizontalmente) e o solo são componentes de maior interação com a polarização HH.

O interior da copa das árvores é um meio capaz de despolarizar as ondas eletromagnéticas, gerando sinais de retorno numa polarização distinta à emitida. Tal fenômeno, resultante de espalhamentos volumétricos, favorece o aumento do retroespalhamento em polarização cruzada e com isso, imagens em polarizações cruzadas proporcionam uma melhor discriminação dos tipos florestais para todas as frequências (SAATCHI et al., 1997; RIGNOT et al., 1997).

As propriedades dielétricas da vegetação e do solo, afetadas pela umidade, também influenciam o retroespalhamento. Quanto maior a umidade da superfície, maior a constante dielétrica, menor a penetração e atenuação do sinal, e conseqüentemente maior a intensidade da resposta de solos e vegetação (HENDERSON e LEWIS, 1998).

2.3 Interferometria – SAR (InSAR)

2.3.1 Descrição e aplicações

O termo interferometria define uma técnica que mede a interferência entre sinais de ondas envolvendo duas grandezas: amplitude, que é um indicador da intensidade do sinal, sendo representada pelo máximo desvio em altura da onda; e fase, uma grandeza cujos valores estão contidos nos intervalos $[0, 2\pi]$ ou $[-\pi, +\pi]$ e que descreve a direção de movimento e a posição ou o deslocamento de um ponto de vibração no senóide em relação a uma posição de referência (VAN DER SANDEN, 1997).

A técnica interferométrica se baseia na propriedade de que dois sinais de onda coerentes retroespalhados por uma mesma superfície podem, sob certas condições, ser interferometricamente processados. A determinação da fase interferométrica resultante desses processamentos é o princípio fundamental da Interferometria-SAR. Ressalta-se que a fase interferométrica a ser determinada é a diferença de fase entre os dois sinais retroespalhados. Segundo [Lu et al. \(2001\)](#), entre as principais causas das diferenças de fase estão: diferentes geometrias de aquisição, decorrelação temporal, topografia, efeitos climáticos e atmosféricos e os ruídos do sistema imageador.

No início de sua operacionalização, a Interferometria-SAR era voltada principalmente ao mapeamento topográfico, visto que possibilita a determinação da altura topográfica dos alvos, conforme explicado em vários trabalhos ([GRAHAM, 1974](#); [GABRIEL e GOLDSTEIN, 1988](#); [MURA, 2000](#)). Sendo assim, podem ser gerados modelos digitais de elevação (MDE's) com o emprego da técnica de InSAR. Os MDE's obtidos dessa forma são chamados de MDE's interferométricos, que podem ser utilizados também para extrair variáveis geomorfológicas tais como gradiente de declividade, orientação de vertentes, curvatura horizontal e vertical, amplitude altimétrica ([ZALOTI JÚNIOR, 2007](#); [HAYAKAWA et al, 2008](#)).

Um exemplo de utilização de InSAR para geração de modelos digitais de elevação pode ser encontrado no trabalho de [Lanari et al. \(1996\)](#), que geraram interferogramas a partir de imagens complexas SIR-C/X-SAR adquiridas com diferença de um dia e a partir deles obtiveram MDE's monobanda e fusionado (três bandas) do Monte Etna (Itália) sendo posteriormente comparados a um MDE de referência. O MDE fusionado apresentou a melhor precisão entre todos os gerados.

Com o desenvolvimento da Interferometria-SAR diferencial (DInSAR), cujo princípio foi descrito primeiramente por [Gabriel et al. \(1989\)](#), as aplicações interferométricas se expandiram para o monitoramento de fenômenos geomorfológicos como deformações do terreno e deslizamentos de terra.

Além das aplicações já citadas, dados interferométricos podem ser utilizados em classificação de uso e cobertura da terra, detecção de mudanças e também em estimativas de biomassa, conforme mostrado em trabalhos recentes (Santos et al., 2004; Neff et. al, 2005; Gama et al., 2007). A justificativa para a utilização de imagens de coerência interferométrica para classificar uso e cobertura da terra será apresentada na seção 2.3.2.3.

Os processamentos interferométricos são feitos a partir de pares de imagens SAR adquiridas do mesmo terreno, com diferentes geometrias de aquisição, a fim de se gerar os produtos interferométricos desejados (interferogramas ou imagens de coerência interferométrica). Para isso, os pares interferométricos adquiridos devem possuir formatos complexos, com informações de amplitude e fase.

A aquisição de um par interferométrico pode ser feita de dois modos:

a) Utilizando-se duas antenas montadas na mesma plataforma, separadas por uma distância chamada de linha-base (B). Este modo é conhecido como interferometria de uma passagem (*single pass interferometry*) ou passagem única, utilizada principalmente em plataformas aerotransportadas. Neste caso, o sinal eletromagnético é emitido por uma das antenas e o sinal retroespalhado é recebido por ambas, gerando-se ao mesmo tempo as duas imagens SAR da mesma cena. Nesse tipo de aquisição a linha-base é fixa e pode ser medida com precisão, porém o fato de existirem duas antenas a bordo pode muitas vezes constituir uma desvantagem operacional para o emprego desse tipo de interferometria.

b) Utilizando-se uma única antena com duas passagens paralelas sobre a mesma área. Este tipo é chamado de interferometria de duas passagens ou passagens repetidas (*two ou repeat pass interferometry*). Nesse caso a linha-base depende da distância entre as duas passagens, devendo ser calculada a partir dos dados de vôo das respectivas plataformas. Nos SAR's orbitais, a linha-base é calculada a partir dos parâmetros orbitais dos satélites. A limitação desse modo de aquisição é a possível ocorrência de decorrelação temporal entre as imagens.

A Figura 2.4 ilustra os dois modos de aquisição do par interferométrico.




Figura 2.4 – Modos de aquisição do par interferométrico: (a) uma passagem; (b) duas passagens.

Fonte: Mura (2000)

Em ambas as situações, as antenas A_1 e A_2 estão separadas pela linha-base B e distantes do ponto P respectivamente por “ r ” e “ $r + \Delta r$ ”. A relação entre a diferença de fase $\Delta \varphi$ entre os dois sinais de onda recebidos pelas antenas A_1 e A_2 de comprimento λ e a diferença (Δr) entre as distâncias do alvo às antenas A_1 e A_2 é dada pela Equação 2.4:

$$\Delta \varphi = \frac{4\pi}{\lambda} (\Delta r) \quad (2.4)$$

A variação de distância Δr e conseqüentemente a variação de fase $\Delta \varphi$ dependem do comprimento da linha-base B (distância entre A_1 e A_2). Uma linha-base muito pequena faz com que seja detectada uma diferença de fase muito pequena para um mesmo ponto. Se a linha-base for muito grande a fase interferométrica se torna ruidosa devido à decorrelação espacial, causada pelas diferentes geometrias de aquisição (MURA, 2000). Sendo assim, é necessário definir um valor limite para o comprimento da linha-base, conhecido como linha-base crítica (ZEBKER e VILLASENOR, 1992).

Quando a componente perpendicular da linha-base, chamada de linha-base normal, ultrapassa a linha-base crítica nenhuma informação de fase é preservada, a coerência é

reduzida e o produto interferométrico gerado se torna ruidoso. A linha-base normal crítica $B_{n,cr}$ pode ser calculada pela Equação 2.5 (SARMAP, 2008):

$$B_{n,cr} = \frac{\lambda R \operatorname{tg}(\theta)}{2R_{rg}} \quad (2.5)$$

onde λ é o comprimento de onda, R é a distância *near-range* (início da faixa imageada), R_{rg} é a resolução em alcance (*range*), e θ o ângulo de incidência.

2.3.2 Processamentos e produtos interferométricos

2.3.2.1 Co-registros

Adquirido um par interferométrico, os processamentos que permitem obter as fases interferométricas ($\Delta \varphi$) e conseqüentemente gerar interferogramas e imagens de coerência dependem primeiramente de um co-registro preciso do par de imagens complexas adquiridas. A qualidade do co-registro, cuja precisão deve ser inferior a um décimo da dimensão linear do pixel (HELLWICH, 1999), reflete-se diretamente na qualidade final do produto interferométrico (GENS, 1998).

De acordo com Gens e Genderen (1996), o co-registro consiste no reposicionamento dos pixels de uma imagem de ajuste (*slave*) em relação a uma imagem de referência (*master*), de modo que cada pixel represente, em ambas as imagens, a mesma região do terreno e com isso são corrigidas possíveis rotações e translações entre as imagens. Esse reposicionamento pode ser feito em duas etapas: um co-registro grosseiro (*coarse co-registration*) seguido de um co-registro fino (*fine co-registration*) (GENS, 1998; SANTITAMNONT, 1998).

Para imagens orbitais, o co-registro grosseiro pode ser realizado a partir das informações das órbitas do satélite enquanto para o co-registro fino o método automático mais empregado é conhecido como função de correlação cruzada, desenvolvido por Li e Goldstein (1990). Neste método, o co-registro fino é baseado no cálculo do deslocamento ótimo da imagem de ajuste em relação à imagem de referência

que maximiza a correlação entre as mesmas. Esse cálculo é feito a partir de um polinômio obtido com a interpolação dos máximos da função de correlação-cruzada aplicada entre sub-janelas retiradas das duas imagens.

Gabriel e Goldstein (1988) e Lin et al. (1991) citados por Mura (2000) propuseram outros dois algoritmos de co-registro fino, conhecidos respectivamente como método do espectro máximo e método da flutuação média.

2.3.2.2 Interferogramas

As imagens interferométricas (P_{int}) são geradas por processamentos que consistem na multiplicação dos valores complexos dos pixels da primeira imagem, chamada de *master* e representada por P_1 , pelos conjugados dos valores complexos dos pixels da segunda imagem, chamada de *slave* e representada por P_2 . A Equação 2.6 mostra como são obtidos os valores dos pixels das imagens interferométricas (p_{int}) a partir dos valores complexos dos pixels das duas imagens (p_1 e p_2), que são representados matematicamente pela Equação 2.7:

$$P_{\text{int}} = P_1 P_2^* \quad ; \quad p_{\text{int}} = p_1 \cdot p_2^* = A_1 A_2 e^{j(\varphi_1 - \varphi_2)} \quad (2.6)$$

$$p_1 = A_1 e^{j\varphi_1} ; p_2 = A_2 e^{j\varphi_2} \quad (2.7)$$

onde A_1 e A_2 são as amplitudes associadas aos pixels da primeira e da segunda imagem respectivamente e φ_1 e φ_2 são as respectivas fases.

De acordo com a Equação 2.6, os argumentos dos pixels das imagens interferométricas são as fases interferométricas, cuja representação digital é dada pelos interferogramas. Desta forma pode-se dizer que os interferogramas contêm os argumentos das imagens interferométricas. Os valores dos pixels dos interferogramas ($\Delta\varphi_p$) são dados pela Equação 2.8:

$$\Delta\varphi_p = \arg(p_{\text{int}}) = \varphi_1 - \varphi_2 \quad (2.8)$$

O cálculo computacional da fase interferométrica apresenta um resultado modulado limitado em 2π , pois a princípio, os *softwares* para processamentos interferométricos não diferenciam arcos cômgruos, fazendo com que haja um erro na determinação dessa fase, gerando com isso a chamada fase “dobrada”. Por causa do caráter cíclico da fase interferométrica, os interferogramas podem apresentar padrões do tipo franjas, e com isso são chamados de interferogramas dobrados.

A Figura 2.5 ilustra dois exemplos de interferogramas dobrados, sendo um deles relativo a um terreno plano (franjas verticais).

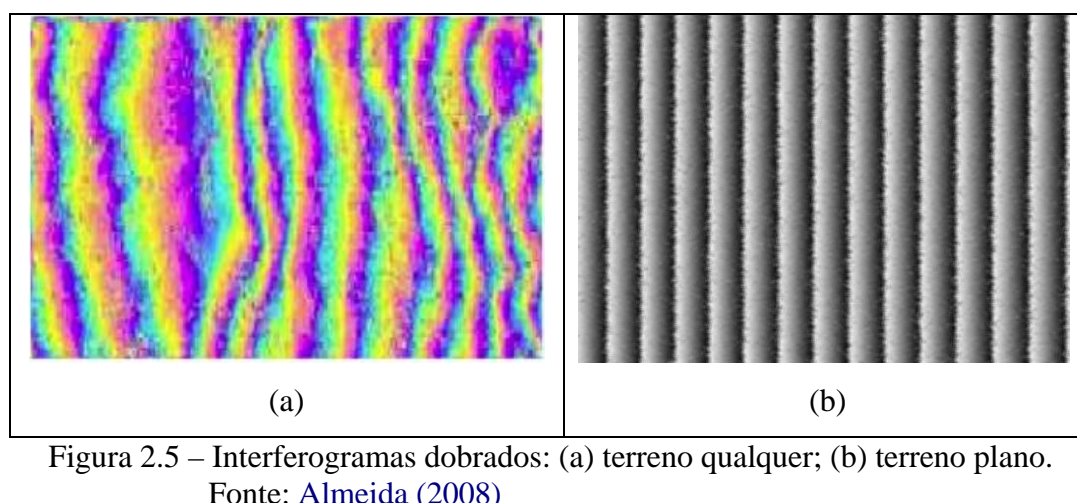


Figura 2.5 – Interferogramas dobrados: (a) terreno qualquer; (b) terreno plano.
 Fonte: Almeida (2008)

A variação das fases interferométricas pode ser visualizada com base no espaçamento das franjas dos interferogramas. Em franjas menos espaçadas as variações observadas em pixels adjacentes são maiores do que em franjas com maior espaçamento, mostrando com isso que houve uma variação mais intensa. O espaçamento (E) ou separação dessas franjas em metros (m) é função do comprimento de onda (λ), da distância inclinada *range* (R) e da linha-base normal (B_n), conforme Equação 2.9 (CCRS, 2007):

$$E[m/ \text{franja}] = \frac{\lambda R}{2B_n} \quad (2.9)$$

Para que a fase interferométrica possa ser utilizada no cálculo de alturas topográficas, e conseqüentemente na geração de modelos digitais de elevação interferométricos, o seu

caráter cíclico limitado em 2π deve ser removido, ou seja, é necessário transformar a fase dobrada em fase absoluta. Essa necessidade de se calcular a fase absoluta implica na execução de um tipo específico de processamento, definido como “desdobramento de fase” (*phase unwrapping*).

Existe na literatura um grande número de algoritmos para a solução do problema de desdobramento bidimensional de fase. Esses algoritmos podem ser divididos em basicamente dois grupos: os que empregam métodos locais para tratar a inconsistência de fase isolando os pontos inconsistentes e os que empregam os métodos globais, baseando-se na integração global dos dados e trabalhando no sentido da minimização do erro global. Entre os métodos locais destaca-se o que utiliza o processo de crescimento de regiões (XU e CUMMING, 1996) e dentre os métodos globais está o método dos mínimos quadrados, que se baseia na minimização da diferença entre a derivada parcial da fase interferométrica antes e depois do desdobramento pela solução da equação de Poisson.

Segundo Mura (2000), técnicas mais recentes procuram tirar vantagens dos dois tipos de métodos, ou seja, a precisão dos métodos locais e a robustez dos métodos globais. Um estudo abrangente, dos métodos de desdobramento de fase, é dado por Giglia e Pritt (1998).

Além do desdobramento de fase, o cálculo da fase absoluta exige ainda outros processamentos intermediários como a remoção da componente de fase plana (*flat earth*) e a calibração de fase (*off-set* de fase). Esses processos são descritos no trabalho de Mura (2000).

A Figura 2.6 ilustra dois tipos de desdobramentos de fase.

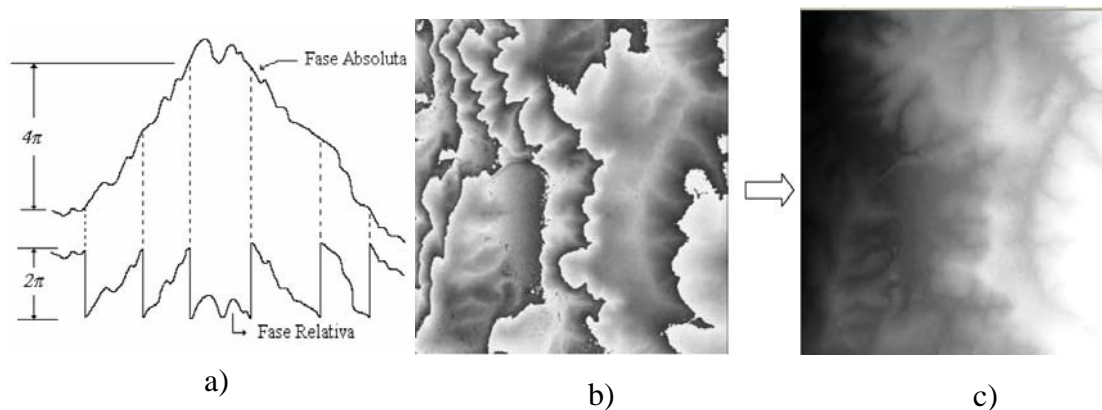


Figura 2.6 – Desdobramentos de fase: (a) unidimensional; (b), (c) bidimensional.
 Fonte: Mura (2000).

2.3.2.3 Imagens de coerência interferométrica

Os interferogramas gerados podem apresentar ruídos, degradando dessa forma a qualidade da informação da fase interferométrica, o que pode comprometer suas aplicações. Para avaliar então se um dado conjunto de dados interferométricos disponíveis é apropriado para aplicações interferométricas, deve-se estimar a coerência interferométrica, que é a medida da correlação da informação da fase correspondente aos sinais que geram cada uma das duas imagens que originam um interferograma (GENS, 1998).

A coerência interferométrica, também chamada de fator de coerência, pode ser representada pelo módulo do coeficiente de correlação complexo, sendo a imagem de coerência interferométrica a representação digital da coerência interferométrica estimada, onde a cada pixel é associado um valor de coerência interferométrica. As Equações 2.10, 2.11 e 2.12 (PAPATHANASSIOU, 1999) definem o coeficiente de correlação complexo e o seu estimador, considerando p_1 e p_2 respectivamente os pixels complexos das imagens 1 (P_1) e 2 (P_2) de um par interferométrico co-registrado e $E[.]$ a esperança ou o valor esperado.

$$\gamma = \frac{E[P_1 P_2^*]}{\sqrt{E[|P_1|^2] E[|P_2|^2]}} \quad (2.10)$$

Como γ é um coeficiente de correlação complexo, pode ser representado na seguinte forma:

$$\gamma = |\gamma| e^{i\theta} \quad (2.11)$$

onde $|\gamma|$ é coerência interferométrica e θ é o argumento do coeficiente complexo.

O estimador do coeficiente de correlação complexo é definido por:

$$\hat{\gamma} = \frac{\langle P_1 P_2^* \rangle}{\sqrt{\langle |P_1|^2 \rangle \langle |P_2|^2 \rangle}}; \quad (2.12)$$

onde $\langle \cdot \rangle$ indica um operador de média espacial das componentes complexas do sinal, então $|\hat{\gamma}|$ é o estimador da coerência interferométrica, tal que $0 \leq |\hat{\gamma}| \leq 1$.

Conforme a Equação 2.12, a estimação da coerência interferométrica em um determinado pixel utiliza uma operação de média espacial móvel a partir de uma janela de “n” x “m” pixels em torno do pixel para o qual se quer estimar a coerência. A janela móvel para a estimação da coerência é chamada filtro *Boxcar*, sendo que tamanhos maiores de janela propiciam estimações menos tendenciosas, porém exigem maior tempo de processamento.

Como uma regra geral, pares interferométricos que apresentam baixa coerência não devem ser utilizados para aplicações interferométricas. Segundo o [CCRS \(2007\)](#), valores de coerência de 0,3 a 0,5 são considerados ruidosos, embora possam ser utilizados, enquanto valores de 0,5 a 0,7 são considerados bons e valores de 0,7 a 1,0 são excelentes. Para aplicações em Cartografia, geralmente são utilizados valores de coerência interferométrica superiores a 0,7.

As imagens de coerência além de ser úteis na verificação da qualidade dos dados interferométricos disponíveis também podem ser utilizadas no processo de auxílio aos algoritmos de desdobramento de fase interferométrica, pois a quantificação da coerência interferométrica determina o nível de ruído existente nos interferogramas gerados. Aos

maiores valores de coerência interferométrica correspondem os menores níveis de ruídos existentes e conseqüentemente, uma melhor qualidade dos produtos interferométricos obtidos.

O valor da coerência interferométrica é relacionado também à razão sinal-ruído (SNR) nas imagens complexas, de acordo com a Equação 2.13 (ZEBKER e VILLASENOR, 1992):

$$|\hat{\gamma}| = \frac{SNR}{SNR + 1} \quad (2.13)$$

Segundo Hanssen (2001), SNR é a razão entre a potência média do sinal recebido (\bar{P}_T) e a potência do ruído (P_n), conforme Equação 2.14:

$$SNR = \frac{\bar{P}_T}{P_n} \quad (2.14)$$

Dessa forma tem-se $\log(SNR) = \log(\bar{P}_T) - \log(P_n)$. As equações que definem \bar{P}_T e P_n podem ser encontradas em Hanssen (2001).

As regiões com baixa SNR como, por exemplo, regiões de água, apresentam baixos valores de coerência, enquanto regiões com alta SNR apresentam altos valores de coerência (áreas mais claras na imagem de coerência).

Além de regiões de água, trechos de vegetação densa podem ocasionar coerências interferométricas baixas enquanto coerências moderadas ou médias podem ser observadas em regiões onde há vegetação em desenvolvimento ou em movimento, como as florestas secundárias ou em regeneração. Valores mais altos de coerências são relacionados às regiões de solo exposto, pastagens, agriculturas, edificações (cidades) e deserto.

Com base nisso, as imagens de coerência interferométrica podem ser usadas, isoladamente ou em conjunto com outros dados SAR e ópticos, em classificações com o objetivo de extrair informações de cobertura da terra em regiões predominantemente florestais, conforme vários trabalhos (NÜESCH et al., 1994; FLOURI et al., 1996;

DUTRA e HUBER, 1999; WEGMÜLLER e WERNER, 1995; SILVA et al., 2008). Segundo Gens e Genderen (1996), há maior separabilidade entre floresta e solo exposto nas imagens de coerência do que nas imagens-Intensidade e Amplitude.

Gaboardi (2002) e Takeuchi e Oguro (2003) mostraram respectivamente que as imagens de coerência ERS-1/2 (banda C) e JERS-1 (banda L) apresentaram bons desempenhos de classificação de cobertura da terra em regiões florestais (respectivamente FLONA do Tapajós e floresta tropical da Ilha de Sumatra/Indonésia) quando utilizadas isoladamente (composição univariada). No caso do trabalho com o JERS-1, quando se acrescentou a imagem-Intensidade à imagem de coerência, gerando uma composição bivariada (Coerência + Intensidade), não foi obtido significativo ganho de qualidade na classificação em relação à classificação univariada.

A Figura 2.7 ilustra uma imagem de coerência interferométrica referente a uma área da Floresta Nacional do Tapajós/PA gerada a partir de um par interferométrico ERS-1/2, com tempo de revisita de um dia (14 e 15/04/1996) e a correspondente imagem óptica TM (18/03/1996) em composição R(3)G(4)B(5).




Figura 2.7 – (a): Imagem de coerência ERS-1/2 (14 e 15/04/1996); (b) imagem óptica TM (R3G4B5) de 18/03/1996. Fonte: Gaboardi (2002).

O valor estimado da coerência é relacionado ao desvio-padrão da fase interferométrica (JUST e BAMLER, 1994). Altos valores de coerência significam que as fases dos sinais retroespalhados são estáveis, traduzindo com isso um espalhamento organizado espacialmente, diferente de um espalhamento volumétrico. Baseado nisso, pode-se concluir que alvos que apresentam espalhamento volumétrico, como as florestas densas, contribuem para baixos valores de coerência.

No caso de interferometria de múltiplas passagens, o deslocamento aleatório dos espalhadores individuais ocorrido entre as aquisições das imagens, devido à decorrelação temporal, reduz a coerência interferométrica (WEGMÜLLER e WERNER, 1997). Sendo assim, pode-se inferir que a decorrelação temporal, conhecida também como “linha-base temporal”, é um dos principais fatores que afetam o valor observado das coerências interferométricas entre imagens adquiridas em passagens repetidas. Como regra geral, supõe-se que a coerência tende a diminuir com o aumento do intervalo de tempo entre as aquisições do par interferométrico.

Segundo Zebker e Villasenor (1992), além da decorrelação temporal a coerência interferométrica depende de outros fatores tais como propriedades do alvo ou objeto imageado, diferenças entre as geometrias de aquisição (ângulos de incidência e linha-base), ruídos inerentes ao sistema imageador, efeitos climáticos e atmosféricos, processamento dos dados interferométricos (aquisição e co-registro), topografia e polarização. Observa-se que todos os fatores que causam diferenças de fase afetam os valores de coerência interferométrica observados.

A coerência interferométrica observada ou estimada pode ser definida como uma função (produto) de todos os fatores citados anteriormente, sendo que cada um deles constitui um chamado fator de coerência, conforme Hanssen (2001), onde são encontradas as fórmulas que definem cada um desses fatores. Ressalta-se que no caso dos pares interferométricos copolarizados, as fases interferométricas não são afetadas pela polarização e em decorrência disso a coerência interferométrica não varia de acordo com a polarização incidente.

Para se analisar apenas a coerência interferométrica devida às propriedades do alvo ou objeto imageado, deve-se fazer uma “calibração” com os valores das coerências observadas, supondo-se constante para toda a imagem de coerência a influência dos outros fatores (topografia, processamento, condições climáticas/atmosféricas, geometria, descorrelação temporal e ângulo de incidência local).

Para a calibração, deve-se aplicar um fator (f_{calib}) a todos os valores de coerência observados. Esse fator de calibração é definido na Equação 2.15:

$$f_{calib} = \frac{1}{\gamma_{obs\ max}} \quad (2.15)$$

onde $\gamma_{obs\ max}$ é o maior valor de coerência observada na imagem, geralmente associado a áreas de pastagem ou solo exposto, que teoricamente deveria ser igual a 1 mas que é alterado em virtude dos fatores citados anteriormente.

Após a calibração, em cada pixel a coerência interferométrica relativa ao objeto imageado (γ_{obj}) se torna igual ao produto da coerência estimada pelo fator de calibração, conforme a Equação 2.16:

$$\gamma_{obj} = (\gamma_{obs})(f_{calib}) \quad (2.16)$$

2.4 Classificação de imagens SAR

A classificação de imagens é um processo de reconhecimento de uma ou várias categorias de objetos do mundo real, a partir dos valores digitais e do arranjo espacial dos pixels (JENSEN, 1996). Sendo assim, a classificação pode ser considerada como uma função que associa cada pixel da imagem a uma determinada classe, rótulo ou categoria de informação. Desta forma, uma imagem numérica com valores digitais (por exemplo, níveis de cinza) é transformada numa imagem temática. Um classificador é um algoritmo no qual está implementada uma determinada função de classificação.

Nas seções 2.4.1 e 2.4.2 são descritos os dois classificadores pontuais supervisionados (dispõem de informações prévias a partir de amostras de treinamento) utilizados nesse trabalho.

2.4.1 Classificadores por máxima verossimilhança (MaxVer)

O classificador MaxVer, cujo algoritmo é baseado na formulação bayesiana e emprega estimadores de máxima verossimilhança, é um dos mais utilizados na classificação automática de imagens de sensoriamento remoto (RICHARDS, 1986; DUTRA e HUBER, 1999) devido ao fato de ser de fácil entendimento e implementação, além de apresentar bom desempenho.

O algoritmo de classificação supõe que cada classe é modelada por uma distribuição de probabilidade, chamada função de densidade de probabilidade, que representa a probabilidade de um determinado pixel pertencer a essa classe. No caso desse trabalho, como foram consideradas distribuições gaussianas, as funções para cada classe foram definidas a partir de parâmetros estatísticos (vetor média e matriz de covariâncias) estimados a partir das amostras de treinamento. Nos trabalhos Vieira (1996) e Correia (1999) são abordadas outras funções de verossimilhança apropriadas para dados SAR, considerando diversos tipos de distribuições estatísticas.

Para classificar um determinado pixel, o algoritmo MaxVer computa o valor da verossimilhança desse pixel pertencer a cada uma das classes e atribui a esse pixel a classe que apresentar o maior valor de verossimilhança calculada. Os limites de classificação são definidos a partir de pontos de mesma probabilidade de classificação de uma e de outra classe, que definem uma região de sobreposição entre as curvas de distribuição.

O critério da máxima verossimilhança não leva em consideração informações contextuais, já que supõe independência entre as observações vizinhas e isso pode levar a resultados não satisfatórios de exatidão da classificação. Em virtude disso, surge a necessidade de se utilizar algoritmos contextuais a fim de refinar os resultados das classificações. Entre esses algoritmos está o ICM (*Iterated Conditional Modes*: Modas

Condicional Iterativas), que é um método iterativo de refinamento de classificação baseado na teoria dos campos Markovianos e que consiste em substituir, a cada iteração, a classe atual associada a cada pixel por aquela que maximiza a distribuição *a posteriori* da classe, dados a radiometria (componente classificação inicial) e as classes vizinhas (componente contextual) (VIEIRA, 1996).

No método empregado nesse trabalho, o algoritmo ICM utiliza para finalizar o processamento o que ocorrer primeiro dos seguintes critérios de parada: 1) ao atingir um nível de convergência determinado pelo usuário (quantidade de pixels modificados na última iteração menor que uma determinada percentagem), ou 2) ao atingir um número máximo de iterações pré-determinado.

2.4.2 Classificadores por Máquina de Vetores Suporte (SVM)

O classificador Máquina de Vetores Suporte (SVM - *Support Vector Machine*) é um método de classificação de imagens baseado em um algoritmo de otimização que, a partir das amostras de treinamento, define hiperplanos de separação ótimos entre as classes maximizando a margem (distância) entre elas. O mapeamento das classes durante a classificação é realizado com base nesses hiperplanos definidos.

Os vetores suporte dos hiperplanos definem a margem de separação das classes e correspondem aos elementos críticos das amostras de treinamento, já que são os pontos que delimitam as superfícies de decisão. No algoritmo SVM podem ser empregadas funções simétricas, chamadas funções *kernel*, que satisfazem a algumas condições com o objetivo de produzir superfícies de separação mais complexas.

O algoritmo SVM pode considerar classes linearmente ou não-linearmente separáveis definindo estratégias multiclasse (regras um-contra-um ou um-contra-todos). Para o caso de classes não-linearmente separáveis, deve ser inserida uma penalidade no algoritmo de classificação permitindo certa tolerância de erro na definição dos hiperplanos de separação, sendo que uma maior penalidade reduz a tolerância ao erro e conseqüentemente os hiperplanos definidos são menos flexíveis, podendo causar problemas de generalização na classificação.

Theodoridis e Koutroumbas (2006) abordam as formulações e as considerações necessárias aos algoritmos SVM para classes linearmente e não-linearmente separáveis.

2.4.3 Avaliação de classificações

Antes de realizar as classificações supervisionadas é possível fazer uma análise a respeito das separabilidades estatísticas entre as classes de estudo, a fim de prever como serão os resultados das classificações. Sendo assim, é fundamental a utilização de algum tipo de medida estatística que forneça o grau de agrupamento ou separação das classes.

Dentre as medidas de distâncias existentes, destaca-se, a de Jeffries-Matusita, também conhecida como distância JM, cuja fórmula para o caso de distribuições estatísticas normais das classes considerando suas médias e covariâncias é apresentada por Theodoridis e Koutroumbas (2006).

A distância JM é determinada a partir de um par de classes, cujo grau de separabilidade se queira medir. É representada por um único número que varia de 0 a 2, e com isso não é necessário visualizar todas as classes simultaneamente, para inferir sobre a respectiva separabilidade das mesmas. Quanto mais próximo de 2, menor a confusão entre as classes, o que acarretará um bom resultado de classificação. Por esse motivo, a distância JM pode ser um indicativo de como será o resultado da classificação supervisionada.

Realizadas as classificações, a avaliação delas é feita com base na análise da exatidão (acurácia) dos resultados gerados. De acordo com Congalton e Green (1999), uma das formas mais eficientes de representar a exatidão de uma classificação é por meio de uma matriz de erro ou confusão, que descreve os resultados obtidos com a classificação realizada comparando-os com dados de referência. A partir dessas comparações podem ser calculados erros de inclusão e omissão, exatidões do produtor e do usuário, além de outras medidas de exatidão como a exatidão ou acurácia global e o coeficiente de concordância *Kappa*.

A exatidão global (P_0) corresponde à razão entre o número de amostras classificadas corretamente e o número total de amostras, sendo representada pela divisão da soma dos

elementos da diagonal principal pela soma de todos os elementos da matriz de confusão, conforme Equação 2.16:

$$P_0 = \frac{\sum_{i=1}^n x_{ii}}{N} \quad (2.16)$$

onde n é o número de classes, x_{ii} representa o número de amostras da classe “i” classificadas corretamente e N é o número total de amostras.

O coeficiente de concordância *Kappa* é uma medida de exatidão de classificação que apresenta como vantagem em relação à exatidão global o fato de incorporar na determinação da acurácia de classificação a informação dos pixels mal classificados, e não apenas dos bem classificados, sendo que no cálculo do valor de *Kappa* são eliminados os pixels classificados corretamente por pura casualidade.

O coeficiente de concordância *Kappa* pode também ser utilizado para determinar se uma matriz de erro é significativamente diferente de outra (CONGALTON e GREEN, 1999), considerando diferentes classificações de uma mesma cena. O estimador do coeficiente *Kappa* é dado pela Equação 2.17:

$$\hat{k} = \frac{P_0 - P_c}{1 - P_c} \quad (2.17)$$

onde P_0 representa a exatidão global, dada pela Equação 2.18, e P_c representa a proporção de unidades que concordam por pura casualidade, admitindo-se nesse caso a independência entre a classificação e a referência. P_c é representada pela somatória dos produtos das proporções marginais das linhas e colunas da matriz (BRITES et al., 1996), conforme Equação 2.18:

$$P_c = \frac{\sum_{i=1}^n x_{i+} x_{+i}}{N} \quad (2.18)$$

Uma aproximação do estimador da variância de *Kappa*, conhecidos P_0 , P_c e N (número total de amostras) é dada pela Equação 2.19 (BRITES et al., 1996):

$$\hat{\sigma}_k^2 = \frac{P_0(1-P_0)}{N(1-P_c)^2} \quad (2.19)$$

Segundo Gabordi (2002), embora o coeficiente de concordância *Kappa* tenha sido amplamente utilizado em análises de exatidão de mapeamento, não há uma fundamentação teórica para indicar quais os níveis mínimos deste coeficiente aceitáveis numa classificação. Diversos autores (VIEIRA, 1996; CORREIA, 1999; GABOARDI, 2002) usaram uma tabela proposta por Landis e Koch (1977) com esta finalidade. Leão et al. (2007) usaram uma tabela proposta por Galparsoro e Fernández (2001). Estas tabelas, obtidas empiricamente, associam critérios qualitativos de aceitação com intervalos de valores de \hat{k} . Outra tabela, proposta por Fleiss (1981) também associa a qualidade da classificação aos valores de \hat{k} .

Os conceitos de \hat{k} , definidos por essas três tabelas, e seus respectivos valores são apresentados na Tabela 2.1:

Tabela 2.1 – Conceitos de \hat{k} .

Crítérios	Landis & Koch	Fleiss	Galparsoro & Fernández
< 0	Péssimo	Ruim	Pobre
$0 \leq \hat{k} < 0.20$	Ruim		
$0.20 < \hat{k} < 0.40$	Razoável		Fraca
$0.40 < \hat{k} < 0.60$	Bom	Bom	Moderada
$0.60 < \hat{k} < 0.75$	Muito Bom		Boa
$0.75 < \hat{k} < 0.80$		Excelente	Muito boa
$0.80 < \hat{k} \leq 1.00$	Excelente		

Fonte: Adaptada de Gaboardi (2002)

A partir dos coeficientes de concordância *Kappa* e de suas respectivas variâncias, torna-se possível testar a hipótese de igualdade de duas matrizes de confusão, baseado na estatística “z” definida pela Equação 2.20 (SMITS et al., 1999):

$$z = \frac{\hat{K}_1 - \hat{K}_2}{\sqrt{\hat{\sigma}_{K_1}^2 + \hat{\sigma}_{K_2}^2}} \quad (2.20)$$

onde \hat{K}_1 e \hat{K}_2 são os estimadores dos coeficientes de concordância *Kappa* relativos a duas matrizes de erro independentes das quais queira se verificar a igualdade a um nível de significância α . Para um número total de pixels suficientemente "grande", a estatística z terá distribuição aproximadamente Normal (CONGALTON e GREEN, 1999).

Para realizar os testes de hipóteses são estabelecidos o nível de significância (α) desejado, geralmente 1%, 5% ou 10% e as hipóteses nula (H_0) e alternativa (H_1), sendo geralmente $H_0: K_1 = K_2$ e $H_1: K_1 \neq K_2$. O nível de significância α representa a probabilidade de se rejeitar a hipótese nula quando ela é verdadeira.

Obtidos os coeficientes *Kappa* e suas respectivas variâncias, é calculado o valor de z conforme a Equação 2.20. A esse valor de z calculado, é associado um valor-p, também denominado de nível de significância experimental ou descritivo (SPIEGEL, 1984), que indica a probabilidade correspondente ao valor da estatística calculada e que representa o máximo nível de significância para o qual se pode aceitar a hipótese nula.

A hipótese nula é aceita ou rejeitada a partir da comparação do valor-p com o nível de significância adotado. Se o valor-p for maior que o nível de significância adotado, H_0 será aceito e em caso contrário, rejeitado.

2.5 O satélite ALOS e o sensor PALSAR

De acordo com JAXA (2008), o satélite ALOS, ilustrado na Figura 2.8, possui 3,5 metros de largura por 4.5 metros de comprimento e 6,5 metros de altura com um peso bruto de aproximadamente 4 toneladas, o que faz dele um dos maiores satélites de observação da Terra. Quanto às características orbitais, o ALOS percorre uma órbita

sol-síncrona com passagem ascendente a uma altitude de 691,65 km (acima do Equador), uma inclinação de 98,16° e um ciclo completo de 46 dias.



Figura 2.8 – Satélite ALOS.
Fonte: JAXA (2008)

Além do PALSAR, o ALOS possui mais dois instrumentos imageadores: PRISM (*Panchromatic Remote-sensing Instrument for Stereo Mapping*), com 2,5 m de resolução espacial, e que compreende três sistemas ópticos para medição precisa das elevações; AVNIR-2 (*Advanced Visible and Near Infrared Radiometer type 2*), com resolução de 10 m, para observação da cobertura e uso do solo. Os três sensores da plataforma ALOS estão ilustrados na Figura 2.9:



Figura 2.9 – Design geral do ALOS.
Fonte: JAXA (2008)

O PALSAR possui resoluções espaciais que variam entre 10 e 100 m podendo operar nos seguintes modos: *Fine*, que possibilita melhores resoluções espaciais operando em uma (FBS – *fine beam single*) ou duas (FBD- *fine beam dual*) polarizações; *ScanSAR*, cuja vantagem se deve ao fato de possibilitar uma maior faixa de imageamento; *Polarimetric* (PLR), que opera nas quatro polarizações (*full polarimetric*) porém com resolução inferior ao modo *Fine*.

A maior capacidade polarimétrica, observada no modo *Polarimetric* e a melhor resolução espacial, observada no modo *Fine* constituem as melhorias em relação ao JERS-1, que operava apenas em uma polarização (HH), com resolução de 18 metros.

3 MATERIAIS E MÉTODOS

3.1 Área de estudo

A área de estudo desse trabalho está situada no oeste do estado do Pará, dentro da área da Floresta Nacional (FLONA) do Tapajós e localizada aproximadamente entre as latitudes S 2° 55' e S 3° 13' e as longitudes W 54° 50' e W 54° 59'. O período de chuvas nessa região inicia em dezembro e termina em maio, sendo o volume médio anual de precipitação de 1911 mm. A Figura 3.1 mostra a localização geográfica da área de estudo.

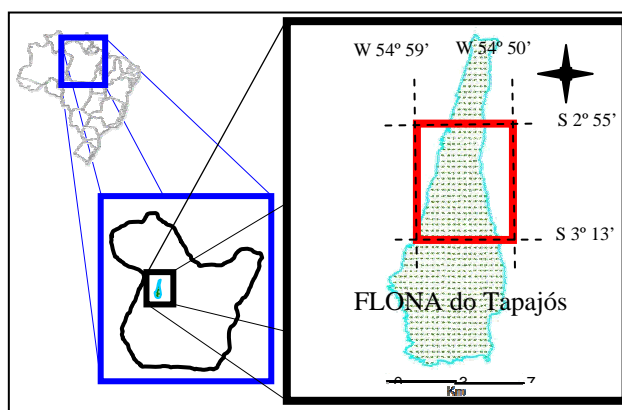


Figura 3.1 – Localização geográfica da área de estudo.
Fonte (Almeida, 2008).

A FLONA do Tapajós é uma unidade de conservação federal criada no início da década de 70 e abrange uma área aproximada de 544 mil hectares (COHENCA, 2007). Santos et al. (2004) relatam que o relevo desta região varia de plano a suavemente ondulado com altitude máxima de 280 metros e recoberto por floresta tropical, sendo essa vegetação composta basicamente por florestas ombrófilas e por algumas áreas de floresta secundária em diferentes estágios de sucessão (SHIMABUKURO et al., 1997).

Essa área apresenta várias regiões desmatadas, que se concentram principalmente ao longo da rodovia BR-163 e adjacências. Desde 2001, com a construção de um porto graneleiro e com diversos incentivos, a produção de grãos vem se alastrando aos

arredores de Santarém, no norte da BR-163, e com isso ocorre um acelerado processo de desmatamento de áreas florestadas para a agricultura mecanizada. Segundo [INPE \(2008\)](#), a extensão total do desflorestamento desta área é de cerca de aproximadamente 1500 Km².

A escolha da FLONA do Tapajós como área de estudo desse trabalho se deve ao grande conhecimento acumulado em anos de trabalhos realizados pelo Instituto Nacional de Pesquisas Espaciais (INPE) nessa região e à disponibilidade de imagens complexas ALOS/PALSAR da mesma.

3.2 Imagens ALOS/PALSAR utilizadas

As imagens complexas ALOS/PALSAR usadas nesse trabalho foram adquiridas em passagens repetidas, com intervalo de tempo entre as aquisições de quarenta e seis dias. Essas imagens foram fornecidas pela Agência de Exploração Aeroespacial Japonesa (JAXA). Juntamente com os arquivos que contém as imagens (.IMG), foram fornecidos também os respectivos arquivos (.LED) contendo informações referentes aos parâmetros geométricos e orbitais de aquisição das imagens bem como informações referentes aos processamentos dos dados brutos adquiridos.

De acordo com a nomenclatura da JAXA, as imagens fornecidas são designadas pelo código 1.1, denotando com isso o fato de serem imagens SLC, as quais permitem extrair a informação de fase, necessária aos processamentos interferométricos. No caso desse trabalho foram utilizadas imagens FBD e PLR.

As principais características das imagens SAR utilizadas nesse trabalho estão descritas na Tabela 3.1 a seguir:

Tabela 3.1 – Principais características das imagens SAR utilizadas

	FBD	PLR
Formato	<i>Single Look Complex</i> (SLC)	<i>Single Look Complex</i> (SLC)
Modo de Aquisição	<i>Fine Beam Double Polarization</i> (FBD)	<i>Polarimetric</i> (PLR)
Polarização	HH/HV	HH/HV/VH/VV
Datas de aquisição	13/06/2007 (imagem 1) e 29/07/2007 (imagem 2)	08/03/2007 (imagem 1) e 23/04/2007 (imagem 2)
Resolução espacial	10 m (range) x 4,5 m (azimute)	10 m (range) x 4,5 m (azimute)
Espaçamento entre pixels	9,3685143 m (range) x 3,197640 m (azimute)	9,3685143 m (range) x 3,5740131 m (azimute)
Ângulo de incidência (centro da faixa)	Imagem 1: 38,981° Imagem 2: 39,015 °	Imagem 1: 24,225° Imagem 2: 24,233 °
Ângulo off-nadir	34,3°	21,5°
Faixa de Imageamento	aprox. 70 km	aprox. 35 km
Passagem	Ascendente	Ascendente

Como as imagens PLR são de março/abril (época chuvosa) e as imagens FBD são de junho/julho (época seca), foram analisadas as condições meteorológicas nessas duas épocas e foram observadas significativas diferenças entre elas. Segundo [INPE \(2009\)](#) a variação da precipitação acumulada na região da FLONA Tapajós entre as duas datas das imagens FBD foi de 125 mm enquanto para as imagens PLR a variação de precipitação acumulada foi de aproximadamente 260 mm, sendo esta, portanto, maior do que a variação de precipitação observada para as imagens FBD. A influência das diferentes condições climáticas ou meteorológicas nas coerências interferométricas observadas será discutida no Capítulo 4 (seção 4.2).

Conforme explicado na seção 2.3.1, para evitar a decorrelação espacial a linha-base normal deve ser menor que a linha-base crítica. A partir dos arquivos .LED referentes às imagens complexas, foram estimadas no *SARscape 4.0* as linhas-base normais, as linhas-base críticas e os “*shifts*” (deslocamentos) entre as imagens *master* (data 1) e *slave* (data 2) de cada um dos pares interferométricos de dados FBD e PLR. Essas informações geométricas estão mostradas na Tabela 3.2:

Tabela 3.2 – Informações geométricas dos pares interferométricos

	FBD	PLR
Linha-base normal	418,567 metros	2810,090 metros
Linha-base crítica	6608,864 metros	3327,895 metros
Range shift	68,879 pixels	-38,028 pixels
Azimuth shift	-2929,556 pixels	-3199,851 pixels

Como as linhas-base normais estimadas são menores que as linhas-base críticas para os dois tipos de dados, foi então possível a realização dos processamentos interferométricos. Na Figura 3.2 estão esquematizadas, para os dados FBD e PLR, as linhas-base normais estimadas bem como a articulação geométrica entre as imagens.

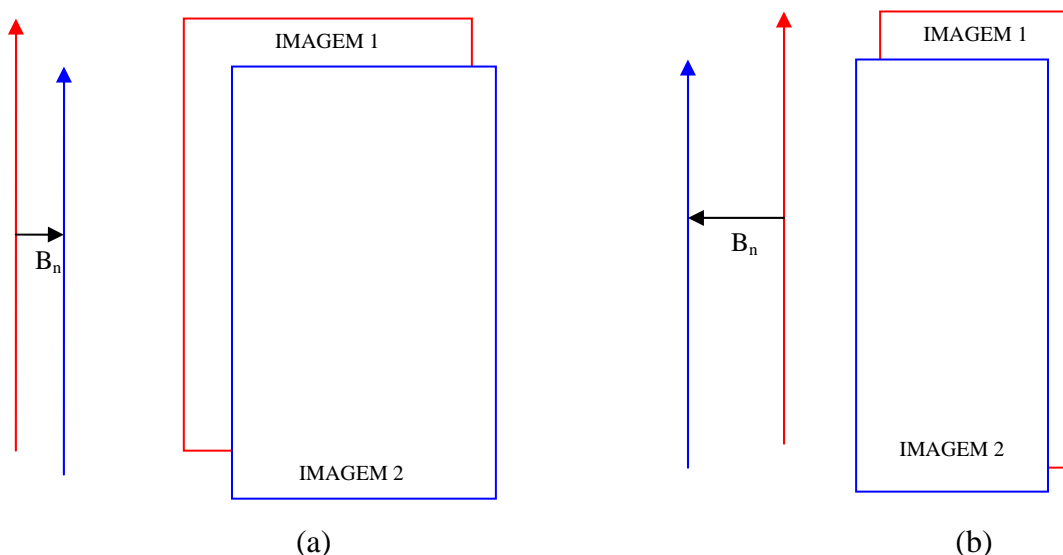


Figura 3.2 – Esquematização das linhas-base normais estimadas e articulação geométrica das imagens: (a) FBD; (b) PLR.

3.3 Dados auxiliares utilizados

Para a realização das classificações supervisionadas foram necessários dados auxiliares relativos à área de estudo que permitiram definir as classes e as amostras de treinamento e teste a serem usadas. Entre esses dados utilizados estão dados de campo obtidos com reambulações e medições realizadas em anos anteriores por integrantes do INPE, com a assistência de outros órgãos e instituições, entre as quais a Diretoria de Serviço Geográfico do Exército Brasileiro, e também imagens ópticas dos sensores LANDSAT-5/TM e SPOT-4/HRVIR, que possibilitaram algumas atualizações dos dados de campo.

A Tabela 3.3 informa as datas dessas imagens ópticas e as composições RGB para auxiliar na definição das amostras e das classes.

Tabela 3.3 – Datas e composições RGB das imagens ópticas auxiliares

Imagem óptica auxiliar	Data	Composição RGB
LANDSAT-5/TM	21/06/2007	R5G4B3
SPOT-4/HRVIR	30/06/2007	R2G3B1

A escolha de tais imagens ópticas auxiliares se deve ao fato dessas imagens serem, entre as disponíveis no acervo digital do INPE, as de datas mais próximas às datas das imagens SAR utilizadas, objetivando com isso diminuir os efeitos da desatualização na seleção das amostras de treinamento e teste.

A Figura 3.3 ilustra a área de estudo nas composições coloridas TM (R5G4B3) e SPOT (R2G3B1) e nas imagens complexas FBD (polarização HH – 13/06/2007) e PLR (polarização HH – 23/04/2007) utilizadas.

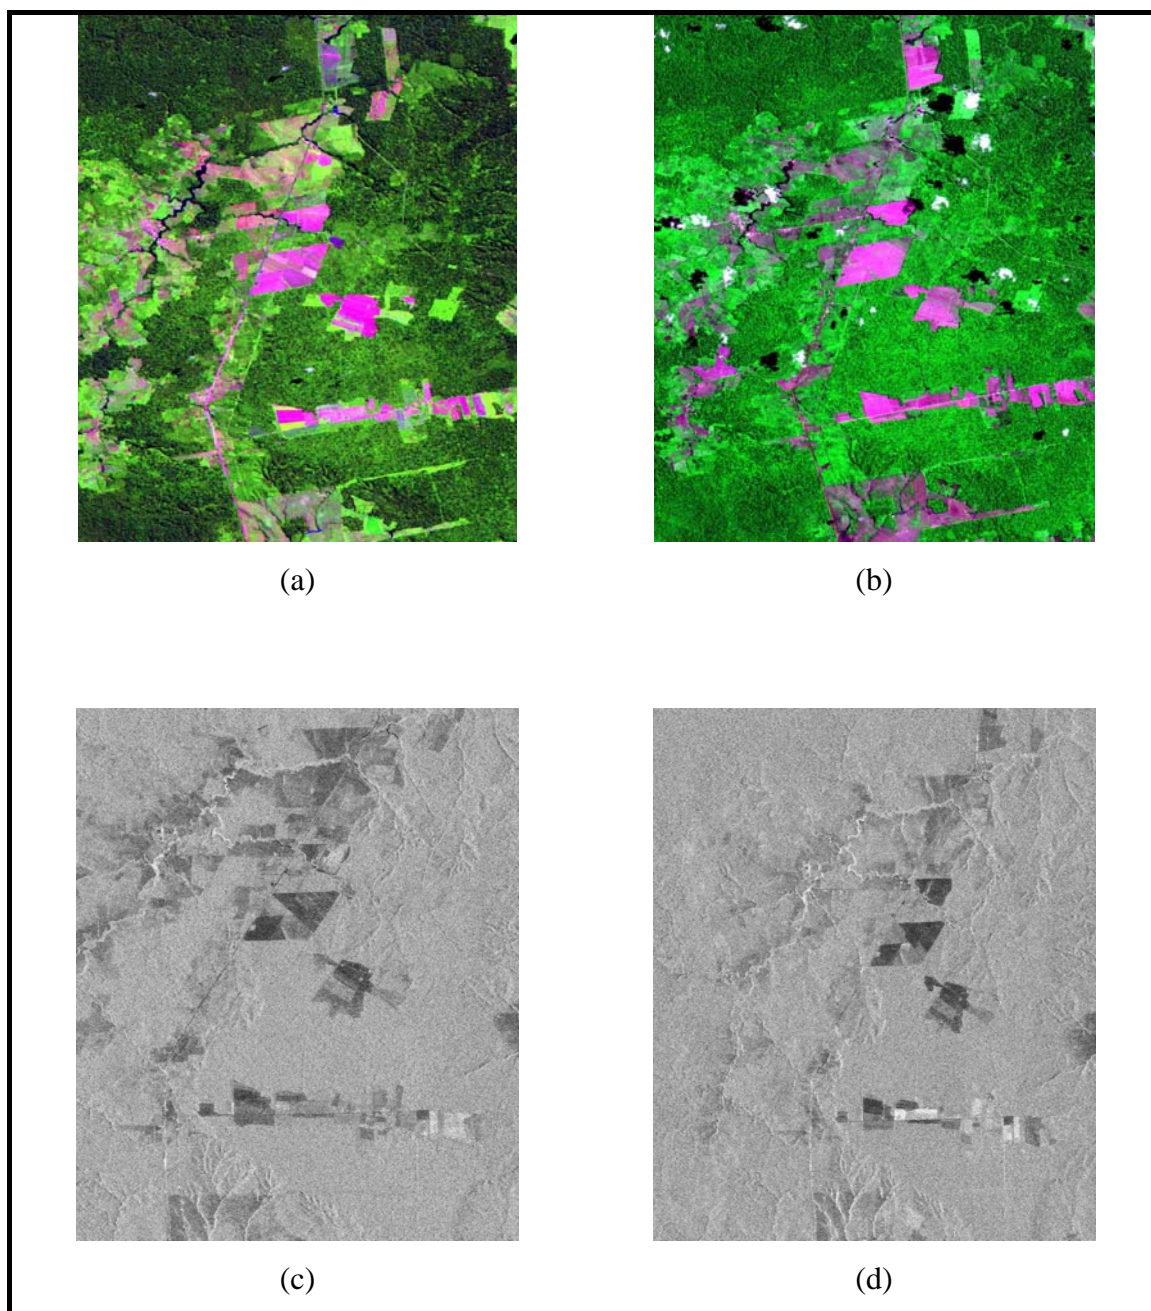


Figura 3.3 – Área de estudo: (a) imagem TM: composição (R5G4B3), data 21/06/2007;
(b) imagem SPOT/HRVIR: composição (R2G3B1), data 30/06/2007;
(c) imagem FBD: polarização HH, data 13/06/2007;
(d) imagem PLR: polarização HH, data 23/04/2007.

3.4 Softwares utilizados

Para o desenvolvimento do presente trabalho foram utilizados os seguintes *softwares* e aplicativos:

- *ASF MapReady 1.0*: aplicativo fornecido pela *Alaska Satellite Facility* que capturou as informações dos arquivos .LED referentes a cada uma das imagens SLC utilizadas.

- *SARscape 4.0*: aplicativo desenvolvido pela [Sarmap \(2008\)](#) que permitiu a realização dos processamentos interferométricos para a geração dos interferogramas e das imagens de coerência interferométrica e também de alguns pré-processamentos necessários tais como recortes, co-registros, estimação de linhas-base e reamostragens por média espacial (*multi-look*).

- *ENVI 4.4*: *software* de visualização e manipulação de imagens em que foram feitas as conversões *slant-to-ground range*, as conversões de dados complexos para dados em Amplitude, as filtragens pelo filtro *Gama*, a calibração das coerências interferométricas e todas as classificações supervisionadas SVM. Nesse *software* foram obtidos os histogramas de coerência para cada uma das classes de estudo e calculadas as distâncias JM entre elas.

- *Polarimetric Classifier 0.7* ([CORREIA, 1999](#)): aplicativo que permitiu a realização de todas as classificações por máxima verossimilhança (MaxVer) acrescidas do algoritmo contextual ICM. Em tal aplicativo foram obtidos também os gráficos das distribuições estatísticas das classes e todas as matrizes de erro ou confusão das classificações realizadas.

- planilhas do *Microsoft Office Excel 2003*: permitiram a obtenção de estatísticas z e dos respectivos valores-p que foram usados nos testes de hipóteses, além da construção dos intervalos de confiança de 95% para as médias de coerência interferométrica e coeficientes *Kappa*.

3.5 Procedimentos Metodológicos

A metodologia empregada nesse trabalho pode ser dividida em quatro etapas, conforme fluxograma geral de trabalho ilustrado na Figura 3.4.

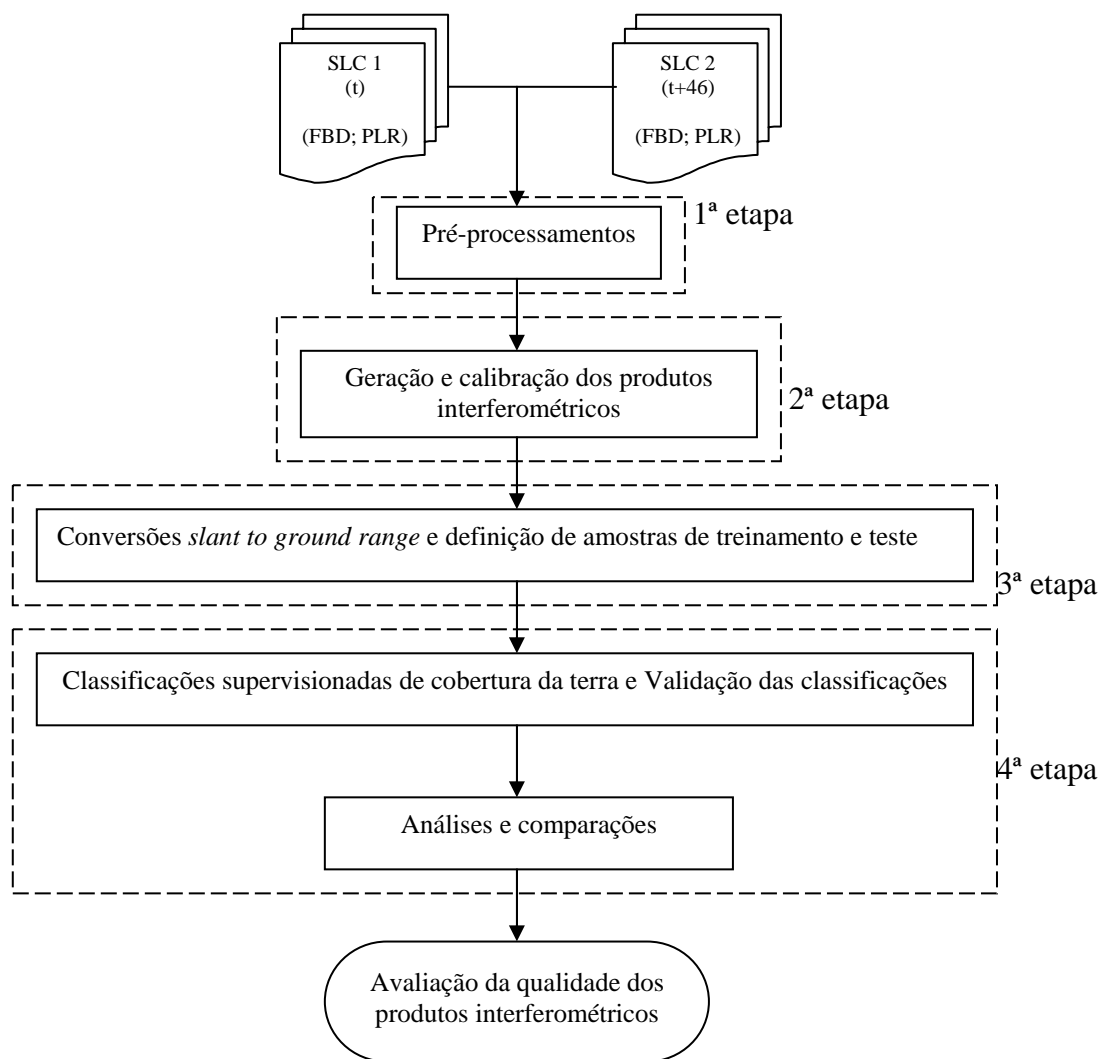


Figura 3.4 – Fluxograma geral de trabalho

Cada uma das quatro etapas da metodologia empregada será descrita nas seções 3.5.1 a 3.5.4.

3.5.1 Pré-processamentos

A primeira etapa correspondeu aos pré-processamentos das imagens SLC FBD e PLR utilizadas (datas 1 e 2) a fim de se obter os pares interferométricos utilizados nos processamentos subsequentes. Entre os pré-processamentos feitos estão recortes da área de estudo, co-registros, conversão de dados complexos para dados em Amplitude e filtragens utilizando o filtro *Gama* com janela 5x5.

A Figura 3.5 ilustra o fluxograma da primeira etapa de trabalho (pré-processamentos). Em destaque estão os dados resultantes dos pré-processamentos, que foram utilizados nas etapas subsequentes:

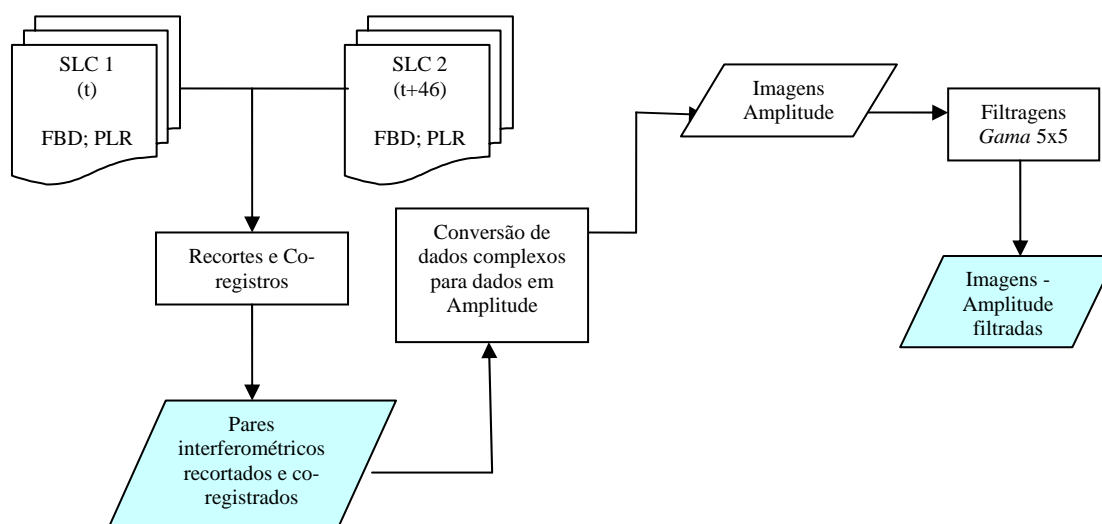


Figura 3.5 – Fluxograma da primeira etapa (Pré-processamentos)

Primeiramente, nas imagens SLC FBD e PLR das datas 1 e 2 foram feitos recortes (1273 x 1776 pixels) referentes à área de estudo. Feitos tais recortes, foram obtidos os pares interferométricos HH1_HH2 e HV1_HV2 para os dados FBD e HH1_HH2, HV1_HV2 e VV1_VV2 para dados PLR, os quais foram co-registrados automaticamente da seguinte forma:

Primeiramente foram estimados grosseiramente os *shifts* entre as imagens complexas nas direções range e em azimute, a partir de parâmetros orbitais. Para tal foi definido

um tamanho de janela central, de 1024 x 1024 pixels. Em seguida, os *shift's* foram otimizados com uma precisão de sub-pixel a partir de um *grid* contendo várias sub-janelas nas imagens-Intensidade correspondentes às imagens complexas a serem co-registradas. Essas imagens-Intensidade foram geradas automaticamente no *SARscape 4.0* durante o processo de registro.

As sub-janelas foram definidas para serem empregadas no cálculo da função de correlação cruzada entre as imagens. No caso, foram definidas cinco sub-janelas em range e seis em azimuth, com tamanho 256 x 256 pixels. A função de correlação cruzada foi calculada entre os pixels dessas sub-janelas correspondentes nas duas imagens (pixels homólogos). O máximo da função de correlação cruzada indicou o *shift* mais ajustado. No cálculo da função de correlação cruzada foi definido um valor limiar para a correlação cruzada, ou seja, valores calculados abaixo deste limiar para determinada janela, impediram tal janela de ser utilizada para estimar o *shift* refinado. Foi definido então o valor limiar de 0,25 para a correlação cruzada.

Os *shifts* a serem aplicados na direção em range e em azimuth, respectivamente Δr e Δaz , foram calculados por polinômios em função da posição do pixel (x,y), conforme Equações 3.1 e 3.2.

$$\Delta r = K_1 + K_2x + K_3y + K_4x^2 + K_5y^2 \quad (\text{Eq. 3.1})$$

$$\Delta az = K_6 + K_7x + K_8y + K_9x^2 + K_{10}y^2 \quad (\text{Eq. 3.2})$$

Os polinômios representam funções de primeiro ou segundo grau, pois funções de grau mais elevado podem degradar as informações de fase dos pixels da imagem (Sarmap, 2008). Os coeficientes dos polinômios foram obtidos a partir de interpolações com os máximos da função de correlação cruzada.

Uma estimativa final mais refinada dos *shifts* (0,1 da dimensão do pixel) foi realizada com auxílio das sub-janelas onde são calculados valores de coerências. Para isso definiu-se o tamanho e o número de tais sub-janelas. No caso, foram definidas 40 sub-janelas em range e 40 em azimuth, com tamanho de 32 x 32 pixels. Caso a coerência seja muito baixa, o número de pontos para estimar os *shifts* refinados pode não ser

suficiente para otimizar o processo de co-registo. Neste caso, o processo de co-registo é feito usando apenas as informações orbitais e as funções de correlação cruzada, permitindo um co-registo com precisão apenas sub-pixel.

Além do valor de coerência, deve-se também estabelecer um valor limiar para a SNR. Caso o valor da SNR calculado em determinada janela esteja abaixo deste limiar, tal janela não é utilizada para a estimativa dos *shifts* refinados. Tanto para o SNR como para a coerência foram adotados os limiares recomendados no manual de utilização do *SARscape 4.0*, respectivamente 2,8 e 0,25.

A Tabela 3.4 contém os valores dos parâmetros definidos para os co-registros.

Tabela 3.4 – Parâmetros dos co-registros

Parâmetros	Valores
Tamanho de janela central (range x azimute) em pixels	1024 x 1024
Número de sub-janelas (range x azimute) para correlação cruzada	5 x 6
Tamanho das sub-janelas para correlação cruzada em pixels	256 x 256
Limiar de correlação cruzada	0,25
Número de sub-janelas (range x azimute) para coerência	40 x 40
Tamanho das sub-janelas (range x azimute) para coerência em pixels	32 x 32
Limiar de coerência	0,25
Limiar de SNR	2,8

Os polinômios de 1° grau obtidos para cada co-registo feito entre os pares interferométricos dos dados FBD e PLR, tanto em range como em azimute, são informados na Tabela 3.5. Ressalta-se que foi utilizado o grau 1 para os polinômios de co-registo a fim de se obter a menor degradação possível da informação de fase.

Tabela 3.5 – Polinômios dos co-registros

Par interferométrico		Polinômios de co-registro	
		Azimute	Range
FBD	HH1_HH2	$2885,691487 + 0,001246 x + 0,004387 y$	$- 67,349257 - 0,000561 x - 0,000003 y$
	HH1_HH2	$2885,691905 + 0,001238 x + 0,004393 y$	$- 67,353787 - 0,000576 x - 0,000001 y$
PLR	HH1_HH2	$3157,766751 + 0,053427 x + 0,000039 y$	$35,787700 + 0,002963 x - 0,000035 y$
	HV1_HV2	$3157,854169 + 0,054723 x - 0,000054 y$	$35,604671 + 0,003218 x - 0,000020 y$
	VV1_VV2	$3163,997843 + 0,036240 x + 0,000513 y$	$38,330840 + 0,010428 x - 0,000085 y$

Nos dados FBD, os coeficientes dos polinômios apresentaram, tanto em azimute como em range, variações menores entre os pares HH1_HH2 e HV1_HV2 do que as variações observadas entre os pares HH1_HH2, HV1_HV2 e VV1_VV2 dos dados PLR. Isso mostra que os pares de imagens FBD são mais correlacionados que os pares de imagens PLR. Ressalta-se que para um mesmo tipo de dado (FBD ou PLR) as variações entre os coeficientes dos polinômios quantificam as diferenças entre os co-registros de cada um dos pares interferométricos nas diferentes polarizações.

Dentre os três pares PLR, o par VV1_VV2 foi o que apresentou as maiores variações nos coeficientes em relação aos outros dois; fato este que permite concluir que tal par apresenta a maior desconexão dentre todos os pares de imagens utilizados.

Os pares interferométricos co-registrados, em formato complexo, foram convertidos para imagens-Amplitude e na seqüência foi aplicado o filtro adaptativo *Gama* de tamanho 5x5, a fim de reduzir o ruído *speckle* nas imagens-Amplitude. Com a filtragem, a distribuição estatística da imagem original é alterada devido à transformação nos níveis de cinza da imagem, fazendo com que sua distribuição seja normalizada (FRERY, 1993) e isto constitui um aspecto importante na utilização de classificadores pontuais de máxima verossimilhança, os quais foram utilizados nesse trabalho.

Os pares interferométricos co-registrados, em formato complexo, e as imagens-Amplitude filtradas foram utilizados respectivamente na segunda e terceira etapas.

3.5.2 Geração e calibração dos produtos interferométricos

A segunda etapa consistiu nos processamentos interferométricos feitos com os pares interferométricos co-registrados a fim de se gerar os interferogramas dobrados, com e sem fase plana (*flat earth*) e as correspondentes imagens de coerência interferométrica, sendo na seqüência feitas calibrações nas imagens de coerência geradas. Foram feitos ainda desdobramentos de fase nos interferogramas utilizando dois métodos diferentes: crescimento de regiões (local) e mínimos quadrados (global).

Ressalta-se que os produtos interferométricos gerados são co-polarizados, em virtude de testes preliminares terem mostrado que os produtos interferométricos do ALOS/PALSAR de polarizações cruzadas são totalmente ruidosos, devido ao efeito das diferentes polarizações na determinação da fase interferométrica e com isso não podendo ser usados em outros processamentos subseqüentes.

A Figura 3.6 ilustra o fluxograma da segunda etapa de trabalho (geração e calibração de produtos interferométricos), com destaque para os dados resultantes que foram utilizados na próxima etapa.

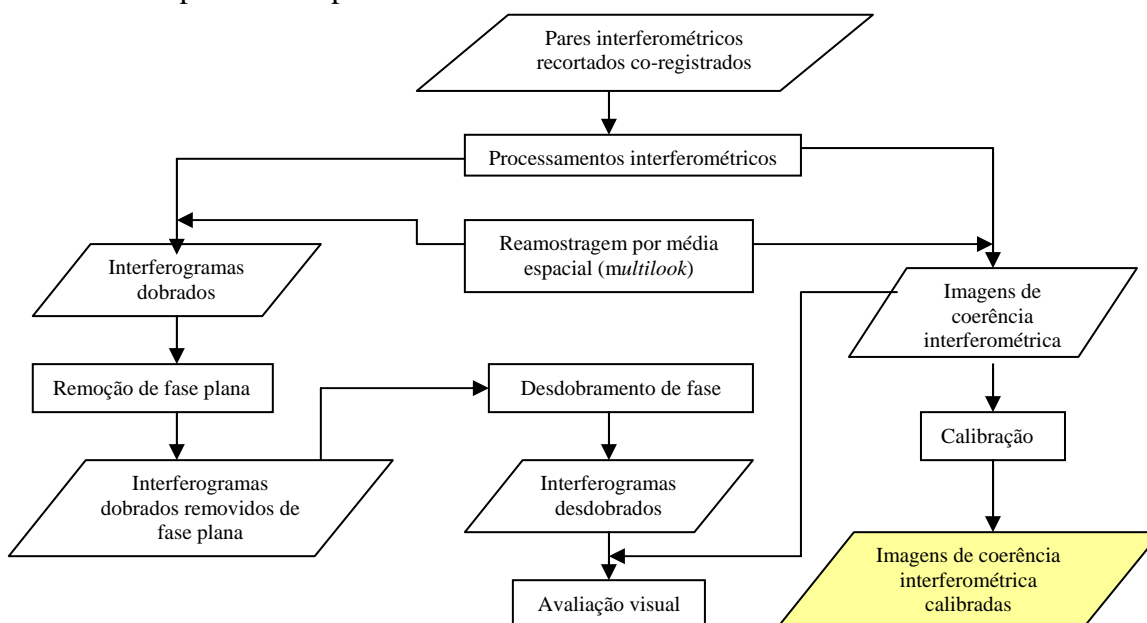


Figura 3.6 – Fluxograma da segunda etapa (geração e calibração de produtos interferométricos)

No *SARscape 4.0*, foram selecionados todos os arquivos (*master* e *slave*) contendo as imagens dos pares interferométricos co-registrados a partir dos quais foram gerados os interferogramas e as imagens de coerência interferométrica. Como o *software* possibilita uma reamostragem por média espacial (*multi-look*) juntamente com a geração dos produtos interferométricos, foi definido o número de *looks* igual a três na direção em azimute, a fim de tornar os pixels com dimensões aproximadas (pixels quadrados) em azimute e em alcance. Essa reamostragem, proposta por Goldstein et al. (1988), foi feita com objetivo de diminuir os ruídos nos interferogramas e nas imagens de coerência interferométrica.

Os interferogramas dobrados gerados contêm todas as componentes da fase interferométrica citadas na seção 2.3.1. A remoção da componente de fase plana e o desdobramento de fase pelo crescimento de regiões foram feitos no *SARscape 4.0* enquanto o desdobramento pelo método dos mínimos quadrados foi feito no *RAT (Radar Tools) 0.20*.

Para a geração das imagens de coerência foi definido o tamanho 3x3 para o filtro *Boxcar*. Ressalta-se que os valores de coerência observados expressam o modelo matemático desenvolvido por Hanssen (2001), levando em consideração o produto de diversos fatores de coerência.

Para se obter apenas os valores de coerência relativos às propriedades do alvo, foram feitas calibrações, conforme explicado na seção 2.3.2.3. Calculados os fatores de calibração para cada imagem, foram obtidas as imagens de coerência calibradas.

A Tabela 3.6 contém os fatores de calibração de cada uma das imagens de coerência interferométrica geradas. As imagens de coerência calibradas geradas são identificadas por (γ_{HH1_HH2} e γ_{HV1_HV2}) no caso das imagens FBD e (γ_{HH1_HH2} , γ_{HV1_HV2} e γ_{VV1_VV2}) no caso das imagens PLR.

Tabela 3.6 – Fatores de calibração das imagens de coerência interferométrica.

Imagem		Máxima coerência observada	Fatores de calibração
FBD	γ_{HH1_HH2}	0,977137	1,023397
	γ_{HV1_HV2}	0,928874	1,076572
PLR	γ_{HH1_HH2}	0,945183	1,057996
	γ_{HV1_HV2}	0,884834	1,130155
	γ_{VV1_VV2}	0,870020	1,149398

Para cada uma das imagens de coerência calibradas foram obtidos os valores da coerência interferométrica por classe, os quais serão mostrados em forma de histogramas no capítulo 4.

3.5.3 Conversões *slant-ground range* e definição de amostras de treinamento e teste

Em virtude das imagens SLC serem formadas em *slant range*, apresentando com isso uma geometria de aquisição diferente das imagens ópticas auxiliares, foram feitas conversões *slant to ground range* nas imagens de coerência calibradas e imagens-Amplitude filtradas para facilitar a coleta das amostras de treinamento e teste. A Figura 3.7 ilustra o fluxograma dessa terceira etapa de trabalho (conversões *slant to ground range* e definição de amostras de treinamento e teste) com destaque para os dados resultantes que foram usados na próxima etapa do trabalho.

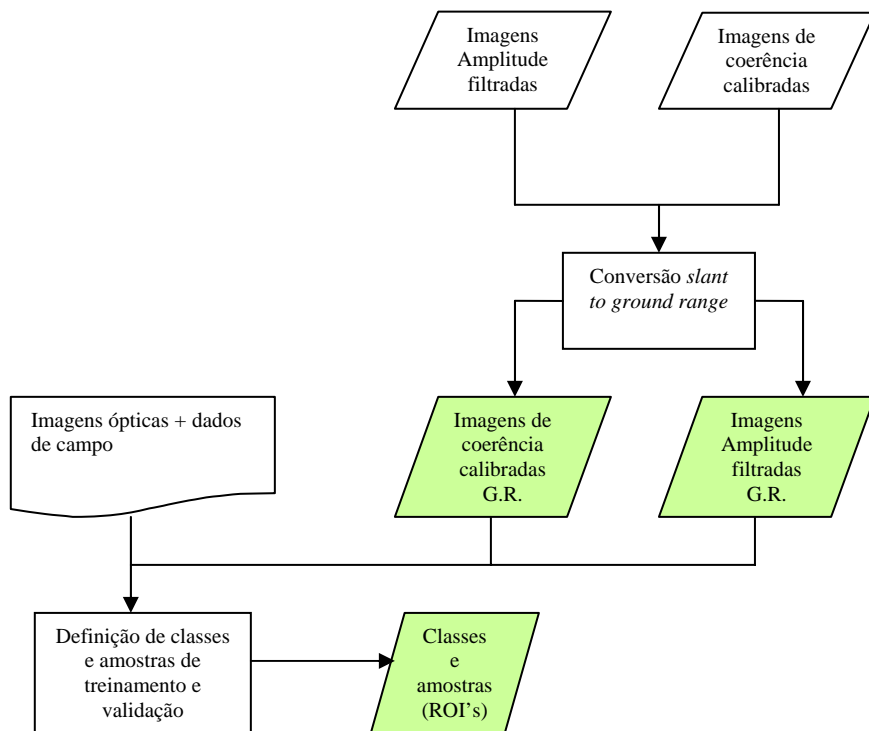


Figura 3.7 – Fluxograma da terceira etapa (conversões *slant to ground range* e definição de amostras de treinamento e teste).

No *ENVI 4.4* foi necessário definir os parâmetros a serem usados nas conversões *slant to ground range*, bem como o método de interpolação empregado, no caso o vizinho mais próximo. Os parâmetros foram calculados com auxílio das informações capturadas dos arquivos .LED das imagens capturadas pelo *ASF MapReady 1.0*. A fim de tornar os pixels da imagem convertida com a mesma dimensão em azimuth e em range (pixels quadrados) foi definido o espaçamento entre pixels em *ground range* igual ao espaçamento em azimuth das imagens após a reamostragem por média espacial com número de *looks* igual a três.

A Tabela 3.7 contém todos os parâmetros calculados para as conversões das imagens. A_1 designa o conjunto das imagens-Amplitude das datas 1 (HH1 e HV1 para os dados FBD; HH1, HV1 e VV1 para dados PLR), A_2 designa o conjunto das imagens-Amplitude das datas 2 (HH2 e HV2 para os dados FBD; HH2, HV2 e VV2 para dados

PLR) e γ designa o conjunto das imagens de coerência interferométrica (HH1_HH2 e HV1_HV2 para dados FBD; HH1_HH2, HV1_HV2 e VV1_VV2 para dados PLR).

Tabela 3.7 – Parâmetros de conversão *slant to ground range*

Imagens Parâmetros	FBD (datas: 13/06/2007 e 29/07/2007)			PLR (datas: 08/03/2007 e 23/04/2007)		
	A ₁	A ₂	γ	A ₁	A ₂	γ
Altitude da plataforma (km)	698,605					
Distância <i>near-range</i> inclinada (km)	865,91	866,3425	866,3425	751,3825	751,4325	751,3825
Espaçamento entre pixels em <i>slant range</i> (m)	9,3685143					
Espaçamento entre pixels em azimute antes da reamostragem com 3 looks (m)	3,197640			3,5740131		
Espaçamento entre pixels em azimute após reamostragem com 3 looks (m)	9,59292 (3 x 3,197640)			10,7220393 (3 x 3,5740131)		
Espaçamento entre pixels em <i>ground range</i> (m)	9,59292			10,7220393		

Feitas as conversões foram obtidas as imagens de coerência calibradas e as imagens-Amplitude filtradas em *ground range*, as quais foram usadas nas classificações. As imagens de coerência interferométrica calibradas convertidas para *ground range* serão mostradas no Capítulo 4.

As Figuras 3.8 e 3.9 ilustram as imagens-Amplitude filtradas convertidas para *ground range* respectivamente para os dados FBD e PLR. Tais imagens são identificadas por (A_{HH1} e A_{HV1} – 13/06/2007; A_{HH2} e A_{HV2} – 29/07/2007) para as imagens FBD e (A_{HH1} , A_{HV1} e A_{VV1} – 08/03/2007; A_{HH2} , A_{HV2} e A_{VV2} – 23/04/2007) para as imagens PLR.




Figura 3.8 – Dados FBD: Imagens-Amplitude em *ground range* filtradas:

- (a) A_{HH1} (13/06/2007); (b) A_{HV1} (13/06/2007);
(c) A_{HH2} (29/07/2007); (d) A_{HV2} (29/07/2007).




Figura 3.9 – Dados PLR: Imagens-Amplitude em *ground range* filtradas:
 (a) A_{HH1} (08/03/2007); (b) A_{HV1} (08/03/2007); (c) A_{VV1} (08/03/2007);
 (d) A_{HH2} (23/04/2007); (e) A_{HV2} (23/04/2007); (f) A_{VV2} (23/04/2007).

Para se proceder às classificações, foi indispensável definir quantas e quais classes seriam usadas nesses procedimentos. Essa definição foi feita com base na interpretação visual dos dados auxiliares (imagens ópticas e dados de campo) citados na seção 3.3. Foram definidas então cinco classes: floresta primária, floresta modificada, pastagem, solo exposto e agricultura. A Figura 3.10 ilustra feições representativas dessas cinco classes.

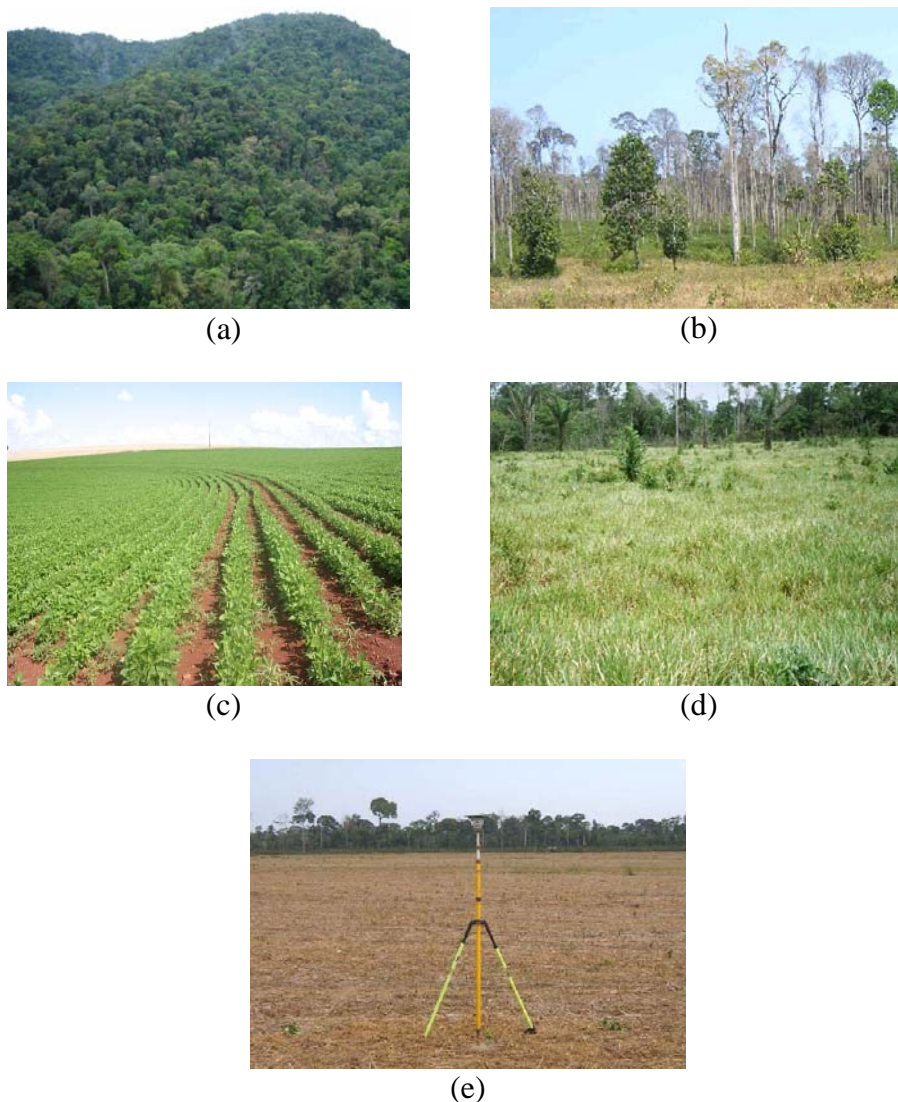



Figura 3.10 – Feições representativas das cinco classes utilizadas:
(a) Floresta primária; (b) Floresta modificada;
(c) Agricultura; (d) Pastagem; (e) Solo exposto

A classe Floresta Primária é representada pelas florestas em que a ação humana não provocou significativas alterações das suas características originais de estrutura. A classe Floresta Modificada engloba florestas secundárias, que são aquelas resultantes de um processo natural de regeneração da vegetação em áreas onde no passado houve corte raso da floresta primária, e também florestas degradadas ou exploradas. A classe Agricultura abrange principalmente plantações de soja, enquanto a classe Pastagem representa os terrenos preparados para pecuária. À classe Solo Exposto estão associados

terrenos sem cobertura vegetal, os quais podem ser preparados para algum tipo de cultivo.

Definidas as classes, foram selecionadas e coletadas as amostras para serem usadas para treinamento e validação das classificações. A Figura 3.11 ilustra imagens-Amplitude FBD (HH – 13/06/2007) e PLR (HH-23/04/2007) com as respectivas ROI's (*regions of interest* – regiões de interesse) contendo as amostras utilizadas. Ressalta-se que para os dados FBD e PLR as amostras são diferentes.



Legenda:











	Floresta Primária		val_Floresta Primária
	Floresta Modificada		val_Floresta Modificada
	Pastagem		val_Pastagem
	Solo exposto		val_Solo exposto
	Agricultura		val_Agricultura

Figura 3.11 – Amostras de treinamento e teste

A Tabela 3.8 contém a quantidade de pixels das amostras de treinamento e teste para cada uma das cinco classes, para os dados FBD e PLR.

Tabela 3.8 – Quantidade de pixels das amostras de treinamento e teste

Classes	FBD		PLR	
	Treino	Teste	Treino	Teste
Floresta Primária	1190	805	1119	572
Floresta Modificada	1125	949	1218	586
Agricultura	1054	592	1003	439
Pastagem	1363	835	1108	603
Solo Exposto	1493	707	1056	602
Total	6225	3888	5504	2802

3.5.4 Classificações supervisionadas

Na última etapa foram feitas classificações usando combinações entre as imagens de coerência interferométrica calibradas e as imagens-Amplitude filtradas geradas, em composições univariadas, bivariadas e multivariadas, todas em geometria *ground range*. A validação das classificações consistiu na obtenção das matrizes de confusão, usando como referência as amostras de teste previamente definidas.

A partir das matrizes de confusão foram feitas as análises de exatidão das classificações com base no coeficiente de concordância *Kappa* de cada classificação. Os testes de hipótese bilaterais, usando como parâmetro a estatística *z* derivada dos estimadores dos coeficientes *kappa*, foram necessários para verificar a igualdade entre classificações dado o nível de significância de 5%.

Feitas todas as comparações e análises dos resultados obtidos, foi possível avaliar o desempenho das imagens de coerência interferométrica nas classificações, e com isso então atestar sobre a potencialidade das mesmas para classificar cobertura da terra. Todos os resultados obtidos, bem como as análises, discussões e conclusões acerca das classificações realizadas serão mostrados no Capítulo 4.

A Figura 3.12 ilustra o fluxograma da última etapa de trabalho (classificações supervisionadas, validações, análises e comparações).

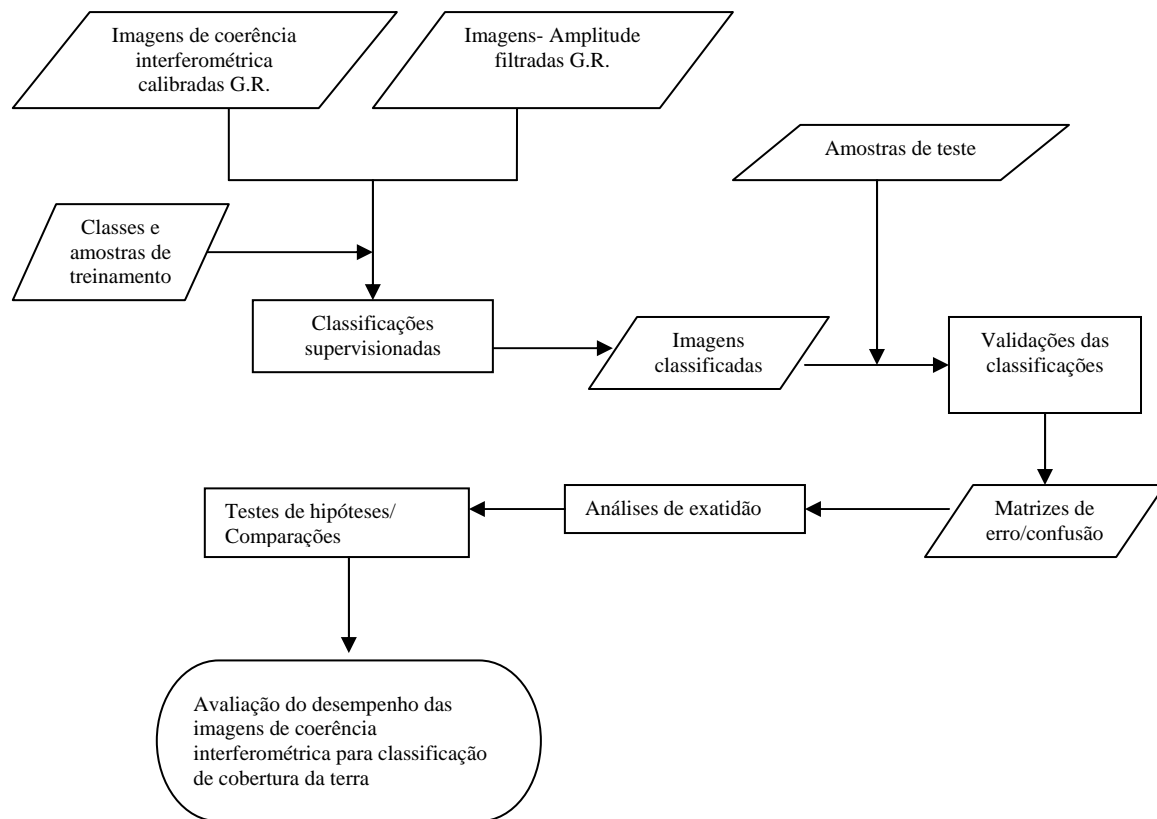


Figura 3.12 – Fluxograma da última etapa (classificações supervisionadas, validações, análises e comparações).

As classificações supervisionadas foram realizadas usando várias composições univariadas, bivariadas e multivariadas de imagens de coerência interferométrica calibradas e imagens-Amplitude geradas. Essas composições foram definidas a partir das combinações entre os atributos Amplitude e Coerência interferométrica.

O atributo de Coerência Interferométrica (γ) é definido pelo conjunto de todas as imagens de coerência $\{\gamma_{HH1_HH2}$ e γ_{HV1_HV2} (para dados FBD); γ_{HH1_HH2} , γ_{HV1_HV2} e γ_{VV1_VV2} (dados PLR)} enquanto para o atributo de Amplitude (A) o conjunto é: $\{A_{HH1}$, A_{HV1} , A_{HH2} e A_{HV2} (dados FBD); e A_{HH1} , A_{HV1} , A_{VV1} , A_{HH2} , A_{HV2} , A_{VV2} (dados PLR)}.

Como o objetivo das classificações foi analisar e comparar o desempenho das imagens de coerência quando utilizadas isoladamente (um atributo de Coerência), combinadas entre si (dois ou três atributos de Coerência) e quando acrescentadas às imagens-Amplitude (um atributo de coerência acrescentado a um, dois ou três atributos de Amplitude), ressalta-se que foi testado apenas um subconjunto de combinações de atributos. As combinações envolvendo apenas os atributos de Amplitude serviram para estabelecer um comparativo com as outras combinações definidas.

A Tabela 3.9 mostra para os dados FBD e PLR quais as combinações entre atributos que definiram todas as composições univariadas, bivariadas e multivariadas.

Tabela 3.9 – Combinações entre os atributos Amplitude e Coerência interferométrica para os dados FBD e PLR.

Tipos de Composições	Combinações entre atributos	
	Dados FBD	Dados PLR
Univariadas	Amplitude; Coerência	Amplitude; Coerência
Bivariadas	Amplitude + Coerência; Coerência + Coerência; Amplitude + Amplitude	Amplitude + Coerência; Coerência + Coerência; Amplitude + Amplitude
Multivariadas	Amplitude + Amplitude + Coerência	Coerência + Coerência + Coerência; Amplitude + Amplitude + Coerência; Amplitude + Amplitude + Amplitude; Amplitude + Amplitude + Amplitude + Coerência;

Cada uma dessas combinações definiu para os dados FBD e PLR as composições com as imagens de coerência calibradas e as imagens-Amplitude geradas. Todas essas composições (univariadas, bivariadas e multivariadas) são mostradas na Tabela 3.10.

Tabela 3.10 - Composições univariadas, bivariadas e multivariadas para as classificações supervisionadas.

Combinação	FBD	PLR
A	$A_{HH1}; A_{HV1}; A_{HH2}; A_{HV2}$	$A_{HH1}; A_{HV1}; A_{VV1}; A_{HH2}; A_{HV2}; A_{VV2}$
γ	$\gamma_{HH1_HH2}; \gamma_{HV1_HV2}$	$\gamma_{HH1_HH2}; \gamma_{HV1_HV2}; \gamma_{VV1_VV2}$
A + γ	$\gamma_{HH1_HH2} + A_{HH1}; \gamma_{HH1_HH2} + A_{HH2};$ $\gamma_{HV1_HV2} + A_{HV1}; \gamma_{HV1_HV2} + A_{HV2};$ $\gamma_{HH1_HH2} + A_{HV1}; \gamma_{HH1_HH2} + A_{HV2};$ $\gamma_{HV1_HV2} + A_{HH1}; \gamma_{HV1_HV2} + A_{HH2};$	$\gamma_{HH1_HH2} + A_{HH1}; \gamma_{HH1_HH2} + A_{HH2}; \gamma_{HV1_HV2} + A_{HV1}; \gamma_{HV1_HV2} + A_{HV2}; \gamma_{VV1_VV2}$ $+ A_{VV1}; \gamma_{VV1_VV2} + A_{VV2}; \gamma_{HH1_HH2} + A_{HV1}; \gamma_{HH1_HH2} + A_{HV2}; \gamma_{HH1_HH2} + A_{VV1};$ $\gamma_{HH1_HH2} + A_{VV2}; \gamma_{HV1_HV2} + A_{HH1}; \gamma_{HV1_HV2} + A_{HH2}; \gamma_{HV1_HV2} + A_{VV1}; \gamma_{HV1_HV2}$ $+ A_{VV2}; \gamma_{VV1_VV2} + A_{HH1}; \gamma_{VV1_VV2} + A_{HH2}; \gamma_{VV1_VV2} + A_{HV1}; \gamma_{VV1_VV2} + A_{HV2};$
$\gamma + \gamma$	$\gamma_{HH1_HH2} + \gamma_{HV1_HV2}$	$\gamma_{HH1_HH2} + \gamma_{HV1_HV2}; \gamma_{HH1_HH2} + \gamma_{VV1_VV2}; \gamma_{HV1_HV2} + \gamma_{VV1_VV2};$
A + A	$A_{HH1} + A_{HV1}; A_{HH2} + A_{HV2}; A_{HH1} +$ $A_{HH2}; A_{HV1} + A_{HV2};$	$A_{HH1} + A_{HH2}; A_{HV1} + A_{HV2}; A_{VV1} + A_{VV2}$
$\gamma + \gamma + \gamma$	-----	$\gamma_{HH1_HH2} + \gamma_{HV1_HV2} + \gamma_{VV1_VV2}$
A + A + γ	$\gamma_{HH1_HH2} + A_{HH1} + A_{HV1};$ $\gamma_{HV1_HV2} + A_{HH1} + A_{HV1};$ $\gamma_{HV1_HV2} + A_{HH2} + A_{HV2};$ $\gamma_{HV1_HV2} + A_{HH2} + A_{HV2};$ $\gamma_{HH1_HH2} + A_{HH1} + A_{HH2};$ $\gamma_{HV1_HV2} + A_{HV1} + A_{HV2}$	$\gamma_{HH1_HH2} + A_{HH1} + A_{HH2}; \gamma_{HV1_HV2} + A_{HV1} + A_{HV2}; \gamma_{VV1_VV2} + A_{VV1} + A_{VV2};$
A + A + A	---	$A_{HH1} + A_{HV1} + A_{VV1}; A_{HH2} + A_{HV2} + A_{VV2};$
A + A + A + γ	---	$A_{HH1} + A_{HV1} + A_{VV1} + \gamma_{HH1_HH2}; A_{HH1} + A_{HV1} + A_{VV1} + \gamma_{HV1_HV2}; A_{HH1} +$ $A_{HV1} + A_{VV1} + \gamma_{VV1_VV2}; A_{HH2} + A_{HV2} + A_{VV2} + \gamma_{HH1_HH2}; A_{HH2} + A_{HV2} +$ $A_{VV2} + \gamma_{HV1_HV2}; A_{HH2} + A_{HV2} + A_{VV2} + \gamma_{VV1_VV2}$

Todas as composições mostradas na Tabela 3.10 foram utilizadas nos dois métodos de classificação empregados: (MaxVer + ICM) e SVM.

Para as classificações pelo algoritmo SVM foi usada a estratégia multiclasse um-contra-um, sendo definida como função *kernel* a RBF (*radial basis function* – função de base radial), com os valores *default* do ENVI 4.4 para o parâmetro *Gamma* (inverso do número de componentes ou canais) e para a penalidade (100).

Antes das classificações (MaxVer + ICM) foram feitos testes de normalidade e de aderência no *Polarimetric Classifier 0.7* (CORREIA, 1999) a fim de verificar quais as distribuições estatísticas melhor ajustadas para cada uma das classes em todas as imagens. Foram obtidos os seguintes valores-p para a normalidade (Tabelas 3.11 e 3.12):

Tabela 3.11 – Dados FBD: Valores-p dos testes de normalidade das classes.

Imagem	Floresta Primária	Floresta Modificada	Pastagem	Agricultura	Solo Exposto
A_{HH1}	3,37 x 10 ⁻²	0	0	0	4,44 x 10 ⁻⁴
A_{HH2}	2,59 x 10 ⁻⁵	1,07 x 10 ⁻⁵	0	0	5,64 x 10 ⁻²
A_{HV1}	1,49 x 10 ⁻²	1,78 x 10 ⁻⁷	0	0	6,05 x 10 ⁻¹
A_{HV2}	3,11 x 10 ⁻²	1,08 x 10 ⁻⁴	0	0	0
γ_{HH1_HH2}	0	0	0	0	7,98 x 10 ⁻⁶
γ_{HV1_HV2}	0	0	0	0	0

Tabela 3.12 - Dados PLR: Valores-p dos testes de normalidade das classes.

Imagem	Floresta Primária	Floresta Modificada	Pastagem	Agricultura	Solo Exposto
A_{HH1}	$3,86 \times 10^{-4}$	$1,78 \times 10^{-7}$	$1,55 \times 10^{-1}$	0	0
A_{HH2}	$3,15 \times 10^{-6}$	$3,57 \times 10^{-7}$	10^{-4}	0	0
A_{HV1}	$1,40 \times 10^{-2}$	$9,99 \times 10^{-2}$	0	0	$1,54 \times 10^{-5}$
A_{HV2}	$9,23 \times 10^{-3}$	$8,27 \times 10^{-5}$	0	0	$3,31 \times 10^{-3}$
A_{VV1}	$4,48 \times 10^{-2}$	$4,32 \times 10^{-4}$	0	0	0
A_{VV2}	$5,65 \times 10^{-4}$	$1,83 \times 10^{-1}$	0	0	$3,31 \times 10^{-2}$
γ_{HH1_HH2}	0	0	0	0	0
γ_{HV1_HV2}	0	0	0	0	0
γ_{VV1_VV2}	0	0	0	0	0

Obtidos os valores-p, a hipótese de normalidade para cada classe é então validada ou invalidada conforme o nível de significância adotado. No caso desta dissertação optou-se por adotar a normalidade em virtude dos testes de aderência não terem acusado outras distribuições estatísticas melhor ajustadas para as classes em muitas das imagens utilizadas. As funções de densidade de probabilidade (f.d.p.) das classes nas imagens usadas nas classificações serão mostradas no Capítulo 4.

As classificações (MaxVer + ICM) foram realizadas no *Polarimetric Classifier 0.7* (CORREIA, 1999) e após realizadas as classificações por máxima verossimilhança o algoritmo ICM empregado utilizou um dos dois critérios de parada: 8 iterações ou 5% de mudanças.

4 RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados e discutidos, para os dados FBD e PLR, os resultados das avaliações visuais dos interferogramas gerados, das análises exploratórias preliminares e das classificações supervisionadas realizadas usando várias combinações entre as imagens de coerência interferométrica e as imagens-Amplitude geradas.

4.1 Avaliação visual dos interferogramas

Gerados os interferogramas dobrados, constatou-se que em todos eles, tanto para os dados FBD como para os dados PLR, são visualizadas as franjas interferométricas apenas nas áreas que apresentam médias de coerência interferométrica consideradas boas segundo o CCRS (2007), ou seja, coerências acima de 0,5 (regiões não-florestadas). As áreas ruidosas nos interferogramas apresentam baixos valores de coerência interferométrica, com médias inferiores a 0,5, sendo associadas principalmente às regiões de florestas primárias e modificadas.

Exemplificando tais ocorrências, a Figura 4.1 ilustra composições RGB de dois interferogramas gerados. As composições RGB foram obtidas após transformação IHS-RGB consideradas as seguintes componentes: H = fase dobrada; I = coerência interferométrica; S = 1.





Figura 4.1 – Composições RGB de interferogramas dobrados: (a) HH1_HH2 (FBD); (b) HH1_HH2 (PLR).

As franjas observadas são quase retas verticais, em virtude do terreno da área de estudo apresentar um modelo topográfico que varia de plano a suavemente ondulado, conforme descrito na seção 3.1. Com base na Equação 2.11 foram calculados os espaçamentos das franjas, que apresentam espaçamento médio de 238 metros nos interferogramas das imagens FBD enquanto para as imagens PLR o espaçamento médio é de 30,75 metros. Os espaçamentos calculados são diferentes para os dados FBD e PLR em virtude das diferenças entre os comprimentos de linha-base e as distâncias *near-range*.


A visualização das franjas é alterada ao ser removida a fase plana. A Figura 4.2 ilustra os mesmos interferogramas da Figura 4.1 removidos de fase plana em composições RGB considerando dois casos diferentes para a componente Intensidade.

H = interferograma; I = coerência; S = 1




(a)


H = interferograma; I = 1; S = 1



(b)



(c)



(d)

Figura 4.2 – Composições RGB de interferogramas removidos de fase plana: (a) e (b) HH1_HH2 (FBD); (c) e (d) HH1_HH2 (PLR).

Assim como ocorreu para os interferogramas da Figura 4.1 (com fase plana), nos interferogramas Figuras 4.2(a) e 4.2(c) as cores não são visualizadas com nitidez nas áreas de baixa coerência, em virtude da componente Intensidade ter sido definida como o valor de coerência interferométrica. Em contrapartida, nas áreas correspondentes às altas coerências as cores apresentam satisfatória nitidez.

Nos interferogramas das Figuras 4.2(b) e 4.2(d), em que a componente Intensidade foi definida como máxima, as cores associadas às áreas de baixas coerências são visualizadas menos escuras do que nos dois casos anteriores, porém também não apresentam nitidez satisfatória, devido ao ruído na fase, provocado pela baixa correlação entre as imagens nestas regiões.

Com base nessas avaliações visuais, constata-se que em áreas de baixa coerência não é possível obter relevante informação de fase interferométrica que, no caso das referidas figuras, está sendo visualizada em cores.

Usando os interferogramas removidos de fase plana foram testados dois diferentes métodos de desdobramento de fase, o de crescimento de regiões (local) e o dos mínimos quadrados (global), a fim de estabelecer uma comparação entre eles e também de avaliar se o nível de ruído de fase poderia comprometer o desempenho dos mesmos, no caso de serem utilizados nos processamentos subseqüentes que visam gerar MDE's, que são basicamente a calibração de fase, o cálculo da fase absoluta e a conversão de fase absoluta em altura topográfica.

Para tal, considerou-se que se um interferograma desdobrado não apresentasse consideráveis ruídos de fase o mesmo poderia ser utilizado nos processamentos citados anteriormente, haja vista que fases interferométricas não-ruídosas (consideradas "confiáveis") permitem calcular alturas topográficas a partir das equações mostradas no trabalho de [Mura \(2000\)](#). As avaliações visuais dos interferogramas desdobrados foram feitas com auxílio das correspondentes imagens de coerência interferométrica.

A Figura 4.3 ilustra os interferogramas desdobrados correspondentes aos interferogramas da Figura 4.2 (b) e (d) obtidos pelos dois métodos testados.

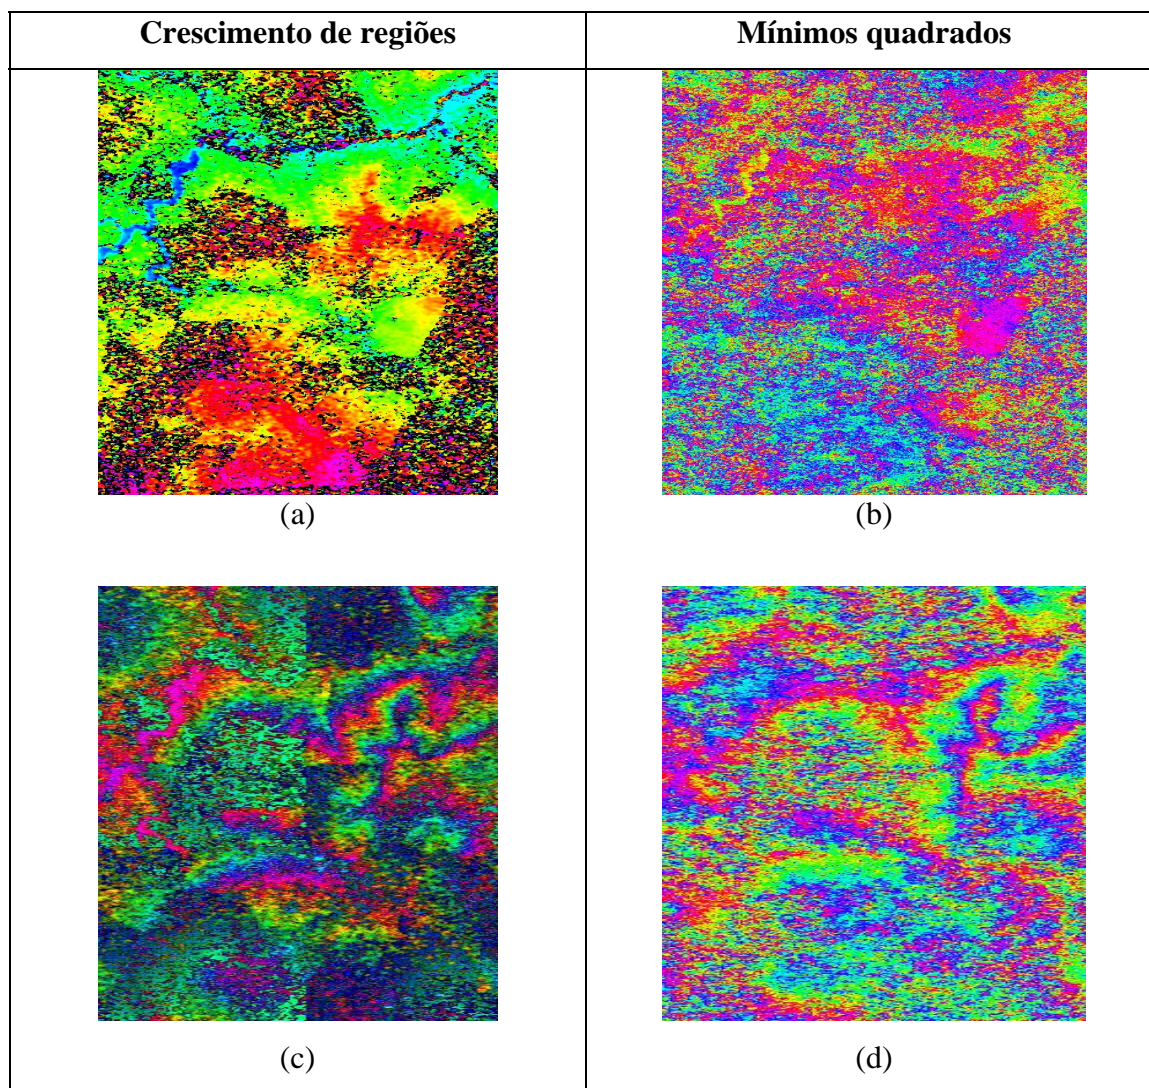


Figura 4.3 – Composições RGB de interferogramas desdobrados:
(a) e (b) HH1_HH2 (FBD); (c) e (d) HH1_HH2 (PLR).

Os ruídos de fase correspondentes às áreas de baixa coerência são mais evidentes nos dois interferogramas desdobrados pelo método do crescimento de regiões (Figuras 4.3 (a) e 4.3 (c)), pois este criou muitas “ilhas” que ilustram as inconsistências de fase interferométrica. Essas inconsistências as impede de serem utilizadas na calibração de fase e no cálculo da fase absoluta. Com isso, o potencial desses interferogramas desdobrados para gerar MDE’s fica comprometido.

No caso dos interferogramas desdobrados pelo método dos mínimos quadrados ((Figuras 4.3 (b) e 4.3(d)), são visualizados menos ruídos, porém a variação de cores e

conseqüentemente de fases interferométricas mostraram-se significativamente diferentes dos interferogramas da Figura 4.2, o que permite concluir que tal método possa ser menos preciso do que o de crescimento de regiões, haja vista que ele gera a fase desdobrada mesmo onde a coerência é baixa.

O fato dos interferogramas desdobrados terem se mostrado inapropriados para gerar modelos digitais de elevação permite concluir que a aplicabilidade dos interferogramas ALOS/PALSAR de regiões florestadas é prejudicada pela descorrelação temporal existente entre as imagens de cada par interferométrico.

4.2 Análises exploratórias

Com o objetivo de auxiliar as conclusões sobre os resultados obtidos com as classificações supervisionadas realizadas, foram feitas análises exploratórias preliminares com base nas distribuições estatísticas apresentadas por cada uma das cinco classes de estudo em todas as imagens geradas (imagens de coerência e imagens-Amplitude). Além de investigar o comportamento da coerência interferométrica nas classes de estudo, as análises preliminares consistiram também em verificar a separabilidade entre elas em todas as imagens geradas, com base na distância estatística JM calculada a partir das médias e desvios-padrão das classes.

As seções 4.2.1 e 4.2.2 mostram respectivamente para os dados FBD e PLR: todas as imagens de coerência interferométrica calibradas e seus respectivos histogramas; as distribuições estatísticas das classes, consideradas normais (gaussianas), para todas as imagens geradas; os histogramas de coerência para cada uma das classes de estudo; e os valores de distância JM para cada um dos pares de classes (Floresta Primária x Floresta Modificada; Floresta Primária x Agricultura; Floresta Primária x Pastagem; Floresta Primária x Solo Exposto; Floresta Modificada x Agricultura; Floresta Modificada x Pastagem; Floresta Modificada x Solo Exposto; Agricultura x Solo Exposto; Agricultura x Pastagem; Pastagem x Solo exposto).

Foram feitas ainda comparações entre as médias de coerência interferométrica das cinco classes nas imagens de coerência dado o nível de significância de 5% e construídos para

cada classe os respectivos intervalos de confiança, definidos a partir da média, do desvio-padrão e do número de amostras.

4.2.1 Dados FBD

A Figura 4.4 mostra as imagens de coerência interferométrica HH1_HH2 (γ_{HH1_HH2}) e HV1_HV2 (γ_{HV1_HV2}) calibradas, com os seus respectivos histogramas.

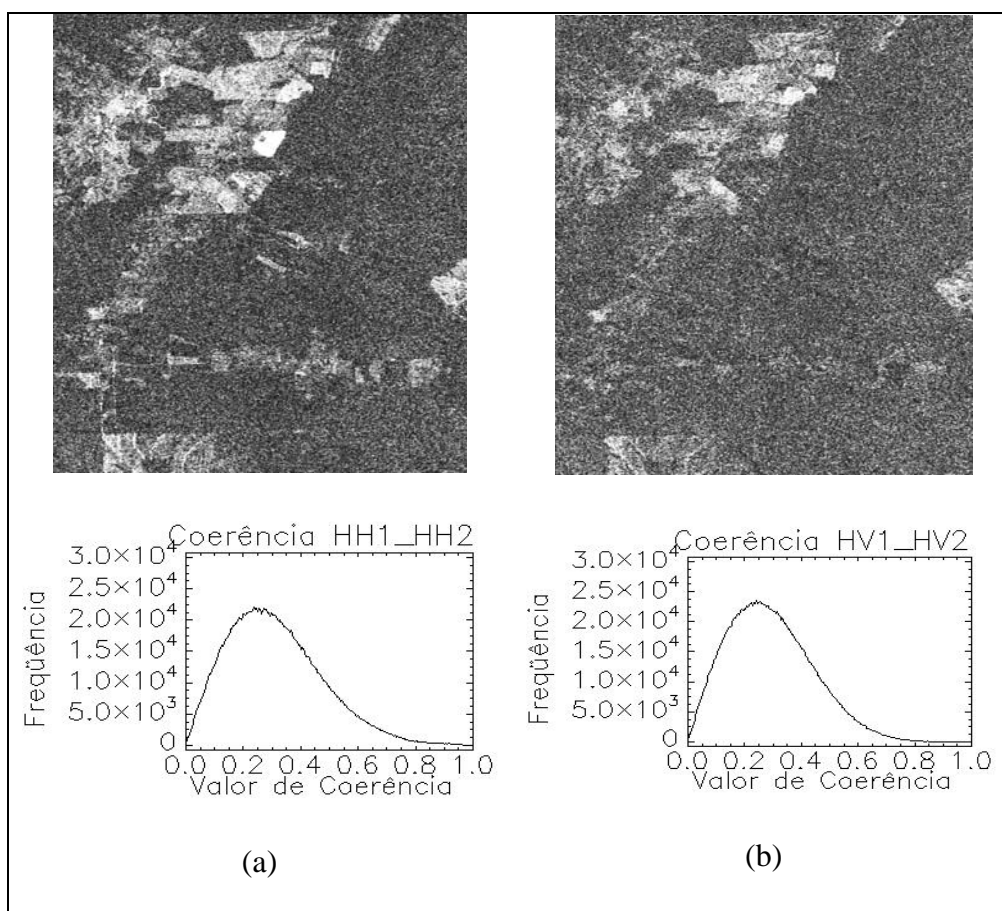


Figura 4.4 – Dados FBD: Imagens de coerência calibradas e seus respectivos histogramas: (a) γ_{HH1_HH2} ; (b) γ_{HV1_HV2}

Com base nos dois histogramas, observa-se que as distribuições estatísticas das duas imagens de coerência γ_{HH1_HH2} e γ_{HV1_HV2} possuem modas próximas, em torno de 0,23, mostrando com isso que nessas imagens predominam as áreas que apresentam baixas coerências interferométricas.

A fim de se investigar o comportamento da coerência interferométrica em cada uma das cinco classes de estudo nas imagens de coerência γ_{HH1_HH2} e γ_{HV1_HV2} são mostrados na Figura 4.5 os respectivos histogramas de coerência.

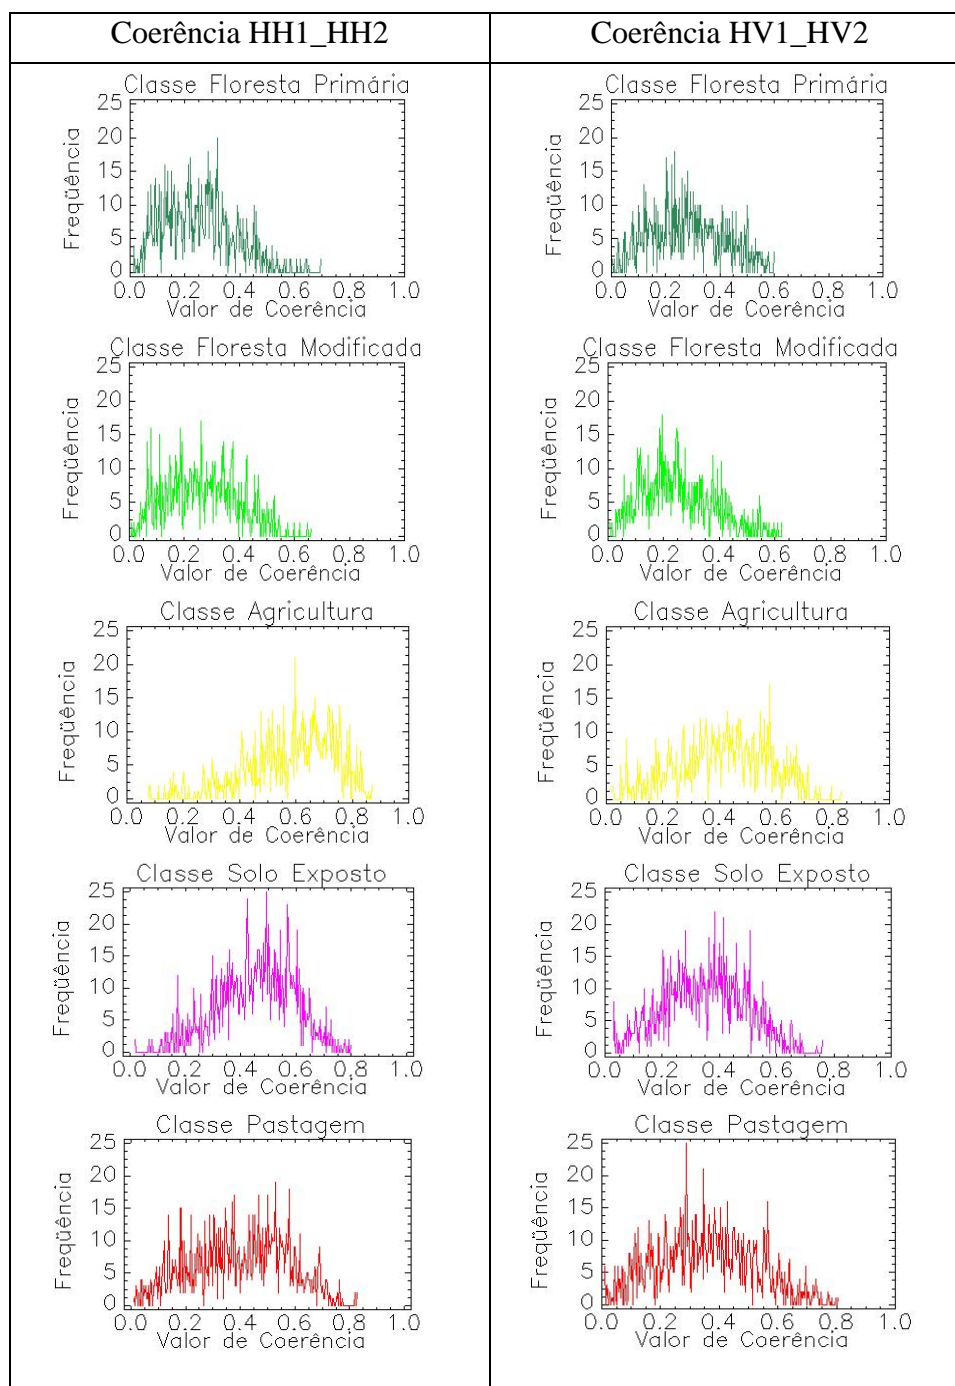


Figura 4.5 – Dados FBD: Histogramas de coerência para as cinco classes de estudo.

Os valores médios e os desvios-padrão de cada um dos histogramas de coerência das imagens de coerência γ_{HH1_HH2} e γ_{HV1_HV2} são mostrados nas Tabelas 4.1 e 4.2, respectivamente.

Tabela 4.1 – Dados FBD: Médias e desvios-padrão de cada histograma (γ_{HH1_HH2})

Classe	Média	Desvio-padrão
Floresta Primária	0,251032	0,127545
Floresta Modificada	0,269609	0,129139
Agricultura	0,584688	0,155537
Pastagem	0,398891	0,175048
Solo Exposto	0,456954	0,136217

Tabela 4.2 - Dados FBD: Médias e desvios-padrão de cada histograma (γ_{HV1_HV2})

Classe	Média	Desvio-padrão
Floresta Primária	0,278984	0,133101
Floresta Modificada	0,250156	0,127965
Agricultura	0,417621	0,158119
Pastagem	0,357783	0,164467
Solo Exposto	0,352640	0,141391

As Figuras 4.6 e 4.7 mostram respectivamente para as imagens γ_{HH1_HH2} e γ_{HV1_HV2} os resumos estatísticos contendo as médias e os intervalos de confiança de 95% para a coerência interferométrica em cada classe.




Figura 4.6 – Dados FBD: resumo estatístico das classes na imagem de coerência γ_{HH1_HH2} .




Figura 4.7 – Dados FBD: resumo estatístico das classes na imagem de coerência γ_{HV1_HV2} .

Conforme o esperado, tanto em γ_{HH1_HH2} como em γ_{HV1_HV2} as médias de coerência observadas para as classes não-florestadas foram significativamente maiores do que as médias associadas às classes de florestas (primárias e modificadas). Comparando o comportamento de cada classe nas duas imagens, nota-se que as classes Agricultura e Solo Exposto apresentaram médias significativamente maiores na imagem de coerência γ_{HH1_HH2} , fato este que permite inferir que nessa imagem as referidas classes podem ser melhor discriminadas, já que as separabilidades de cada uma delas em relação às demais classes podem ser maiores do que em γ_{HV1_HV2} . Em contrapartida, nas duas imagens de coerência as médias observadas para as classes florestadas não diferem significativamente, o que permite deduzir que a separabilidade entre elas seja a menor dentre todas as calculadas.

A fim de analisar simultaneamente o comportamento das cinco classes de estudo nas imagens de coerência interferométrica e nas imagens-Amplitude geradas a Figura 4.8 e a Tabela 4.3 mostram respectivamente as distribuições gaussianas associadas às classes e as distâncias JM entre elas (valores de 0 a 2) considerando apenas um atributo, apresentando alguns valores destacados (cores verde, vermelho e azul) que foram analisados na seqüência.

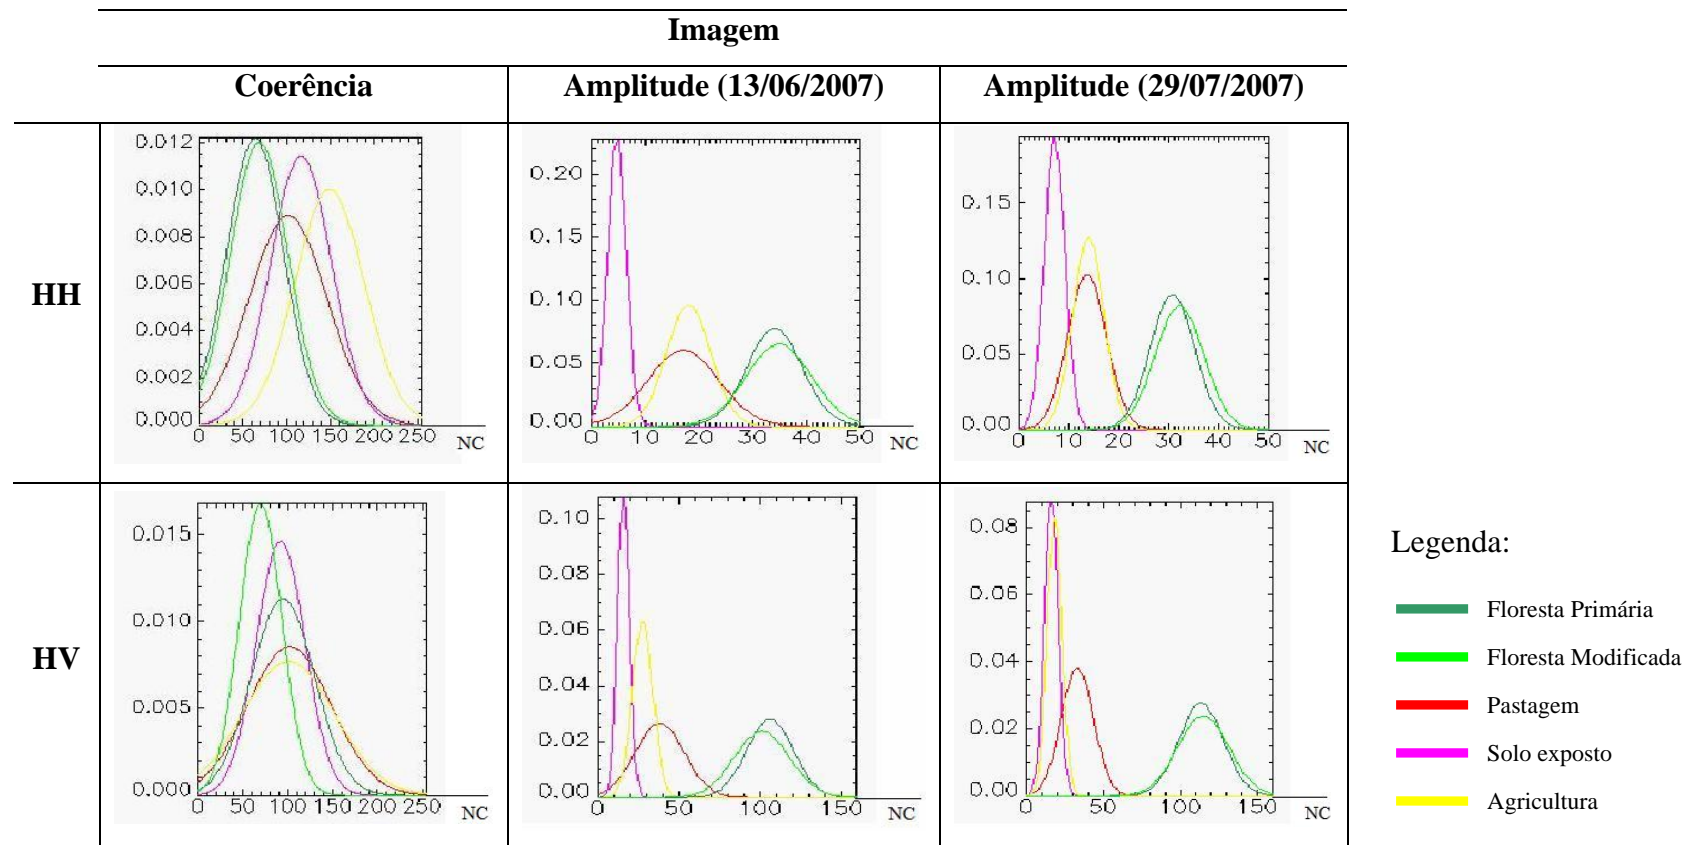


Figura 4.8 – Dados FBD: distribuições gaussianas das cinco classes de estudo

Tabela 4.3 – Dados FBD: distâncias estatísticas JM entre as classes para apenas um atributo.

<u>Pares de classes</u>	γ_{HH1_HH2}	γ_{HV1_HV2}	A_{HH1}	A_{HH2}	A_{HV1}	A_{HV2}
Floresta Primária x Floresta Modificada	0,01808	0,01710	0,04645	0,04766	0,06417	0,06309
Floresta Primária x Pastagem	0,36398	0,31936	1,81345	1,90287	1,99093	1,99792
Floresta Primária x Agricultura	1,11995	1,04772	1,90506	1,92375	1,99998	2,00000
Floresta Primária x Solo Exposto	0,57164	0,56518	2,00000	1,99997	1,99999	2,00000
Floresta Modificada x Agricultura	1,09970	1,01186	1,88482	1,92957	1,99977	2,00000
Floresta Modificada x Solo Exposto	0,54978	0,53979	2,00000	1,99965	1,99995	2,00000
Floresta Modificada x Pastagem	0,32673	0,37878	1,81549	1,90051	1,97933	1,99762
Solo Exposto x Agricultura	0,22427	0,21546	1,98351	1,82635	1,32065	1,10517
Solo Exposto x Pastagem	0,08395	0,08048	1,97414	1,39557	1,93987	1,28931
Agricultura x Pastagem	0,30725	0,30232	0,13599	0,12264	1,31313	1,00369

Legenda:

- █ Valores altos
- █ Valores baixos
- █ Divergência

Conforme o esperado, as menores distâncias JM calculadas referem-se ao par (Floresta Primária x Floresta Modificada) nas duas imagens de coerência, o que permite concluir que γ_{HH1_HH2} e γ_{HV1_HV2} não permitem separar satisfatoriamente as classes Floresta Primária e Floresta Modificada. Nessas duas imagens as maiores distâncias JM observadas referem-se às separabilidades entre as duas classes florestadas e a Agricultura, mostrando que essa possa ser a melhor classe discriminada, tanto em γ_{HH1_HH2} como em γ_{HV1_HV2} .

Comparando-se apenas as distâncias JM calculadas para as duas imagens de coerência constata-se que, exceto para o par (Floresta Modificada x Pastagem), as separabilidades entre as classes são maiores em γ_{HH1_HH2} do que em γ_{HV1_HV2} . Este fato confirma a inferência de que as separabilidades das classes Solo Exposto e Agricultura em relação às demais são maiores na imagem γ_{HH1_HH2} , o que permite concluir que, além da classe Agricultura, a classe Solo Exposto possa ser também melhor discriminada nessa imagem.

Ao comparar as distâncias JM observadas para as imagens de coerência e para as imagens-Amplitude nota-se que apenas para o par (Pastagem x Agricultura) as distâncias calculadas nas imagens-Amplitude não foram todas maiores do que as distâncias associadas às imagens de coerência. As distâncias JM para esse par são maiores nas duas imagens de coerência do que nas imagens-Amplitude HH (tanto HH1 como HH2), o que permite concluir que o potencial de imagens de polarização horizontal para separar pastagens de áreas agrícolas pode ser inferior ao potencial das duas imagens de coerência e das imagens-Amplitude HV.

Isso é explicado pelo fato de que sob polarização HV, em relação à polarização HH, a aleatoriedade do espalhamento das microondas em áreas de pastagens pode ser maior do que em áreas agrícolas e com isso o retroespalhamento de pastagens é mais intenso do que o observado para agricultura. Além disso, como as imagens-Amplitude HH apresentaram distâncias JM maiores que as imagens-Amplitude HV apenas para o par (Solo Exposto x Agricultura), fica mostrado que as áreas de Agricultura interagem de

forma mais intensa com microondas horizontalmente polarizadas do que as áreas de pastagens. Assim como as imagens-Amplitude HV, as imagens-Amplitude HH apresentaram máximas distâncias JM (iguais ou próximas a 2,0) para os pares (Solo Exposto x Floresta Primária) e (Solo Exposto x Floresta Modificada).

As separabilidades observadas entre as duas classes florestadas e as outras três (Pastagem, Solo Exposto e Agricultura) apresentaram distâncias JM iguais ou próximas ao valor máximo (2,0) nas duas imagens-Amplitude (HV1 e HV2); fato este que mostra que as duas classes de florestas podem ser melhor discriminadas nas imagens-Amplitude HV.

Feitas as análises exploratórias para os dados FBD pode-se concluir que, apesar de não ter sido obtida nenhuma separabilidade significativa entre Floresta Primária e Floresta Modificada, as imagens-Amplitude HV apresentaram máxima potencialidade para separar as duas classes florestadas em relação às outras três classes, além de possibilitar a maior separação entre as classes Pastagem e Agricultura. Além de possuir máxima potencialidade para separar áreas de solo exposto de áreas florestadas, as imagens-Amplitude HH podem ser utilizadas para se obter uma melhor separação entre Solo Exposto e Agricultura, sendo que essas duas classes, principalmente a classe Agricultura, podem ser satisfatoriamente discriminadas na imagem de coerência

γ_{HH1_HH2} .

4.2.2 Dados PLR

A Figura 4.9 mostra as imagens de coerência interferométrica γ_{HH1_HH2} , γ_{HV1_HV2} e γ_{VV1_VV2} calibradas, com os seus respectivos histogramas.

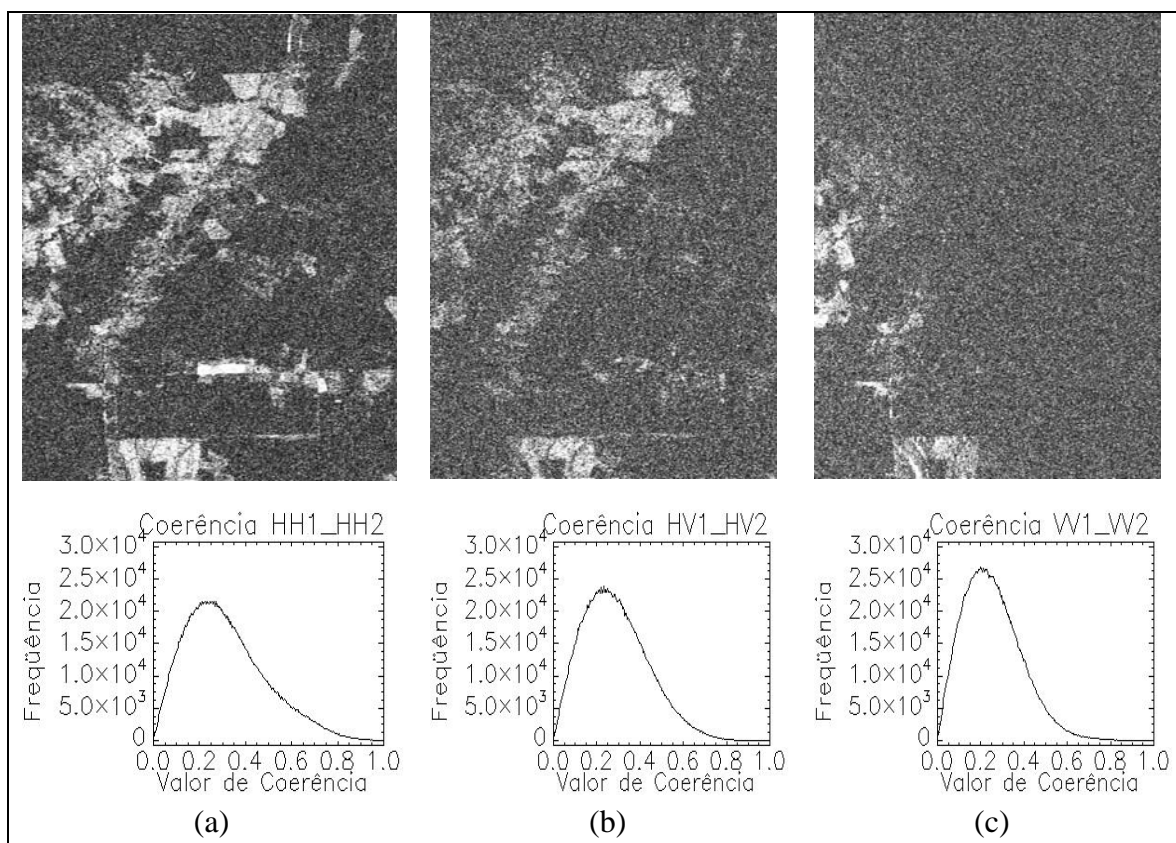


Figura 4.9 – Dados PLR: Imagens de coerência calibradas e seus respectivos histogramas: (a) γ_{HH1_HH2} ; (b) γ_{HV1_HV2} ; (c) γ_{VV1_VV2}

Com base nos dois histogramas, observa-se que as distribuições estatísticas das três imagens de coerência γ_{HH1_HH2} , γ_{HV1_HV2} e γ_{VV1_VV2} possuem modas respectivamente 0,22; 0,23 e 0,20; mostrando com isso que nessas imagens, a exemplo do que ocorreu com os dados FBD, predominam as áreas que apresentam baixas coerências interferométricas. O fato da imagem de coerência γ_{VV1_VV2} ter apresentado moda inferior às outras duas imagens mostra que entre os três pares interferométricos PLR analisados o par VV1_VV2 apresentou maior desconexão, confirmando a análise feita na seção 3.5.1.

A fim de se investigar o comportamento da coerência interferométrica em cada uma das cinco classes de estudo nas imagens de coerência γ_{HH1_HH2} , γ_{HV1_HV2} e γ_{VV1_VV2} são mostrados na Figura 4.10 os respectivos histogramas de coerência.

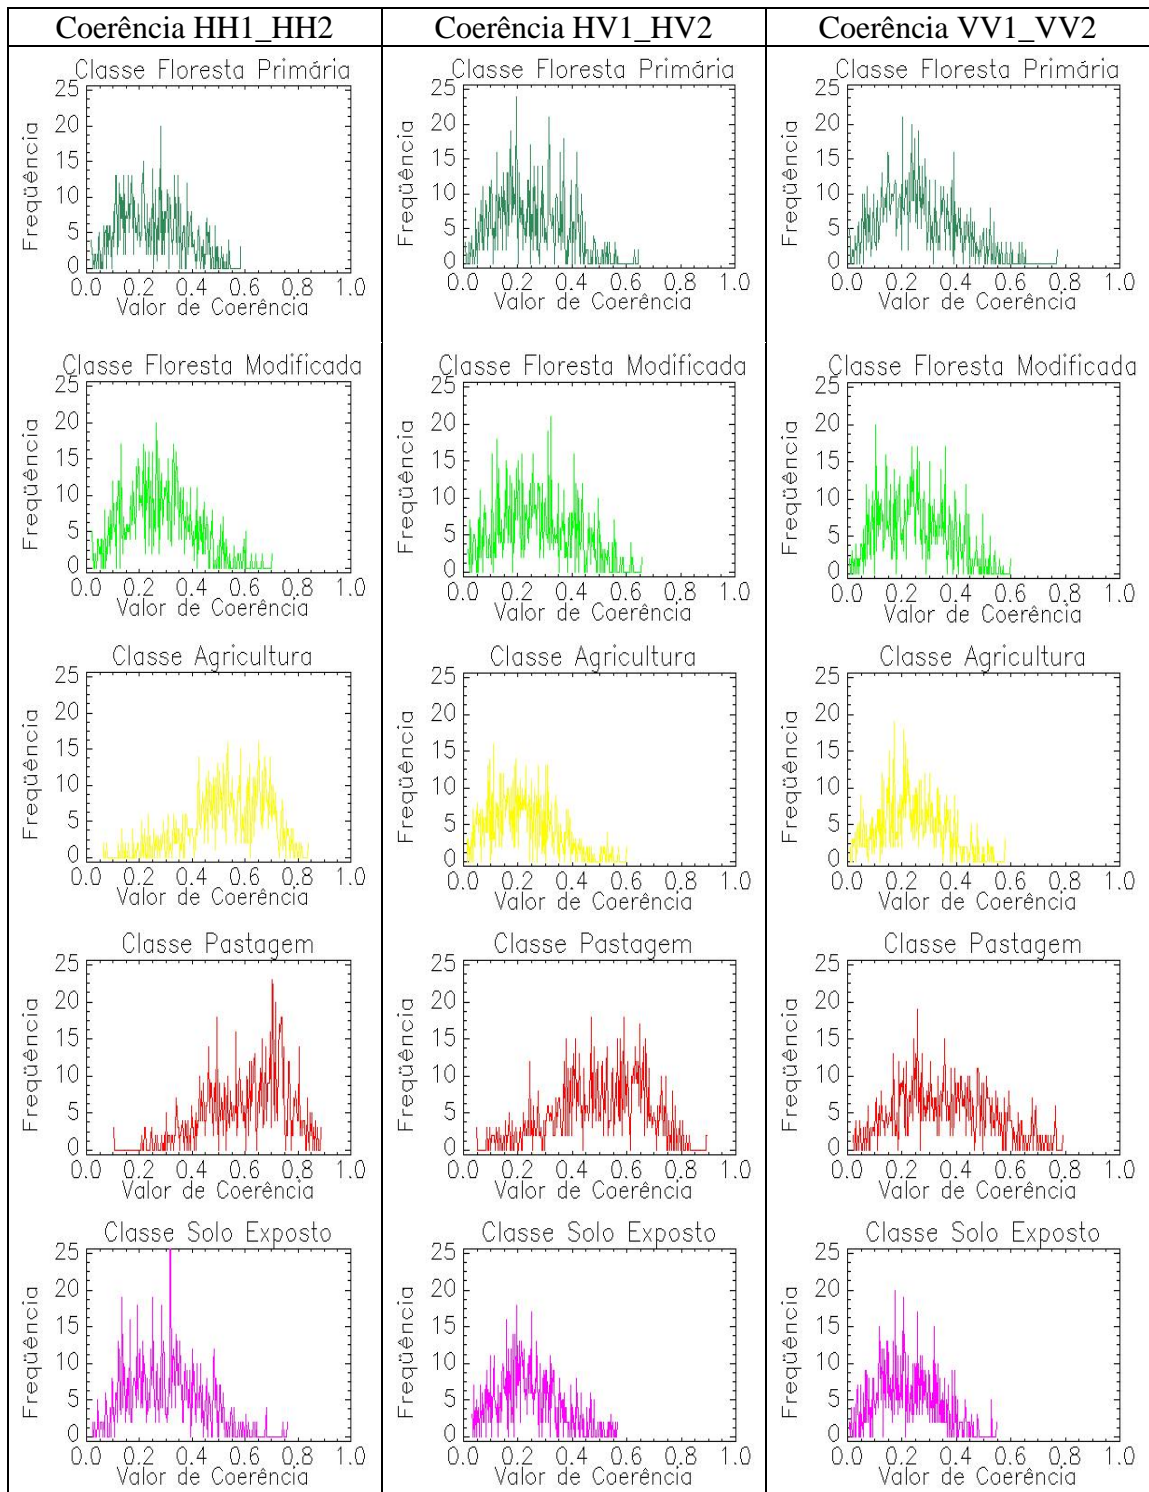


Figura 4.10 – Dados PLR: Histogramas de coerência para as cinco classes de estudo

Os valores médios e os desvios-padrão de cada um dos histogramas de coerência das imagens de coerência γ_{HH1_HH2} , γ_{HV1_HV2} e γ_{VV1_VV2} são mostrados nas Tabelas 4.3, 4.4 e 4.5, respectivamente.

Tabela 4.4 – Dados PLR: Média e desvio-padrão de cada histograma (γ_{HH1_HH2})

Classe	Média	Desvio-padrão
Floresta Primária	0,250546	0,117098
Floresta Modificada	0,278507	0,125170
Agricultura	0,538260	0,144614
Pastagem	0,610752	0,146481
Solo Exposto	0,299871	0,135299

Tabela 4.5 - Dados PLR: Média e desvio-padrão de cada histograma (γ_{HV1_HV2})

Classe	Média	Desvio-padrão
Floresta Primária	0,246955	0,121551
Floresta Modificada	0,274311	0,135743
Agricultura	0,220891	0,116527
Pastagem	0,500697	0,163319
Solo Exposto	0,242297	0,113574

Tabela 4.6 - Dados PLR: Média e desvio-padrão de cada histograma (γ_{VV1_VV2})

Classe	Média	Desvio-padrão
Floresta Primária	0,263391	0,135574
Floresta Modificada	0,250372	0,119768
Agricultura	0,240769	0,114631
Pastagem	0,363269	0,166336
Solo Exposto	0,221099	0,107376

As Figuras 4.11, 4.12 e 4.13 mostram respectivamente para as imagens γ_{HH1_HH2} , γ_{HV1_HV2} e γ_{VV1_VV2} as médias e os intervalos de confiança de 95% para a coerência interferométrica em cada classe.




Figura 4.11 – Dados PLR: resumo estatístico das classes na imagem de coerência γ_{HH1_HH2} .




Figura 4.12 – Dados PLR: resumo estatístico das classes na imagem de coerência γ_{HV1_HV2} .




Figura 4.13 – Dados PLR: resumo estatístico das classes na imagem de coerência γ_{VV1_VV2} .

A classe Pastagem apresentou significativamente as maiores médias, sendo com isso esperado que as maiores separabilidades encontradas nas imagens de coerência sejam entre Pastagem e todas as outras quatro classes de estudo.

A classe Solo Exposto não apresentou médias de coerência interferométrica significativamente superiores às médias das classes Floresta Primária e Floresta Modificada. Isto permite inferir que a classe Solo Exposto apresenta, em relação às duas classes florestadas, separabilidades menores do que as observadas para as imagens de coerência FBD.

Tal como ocorreu na análise dos dados FBD, em cada uma das imagens de coerência não foram observadas significativas diferenças entre as médias de coerência interferométrica associadas às duas classes florestadas, indicando assim que a separabilidade entre elas possa ser a menor entre todas as calculadas para os dados PLR.

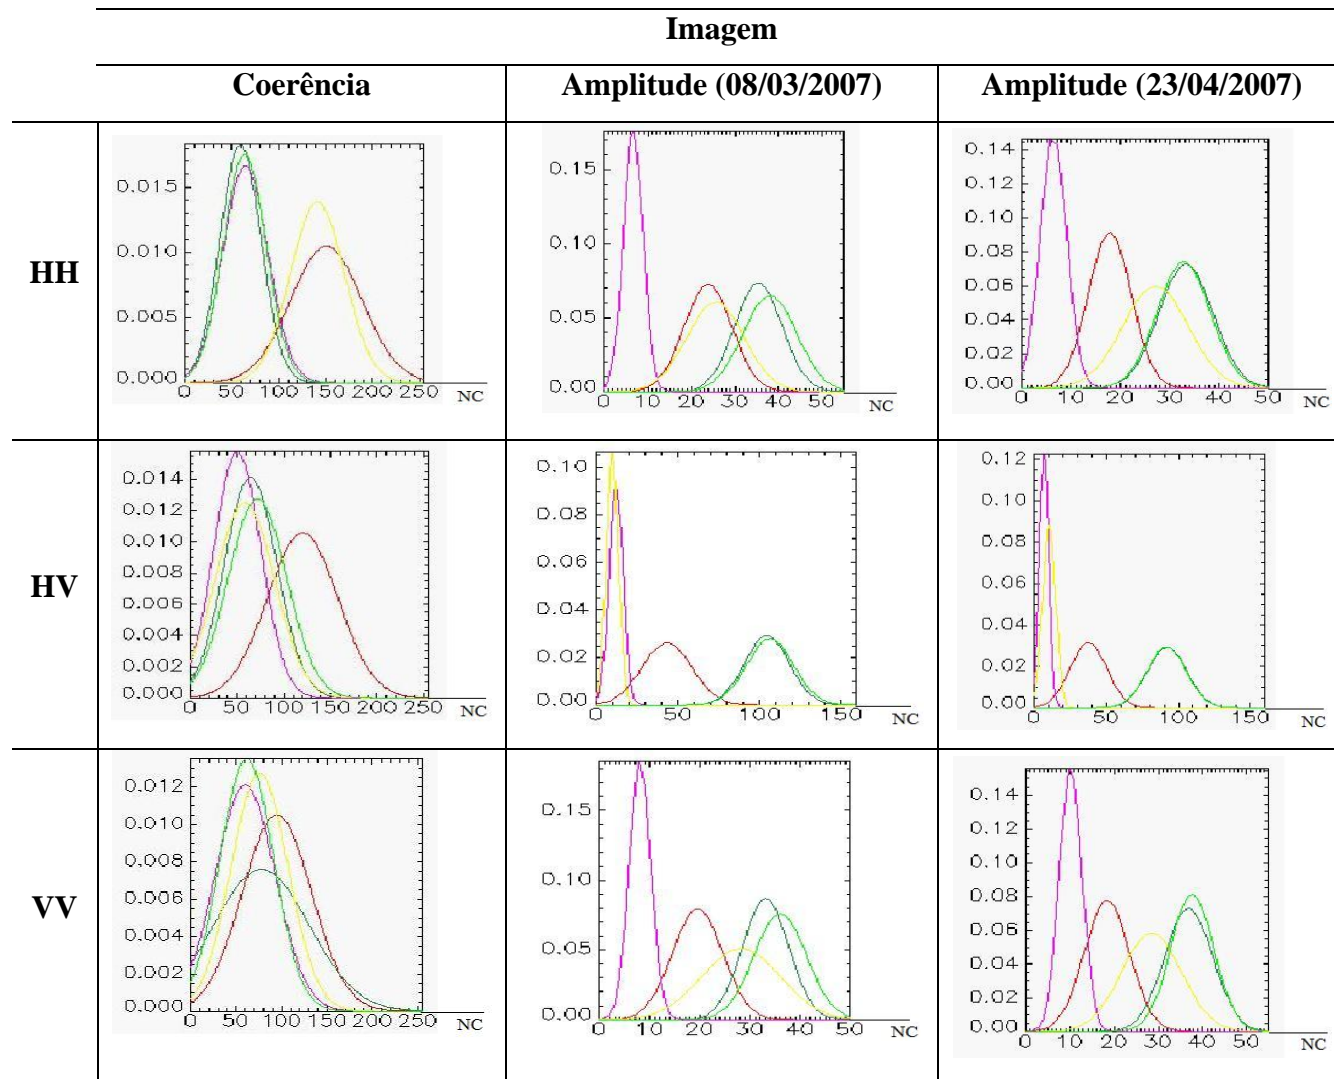
Analisando o comportamento de cada classe nas três imagens, nota-se que as classes Agricultura e Pastagem apresentaram médias de coerência maiores na imagem de coerência γ_{HH1_HH2} , fato este que permite inferir que nessa imagem as referidas classes podem ser melhor discriminadas, já que as separabilidades de cada uma delas em relação às demais classes podem ser maiores do que em γ_{HV1_HV2} e γ_{VV1_VV2} .

Ao comparar as médias de coerência mostradas nas Tabelas 4.4 e 4.5 com as médias de coerência para os dados FBD mostrados nas Tabelas 4.1 e 4.2, nota-se que as três classes não-florestadas apresentaram, para as imagens γ_{HH1_HH2} e γ_{HV1_HV2} , significativas diferenças nas médias de coerência interferométrica, sendo que nas classes Solo Exposto e Agricultura as médias aumentaram enquanto na classe Pastagem as médias diminuíram.

Essas ocorrências se justificam entre outros fatores por ter havido variações nas condições climáticas entre as duas épocas consideradas (março/abril – PLR e junho-julho/FBD), conforme citado na seção 3.2. As variações de precipitação acumulada aliadas à ocorrência de possíveis mudanças na cobertura da terra entre as duas épocas e

aos diferentes ângulos de incidência para as imagens FBD e PLR afetaram o retroespalhamento e conseqüentemente as fases interferométricas foram alteradas.

A fim de analisar simultaneamente o comportamento das cinco classes de estudo nas imagens de coerência interferométrica e nas imagens-Amplitude geradas, a Figura 4.14 e a Tabela 4.7 mostram respectivamente as distribuições estatísticas associadas às classes e as distâncias JM entre elas (valores de 0 a 2) considerando apenas um atributo, apresentando alguns valores destacados (cores vermelho e azul) que foram analisados na seqüência.



Legenda:

- █ Floresta Primária
- █ Floresta Modificada
- █ Pastagem
- █ Solo exposto
- █ Agricultura

Figura 4.14 – Dados PLR: distribuições gaussianas das cinco classes de estudo

Tabela 4.7 - Dados PLR: distâncias estatísticas JM entre as classes para apenas um atributo.

Pares de classes	γ_{HH1_HH2}	γ_{HV1_HV2}	γ_{VV1_VV2}	A_{HH1}	A_{HH2}	A_{HV1}	A_{HV2}	A_{VV1}	A_{VV2}
Floresta Primária x Floresta Modificada	0,03209	0,03227	0,02822	0,06866	0,06735	0,01320	0,01309	0,11904	0,11630
Floresta Primária x Pastagem	1,44204	1,35579	0,72391	1,51578	1,59128	1,88175	1,89731	1,75107	1,81998
Floresta Primária x Agricultura	0,92977	0,75877	0,03550	0,72006	0,65387	1,99999	2,00000	0,65188	0,84836
Floresta Primária x Solo Exposto	0,05132	0,05226	0,03198	1,99999	1,99984	1,99999	2,00000	1,99998	1,99999
Floresta Modificada x Agricultura	0,80567	0,79283	0,05927	0,94076	0,85141	2,00000	1,99999	0,86405	0,69151
Floresta Modificada x Solo Exposto	0,04210	0,04292	0,03707	1,99999	1,99989	1,99999	2,00000	1,99998	2,00000
Floresta Modificada x Pastagem	1,24449	1,18658	0,62914	1,57901	1,61417	1,89907	1,91416	1,81094	1,83738
Solo Exposto x Agricultura	0,62392	0,62177	0,61925	1,87363	1,99958	0,48127	0,53673	1,80092	1,99981
Solo Exposto x Pastagem	1,27831	1,18508	0,89595	1,99001	1,82137	1,70122	1,99990	1,48046	1,69060
Agricultura x Pastagem	0,81140	0,88820	0,70263	0,89013	1,01835	1,99719	1,63284	0,68641	0,74447

Legenda:

- Valores altos
- Valores baixos

Considerando-se apenas as três imagens de coerência, nota-se que para cada par de classes as separabilidades são menores em γ_{VV1_VV2} , fazendo com que ocorra nessa imagem uma maior confusão entre as classes e com isso seu desempenho nas classificações supervisionadas possa ser afetado. Em cada imagem de coerência as maiores distâncias JM observadas referem-se às separabilidades envolvendo a classe Pastagem e todas as outras classes, permitindo deduzir que nas três imagens de coerência a referida classe pode ser a melhor discriminada. Essas separabilidades mostraram-se maiores em γ_{HH1_HH2} do que em γ_{HV1_HV2} e γ_{VV1_VV2} , e com isso pode-se assumir que entre as três imagens de coerência a imagem γ_{HH1_HH2} apresenta melhor capacidade de discriminar a classe Pastagem.

Além do par (Floresta Primária x Floresta Modificada), os pares (Floresta Primária x Solo Exposto) e (Floresta Modificada x Solo Exposto) apresentaram as menores distâncias JM em cada uma das três imagens de coerência, confirmando a inferência de que as imagens de coerência FBD apresentam separabilidades maiores envolvendo a classe Solo Exposto. Em contrapartida, todas as imagens-Amplitude apresentaram distâncias JM máximas (iguais ou próximas a 2,0) para essas mesmas separabilidades.

Tal como ocorreu nas análises com os dados FBD, não houve nenhuma separação significativa entre as duas classes florestadas, sendo com isso concluído que nenhuma das imagens geradas permitiu separar satisfatoriamente essas duas classes. Outras duas ocorrências, ambas relacionadas às imagens-Amplitude HV, repetiram-se nas análises para os dados PLR: distâncias JM observadas entre as classes Floresta Primária e Floresta Modificada e cada uma das três classes não-florestadas iguais ou próximas ao valor máximo (2,0); maior separabilidade entre as classes Pastagem e Agricultura. Estes fatos mostram a máxima potencialidade das imagens-Amplitude HV para separar as classes florestadas em relação às outras três e também a capacidade de permitir a maior separação entre as classes Pastagem e Agricultura.

Devido ao fato das imagens-Amplitude HH e VV terem apresentado distâncias JM significativamente maiores que as imagens-Amplitude HV para o par (Solo Exposto x Agricultura), conclui-se que aquelas imagens podem ser utilizadas para se obter uma melhor separação entre áreas agrícolas e de solo exposto.

Feitas as análises exploratórias para os dados PLR, conclui-se que entre as três imagens de coerência, a imagem γ_{VV1_VV2} pode apresentar o pior potencial para discriminar todas as classes enquanto a imagem de coerência γ_{HH1_HH2} pode discriminar satisfatoriamente a classe Pastagem. Em relação às imagens-Amplitude pode-se concluir que as imagens-Amplitude HV apresentam o melhor potencial para discriminar as duas classes de florestas, embora não tenha ocorrido nenhuma separabilidade significativa entre essas duas classes. Outra significativa potencialidade observada nas imagens-Amplitude HV está na capacidade de separar áreas agrícolas de pastagens.

Além da separação (Solo Exposto x classes florestadas), as imagens-Amplitude HH e VV apresentaram boas potencialidades para separar também as classes (Solo Exposto x Agricultura). Porém, ao se comparar as distâncias JM apresentadas por essas imagens para os pares envolvendo (Pastagem x classes florestadas), nota-se que as imagens-Amplitude VV apresentaram separabilidades maiores do que as imagens-Amplitude HH, mostrando mais uma vez que para discriminar áreas de pastagem as imagens-Amplitude HH podem não apresentar satisfatório potencial.

4.3 Classificações supervisionadas

Nessa seção são descritos e analisados os resultados obtidos com todas as classificações supervisionadas realizadas. Para isso, os resultados apresentados juntamente com as respectivas análises e discussões foram divididos em doze casos diferentes, considerando os dois algoritmos de classificação empregados (MaxVer + ICM e SVM), os dois tipos de dados utilizados (FBD e PLR) e os três tipos de composições entre as imagens utilizadas (univariadas, bivariadas e multivariadas).

Os resultados estão organizados nas Tabelas 4.8 a 4.19, que contêm os valores dos parâmetros estatísticos (Exatidão Global (P_0), coeficiente *Kappa* (\hat{k}) e sua variância ($\hat{\sigma}_k^2$)) estimados a partir das matrizes de confusão geradas na validação das classificações, e também nas Figuras 4.15 a 4.38, que ilustram os intervalos de confiança de 95% para o coeficiente *Kappa* em cada classificação além das melhores classificações realizadas em cada um dos doze casos considerados. A conceituação de cada classificação foi feita com base no valor do coeficiente *Kappa*, de acordo com os critérios Landis & Koch, Fleiss e Galparsoro & Fernández, citados na seção 2.4.3.

Os intervalos de confiança foram obtidos a partir dos coeficientes *Kappa* estimados (\hat{k}) e seus respectivos desvios-padrão ($\hat{\sigma}_k$), que permitiram ainda a realização de testes de hipóteses a fim de se verificar igualdades entre exatidões de classificação, dado o nível de significância de 5%. Para tal foram consideradas comparações feitas entre classificações usando um mesmo algoritmo. As hipóteses de igualdade entre as classificações foram validadas ou invalidadas com base nas comparações do nível de significância adotado ($\alpha = 0,05$) com os valores-p associados a cada teste, conforme explicado na seção 2.4.3.

Na seção 4.3.3 são feitas as conclusões acerca das análises e discussões para todos os doze casos considerados. A partir dessas conclusões é possível atestar sobre o potencial de utilização das imagens de coerência interferométrica do ALOS/PALSAR para classificar cobertura da terra.

4.3.1 Classificações MaxVer + ICM

4.3.1.1. Dados FBD

a) Composições univariadas

A Tabela 4.8 apresenta os resultados das avaliações das classificações das composições univariadas com os respectivos conceitos e em destaque, a classificação com o maior valor de \hat{k} obtido.

Tabela 4.8 – Dados FBD: resultados das avaliações das classificações (MaxVer + ICM) para as composições univariadas.

Canais	P_0	\hat{k}	$\hat{\sigma}_k^2$ ($\times 10^{-5}$)	Conceitos		
				Landis & Koch	Fleiss	Galp. & Fern.
γ_{HH1_HH2}	25,900	0,07622	12,541	Ruim	Ruim	Pobre
γ_{HV1_HV2}	31,918	0,13913	11,928	Ruim	Ruim	Pobre
A_{HH1}	30,169	0,13798	9,3514	Ruim	Ruim	Pobre
A_{HV1}	59,002	0,48909	9,1124	Bom	Bom	Moderada
A_{HH2}	54,063	0,43319	9,4996	Bom	Bom	Moderada
A_{HV2}	66,666	0,58196	9,0303	Bom	Bom	Moderada

A Figura 4.15 mostra os intervalos de confiança de 95% para cada um dos \hat{k} obtidos.




Figura 4.15 – Dados FBD: intervalos de confiança de 95% para os coeficientes Kappa das classificações (MaxVer + ICM) das composições univariadas.

Apenas as classificações de A_{HH1} e γ_{HV1_HV2} possuíram valores de \hat{k} significativamente iguais (valor-p = 0,469), ao passo que as outras três imagens-Amplitude (A_{HH2} , A_{HV1} e A_{HV2}) apresentaram \hat{k} significativamente maiores aos apresentados pelas duas imagens de coerência. Isto pode ser atribuído à ocorrência de maiores separabilidades entre as classes nas imagens-Amplitude, principalmente de polarização HV.

Para verificar o desempenho das classes nas seis classificações, foram feitas as seguintes comparações pareadas usando as respectivas matrizes de confusão (Apêndice - Tabelas A.1 a A.6): $A_{HH1} \times A_{HH2}$; $A_{HV1} \times A_{HV2}$; $A_{HH1} \times A_{HV1}$; $A_{HH2} \times A_{HV2}$; $\gamma_{HH1_HH2} \times \gamma_{HV1_HV2}$.

Analisadas tais matrizes de confusão foram feitas as seguintes observações:

- tanto em ($A_{HH1} \times A_{HH2}$) como em ($A_{HV1} \times A_{HV2}$) as duas imagens-Amplitude da data 1 (13/06/2007), no caso A_{HH1} e A_{HV1} , apresentaram maior confusão entre as classes (Solo Exposto x Agricultura) do que as duas imagens-Amplitude da data 2 (29/07/2007), concluindo-se que a evolução no estágio de desenvolvimento agrícola do cultivo da soja na área de estudo permitiu o aumento da separabilidade entre as duas referidas classes.

- tanto em ($A_{HH1} \times A_{HV1}$) como em ($A_{HH2} \times A_{HV2}$) as duas imagens-Amplitude HH, no caso A_{HH1} e A_{HH2} , apresentarem maiores confusões entre as classes (Agricultura x Pastagem) do que as duas imagens-Amplitude HV. Isto confirma o comentário feito nas análises exploratórias, de que imagens-Amplitude HV possuem um satisfatório potencial para separar as classes Agricultura e Pastagem.

- a classe Floresta Modificada apresentou na imagem γ_{HH1_HH2} maior confusão do que em γ_{HV1_HV2} , o que fez com que a exatidão do produtor para tal classe se apresentasse inferior na imagem γ_{HH1_HH2} (11,06 % em γ_{HH1_HH2} e 75,4 %, para γ_{HV1_HV2}). A isto se deve o fato de γ_{HV1_HV2} ter apresentado exatidão de classificação significativamente

superior a γ_{HH1_HH2} , embora as duas classificações tenham sido conceituadas como ruins ou pobres.

Com base nas comparações feitas, conclui-se que a imagem A_{HV2} apresentou a maior exatidão de classificação ($\hat{k} = 0,58196$) em virtude de ter apresentado as menores confusões entre as classes (Solo Exposto x Agricultura) e (Pastagem x Agricultura); fato este confirmado pelas distâncias JM na Tabela 4.3.

Outra conclusão, a partir das comparações, é que a imagem A_{HH1} apresentou o pior desempenho entre as imagens-Amplitude em virtude de terem ocorrido nela as maiores confusões entre as classes (Solo Exposto x Agricultura) e (Pastagem x Agricultura). Sobre as duas imagens de coerência, pode-se concluir que isoladamente não apresentaram resultado satisfatório para classificar cobertura da terra, devendo-se testar combinações entre elas e com as imagens-Amplitude.

A Figura 4.16 ilustra a classificação (MaxVer + ICM) de A_{HV2} , que apresentou a maior exatidão ($\hat{k} = 0,58196$) entre as classificações realizadas com as composições univariadas para os dados FBD e foi conceituada como boa ou moderada.




Figura 4.16 – Dados FBD: resultado da melhor entre as classificações (MaxVer + ICM) das composições univariadas (A_{HV2}), com $\hat{k} = 0,58196$.

b) Composições bivariadas

A Tabela 4.9 apresenta os resultados das avaliações das classificações das composições bivariadas com os respectivos conceitos e em destaque, a classificação com o maior valor de \hat{k} obtido.

Tabela 4.9 – Dados FBD: resultados das avaliações das classificações (MaxVer + ICM) para as composições bivariadas.

Canais	P_0	\hat{k}	$\hat{\sigma}_k^2$ (x10 ⁻⁵)	Conceitos		
				Landis & Koch	Fleiss	Galp. & Fern.
$\gamma_{HH1_HH2} + A_{HH1}$	40,226	0,25045	9,9592	Razoável	Ruim	Fraca
$\gamma_{HH1_HH2} + A_{HH2}$	63,065	0,53836	9,6254	Bom	Bom	Moderada
$\gamma_{HV1_HV2} + A_{HV1}$	59,439	0,49428	8,9997	Bom	Bom	Moderada
$\gamma_{HV1_HV2} + A_{HV2}$	71,244	0,63724	8,4606	Muito Bom	Bom	Boa
$\gamma_{HH1_HH2} + \gamma_{HV1_HV2}$	33,461	0,16233	10,031	Ruim	Ruim	Pobre
$\gamma_{HH1_HH2} + A_{HV1}$	60,931	0,50650	9,4164	Bom	Bom	Moderada
$\gamma_{HH1_HH2} + A_{HV2}$	61,368	0,51398	9,8240	Bom	Bom	Moderada
$\gamma_{HV1_HV2} + A_{HH1}$	35,956	0,20796	9,6656	Razoável	Ruim	Fraca
$\gamma_{HV1_HV2} + A_{HH2}$	58,076	0,48134	9,4776	Bom	Bom	Moderada
$A_{HH1} + A_{HV1}$	52,057	0,39780	9,5561	Razoável	Ruim	Fraca
$A_{HH2} + A_{HV2}$	68,775	0,60780	8,9734	Muito Bom	Bom	Boa
$A_{HH1} + A_{HH2}$	32,484	0,17069	10,503	Ruim	Ruim	Pobre
$A_{HV1} + A_{HV2}$	56,502	0,45590	9,2207	Bom	Bom	Moderada

A Figura 4.17 mostra os intervalos de confiança de 95% para cada um dos \hat{k} obtidos.




Figura 4.17 – Dados FBD: intervalos de confiança de 95% para os coeficientes *Kappa* das classificações (MaxVer + ICM) das composições bivariadas.

Todas as classificações das composições bivariadas contendo uma imagem-Amplitude e uma imagem de coerência apresentaram valores de coeficiente *Kappa* significativamente superiores aos valores associados às classificações univariadas de imagens de coerência. Porém, ao serem comparadas às suas correspondentes classificações univariadas de imagens-Amplitude (por exemplo, A_{HV2} é a correspondente composição univariada de imagem-Amplitude da composição bivariada $A_{HV2} + \gamma_{HV1-HV2}$), observa-se que houve significativo aumento na exatidão de classificação em relação às classificações de A_{HH1} , A_{HH2} e A_{HV2} (para esta apenas quando combinada com $\gamma_{HV1-HV2}$), sendo a classificação de $(A_{HV2} + \gamma_{HV1-HV2})$ a que apresentou o maior coeficiente *Kappa*. Isto mostra que $\gamma_{HV1-HV2}$ contém significativa informação adicional à imagem-Amplitude A_{HV2} .

Embora conceituada como ruim ou pobre, a classificação de $(\gamma_{HH1-HH2} + \gamma_{HV1-HV2})$ foi significativamente mais acurada do que a classificação de $\gamma_{HH1-HH2}$ e igual à exatidão de $\gamma_{HV1-HV2}$, apresentando valor-p para o teste de comparação igual a 0,0587. Pode-se concluir que tal como ocorreu com as classificações univariadas, $\gamma_{HV1-HV2}$ apresentou

um desempenho melhor que γ_{HH1_HH2} nas classificações (MaxVer + ICM) das composições bivariadas.

Dentre as classificações bivariadas apenas de imagens-Amplitude, somente ($A_{HH2} + A_{HV2}$) apresentou valor *Kappa* significativamente superior a todos os valores associados às classificações univariadas das imagens-Amplitude. Conclui-se então que dentre todas as classificações usando apenas imagens-Amplitude, essa é a mais acurada.

A Figura 4.18 ilustra as classificações MaxVer + ICM de ($A_{HV2} + \gamma_{HV1_HV2}$) e ($A_{HH2} + A_{HV2}$), que apresentaram respectivamente as maiores exatidões entre as classificações realizadas com as composições bivariadas para os dados FBD e foram conceituadas como boas ou muito boas.




Figura 4.18 - Dados FBD: resultados das duas melhores entre as classificações (MaxVer + ICM) das composições bivariadas:

a) ($A_{HV2} + \gamma_{HV1_HV2}$), com $\hat{k} = 0,63724$;

(b) ($A_{HH2} + A_{HV2}$), com $\hat{k} = 0,60780$.

c) Composições multivariadas

A Tabela 4.10 apresenta os resultados das avaliações das classificações das composições multivariadas com os respectivos conceitos e em destaque, a classificação com o maior valor de \hat{k} obtido.

Tabela 4.10 – Dados FBD: resultados das avaliações das classificações (MaxVer +ICM) para as composições multivariadas.

Canais	P_0	\hat{k}	$\hat{\sigma}_k^2$ (x10 ⁻⁵)	Conceitos		
				Landis & Koch	Fleiss	Galp. & Fern.
$(\gamma_{HH1_HH2}) + A_{HH1} + A_{HV1}$	53,729	0,41518	9,7332	Bom	Bom	Moderada
$(\gamma_{HV1_HV2}) + A_{HH1} + A_{HV1}$	55,735	0,44352	9,3204	Bom	Bom	Moderada
$(\gamma_{HH1_HH2}) + A_{HH2} + A_{HV2}$	68,029	0,59794	9,1735	Bom	Bom	Moderada
$(\gamma_{HV1_HV2}) + A_{HH2} + A_{HV2}$	72,813	0,65908	8,1435	Muito Bom	Bom	Boa
$\gamma_{HH1_HH2} + A_{HH1} + A_{HH2}$	44,007	0,30547	9,7322	Razoável	Ruim	Fraca
$\gamma_{HV1_HV2} + A_{HV1} + A_{HV2}$	59,670	0,49553	8,9211	Bom	Bom	Moderada

A Figura 4.19 mostra os intervalos de confiança de 95% para cada um dos coeficientes *Kappa* obtidos.




Figura 4.19 – Dados FBD: intervalos de confiança de 95% para os coeficientes *Kappa* das classificações (MaxVer + ICM) das composições multivariadas.

As classificações das composições multivariadas contendo as imagens-Amplitude da data 2 (29/07/2007) apresentaram exatidões significativamente maiores do que as classificações contendo imagens-Amplitude da data 1 (13/06/2007), em virtude destas imagens terem apresentado menores exatidões do produtor para a classe Solo Exposto (95,04% e 95,17% para $A_{HH2} + A_{HV2} + \gamma_{HH1_HH2}$ e $A_{HH2} + A_{HV2} + \gamma_{HV1_HV2}$ respectivamente, e 0,7 % e 1,13% para $A_{HH1} + A_{HV1} + \gamma_{HH1_HH2}$ e $A_{HH1} + A_{HV1} + \gamma_{HV1_HV2}$ respectivamente), conforme suas matrizes de confusão (Apêndice – Tabelas A.7 a A.10).

Observou-se que, exceto para a composição ($A_{HH2} + A_{HV2} + \gamma_{HH1_HH2}$), as classificações multivariadas apresentaram melhores exatidões do que as correspondentes classificações bivariadas sem as imagens de coerência, mostrando mais uma vez que γ_{HH1_HH2} é a imagem de coerência que contém informação adicional menos significativa às imagens-Amplitude. Para o teste estatístico que verificou a igualdade dos \hat{k} entre as classificações ($A_{HH2} + A_{HV2} + \gamma_{HH1_HH2}$) e ($A_{HH2} + A_{HV2}$) foi obtido o valor-p igual a 0,232.

Em concordância com as melhores classificações univariadas e bivariadas, que apresentaram respectivamente A_{HV2} e $(A_{HV2} + \gamma_{HV1_HV2})$ e $(A_{HH2} + A_{HV2})$ como as mais acuradas, foi observado que $(A_{HH2} + A_{HV2} + \gamma_{HV1_HV2})$ apresentou a melhor classificação dentre as composições multivariadas, que foi também a melhor de todas as classificações (MaxVer + ICM) realizadas com dados FBD.

A Figura 4.20 ilustra essa classificação, que foi conceituada como boa ou muito boa.

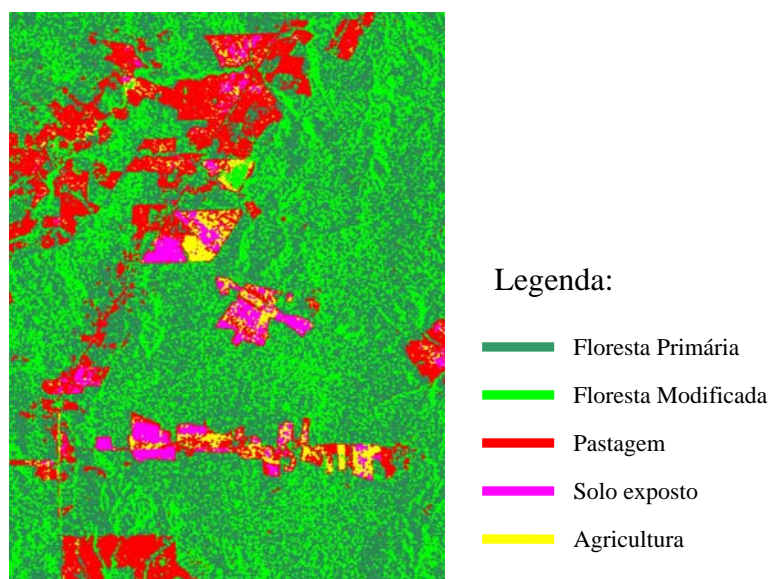


Figura 4.20 - Dados FBD: resultado da melhor entre as classificações (MaxVer + ICM) das composições multivariadas $(A_{HH2} + A_{HV2} + \gamma_{HV1_HV2})$, com $\hat{k} = 0,65908$.

4.3.1.2 Dados PLR

a) Composições univariadas

A Tabela 4.11 apresenta os resultados das avaliações das classificações das composições univariadas com os respectivos conceitos e em destaque, a classificação com o maior valor de \hat{k} obtido.

Tabela 4.11 – Dados PLR: resultados das avaliações das classificações (MaxVer + ICM) para as composições univariadas.

Canais	P_0	\hat{k}	$\hat{\sigma}_k^2$ ($\times 10^{-5}$)	Conceitos		
				Landis & Koch	Fleiss	Galp. & Fern.
γ_{HH1_HH2}	43,183	0,29148	14,317	Razoável	Ruim	Fraca
γ_{HV1_HV2}	34,689	0,19622	14,094	Ruim	Ruim	Pobre
γ_{VV1_VV2}	38,329	0,21502	19,688	Razoável	Ruim	Fraca
A _{HH1}	44,147	0,29307	14,779	Razoável	Ruim	Fraca
A _{HV1}	66,131	0,57509	12,404	Bom	Bom	Moderada
A _{VV1}	43,825	0,29247	14,061	Razoável	Ruim	Fraca
A _{HH2}	67,773	0,59742	11,765	Bom	Bom	Moderada
A _{HV2}	63,775	0,54830	12,320	Bom	Bom	Moderada
A _{VV2}	58,493	0,48387	12,604	Bom	Bom	Moderada

A Figura 4.21 mostra os intervalos de confiança de 95% para cada um dos coeficientes *Kappa* obtidos.




Figura 4.21 – Dados PLR: intervalos de confiança de 95% para os coeficientes *Kappa* das classificações (MaxVer + ICM) das composições univariadas.

São significativamente iguais os coeficientes *kappa* associados às seguintes classificações: (γ_{HV1_HV2} e γ_{VV1_VV2}), (A_{HV1} e A_{HH2}), (A_{HH1} e A_{VV1}) e (A_{HH1} e γ_{HH1_HH2}).

Os valores-p associados a esses quatro testes realizados foram respectivamente iguais a 0,153, 0,0755, 0,485, e 0,463.

Exceto A_{HH1} e A_{VV1} , as imagens-Amplitude apresentaram \hat{k} significativamente maiores aos apresentados pelas três imagens de coerência, que foram conceituadas como ruins, razoáveis ou fracas, segundo os três critérios de conceituação. A imagem de coerência γ_{HH1_HH2} mostrou-se significativamente superior às outras duas imagens de coerência, sendo que em tal imagem a classe Pastagem foi suficientemente discriminada (exatidão do produtor = 76,61%), conforme foi previsto nas análises exploratórias preliminares.

Ao analisar as matrizes de confusão das classificações das três imagens de coerência (Apêndice – Tabelas A.11 a A.13) nota-se que a classe Pastagem foi bem discriminada também em γ_{HV1_HV2} e γ_{VV1_VV2} , apresentando exatidões do usuário respectivamente iguais a 83,25% e 86,23%. Observa-se também que a classe Floresta Primária apresenta exatidão do produtor igual a 84,96 % na imagem γ_{HH1_HH2} , enquanto para as outras duas imagens de coerência apresenta 0% para a mesma medida de exatidão. Isto justifica o fato de γ_{HH1_HH2} ter apresentado melhor desempenho de classificação.

Analisando-se as matrizes de confusão de A_{HH1} e A_{VV1} (Apêndice – Tabelas A.14 e A.15) percebe-se que além de apresentarem \hat{k} significativamente iguais, as duas imagens apresentaram para a classe Solo Exposto a mesma confusão com a classe Pastagem. 97,67% da classe Solo Exposto foi erroneamente classificada como classe Pastagem nas duas imagens, o que pôde ter contribuído para seus desempenhos iguais e fracos.

A Figura 4.22 ilustra o resultado das classificações (MaxVer + ICM) de A_{HV1} e A_{HH2} , que apresentaram as maiores exatidões entre as classificações realizadas com as composições univariadas para os dados PLR. As duas classificações foram conceituadas como boas ou moderadas.

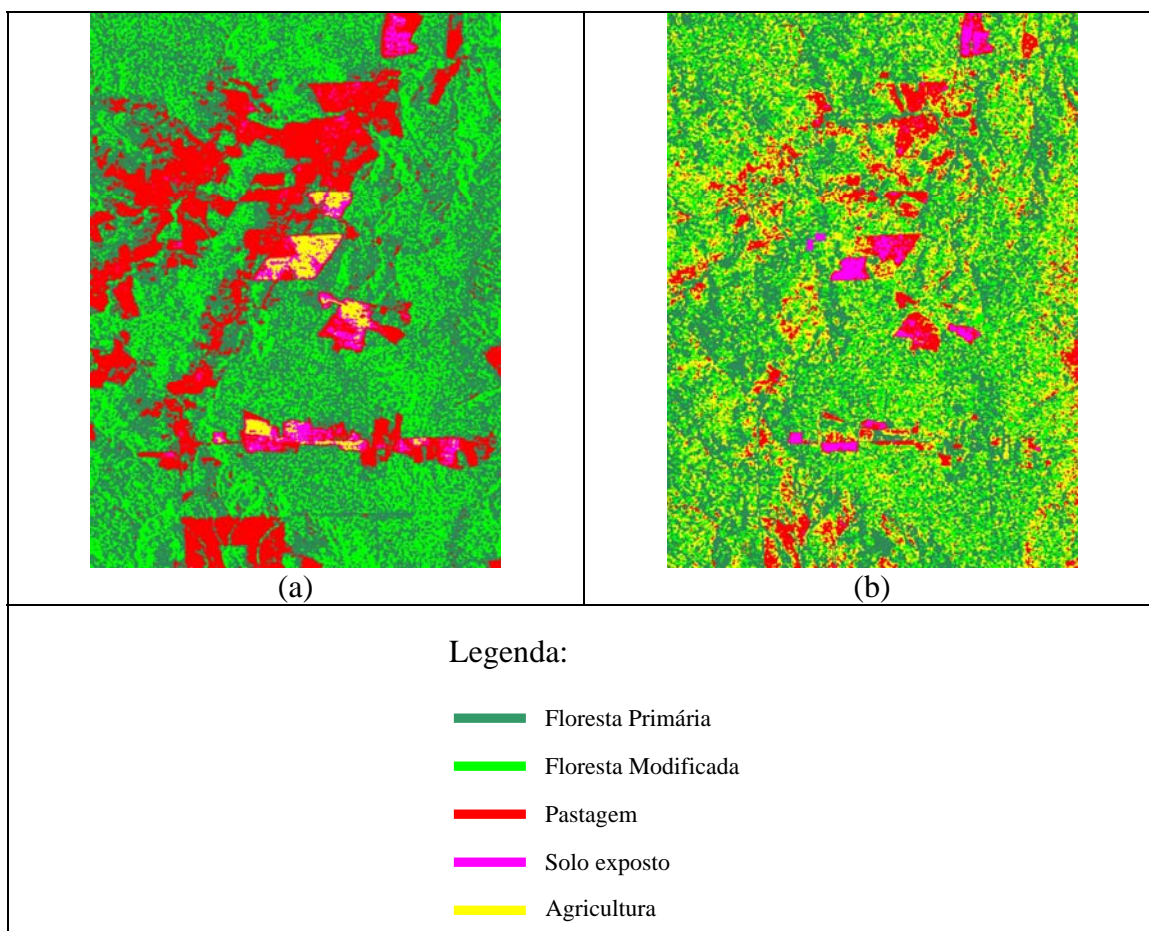


Figura 4.22 - Dados PLR: resultados das duas melhores entre as classificações (MaxVer + ICM) das composições univariadas: (a) (A_{HH2}), com $\hat{k} = 0,59742$; (b) (A_{HV1}), com $\hat{k} = 0,57509$).

b) Composições bivariadas

A Tabela 4.12 apresenta os resultados das avaliações das classificações das composições bivariadas com os respectivos conceitos e em destaque, a classificação com o maior valor de \hat{k} obtido.

Tabela 4.12 – Dados PLR: resultados das avaliações das classificações (MaxVer +ICM) para as composições bivariadas.

Canais	P_0	\hat{k}	$\hat{\sigma}_k^2$ (x10 ⁻⁵)	Conceitos		
				Landis & Koch	Fleiss	Galp. & Fern.
$\gamma_{HH1_HH2} + A_{HH1}$	56,923	0,46687	12,469	Bom	Bom	Moderada
$\gamma_{HH1_HH2} + A_{HH2}$	75,196	0,68922	10,301	Muito Bom	Bom	Boa
$\gamma_{HV1_HV2} + A_{HV1}$	75,374	0,69076	10,377	Muito Bom	Bom	Boa
$\gamma_{HV1_HV2} + A_{HV2}$	65,310	0,56755	12,088	Bom	Bom	Moderada
$\gamma_{VV1_VV2} + A_{VV1}$	50,892	0,38888	12,413	Razoável	Ruim	Fraca
$\gamma_{VV1_VV2} + A_{VV2}$	67,701	0,59880	11,144	Bom	Bom	Moderada
$\gamma_{HH1_HH2} + \gamma_{HV1_HV2}$	51,284	0,38982	13,632	Razoável	Ruim	Fraca
$\gamma_{HH1_HH2} + \gamma_{VV1_VV2}$	54,853	0,43384	13,654	Bom	Bom	Moderada
$\gamma_{HV1_HV2} + \gamma_{VV1_VV2}$	38,472	0,23264	12,704	Razoável	Ruim	Fraca
$\gamma_{HH1_HH2} + A_{HV1}$	78,122	0,72516	9,6326	Muito Bom	Bom	Boa
$\gamma_{HH1_HH2} + A_{HV2}$	42,826	0,27800	15,031	Razoável	Ruim	Fraca
$\gamma_{HH1_HH2} + A_{VV1}$	48,429	0,36255	12,854	Razoável	Ruim	Fraca
$\gamma_{HH1_HH2} + A_{VV2}$	74,732	0,68461	10,342	Muito Bom	Bom	Boa
$\gamma_{HV1_HV2} + A_{HH1}$	63,526	0,54757	11,585	Bom	Bom	Moderada
$\gamma_{HV1_HV2} + A_{HH2}$	72,947	0,66252	10,703	Muito Bom	Bom	Boa
$\gamma_{HV1_HV2} + A_{VV1}$	51,284	0,39577	12,460	Razoável	Ruim	Fraca
$\gamma_{HV1_HV2} + A_{VV2}$	70,271	0,62995	10,821	Muito Bom	Bom	Boa
$\gamma_{VV1_VV2} + A_{HH1}$	57,887	0,47678	12,159	Bom	Bom	Moderada
$\gamma_{VV1_VV2} + A_{HH2}$	79,122	0,73960	8,8379	Muito Bom	Bom	Boa
$\gamma_{VV1_VV2} + A_{HV1}$	76,623	0,70625	9,9819	Muito Bom	Bom	Boa
$\gamma_{VV1_VV2} + A_{HV2}$	62,455	0,53155	12,177	Bom	Bom	Moderada
$A_{HH1} + A_{HH2}$	51,784	0,39647	13,661	Razoável	Ruim	Fraca
$A_{HV1} + A_{HV2}$	65,417	0,56778	12,116	Bom	Bom	Moderada
$A_{VV1} + A_{VV2}$	41,684	0,27200	13,363	Razoável	Ruim	Fraca

A Figura 4.23 mostra os intervalos de confiança de 95% para cada um dos coeficientes Kappa obtidos.




Figura 4.23 – Dados PLR: intervalos de confiança de 95% para os coeficientes Kappa das classificações (MaxVer + ICM) das composições bivariadas.

Das três classificações bivariadas apenas com imagens de coerência apenas ($\gamma_{HH1_HH2} + \gamma_{HV1_HV2}$) e ($\gamma_{HH1_HH2} + \gamma_{VV1_VV2}$) apresentaram exatidões maiores do que todas as três classificações univariadas com imagens de coerência, sendo a classificação de ($\gamma_{HH1_HH2} + \gamma_{VV1_VV2}$) conceituada como boa ou moderada. A classificação de ($\gamma_{HV1_HV2} + \gamma_{VV1_VV2}$) apresentou acurácia significativamente igual à apresentada pela classificação de γ_{VV1_VV2} (valor-p de 0,164).

Dentre as três classificações bivariadas apenas de imagens-Amplitude, nenhuma se apresentou significativamente superior a todas as classificações univariadas de imagens-Amplitude, permitindo com isso concluir que o desempenho das composições bivariadas não foi significativamente melhor do que o desempenho das composições univariadas de imagens-Amplitude.

A Figura 4.24 ilustra as classificações (MaxVer + ICM) de ($\gamma_{VV1_VV2} + A_{HH2}$) e ($\gamma_{HH1_HH2} + A_{HV1}$), que apresentaram respectivamente as maiores exatidões entre as

classificações realizadas com as composições bivariadas para os dados PLR e foram conceituadas como boas ou muito boas.

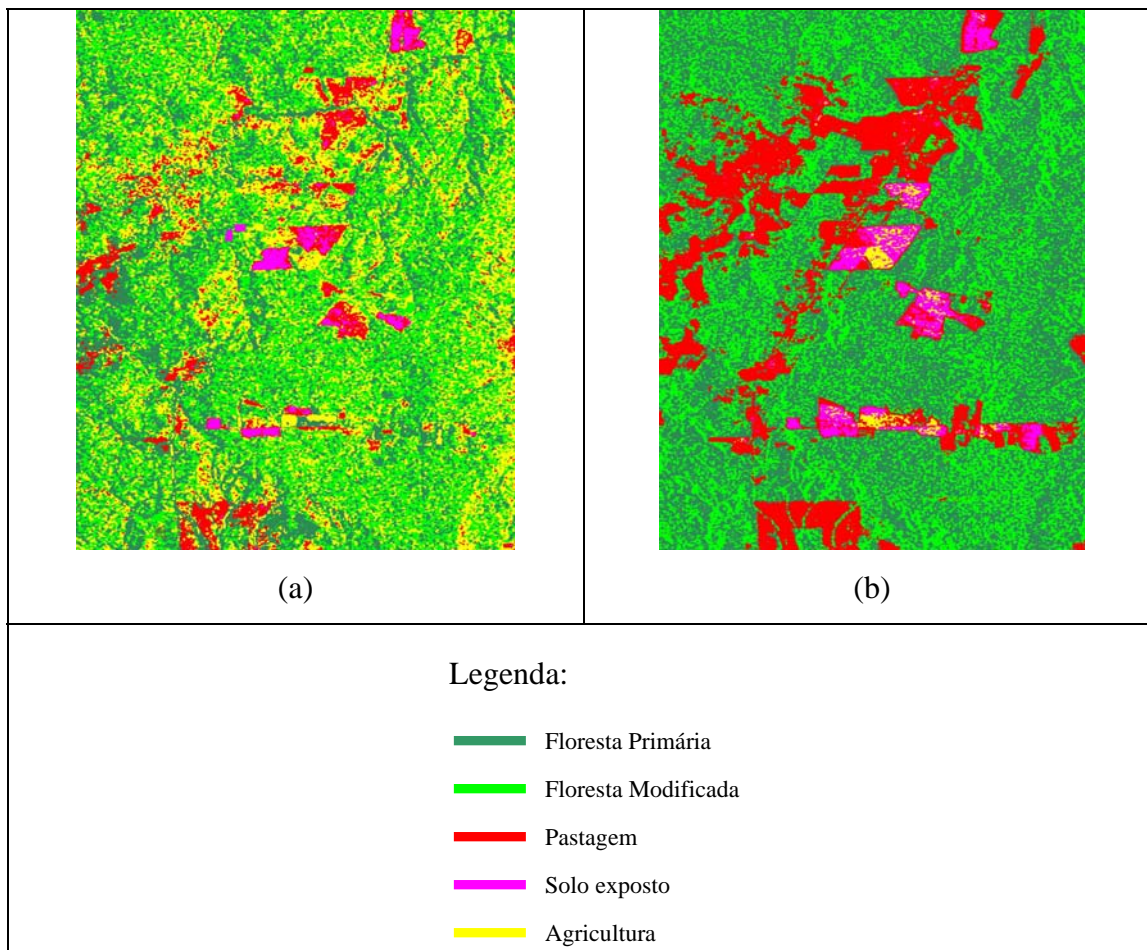


Figura 4.24 - Dados PLR: resultados das duas melhores entre as classificações (MaxVer + ICM) das composições bivariadas: (a) $(A_{HH2} + \gamma_{VV1_VV2})$, com $\hat{k} = 0,73960$; (b) $(\gamma_{HH1_HH2} + A_{HV1})$, com $\hat{k} = 0,72516$.

c) Composições multivariadas

A Tabela 4.13 apresenta os resultados das avaliações das classificações das composições multivariadas com os respectivos conceitos e em destaque, as classificações com os maiores valores de \hat{k} obtidos.

Tabela 4.13 – Dados PLR: resultados das avaliações das classificações (MaxVer +ICM) para as composições multivariadas.

Canais	P_0	\hat{k}	$\hat{\sigma}_k^2$ (x10 ⁻⁵)	Conceitos		
				Landis & Koch	Fleiss	Galp. & Fern.
$\gamma_{HH1_HH2} + \gamma_{HV1_HV2} + \gamma_{VV1_VV2}$	57,280	0,46328	13,718	Bom	Bom	Moderada
$\gamma_{HH1_HH2} + A_{HH1} + A_{HH2}$	58,101	0,47527	13,061	Bom	Bom	Moderada
$\gamma_{HV1_HV2} + A_{HV1} + A_{HV2}$	73,411	0,66759	10,674	Muito Bom	Bom	Boa
$\gamma_{VV1_VV2} + A_{VV1} + A_{VV2}$	47,537	0,34660	12,921	Razoável	Ruim	Fraca
$A_{HH1} + A_{HV1} + A_{VV1}$	60,992	0,51400	11,926	Bom	Bom	Moderada
$\gamma_{HH1_HH2} + A_{HH1} + A_{HV1} + A_{VV1}$	58,779	0,48886	11,985	Bom	Bom	Moderada
$\gamma_{HV1_HV2} + A_{HH1} + A_{HV1} + A_{VV1}$	60,670	0,51254	11,653	Bom	Bom	Moderada
$\gamma_{VV1_VV2} + A_{HH1} + A_{HV1} + A_{VV1}$	55,960	0,45409	12,901	Bom	Bom	Moderada
$A_{HH2} + A_{HV2} + A_{VV2}$	75,017	0,68675	10,614	Muito Bom	Bom	Boa
$\gamma_{HH1_HH2} + A_{HH2} + A_{HV2} + A_{VV2}$	79,336	0,74803	9,2041	Muito Bom	Bom	Boa
$\gamma_{HV1_HV2} + A_{HH2} + A_{HV2} + A_{VV2}$	81,084	0,76293	8,5965	Muito Bom	Excelente	Boa
$\gamma_{VV1_VV2} + A_{HH2} + A_{HV2} + A_{VV2}$	77,052	0,71226	10,006	Muito Bom	Bom	Boa

A Figura 4.25 mostra os intervalos de confiança de 95% para cada um dos coeficientes *Kappa* obtidos.




Figura 4.25 – Dados PLR: intervalos de confiança de 95% para os coeficientes Kappa das classificações (MaxVer + ICM) das composições multivariadas.

A classificação multivariada ($\gamma_{HH1_HH2} + \gamma_{HV1_HV2} + \gamma_{VV1_VV2}$) apresentou exatidão significativamente superior às três classificações bivariadas contendo apenas as imagens de coerência, o que mostra que a melhor classificação usando apenas imagens de coerência é aquela em que são combinadas as três componentes (γ_{HH1_HH2} , γ_{HV1_HV2} e γ_{VV1_VV2}).

Ao combinar todas as imagens-Amplitude para as datas 1 (08/03/2007) e 2 (23/04/2007), observou-se que para a data 2, a exatidão foi significativamente maior, em virtude desta ter apresentado maior exatidão do produtor para a classe Solo Exposto (87,54 %) do que a composição com as imagens da data 1 (exatidão do produtor de 3,15%), conforme mostrados em suas matrizes de confusão (Apêndice – Tabelas A.16 e A.17).

O mesmo comportamento foi observado ao se acrescentar cada uma das três imagens de coerência a essas composições com três imagens-Amplitude. Conclui-se que a

confusão da classe Solo Exposto, maior na composição multivariada contendo imagens da data 1, afetou seu desempenho de classificação.

A Figura 4.26 ilustra as classificações (MaxVer + ICM) de $(A_{HH2} + A_{HV2} + A_{VV2} + \gamma_{HH1_HH2})$ e $(A_{HH2} + A_{HV2} + A_{VV2} + \gamma_{HV1_HV2})$, que além de ter apresentado as maiores exatidões entre as classificações realizadas com as composições multivariadas para os dados PLR, apresentaram também os maiores \hat{k} entre todas as classificações (MaxVer + ICM) para os dados PLR e foram conceituadas como boas, muito boas ou excelente (no caso da primeira).




Figura 4.26 - Dados PLR: resultados das duas melhores entre as classificações (MaxVer + ICM) das composições multivariadas: (a) $(A_{HH2} + A_{HV2} + A_{VV2} + \gamma_{HH1_HH2})$, com $\hat{k} = 0,74803$; (b) $(A_{HH2} + A_{HV2} + A_{VV2} + \gamma_{HV1_HV2})$, com $\hat{k} = 0,76293$.

4.3.2 Classificações SVM

4.3.2.1 Dados FBD

a) Composições univariadas

A Tabela 4.14 apresenta os resultados das avaliações das classificações das composições univariadas com os respectivos conceitos e em destaque, as classificações com os maiores valores de \hat{k} obtidos.

Tabela 4.14 – Dados FBD: resultados das avaliações das classificações SVM para as composições univariadas.

Canais	P_0	\hat{k}	$\hat{\sigma}_k^2$ ($\times 10^{-5}$)	Conceitos		
				Landis & Koch	Fleiss	Galp. & Fern.
γ_{HH1_HH2}	23,868	0,05188	12,273	Ruim	Ruim	Pobre
γ_{HV1_HV2}	23,739	0,04844	14,149	Ruim	Ruim	Pobre
A_{HH1}	34,259	0,18464	9,4301	Ruim	Ruim	Pobre
A_{HV1}	54,912	0,43780	9,4143	Bom	Bom	Moderada
A_{HH2}	59,027	0,48062	9,3221	Bom	Bom	Moderada
A_{HV2}	57,150	0,46026	9,0693	Bom	Bom	Moderada

A Figura 4.27 mostra os intervalos de confiança de 95% para cada um dos coeficientes *Kappa* obtidos.




Figura 4.27 – Dados FBD: intervalos de confiança de 95% para os coeficientes *Kappa* das classificações SVM das composições univariadas.

São significativamente iguais os coeficientes *kappa* associados às seguintes classificações: (A_{HH2} e A_{HV2}) e (γ_{HH1_HH2} e γ_{HV1_HV2}). Os valores-p associados aos dois testes realizados foram respectivamente iguais a 0,066 e 0,416.

Todas as imagens-Amplitude (A_{HH1} , A_{HH2} , A_{HV1} e A_{HV2}) apresentaram \hat{k} significativamente maiores aos apresentados pelas duas imagens de coerência, que a exemplo do que aconteceu na classificação (MaxVer + ICM) foram conceituadas como ruins ou pobres.

Outras duas ocorrências nas classificações (MaxVer + ICM) se repetiram nas classificações SVM: o baixo desempenho de A_{HH1} ; imagens da data 2 (29/07/2007) apresentando exatidões de classificação superiores às observadas para as imagens da data 1 (13/06/2007). As justificativas para isso são as mesmas feitas nas análises das classificações (MaxVer + ICM).

Diferentemente do que ocorreu nas classificações (MaxVer + ICM), a imagem A_{HH2} apresentou desempenho igual ao apresentado pela imagem A_{HV2} . Ao comparar as matrizes de confusão das classificações SVM e (MaxVer + ICM) para a imagem A_{HH2} (Apêndice – Tabelas A.2 e A.18), nota-se que na classificação SVM a classe Pastagem foi melhor discriminada do que no outro método de classificação, e com isso aumentou significativamente sua exatidão de classificação.

A Figura 4.28 ilustra o resultado das classificações SVM de A_{HV2} e A_{HH2} , que apresentaram as maiores exatidões entre as classificações realizadas com as composições univariadas para os dados FBD. As duas classificações foram conceituadas como boas ou moderadas.

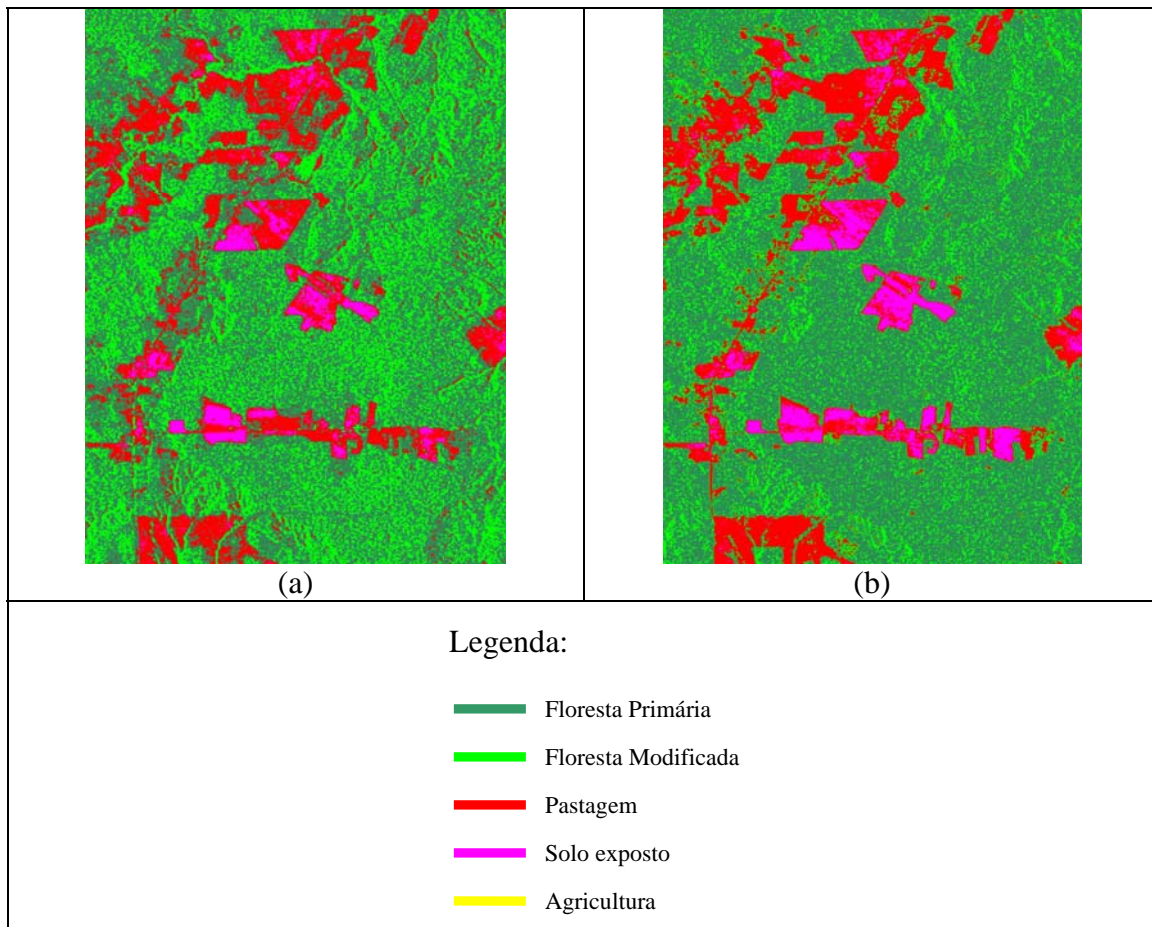


Figura 4.28 - Dados FBD: resultados das duas melhores entre as classificações SVM das composições univariadas: (a) (A_{HH2}), com $\hat{k} = 0,48062$; (b) (A_{HV2}), com $\hat{k} = 0,46026$.

b) Composições bivariadas

A Tabela 4.15 apresenta os resultados das avaliações das classificações das composições bivariadas com os respectivos conceitos e em destaque, a classificação com o maior valor de \hat{k} obtido.

Tabela 4.15 – Dados FBD: resultados das avaliações das classificações SVM para as composições bivariadas.

Canais	P_0	\hat{k}	$\hat{\sigma}_k^2$ (x10 ⁻⁵)	Conceitos		
				Landis & Koch	Fleiss	Galp. & Fern.
$\gamma_{HH1_HH2} + A_{HH1}$	41,126	0,25671	10,316	Razoável	Ruim	Fraca
$\gamma_{HH1_HH2} + A_{HH2}$	61,368	0,51402	9,7580	Bom	Bom	Moderada
$\gamma_{HV1_HV2} + A_{HV1}$	56,610	0,45701	9,2072	Bom	Bom	Moderada
$\gamma_{HV1_HV2} + A_{HV2}$	63,425	0,53900	9,0260	Bom	Bom	Moderada
$\gamma_{HH1_HH2} + \gamma_{HV1_HV2}$	26,491	0,07777	10,403	Ruim	Ruim	Pobre
$\gamma_{HH1_HH2} + A_{HV1}$	57,767	0,46795	9,5046	Bom	Bom	Moderada
$\gamma_{HH1_HH2} + A_{HV2}$	59,850	0,49468	9,6626	Bom	Bom	Moderada
$\gamma_{HV1_HV2} + A_{HH1}$	42,361	0,27262	9,8124	Razoável	Ruim	Fraca
$\gamma_{HV1_HV2} + A_{HH2}$	60,879	0,50821	9,5822	Bom	Bom	Moderada
$A_{HH1} + A_{HV1}$	52,057	0,39617	9,7361	Razoável	Ruim	Fraca
$A_{HH2} + A_{HV2}$	67,618	0,59301	9,0429	Bom	Bom	Moderada
$A_{HH1} + A_{HH2}$	34,387	0,18495	9,4914	Ruim	Ruim	Pobre
$A_{HV1} + A_{HV2}$	55,427	0,44243	9,3283	Bom	Bom	Moderada

A Figura 4.29 mostra os intervalos de confiança de 95% para cada um dos coeficientes *Kappa* obtidos.




Figura 4.29 – Dados FBD: intervalos de confiança de 95% para os coeficientes *Kappa* das classificações SVM das composições bivariadas.

A classificação bivariada ($\gamma_{HH1_HH2} + \gamma_{HV1_HV2}$) apresentou exatidão maior do que as duas classificações univariadas com γ_{HH1_HH2} e γ_{HV1_HV2} , porém foi conceituada também como ruim ou pobre.

Todas as classificações das composições bivariadas de imagens-Amplitude mais imagens de coerência apresentaram valores de \hat{k} significativamente superiores aos valores associados às classificações univariadas de imagens de coerência. Porém, ao comparar com as correspondentes classificações univariadas de imagens-Amplitude, observa-se que apenas para a classificação de A_{HV1} não houve significativo aumento na exatidão.

Conforme ocorreu nas classificações (MaxVer + ICM), dentre as classificações bivariadas apenas de imagens-Amplitude, somente ($A_{HH2} + A_{HV2}$) apresentou \hat{k} significativamente superior a todos os valores associados às classificações univariadas das imagens-Amplitude, sendo essa inclusive a classificação que apresentou a maior exatidão dentre as classificações SVM realizadas com as composições bivariadas para os dados FBD e foi conceituada como boa ou moderada. A Figura 4.30 ilustra tal classificação.




Figura 4.30 - Dados FBD: resultado da melhor entre as classificações SVM das composições bivariadas ($A_{HH2} + A_{HV2}$), com $\hat{k} = 0,59301$.

c) Composições multivariadas

A Tabela 4.16 apresenta os resultados das avaliações das classificações das composições multivariadas com os respectivos conceitos e em destaque, a classificação com o maior valor de \hat{k} obtido.

Tabela 4.16 – Dados FBD: resultados das avaliações das classificações SVM para as composições multivariadas.

Canais	P_0	\hat{k}	$\hat{\sigma}_k^2$ ($\times 10^{-5}$)	Conceitos		
				Landis & Koch	Fleiss	Galp. & Fern.
$\gamma_{HH1_HH2} + A_{HH1} + A_{HV1}$	53,5237	0,412609	9,8112	Bom	Bom	Moderada
$\gamma_{HV1_HV2} + A_{HH1} + A_{HV1}$	52,5463	0,401768	9,7864	Bom	Bom	Moderada
$\gamma_{HH1_HH2} + A_{HH2} + A_{HV2}$	66,6409	0,580687	9,2120	Bom	Bom	Moderada
$\gamma_{HV1_HV2} + A_{HH2} + A_{HV2}$	70,3704	0,627815	8,5525	Muito Bom	Bom	Boa
$\gamma_{HH1_HH2} + A_{HH1} + A_{HH2}$	44,007	0,29177	10,275	Razoável	Ruim	Fraca
$\gamma_{HV1_HV2} + A_{HV1} + A_{HV2}$	56,610	0,45694	9,2247	Bom	Bom	Moderada

A Figura 4.31 mostra os intervalos de confiança de 95% para cada um dos coeficientes *Kappa* obtidos.




Figura 4.31 – Dados FBD: intervalos de confiança de 95% para os coeficientes *Kappa* das classificações SVM das composições multivariadas.

Assim como aconteceu nas classificações (MaxVer + ICM), nas classificações SVM das composições multivariadas contendo as imagens-Amplitude da data 2 (29/07/2007) foram obtidas exatidões significativamente maiores do que para as classificações multivariadas contendo imagens-Amplitude da data 1 (13/06/2007), em virtude destas imagens terem apresentado menores exatidões do produtor para a classe Solo Exposto (3,96% para $A_{HH1} + A_{HV1} + \gamma_{HH1_HH2}$ e $A_{HH1} + A_{HV1} + \gamma_{HV1_HV2}$, e 94,90% e 94,62 % para $A_{HH2} + A_{HV2} + \gamma_{HH1_HH2}$ e $A_{HH2} + A_{HV2} + \gamma_{HV1_HV2}$ respectivamente), conforme suas matrizes de confusão (Apêndice – Tabelas A.19 a A.22).

Em relação à melhor classificação bivariada ($A_{HH2} + A_{HV2}$), foi observado um significativo aumento no valor de *Kappa* apenas quando a essa foi acrescentada a imagem de coerência γ_{HV1_HV2} , confirmando que dentre as duas imagens de coerência FBD essa é a que apresentou melhor desempenho.

Da mesma forma como foi observado para as classificações (MaxVer + ICM), o fato da classificação de ($A_{HH2} + A_{HV2} + \gamma_{HV1_HV2}$) ter apresentado a maior exatidão dentre as composições multivariadas se mostrou em concordância com as mais acuradas classificações univariadas e bivariadas, que foram respectivamente (A_{HH2} e A_{HV2}) e ($A_{HH2} + A_{HV2}$), além do significativo acréscimo de informação de γ_{HV1_HV2} observado. Repetindo o que ocorreu para as classificações pelo outro método, a composição multivariada ($A_{HH2} + A_{HV2} + \gamma_{HV1_HV2}$) apresentou o melhor resultado dentre todas as classificações SVM realizadas com dados FBD.

A Figura 4.32 ilustra essa classificação, que foi conceituada como boa ou muito boa.

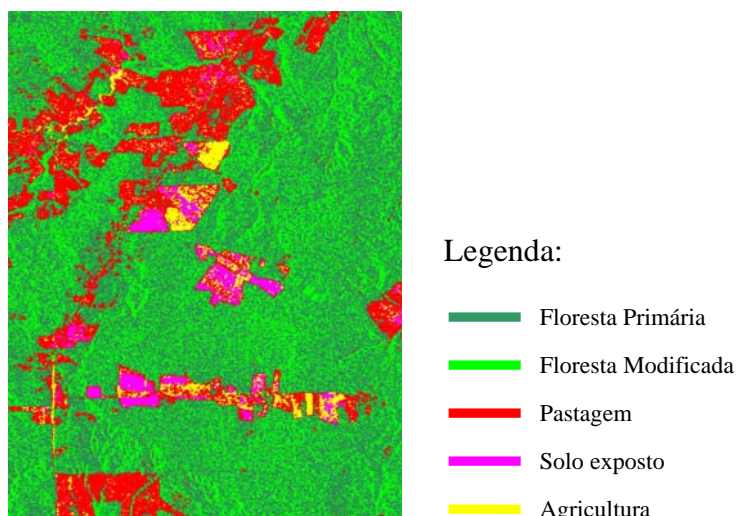


Figura 4.32 - Dados FBD: resultado da melhor entre as classificações SVM das composições multivariadas ($A_{HH2} + A_{HV2} + \gamma_{HV1_HV2}$), com $\hat{k} = 0,627815$.

4.3.2.2 Dados PLR

a) Composições univariadas

A Tabela 4.17 apresenta os resultados das avaliações das classificações das composições univariadas com os respectivos conceitos e em destaque, a classificação com o maior valor de \hat{k} obtido.

Tabela 4.17 – Dados PLR: resultados das avaliações das classificações SVM para as composições univariadas.

Canais	P_0	\hat{k}	$\hat{\sigma}_k^2$ ($\times 10^{-5}$)	Conceitos		
				Landis & Koch	Fleiss	Galp. & Fern.
γ_{HH1_HH2}	61,242	0,23498	14,746	Razoável	Ruim	Fraca
γ_{HV1_HV2}	31,227	0,13794	16,435	Ruim	Ruim	Pobre
γ_{VV1_VV2}	32,476	0,14327	16,542	Ruim	Ruim	Pobre
A_{HH1}	41,291	0,25621	14,941	Razoável	Ruim	Fraca
A_{HV1}	68,808	0,60744	10,951	Muito Bom	Bom	Boa
A_{VV1}	43,147	0,28792	13,195	Razoável	Ruim	Fraca
A_{HH2}	64,703	0,55823	11,501	Bom	Bom	Moderada
A_{HV2}	56,638	0,45948	11,964	Bom	Bom	Moderada
A_{VV2}	57,994	0,47590	12,538	Bom	Bom	Moderada

A Figura 4.33 mostra os intervalos de confiança de 95% para cada um dos coeficientes *Kappa* obtidos.




Figura 4.33 – Dados PLR: intervalos de confiança de 95% para os valores de *Kappa* das classificações SVM das composições univariadas.

São significativamente iguais os \hat{k} associados às seguintes classificações: (γ_{HV1_HV2} e γ_{VV1_VV2}), (A_{HV2} e A_{VV2}) e (A_{HH1} e γ_{HH1_HH2}). Os valores-p associados a esses três testes realizados foram respectivamente iguais a 0,385, 0,147 e 0,109.

Exceto A_{HH1} , as imagens-Amplitude apresentaram \hat{k} significativamente maiores aos apresentados pelas três imagens de coerência, que foram conceituadas como ruins, razoáveis ou fracas, segundo os três critérios de conceituação. Assim como foi observado nas classificações (MaxVer + ICM), a classificação de γ_{HH1_HH2} mostrou-se significativamente superior às classificações das outras duas imagens de coerência.

Analisando as matrizes de confusão das classificações das três imagens de coerência (Apêndice – Tabelas A.23 a A.25) nota-se que a classe Solo Exposto apresentou exatidão do produtor de 0% em γ_{HV1_HV2} , enquanto na imagem γ_{VV1_VV2} foi a classe Floresta Primária que apresentou o mesmo valor para tal medida de exatidão. Isto justifica o desempenho inferior dessas duas imagens em relação à γ_{HH1_HH2} .

A Figura 4.34 ilustra o resultado da classificação SVM de A_{HVI} , que apresentou a maior exatidão entre as classificações realizadas com as composições univariadas para os dados PLR e que foi conceituada como boa ou muito boa.

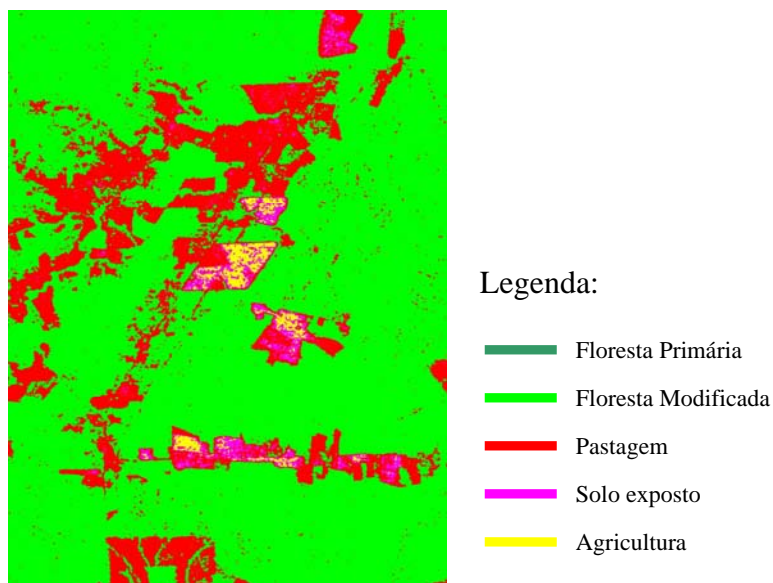


Figura 4.34 - Dados PLR: resultado da melhor entre as classificações SVM das composições univariadas (A_{HVI}), com $\hat{k} = 0,60744$.

b) Composições bivariadas

A Tabela 4.18 apresenta os resultados das avaliações das classificações das composições bivariadas com os respectivos conceitos e em destaque, as classificações com os maiores valores de \hat{k} obtido.

Tabela 4.18 – Dados PLR: resultados das avaliações das classificações SVM para as composições bivariadas.

Canais	P_0	\hat{k}	$\hat{\sigma}_k^2$ (x10 ⁻⁵)	Conceitos		
				Landis & Koch	Fleiss	Galp. & Fern.
$\gamma_{HH1_HH2} + A_{HH1}$	53,890	0,42888	13,003	Bom	Bom	Moderada
$\gamma_{HH1_HH2} + A_{HH2}$	71,199	0,63904	11,167	Muito Bom	Bom	Boa
$\gamma_{HV1_HV2} + A_{HV1}$	71,306	0,63885	11,146	Muito Bom	Bom	Boa
$\gamma_{HV1_HV2} + A_{HV2}$	58,886	0,48719	12,269	Bom	Bom	Moderada
$\gamma_{VV1_VV2} + A_{VV1}$	46,038	0,33044	12,620	Razoável	Ruim	Fraca
$\gamma_{VV1_VV2} + A_{VV2}$	61,563	0,52202	12,361	Bom	Bom	Moderada
$\gamma_{HH1_HH2} + \gamma_{HV1_HV2}$	43,076	0,28650	13,535	Razoável	Ruim	Fraca
$\gamma_{HH1_HH2} + \gamma_{VV1_VV2}$	42,005	0,27290	14,101	Razoável	Ruim	Fraca
$\gamma_{HV1_HV2} + \gamma_{VV1_VV2}$	35,688	0,19131	13,072	Ruim	Ruim	Pobre
$\gamma_{HH1_HH2} + A_{HV1}$	75,303	0,68905	10,147	Muito Bom	Bom	Boa
$\gamma_{HH1_HH2} + A_{HV2}$	74,018	0,67302	10,420	Muito Bom	Bom	Boa
$\gamma_{HH1_HH2} + A_{VV1}$	47,823	0,35320	13,133	Razoável	Ruim	Fraca
$\gamma_{HH1_HH2} + A_{VV2}$	71,127	0,63929	11,293	Muito Bom	Bom	Boa
$\gamma_{HV1_HV2} + A_{HH1}$	54,389	0,43433	12,767	Bom	Bom	Moderada
$\gamma_{HV1_HV2} + A_{HH2}$	68,308	0,60389	11,483	Muito Bom	Bom	Boa
$\gamma_{HV1_HV2} + A_{VV1}$	46,859	0,34130	12,786	Razoável	Ruim	Fraca
$\gamma_{HV1_HV2} + A_{VV2}$	64,917	0,56318	12,088	Bom	Bom	Moderada
$\gamma_{VV1_VV2} + A_{HH1}$	48,893	0,36218	12,973	Razoável	Ruim	Fraca
$\gamma_{VV1_VV2} + A_{HH2}$	68,950	0,61210	11,221	Muito Bom	Bom	Boa
$\gamma_{VV1_VV2} + A_{HV1}$	68,665	0,60574	11,345	Muito Bom	Bom	Boa
$\gamma_{VV1_VV2} + A_{HV2}$	58,422	0,48131	12,358	Bom	Bom	Moderada
$A_{HH1} + A_{HH2}$	53,212	0,41377	13,840	Bom	Bom	Moderada
$A_{HV1} + A_{HV2}$	65,738	0,57012	11,344	Bom	Bom	Moderada
$A_{VV1} + A_{VV2}$	40,970	0,26336	13,455	Razoável	Ruim	Fraca

A Figura 4.35 mostra os intervalos de confiança de 95% para cada um dos coeficientes *Kappa* obtidos.




Figura 4.35 – Dados PLR: intervalos de confiança para os coeficientes *Kappa* das classificações SVM das composições bivariadas.

Tal como foi observado nas análises das classificações (MaxVer + ICM), das três classificações bivariadas apenas com imagens de coerência somente ($\gamma_{HH1_HH2} + \gamma_{HV1_HV2}$) e ($\gamma_{HH1_HH2} + \gamma_{VV1_VV2}$) apresentaram exatidões maiores do que todas as três classificações univariadas com imagens de coerência. A classificação de ($\gamma_{HV1_HV2} + \gamma_{VV1_VV2}$) apresentou-se significativamente pior à classificação de γ_{HH1_HH2} e melhor que as classificações de γ_{HV1_HV2} e γ_{VV1_VV2} .

Dentre as três classificações bivariadas apenas de imagens-Amplitude, nenhuma se apresentou significativamente superior a todas as correspondentes classificações univariadas de imagens-Amplitude, permitindo com isso concluir que o desempenho das composições bivariadas não foi significativamente melhor do que o desempenho das composições univariadas de imagens-Amplitude.

A Figura 4.36 ilustra as classificações SVM de $(A_{HV1} + \gamma_{HH1_HH2})$, $(A_{HV2} + \gamma_{HH1_HH2})$, que apresentaram as maiores exatidões entre as classificações realizadas com as composições bivariadas para os dados PLR e foram conceituadas como boas ou muito boas.




Figura 4.36 - Dados PLR: resultados das duas melhores entre as classificações SVM das composições bivariadas: (a) $(A_{HV1} + \gamma_{HH1_HH2})$, com $\hat{k} = 0,68905$; (b) $(A_{HV2} + \gamma_{HH1_HH2})$, com $\hat{k} = 0,67302$.

c) Composições multivariadas

A Tabela 4.19 apresenta os resultados das avaliações das classificações das composições multivariadas com os respectivos conceitos e em destaque, a classificação com o maior valor de \hat{k} obtido.

Tabela 4.19 – Dados PLR: resultados das avaliações das classificações SVM para as composições multivariadas.

Canais	P_0	\hat{k}	$\hat{\sigma}_k^2$ ($\times 10^{-5}$)	Conceitos		
				Landis & Koch	Fleiss	Galp. & Fern.
$\gamma_{HH1_HH2} + \gamma_{HV1_HV2} + \gamma_{VV1_VV2}$	44,932	0,30899	13,810	Razoável	Ruim	Fraca
$\gamma_{HH1_HH2} + A_{HH1} + A_{HH2}$	64,739	0,55822	12,597	Bom	Bom	Moderada
$\gamma_{HV1_HV2} + A_{HV1} + A_{HV2}$	67,701	0,59511	11,825	Bom	Bom	Moderada
$\gamma_{VV1_VV2} + A_{VV1} + A_{VV2}$	45,610	0,32232	13,089	Razoável	Ruim	Fraca
$A_{HH1} + A_{HV1} + A_{VV1}$	56,995	0,46548	12,224	Bom	Bom	Moderada
$\gamma_{HH1_HH2} + A_{HH1} + A_{HV1} + A_{VV1}$	60,920	0,51462	12,123	Bom	Bom	Moderada
$\gamma_{HV1_HV2} + A_{HH1} + A_{HV1} + A_{VV1}$	60,207	0,50557	11,967	Bom	Bom	Moderada
$\gamma_{VV1_VV2} + A_{HH1} + A_{HV1} + A_{VV1}$	57,316	0,46962	12,218	Bom	Bom	Moderada
$A_{HH2} + A_{HV2} + A_{VV2}$	76,730	0,70791	9,1606	Muito Bom	Bom	Boa
$\gamma_{HH1_HH2} + A_{HH2} + A_{HV2} + A_{VV2}$	82,012	0,77445	8,2717	Muito Bom	Excelente	Boa
$\gamma_{HV1_HV2} + A_{HH2} + A_{HV2} + A_{VV2}$	82,298	0,77804	8,2117	Muito Bom	Excelente	Boa
$\gamma_{VV1_VV2} + A_{HH2} + A_{HV2} + A_{VV2}$	79,122	0,73812	9,2217	Muito Bom	Bom	Boa

A Figura 4.37 mostra os intervalos de confiança de 95% para cada um dos coeficientes *Kappa* obtidos.




Figura 4.37 – Dados PLR: intervalos de confiança para os coeficientes *Kappa* das classificações SVM das composições multivariadas.

Das três classificações bivariadas contendo apenas as imagens de coerência, a classificação multivariada ($\gamma_{HH1_HH2} + \gamma_{HV1_HV2} + \gamma_{VV1_VV2}$) só não apresentou exatidão significativamente superior à classificação de ($\gamma_{HH1_HH2} + \gamma_{HV1_HV2}$), sendo neste caso os valores de \hat{k} significativamente iguais (valor-p associado ao teste igual a 0,0869).

Assim como ocorreu nas classificações (MaxVer + ICM), a composição multivariada contendo todas as imagens-Amplitude da data 1 (08/03/2007) apresentou classificação significativamente pior do que a classificação da composição contendo todas as imagens-Amplitude da data 2 (23/04/2007), em virtude desta ter apresentado maior exatidão do produtor para a classe Solo Exposto (100 %) do que a composição com as imagens da data 1 (exatidão do produtor de 44,36 %), conforme observado nas respectivas matrizes de confusão (Apêndice – Tabelas A.26 e A.27). Conclui-se que a confusão da classe Solo Exposto, maior na composição multivariada de imagens-Amplitude da data 1, afetou seu desempenho de classificação.

O mesmo comportamento foi observado ao se acrescentar cada uma das três imagens de coerência a essas composições com três imagens-Amplitude.

Tal como ocorreu para as classificações das composições multivariadas empregando o método (MaxVer + ICM), as classificações de $(A_{HH2} + A_{HV2} + A_{VV2} + \gamma_{HH1_HH2})$ e $(A_{HH2} + A_{HV2} + A_{VV2} + \gamma_{HV1_HV2})$ apresentaram não só as maiores exatidões entre as classificações realizadas com as composições multivariadas para os dados PLR como também os maiores \hat{k} entre todas as classificações SVM realizadas. A Figura 4.38 ilustra essas duas classificações, que foram conceituadas como muito boas ou excelentes.

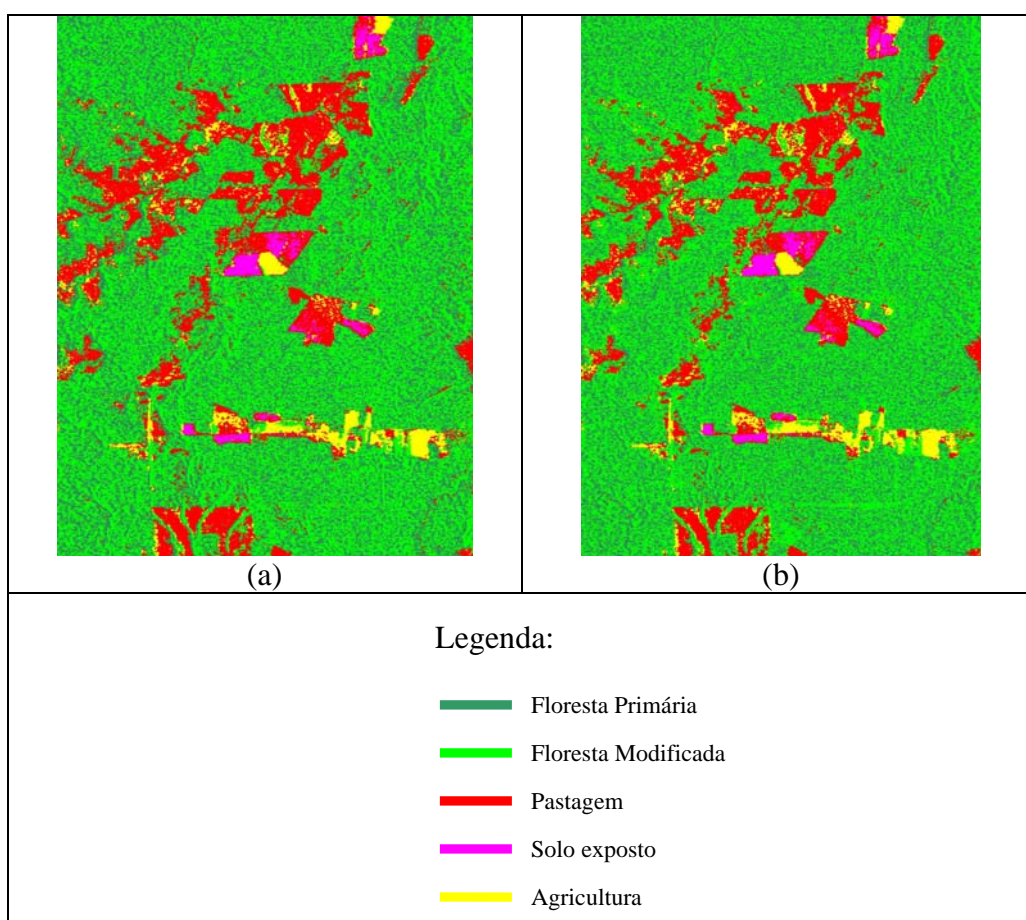


Figura 4.38 - Dados PLR: resultados das duas melhores entre as classificações SVM das composições multivariadas: (a) $(A_{HH2} + A_{HV2} + A_{VV2} + \gamma_{HV1_HV2})$, com $\hat{k} = 0,77804$; (b) $(A_{HH2} + A_{HV2} + A_{VV2} + \gamma_{HH1_HH2})$, com $\hat{k} = 0,77445$.

4.3.3 Discussões acerca dos resultados das classificações

As análises e as comparações entre os resultados das classificações validaram a maioria das suposições e inferências feitas nas análises exploratórias, mostrando que estas puderam realmente servir como um indicativo preliminar dos resultados obtidos.

Analisando as classificações univariadas de todas as imagens de coerência, conclui-se que as imagens de coerência FBD apresentaram desempenhos inferiores aos apresentados pelas imagens de coerência PLR, embora as classificações destas também não tivessem sido conceituadas como boas. Entre as duas imagens de coerência FBD, foi observado que γ_{HV1_HV2} apresentou um desempenho significativamente melhor do que γ_{HH1_HH2} , embora a análise das distâncias JM pudesse indicar o contrário. Isso se deve à maior exatidão do produtor para a Floresta Modificada em γ_{HV1_HV2} . Entre as três imagens de coerência PLR, γ_{HH1_HH2} apresentou o melhor desempenho nas classificações, e em todas elas a classe Pastagem apresentou as maiores exatidões do produtor.

De todas as classificações (univariadas, bivariadas e multivariadas) contendo apenas imagens de coerência, a maior acurácia de classificação foi obtida para a composição multivariada (PLR), no caso $\gamma_{HH1_HH2} + \gamma_{HV1_HV2} + \gamma_{VV1_VV2}$, empregando o método (MaxVer + ICM). Tal classificação foi conceituada como boa ou moderada, apresentando $\hat{k} = 0,46328$.

Ao acrescentar as imagens de coerência às imagens-Amplitude, definindo composições bivariadas e multivariadas, foram observados para muitas classificações significativos aumentos nos valores de \hat{k} em relação às classificações univariadas de imagens-Amplitude, o que mostra que as imagens de coerência, embora apresentassem desempenhos pobres, ruins ou fracos quando utilizadas em composições univariadas, possuem significativa informação adicional às imagens-Amplitude para classificar cobertura da terra.

As potencialidades das imagens-Amplitude para discriminar florestas, áreas agrícolas e pastagens foram evidenciadas pelas distâncias JM calculadas e também pelos melhores resultados de classificação usando composições univariadas. As imagens-Amplitude HV mostraram excelente potencial para discriminar as duas classes florestas em relação às demais classes, além de possibilitar boa separação entre pastagens e áreas agrícolas. Já as imagens-Amplitude HH mostraram-se melhores para discriminar áreas agrícolas.

Em muitas classificações univariadas de imagens de coerência, foram observadas confusões entre as classes Floresta Primária, Floresta Modificada e Solo Exposto, o que diminuiu a exatidão do produtor dessas classes e conseqüentemente afetou a exatidão total e o \hat{k} .

Em nenhuma das imagens utilizadas nas classificações foi obtida significativa separabilidade entre as duas classes de florestas, embora algumas classificações tenham apresentado boa exatidão do produtor para apenas uma delas, como no caso da classificação de γ_{HV1_HV2} (FBD).

Foram observadas também significativas diferenças entre os resultados obtidos nas classificações das imagens de data 1 e data 2, tanto para os dados FBD como para os dados PLR. Isto se deve ao fato de que as maiores exatidões do produtor referentes à classe Solo Exposto foram associadas às classificações com as imagens das datas 2, o que contribuiu para que o desempenho dessas imagens fosse melhor.

Embora algumas constatações nas análises dos resultados tenham se repetido para as classificações SVM e (MaxVer + ICM), esses dois métodos de classificação apresentaram diferenças significativas entre os resultados obtidos. Das 70 composições (univariadas, bivariadas e multivariadas), o método (MaxVer + ICM) foi significativamente melhor para 39 delas, enquanto a classificação SVM foi significativamente melhor para 6 composições e para as outras 25 os dois métodos apresentaram desempenhos significativamente iguais. Isso permite concluir que para a maioria das classificações realizadas o método (MaxVer + ICM) apresentou melhor

exatidão. Uma justificativa para isso pode ser o significativo aumento da acurácia das classificações ao ser incorporada a informação do contexto (algoritmo ICM).

A Tabela 4.20 mostra para cada tipo de composição um resumo contendo detalhes (\hat{k} , método e tipo de dado) dos melhores resultados das classificações realizadas.

Tabela 4.20 – Resumo dos melhores resultados das classificações realizadas

Composição	Classificação	\hat{k}	Método	Tipo de Dado
Univariada	A_{HV1}	0,60744	SVM	PLR
	A_{HH2}	0,59742	MaxVer + ICM	PLR
	A_{HV2}	0,58196		FBD
	A_{HV1}	0,57509		PLR
Bivariada	$\gamma_{VV1_VV2} + A_{HH2}$	0,73960	MaxVer + ICM	PLR
	$\gamma_{HH1_HH2} + A_{HV1}$	0,72516		
Multivariada	$A_{HH2} + A_{HV2} + A_{VV2} + \gamma_{HV1_HV2}$	0,77804	SVM	PLR
		0,74803	MaxVer + ICM	
	$A_{HH2} + A_{HV2} + A_{VV2} + \gamma_{HH1_HH2}$	0,77445	SVM	
		0,76293	MaxVer + ICM	

A partir dessa tabela, pode-se constatar também que o desempenho dos dados PLR nas classificações foi melhor do que o observado para os dados FBD, em virtude das maiores exatidões em cada um dos três tipos de composição analisados serem associadas a classificações de dados PLR.

5 CONSIDERAÇÕES FINAIS

5.1 Conclusões

O principal objetivo da presente dissertação foi gerar e avaliar a qualidade de produtos interferométricos do ALOS/PALSAR a partir de imagens SLC FBD e PLR. Após os devidos processamentos com essas imagens, foram gerados interferogramas e imagens de coerência interferométrica co-polarizados de uma área da FLONA do Tapajós. A avaliação desses produtos consistiu em testar a potencialidade dos mesmos no tocante às suas respectivas aplicações.

Os interferogramas gerados foram testados em dois tipos diferentes de desdobramento de fase e posteriormente avaliados visualmente, com base nas correspondentes imagens de coerência interferométrica, haja vista que a coerência interferométrica é um parâmetro de qualidade dos interferogramas. Nas áreas onde as coerências são baixas (florestas) as fases interferométricas resultantes do desdobramento de fase pelo método de crescimento de regiões se mostraram muito ruidosas, comprometendo e inviabilizando os processamentos necessários à geração dos MDE's, haja vista que os valores médios de coerência nessas áreas terem sido inferiores ao limite definido pelo [CCRS \(2007\)](#), no caso 0,7. Sendo assim, conclui-se que para o caso da região florestada desse trabalho os interferogramas ALOS/PALSAR em qualquer polarização não apresentam satisfatório potencial para gerar MDE's interferométricos.

A avaliação das imagens de coerência interferométrica foi feita com base nos resultados obtidos com as classificações supervisionadas de cobertura da terra considerando cinco classes de estudo (Floresta Primária, Floresta Modificada, Agricultura, Solo Exposto e Pastagem), dois diferentes métodos de classificação (critério da máxima verossimilhança acrescido do algoritmo contextual ICM e máquinas de vetor-suporte) e várias composições (univariadas, bivariadas e multivariadas) combinando as imagens de coerência e as imagens-Amplitude geradas.

Os resultados mostraram que as exatidões das classificações realizadas apenas com as imagens de coerência enquadram-se nos conceitos razoáveis, pobres ou ruins, o que faz concluir que isoladamente as imagens de coerência não apresentaram boas exatidões. Em contrapartida, ao combinar as imagens de coerência interferométrica com as imagens-Amplitude em várias composições foram obtidos aumentos estatisticamente significativos nas exatidões de classificação, porém tais diferenças foram pequenas em relação às classificações das imagens-Amplitude isoladas. Isto mostra que as imagens de coerência interferométrica possuem pequenas, mas estatisticamente significativas informações adicionais às imagens-Amplitude para classificar cobertura da terra.

Conclui-se então que diferentemente do que foi mostrado nos trabalhos de [Takeuchi e Oguro \(2003\)](#) e [Gaboardi \(2002\)](#), que avaliaram as potencialidades das imagens de coerência JERS-1 e ERS-1/2, a potencialidade das imagens de coerência interferométrica ALOS/PALSAR para classificar cobertura da terra fica restrita ao uso em conjunto com imagens-Amplitude.

Anteriormente à realização das classificações, foram feitas análises exploratórias com base nos histogramas de coerência das classes e nas distâncias estatísticas JM entre elas, considerando como atributos as composições univariadas das imagens de coerência e das imagens-Amplitude geradas. Essas análises serviram como um indicativo preliminar, já que muitas inferências e suposições foram validadas pelos resultados das classificações.

Os resultados das classificações confirmaram que as classes Floresta Primária e Floresta Modificada são melhores discriminadas nas imagens-Amplitude HV, embora não tenha ocorrido nenhuma separabilidade significativa entre elas. As imagens-Amplitude HV também apresentaram potencial para separar áreas agrícolas de pastagens. Por sua vez, as imagens-Amplitude HH apresentaram o melhor potencial para discriminar a classe Agricultura, enquanto nas classificações univariadas com imagens de coerência a classe Pastagem foi a que apresentou as maiores exatidões do produtor. A classe Solo Exposto apresentou exatidões do produtor maiores nas classificações das imagens das datas 2 (23/04/2007-PLR e 29/07/2007-FBD) do que nas classificações das imagens das datas 1

(08/03/2007-PLR e 13/06/2007-FBD), mostrando com isso que houve menos confusão com as classes Agricultura e Pastagem.

Como foram utilizados dados adquiridos em duas diferentes épocas puderam ser feitas comparações entre as médias de coerência interferométrica para cada classe analisando as imagens de coerência γ_{HH1_HH2} e γ_{HV1_HV2} das épocas março/abril (PLR) e junho/julho (FBD), a fim de verificar se houve significativas diferenças entre os valores de coerência interferométrica observados em cada classe. Foi constatado que houve significativas diferenças entre as médias de coerência interferométrica apenas para as classes não-florestadas, sendo este fato atribuído às variações de precipitação acumulada entre as épocas das imagens, às possíveis mudanças ocorridas nas três classes (Pastagem, Solo Exposto e Agricultura) e também aos diferentes ângulos de incidência, que provocaram diferentes retroespalhamentos e conseqüentemente diferentes fases interferométricas, alterando as coerências interferométricas observadas.

Pode-se concluir que as variações entre coerências interferométricas associadas às duas épocas analisadas podem ser consideradas um dos indicativos da ocorrência de mudanças na cobertura da terra e que a análise conjunta de imagens de coerência interferométrica FBD e PLR permitiu detectar tais mudanças.

Comparando-se os resultados obtidos com as imagens FBD e PLR observa-se que os dados PLR, embora tenham apresentado maiores variações nos coeficientes dos polinômios dos co-registros, tiveram melhor desempenho nas classificações, principalmente as imagens-Amplitude de 23/04/2007, cuja composição multivariada acrescida de cada umas três imagens de coerência (γ_{HH1_HH2} , γ_{HV1_HV2} , γ_{VV1_VV2}) apresentou dentre todas as classificações realizadas os maiores coeficientes *Kappa*, sendo tais classificações conceituadas como muito boas ou excelentes.

Dos dois métodos de classificação empregados, o (MaxVer + ICM) apresentou melhor desempenho na maioria das classificações, embora as melhores para cada um dos três tipo de composição analisados tenham se mostrado significativamente iguais para os dois métodos.

Em virtude das potencialidades dos produtos interferométricos ALOS/PALSAR terem se mostrado inferiores às potencialidades dos produtos interferométricos JERS-1 e ERS-1/2, conclui-se que a descorrelação temporal das imagens ALOS/PALSAR, maior que a descorrelação entre as imagens dos outros três radares, afetou a qualidade dos produtos interferométricos gerados. Este fato não permitiu validar a hipótese desse trabalho.

Além de poder servir como base a previsões relacionadas à aplicabilidade interferométrica de radares imageadores futuros que venham a ser desenvolvidos, as conclusões acerca da potencialidade interferométrica do ALOS/PALSAR sob diferentes polarizações podem contribuir com pesquisas atuais que envolvem aplicações de radares polarimétricos imageadores nas Geociências, especialmente em estudos florestais e aplicações topográficas.

5.2 Sugestões para trabalhos futuros

Finalmente, são apresentadas algumas sugestões para trabalhos futuros:

1 – Repetição da metodologia empregada utilizando: distribuições estatísticas mais ajustadas para as classes; outros métodos de classificação; imagens complexas ALOS/PALSAR de outras datas e/ou outras áreas, como, por exemplo, regiões tropicais que incluam outras culturas agrícolas, áreas urbanas e áreas montanhosas.

2 – Avaliação da qualidade das imagens de coerência polarimétrica geradas a partir de imagens PLR do ALOS/PALSAR para classificação de cobertura da terra. As imagens de coerência polarimétrica são geradas a partir de pares de imagens de mesma data e polarizações diferentes (HH, VV).

4 – Geração de modelos digitais de elevação ALOS/PALSAR a partir de interferogramas co-polarizados de áreas não-florestadas.

5 – Avaliação da potencialidade de imagens de coerência polarimétrica e interferométrica ALOS/PALSAR para detectar incrementos de desmatamento.

REFERÊNCIAS BIBLIOGRÁFICAS

AGÊNCIA DE EXPLORAÇÃO AEROESPECIAL JAPONESA-JAXA. Tutorial: **ALOS-Advanced Land Observing Satellite DAICHI**. 2008. Disponível em: <http://www.jaxa.jp/projects/sat/alos/index_e.html>. Acesso em 01 fev. 2008

ALMEIDA, F. C. **Simulação de resposta de estruturas simplificadas de vegetação ao radar de abertura sintética interferométrico**. 2008. 102 p. (INPE-15433-TDI/1419). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2008.

BRITES, R. S., VICENTE, P.S., RIBEIRO, C. A. A. S. Comparação de desempenho entre três índices de exatidão aplicados a classificação de imagens orbitais. In: Simpósio Brasileiro de Sensoriamento Remoto, 8., Salvador, 1996. **Anais...** São José dos Campos, INPE, 1996.1CD-ROM.

CANADA CENTRE FOR REMOTE SENSING (CCRS). Tutorial: **Fundamentals of remote sensing**. 2007. 258 p. Disponível em: <http://www.ccrs.nrcan.gc.ca/resource/tutor/fundam/pdf/fundamentals_e.pdf>. Acesso em 02 out. 2008.

COHENCA, D. Evolução anual de desmatamentos na Floresta Nacional do Tapajós de 1997 a 2005. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 13., 2007, Florianópolis. **Anais...** São José dos Campos: INPE, 2007, p. 6653-6660. CD-ROM. ISBN 978-85-17-00031-7.

CONGALTON, R. G., GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Lewis Publishers, 1999. 137 p.

CORREIA, A. H. **Projeto, desenvolvimento e avaliação de classificadores estatísticos pontuais e contextuais para imagens SAR polarimétricas**. 1999, 271 p. (INPE-7178- DI/679) Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 1998.

DOBSON, M. C. Forest information from Synthetic Aperture Radar. **Journal of Forestry**. n.98, p.41-43, 2000.

DUTRA, L. V., HUBER, R. Feature Extraction and Selection for ERS-1/2 InSAR Classification. **International Journal of Remote Sensing**, v. 20, n.5, p. 993-1016, 1999.

FLEISS, J. L. **Statistical methods for rates and proportions**. New York: John Wiley & Sons, 1981. 321p.

- FLOURI, N., TOAN, T. L., SOUYRIS, J., SINGH, K., STUSSI, N., HSU, C. C., KONG, J. A. Interferometry for forest studies. In: FRINGE 96, 1996, Zurich. **Proceedings...** Zurich, [s.n], 1996.
- FREITAS, C. C.; SANT'ANNA, S. J. S.; RENNÓ, C. D.; CORREA, A. H. **Utilização de imagens de radar de abertura sintética na classificação de uso e ocupação do solo.** São José dos Campos: INPE, 2007-08-11. (INPE ePrint sid.inpe.br/mtc-m17@80/2007/08.10.18.20). Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m17@80/2007/08.10.18.20>>. Acesso em: 28 jul. 2009.
- FREITAS, C. C.; FRERY, A. C. O.; CORREIA, A. H. The polarimetric G distributions for SAR data analysis. **Environmetrics**, v. 16, n. 1, p. 13-31, 2005. (INPE-13585-PRE/8795).
- FRERY, A. C.; MÜLLER, H. J.; YANASSE, C. C. F.; SANT'ANNA, S. J. S. A model for extremely heterogeneous clutter. **IEEE Transactions on Geoscience and Remote Sensing**, v. 33, n. 3, p. 648-659, May 1997.
- FRERY, A. C. O. **Algumas ferramentas estatísticas na síntese, processamento e análise de imagens de radar de abertura sintética.** 1993. 242 p. (INPE-5548-TDI/534). Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, Sao Jose dos Campos. 1993.
- GABOARDI, C. **Utilização de imagem de coerência SAR para classificação do uso da terra: Floresta Nacional do Tapajós.** 2002. 137 p. (INPE-9612-TDI/842). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2002.
- GABRIEL, A. K.; GOLDSTEIN, R. M. Crossed orbit interferometry: theory and experimental results from SIR-B. **International Journal of Remote Sensing**. v. 9, n. 5, p. 857-872, 1988.
- GABRIEL, A. K.; GOLDSTEIN, R. M.; ZEBKER, H. A., Mapping small elevation changes over large areas: Differential radar interferometry. **Journal of Geophysical Research**. v. 94, n. 7, p. 9183-9191, 1989.
- GALPARSORO, L. U. FERNÁNDEZ, S. P. **Medidas de concordancia:** el índice Kappa. 2001. Disponível em: <<http://www.fisterra.com/mbe/investiga/kappa/kappa.htm>>. Acesso em: 21 jul. 2006.
- GAMA, F.F. dos SANTOS, J.R., MURA, J.C., FREITAS, C.C. Utilização de dados polarimétricos e interferométricos SAR para estimativa de biomassa de povoamentos de *Eucalyptus*. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 13., 21-26 abr 2007, Florianópolis. **Anais...** São José dos Campos: INPE, 2007, p. 4857-4864. CD-ROM. ISBN 978-85-17-00031-7.

GENS, R. **Quality assessment of SAR interferometric data**. 1998. 119 p. Doctoral Thesis. Hannover: Technische Universität Hannover. 1998.

GENS, R.; GENDEREN, J.L.V. SAR interferometry – issues, techniques, applications. **International Journal of Remote Sensing**, v. 17, n. 10, p. 1803-1835, 1996.

GIGLIA, D. C., PRITT, M. D. **Two-dimensional phase unwrapping**: theory, algorithms, and software. New York: John Wiley & Sons, 1998. 493 p.

GOLDSTEIN, R. M., ZEBKER, H. A., WERNER, C. L. Satellite radar interferometry: Two-dimensional phase unwrapping. **Radio Science**. v. 23, n. 4, p. 713–720. 1988

GRAHAM, L. C. Synthetic interferometer radar for topographic mapping. **Proceeding of the IEEE**, v. 62, n. 6, p. 763-768. June 1974.

HANSSEN R.F. Radar Interferometry: data interpretation and error analysis. **Remote Sensing and Digital Image Processing**. 2001. v.2, 368 p.

HAYAKAWA, E. H.; SILVA, D. L. A.; BERTANI, T. C.; PRADO, B. R. Interferometria SAR e geração de MDE's interferométricos aplicados na Geomorfologia. In: SIMPÓSIO NACIONAL DE GEOMORFOLOGIA, 7., E ENCONTRO LATINO-AMERICANO DE GEOMORFOLOGIA, 2., 03 a 08 ago. 2008, Belo Horizonte. **Anais...** Belo Horizonte: UFMG, 2008, v. único.

HELLWICH, O. **Basic principles and current issues of SAR interferometry**. 1999. Disponível em: <<http://www.ipi.uni-hannover.de/html/publikationen/1999/isprs-workshop/cd/pdfpapers/hellwich.pdf>>. Acesso em: 10 fev. 2008.

HENDERSON, F. M.; LEWIS, A. J. **Manual of remote sensing**: principles and applications of imaging radar. 3 ed. New York: John Wiley & Sons, 1998. v. 2, 896 p.

INSTITUTO DE ESTUDOS AVANÇADOS – Força Aérea Brasileira. IEAv. Tutorial: **Imageamento por radar**. São José dos Campos. 2002. 83 p.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Monitoramento da Floresta Amazônica por satélite**: Projeto PRODES. Desenvolvido pela Divisão de Processamento de Imagens do Instituto Nacional de Pesquisas Espaciais. Apresenta gráficos com os resultados obtidos pelo projeto PRODES até o ano de 2008. Disponível em: <http://www.obt.inpe.br/prodes/r2008.htm>. Acesso em: 7 jan. 2009.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). Centro de Previsão do Tempo e Estudos Climáticos. **Plataforma de coleta de dados**: dados meteorológicos, hidrológicos e ambientais de PCD's. Disponível em: <http://satelite.cptec.inpe.br/PCD/metadados.jsp?uf=15&id=32207&tipo=HIDRO&idVariavel=6&dia=03&mes=03&ano=2007&Submit2.x=9&Submit2.y=8>. Acesso em: 03 mar. 2009.

JENSEN, J. R. **Introductory digital image processing : a remote sensing perspective**. Upper Saddle River: Prentice-Hall, 1996. 316 p.

JENSEN, J.R. **Remote sensing of the environment: an Earth resource perspective**. Upper Saddle River N.J.: Prentice-Hall, 2000. 545p.

JUST, D., BAMLER, R. Phase statistics of interferograms with applications to synthetic aperture radar. **Applied Optics**, n.33, p. 4361-4368. 1994.

LANARI, R., FORNARO, G., RICCIO, D., MIGLIACCIO, M. PAPANASSIOU, K.P., MOREIRA, J.R., SCHWABISCH, M., DUTRA, L.V, PUGLISI, G., FRANCESCHETTI, G., COLTELLI, M. Generation of Digital Elevation Models by Using SIR-C/X-SAR Multifrequency Two-Pass Interferometry: The Etna Case Study. **IEEE Transactions on Geoscience and Remote Sensing**, v. 34, n. 5, p. 1097-1114, 1996.

LANDIS, J. R., KOCH, C. H. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 3, p. 159-174. Mar. 1977.

LEÃO, C., KRUG, L., KAMPEL, M. FONSECA, L.M.G. Avaliação de métodos de classificação em imagens TM/Landsat e CCD/CBERS para o mapeamento do uso e cobertura da terra na região costeira do extremo sul da Bahia. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 13., 2007, Florianópolis. **Anais...** São José dos Campos: INPE, 2007, p. 939-946. CD-ROM. ISBN 978-85-17-00031-7.

LE TOAN, T., PICARD, G., MARTINEZ, J. M., MELON, P., DAVIDSON, M. On the relationships between radar measurements and forest structure and biomass. In: III International Symposium on Retrieval of Bio- and Geophysical Parameters from SAR data for Land Applications, 2002, Sheffield. **Proceedings...** Sheffield: ESA (ESA SP-475), 2002, p. 3-12.

LI, F.K; GOLDSTEIN, M.R. Studies of Multibaseline Spaceborne Interferometric Synthetic Aperture Radars. **IEEE Transactions on Geoscience and Remote Sensing**, v. 27, n.1 p. 88-97, 1990.

LIN, Q., VESECKY, J. F., ZEBKER, H. A. New approaches in interferometric SAR data processing. **IEEE Transactions on Geoscience and Remote Sensing**, v.30, n.3, p. 560-567, 1991.

LU, Z.; WICKS JR., C.; DZURISIN, D.; POWER, J.; THATCHER, W. Studying Deformation of Volcanoes in the Aleutian Islands and the Kamchatka Peninsula Using L-Band ALOS PALSAR Interferometry. In: ALOS PI Workshop, 1., 2001. **Proceedings...** Tóquio: JAXA, 2001, p. 199-204.

MURA, J.C. **Geocodificação automática de imagens de radar de abertura sintética interferométrico: sistema Geo-InSAR**. 2000. 160 p. (INPE-8209-TDI/764). Tese

(Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2000.

NEEFF T., DUTRA L.V, SANTOS J.R., FREITAS C.C., ARAUJO L.S. Tropical forest measurement by interferometric height modeling and P-band backscatter. **Forest Science**. Bethesda, MD, USA, v. 51, n. 6, p. 585-594, 2005.

NÜESCH, D. R., SIEBER, A., WEGMÜLLER, U., WERNER, C. L. Interferometric signatures of temperate forest from ERS-1 SAR data. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SIMPOSIUM, 1994, Pasadena. **Proceedings...** Piscataway, 1994.

PAPATHANASSIOU, K. P. **Polarimetric SAR interferometry**. 1999. 131 p. Doctoral Thesis. Oberpfaffenhofen: Technische Universität Graz. 1999.

PARADELLA, W.R. Simulação do satélite brasileiro MAPSAR finaliza mais uma fase. **Notícias 14/10/2005**. Disponível em: <<http://www.fatorgis.com.br>>. Acesso em: 27 Jan 2008.

RICHARDS, J. A. **Remote sensing digital image analysis: an introduction**. Berlin: Springer-Verlag, 1986. 281 p.

RIGNOT, E.; SALAS, W. A.; SKOLE, D. L. Mapping deforestation and secondary growth in Rondônia, Brazil, using imaging radar and thematic mapper data. **Remote Sensing of Environment**, v. 59, n.2, p. 167-179, 1997.

SAATCHI, S. S.; SOARES, J. V.; ALVES, D. S. Mapping deforestation and land use in Amazon rainforest by using SIR-C imagery. **Remote Sensing of Environment**, v. 59, n.2, p. 191-202, 1997.

SANTITAMNONT, P. **Interferometric SAR processing for topographic mapping**. 1998. 105 p. Doctoral Thesis. Hannover: Technische Universität Hannover. 1998.

SANTOS, J. R.; NEEFF, T.; ARAUJO, L. S.; GAMA, F. F.; DUTRA, L. V.; SOUSA JÚNIOR, M. A. Interferometria Sar (Bandas X E P) na estimativa de biomassa florestal. In: SIMPÓSIO DE CIÊNCIAS GEODÉSICAS E TECNOLOGIAS DA GEOINFORMAÇÃO, 1., , Recife. **Anais...** 2004. On-line. (INPE-11419-PRE/6855). Disponível em: <<http://urlib.net/sid.inpe.br/sergio/2004/09.27.10.21>>. Acesso em: 28 jul. 2009.

SARMAP. **SARscape**[®]. 4.0.003. Switzerland: Purasca, Sarmap S.A. 2008. Disponível em: <http://www.creaso.com/english/11_wsnew/main.htm>. Acesso em: 15 ago. 2008.

SILVA, D. L. A., SCOFIELD, G. B.; ABOUD NETA, S. R., NEGRI, R. G., DUTRA, L. V.; FREITAS, C. C.. Utilização de imagens de coerência interferométrica em banda L para classificação de cobertura da terra na região de Tapajós-PA.. In: SIMPÓSIO

BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 14., 2009, Natal. **Anais...** São José dos Campos: INPE, 2009, p. 7489-7496. CD-ROM. ISBN 978-85-17-00044-7.

SHIMABUKURO, Y.E., AMARAL, S., AHERN, F.J. AND PIETSCH, R.W. Classification and monitoring the Tapajós National Forest region using SAR (RADARSAT-Standard mode and SAREX-Wide swath mode) and Landsat Thematic Mapper data. In: Geomatics in the era of RADARSAT, 1997, Ottawa. **Proceedings...** Ottawa: CCRS, 1997.

SMITS, P. C., DELLEPIANE, S. G., SCHOWENGERDT, R. A. Quality assessment of image classification algorithms for land-cover mapping: a review and a proposal for a cost-based approach. **International Journal of Remote Sensing**, v. 20, n.8, p. 1461-1486. Aug. 1999.

SPIEGEL, M. R. **Estatística**. 2. ed. Tradução de Crusius, C. A. Rio de Janeiro: McGraw-Hill, 1984. 454 p.

SWAIN, P. H., DAVIS, S. M. **Remote sensing: the quantitative approach**. New York: McGraw-Hill, 1978. 396 p.

TAKEUCHI, S., OGURO, Y. A comparative study of coherence patterns in C-band and L-band interferometric SAR from tropical rain forest areas. **Advances in Space Research**. v. 32, n. 11, p. 2305-2310, 2003.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern recognition**. 4. ed. San Diego: Academic Press, , 2006.

VAN DER SANDEN, J. J. **Radar remote sensing to support tropical forest management**. 1997, 330 p. Doctoral Thesis - Wageningen Agricultural University. Series 5. Tropenbos-Guyana, Georgetown. 1997. ISBN: 90-5485-778-1

VIEIRA, P. R., **Desenvolvimento de classificadores de máxima verossimilhança e ICM para imagens SAR**. São José dos Campos, 1996, 251 p. (INPE 6124-TDI/585). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 1996.

XU, W., CUMMING, I. A region-growing algorithm for InSAR phase unwrapping. **IEEE Transactions on Geoscience and Remote Sensing**, v. 37, n.1, p. 124-134, 1999.

WEGMÜLLER, U., WERNER, C. SAR interferometric signatures of forest. **IEEE Transactions on Geoscience and Remote Sensing**, v. 33, n. 5, p. 1153-1161, 1995.

WEGMÜLLER, U., WERNER, C. Retrieval of vegetation parameters with SAR interferometry. **IEEE Transactions on Geoscience and Remote Sensing**, v. 35, n. 1, p.18-24, 1997.

ZALOTI JÚNIOR, O. D. **Avaliação do modelo digital do terreno extraído de dados SAR interferométricos na banda X do SAR R-99B.** 2007. 145 p. (INPE-15312-TDI/1357). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2007.

ZEBKER, H.A., VILLASENOR, J. Decorrelation in interferometric radar echoes. **IEEE Transactions on Geoscience and Remote Sensing.** v. 30. n.5, p. 950–959. 1992

APÊNDICE A – MATRIZES DE CONFUSÃO

Tabela A.1 – Dados FBD: matriz de confusão da classificação (MaxVer + ICM) de A_{HH1}

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	545	887	17	5	0	1454
	FloMod	228	56	0	0	0	284
	Agr	32	0	496	798	150	1476
	Pastagem	0	6	79	32	513	630
	Solo	0	0	0	0	44	44
	Total	805	949	592	835	707	3888

Tabela A.2 – Dados FBD: matriz de confusão da classificação (MaxVer + ICM) de A_{HH2}

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	496	657	0	2	0	1155
	FloMod	271	289	0	0	0	560
	Agr	0	0	543	757	9	1309
	Pastagem	38	3	28	76	0	145
	Solo	0	0	21	0	698	719
	Total	805	949	592	835	707	3888

Tabela A.3 – Dados FBD: matriz de confusão da classificação (MaxVer + ICM) de A_{HV1}

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	553	456	0	0	0	1009
	FloMod	252	493	0	0	0	745
	Agr	0	0	498	141	622	1261
	Pastagem	0	0	83	694	29	806
	Solo	0	0	11	0	56	67
	Total	805	949	592	835	707	3888

Tabela A.4 – Dados FBD: matriz de confusão da classificação (MaxVer + ICM) de A_{HV2}

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	506	758	0	0	0	1264
	FloMod	299	191	0	0	0	490
	Agr	0	0	408	10	12	430
	Pastagem	0	0	87	825	33	945
	Solo	0	0	97	0	662	759
	Total	805	949	592	835	707	3888

Tabela A.5 – Dados FBD: matriz de confusão da classificação (MaxVer + ICM) de γ_{HH1_HH2}

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	450	787	5	242	584	2068
	FloMod	148	105	15	89	66	423
	Agr	14	0	398	132	3	547
	Pastagem	0	0	0	0	0	0
	Solo	193	57	174	372	54	850
	Total	805	949	592	835	707	3888

Tabela A.6 – Dados FBD: matriz de confusão da classificação (MaxVer + ICM) de γ_{HV1_HV2}

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	9	7	0	28	0	44
	FloMod	485	716	98	351	614	2264
	Agr	208	129	468	362	45	1212
	Pastagem	0	0	0	0	0	0
	Solo	103	97	26	94	48	368
	Total	805	949	592	835	707	3888

Tabela A.7 – Dados FBD: matriz de confusão da classificação (MaxVer + ICM) de $(A_{HH1} + A_{HV1} + \gamma_{HH1_HH2})$.

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	376	521	0	0	0	897
	FloMod	429	418	0	2	0	849
	Agr	0	0	500	112	118	730
	Pastagem	0	10	92	721	571	1394
	Solo	0	0	0	0	18	18
	Total	805	949	592	835	707	3888

Tabela A.8 – Dados FBD: matriz de confusão da classificação (MaxVer + ICM) de $(A_{HH1} + A_{HV1} + \gamma_{HV1_HV2})$.

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	432	525	0	0	0	957
	FloMod	371	414	0	1	0	786
	Agr	0	0	484	169	276	929
	Pastagem	2	10	108	665	414	1199
	Solo	0	0	0	0	17	17
	Total	805	949	592	835	707	3888

Tabela A.9 – Dados FBD: matriz de confusão da classificação (MaxVer + ICM) de $(A_{HH2} + A_{HV2} + \gamma_{HH1_HH2})$.

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	466	588	0	0	0	1054
	FloMod	339	361	0	0	0	700
	Agr	0	0	452	38	6	496
	Pastagem	0	0	99	797	33	929
	Solo	0	0	41	0	668	709
	Total	805	949	592	835	707	3888

Tabela A.10 - Dados FBD: matriz de confusão da classificação (MaxVer + ICM) de $(A_{HH2} + A_{HV2} + \gamma_{HV1_HV2})$

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	333	569	0	0	0	902
	FloMod	472	380	0	0	0	852
	Agr	0	0	451	27	5	483
	Pastagem	0	0	93	808	34	935
	Solo	0	0	48	0	668	716
	Total	805	949	592	835	707	3888

Tabela A.11 – Dados PLR: matriz de confusão da classificação (MaxVer + ICM) de γ_{HH1_HH2}

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	486	301	53	27	570	1437
	FloMod	0	13	21	0	0	34
	Agr	52	157	226	99	9	543
	Pastagem	0	4	113	462	0	579
	Solo	34	111	26	15	23	209
	Total	572	586	439	603	602	2802

Tabela A.12 – Dados PLR: matriz de confusão da classificação (MaxVer + ICM) de γ_{HV1_HV2}

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	0	0	0	0	0	0
	FloMod	54	84	23	55	88	304
	Agr	439	229	262	30	335	1295
	Pastagem	22	219	81	502	55	879
	Solo	57	54	73	16	124	324
	Total	572	586	439	603	602	2802

Tabela A.13 – Dados PLR: matriz de confusão da classificação (MaxVer + ICM) de γ_{VV1_VV2} .

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	0	0	0	0	0	0
	FloMod	0	0	37	13	0	50
	Agr	5	11	0	0	7	23
	Pastagem	161	37	20	520	41	779
	Solo	406	538	382	70	554	1950
	Total	572	586	439	603	602	2802

Tabela A.14 – Dados PLR: matriz de confusão da classificação (MaxVer + ICM) de A_{HH1}

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	436	335	9	18	0	798
	FloMod	121	246	10	0	0	377
	Agr	14	5	0	44	0	63
	Pastagem	1	0	420	541	588	1550
	Solo	0	0	0	0	14	14
	Total	572	586	439	603	602	2802

Tabela A.15 – Dados PLR: matriz de confusão da classificação (MaxVer + ICM) de A_{VV1}

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	320	352	21	0	0	693
	FloMod	236	145	0	0	0	381
	Agr	16	77	160	0	15	268
	Pastagem	0	12	258	603	587	1460
	Solo	0	0	0	0	0	0
	Total	572	586	439	603	602	2802

Tabela A.16 – Dados PLR: matriz de confusão da classificação (MaxVer + ICM) de $(A_{HH1} + A_{HV1} + A_{VV1})$.

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	364	302	0	0	0	666
	FloMod	208	284	0	0	0	492
	Agr	0	0	439	0	238	677
	Pastagem	0	0	0	603	345	948
	Solo	0	0	0	0	19	19
	Total	572	586	439	603	602	2802

Tabela A.17 – Dados PLR: matriz de confusão da classificação (MaxVer + ICM) de ($A_{HH2} + A_{HV2} + A_{VV2}$).

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	235	269	0	19	0	523
	FloMod	337	317	0	0	0	654
	Agr	0	0	439	0	0	439
	Pastagem	0	0	0	584	75	659
	Solo	0	0	0	0	527	527
	Total	572	586	439	603	602	2802

Tabela A.18 – Dados FBD: matriz de confusão da classificação SVM de A_{HH2}

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	471	631	0	4	0	1106
	FloMod	297	311	0	0	0	608
	Agr	0	0	0	0	0	0
	Pastagem	37	7	568	828	22	1462
	Solo	0	0	24	3	685	712
	Total	805	949	592	835	707	3888

Tabela A.19 – Dados FBD: matriz de confusão da classificação SVM de ($A_{HH1} + A_{HV1} + \gamma_{HH1_HH2}$).

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	431	464	0	0	0	895
	FloMod	374	479	0	0	0	853
	Agr	0	0	446	138	64	648
	Pastagem	0	6	146	697	615	1464
	Solo	0	0	0	0	28	28
	Total	805	949	592	835	707	3888

Tabela A.20 – Dados FBD: matriz de confusão da classificação SVM de ($A_{HH1} + A_{HV1} + \gamma_{HV1_HV2}$).

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	491	500	0	0	0	991
	FloMod	313	443	0	0	0	756
	Agr	0	0	436	190	89	715
	Pastagem	1	6	156	645	590	1398
	Solo	0	0	0	0	28	28
	Total	805	949	592	835	707	3888

Tabela A.21 – Dados FBD: matriz de confusão da classificação SVM de $(A_{HH2} + A_{HV2} + \gamma_{HH1_HH2})$.

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	422	663	0	0	0	1085
	FloMod	383	286	0	0	0	669
	Agr	0	0	407	30	3	440
	Pastagem	0	0	130	805	33	968
	Solo	0	0	55	0	671	726
	Total	805	949	592	835	707	3888

Tabela A.22 - Dados FBD: matriz de confusão da classificação SVM de $(A_{HH2} + A_{HV2} + \gamma_{HV1_HV2})$.

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	512	606	0	0	0	1118
	FloMod	292	343	0	0	0	635
	Agr	0	0	416	39	5	460
	Pastagem	1	0	132	796	33	962
	Solo	0	0	44	0	669	713
	Total	805	949	592	835	707	3888

Tabela A.23 – Dados PLR: matriz de confusão da classificação SVM de γ_{HH1_HH2}

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	174	70	4	8	210	466
	FloMod	336	388	175	67	360	1326
	Agr	56	116	160	164	32	528
	Pastagem	6	12	100	364	0	482
	Solo	0	0	0	0	0	0
	Total	572	586	439	603	602	2802

Tabela A.24 – Dados PLR: matriz de confusão da classificação SVM de γ_{HV1_HV2}

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	50	10	30	9	32	131
	FloMod	343	335	261	179	392	1510
	Agr	153	68	88	13	68	440
	Pastagem	26	173	60	402	60	721
	Solo	0	0	0	0	0	0
	Total	572	586	439	603	602	2802

Tabela A.25 – Dados PLR: matriz de confusão da classificação (MaxVer + ICM) de γ_{VV1_VV2}

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	0	0	0	0	0	0
	FloMod	335	362	271	191	358	1517
	Agr	0	0	0	0	0	0
	Pastagem	150	64	61	387	83	745
	Solo	87	160	107	25	161	540
	Total	572	586	439	603	602	2802

Tabela A.26 – Dados PLR: matriz de confusão da classificação SVM de $(A_{HH1} + A_{HV1} + A_{VV1})$.

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	277	325	0	0	0	602
	FloMod	294	260	0	0	0	554
	Agr	0	0	439	0	336	775
	Pastagem	1	1	0	603	248	853
	Solo	0	0	0	0	18	18
	Total	572	586	439	603	602	2802

Tabela A.27 – Dados PLR: matriz de confusão da classificação (SVM) de $(A_{HH2} + A_{HV2} + A_{VV2})$.

		REFERÊNCIA					Total
		FloPrim	FloMod	Agr	Pastagem	Solo	
CLASSIF.	FloPrim	3	0	0	4	0	7
	FloMod	568	586	0	1	0	1155
	Agr	0	0	439	5	0	444
	Pastagem	1	0	0	593	73	667
	Solo	0	0	0	0	529	529
	Total	572	586	439	603	602	2802