



Ministério da
Ciência e Tecnologia



INPE-16220-TDI/1541

AVALIAÇÃO DE DADOS POLARIMÉTRICOS DO SENSOR ALOS PALSAR PARA CLASSIFICAÇÃO DA COBERTURA DA TERRA DA AMAZÔNIA

Rogério Galante Negri

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

Registro do documento original:
<<http://urlib.net/sid.inpe.br/mtc-m18@80/2009/05.14.12.59>>

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-16220-TDI/1541

**AVALIAÇÃO DE DADOS POLARIMÉTRICOS DO
SENSOR ALOS PALSAR PARA CLASSIFICAÇÃO DA
COBERTURA DA TERRA DA AMAZÔNIA**

Rogério Galante Negri

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

Registro do documento original:
<<http://urlib.net/sid.inpe.br/mtc-m18@80/2009/05.14.12.59>>

INPE
São José dos Campos
2009

Dados Internacionais de Catalogação na Publicação (CIP)

Negri, Rogério Galante.

N312a Avaliação de dados polarimétricos do sensor ALOS PALSAR para classificação da cobertura da terra da Amazônia / Rogério Galante Negri. – São José dos Campos : INPE, 2009.

170p. ; (INPE-16220-TDI/1541)

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

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

1. Amazônia. 2. Classificação de imagens. 3. SAR. 4. ALOS.
5. Polarimetria 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
Computação Aplicada

Dr. Nandamudi Lankalapalli Vijaykumar

N. L. Vijaykumar

Presidente / INPE / SJCampos - SP

Dr. Luciano Vieira Dutra

Luciano Dutra

Orientador(a) / INPE / SJCampos - SP

Dra. Corina da Costa Freitas

Corina Freitas

Orientador(a) / INPE / SJCampos - SP

Dr. Dalton de Morisson Valeriano

Dalton de M. Valeriano

Membro da Banca / INPE / SJCampos - SP

Dr. Alejandro Cesar Frery Orgambide

Alejandro Cesar

Convidado(a) / UFAL / Macapá - AL

Aluno (a): Rogério Galante Negri

São José dos Campos, 19 de maio de 2009

“A Matemática é a honra do espírito humano.”

GOTTFRIED WILHELM LEIBNIZ

*Dedico a meus exemplos... meus pais, Dircio e Ivete,
pelo apoio incondicional e permanente.*

AGRADECIMENTOS

Agradeço a meus orientadores Luciano Vieira Dutra e Corina da Costa Freitas pela grande oportunidade de orientação, amizade, ensino e paciência. Presto os mais sinceros sentimentos de gratidão!

Ao Instituto Nacional de Pesquisas Espaciais (INPE) pela oportunidade de estudo.

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), pela bolsa de estudos oferecida.

Aos integrantes da “Senzala” pela ajuda e companhia prestadas durante o desenvolvimento deste trabalho.

Agradeço também ao professor Edilson Ferreira Flores pela orientação durante a graduação, que de certa forma foi responsável por despertar meu interesse pela pesquisa.

A meus pais, pessoas em que me inspiro pelo exemplo de bondade, honestidade, esforço e dedicação.

RESUMO

A Amazônia é considerada a maior floresta tropical do planeta, abrigando parte considerável da biodiversidade e exercendo papel fundamental nos ciclos biogeoquímicos. Devido a atuação antrópica, esta floresta sofre constantemente processos destrutivos, como por exemplo, desmatamentos e queimadas, que por sua vez, pode provocar desequilíbrios ao ecossistema. Tais circunstâncias tornam o monitoramento desta região importante, para o qual, o uso de Sensoriamento Remoto é conveniente. Fatores atmosféricos desta região, como a intensa presença de nuvens, prejudicam a aquisição de informações a partir de sensores ópticos. Neste contexto, a utilização de radares imageadores tornam-se úteis, uma vez que as condições atmosféricas não interferem terminantemente na aquisição dos dados. Uma recente tecnologia são os radares polarimétricos, capazes de coletar uma maior quantidade de informação a respeito dos alvos, proporcionando assim o aumento na capacidade de discriminação destes. Recentemente, a JAXA lançou o satélite ALOS, munido do sensor PALSAR, um radar polarimétrico que opera em banda L. Para avaliação do potencial das imagens PALSAR na discriminação de diferentes tipos de alvos habituais de regiões de floresta tropical, foram empregados os métodos MaxVer/ICM e K-Médias Wishart H/A/ $\bar{\alpha}$ de classificação de imagens SAR, associados a diferentes conjuntos de informações provenientes das imagens polarimétricas, considerando diferentes níveis de discriminação de alvos. Os resultados obtidos possibilitaram afirmar que o método MaxVer/ICM possui maior capacidade de discriminação dos alvos. A utilização de dados Univariados (HH, HV ou VV em Amplitude) é limitada para separação de diferentes alvos, ao contrário do que ocorre com o emprego de duas ou mais componentes polarimétricas, definido pelos conjuntos Bivariados, Multivariados e Polarimétricos. Classes derivadas de área florestais, como por exemplo, florestas primárias e tipos de regenerações não foram discriminadas satisfatóriamente, independente dos dados utilizados, porém, diferentes tipos de agricultura e pastagem foram discriminadas. Os resultados possibilitam concluir que o ganho de capacidade em discriminação dos alvos com uso de dados Multivariados e Polarimétricos não proporciona aumento considerável, e logo, é indicando assim os dados Bivariados, em especial HH+HV, denominado por Modo Operacional de Aquisição, para trabalhos relacionados ao monitoramento de florestas tropicais a partir do emprego de radares que operam em banda L.

ASSESSMENT OF POLARIMETRIC ALOS PALSAR DATA FOR AMAZON LAND COVER CLASSIFICATION

ABSTRACT

Amazon Forest is considered the largest tropical forest of the planet. It keeps considerable part of the biodiversity and has great importance to the biogeochemistry cycles. The anthropic actions cause destructive processes such as deforestations and burnings, which can provoke unbalances on the ecosystem. This scenario highlights the importance of the monitoring on this area by Remote Sensing. Atmospheric factors over the Amazon region as the cloud cover could affect the quality of the optical remote sensing. In this context, the use of the imaging radars in the tropics is important, because the atmospheric conditions do not flatly prejudice the data acquisition. Polarimetric radars are a recent technology capable to collect a large amount of information of the target characteristics, improving the discrimination capability of them. Recently, the L-band PALSAR sensor on ALOS was launched. The potential of PALSAR data in the discrimination of different targets was evaluated using Maximum Likelihood and the K-Means Wishart H/A/ $\bar{\alpha}$ SAR image classifiers. The results showed that Maximum Likelihood presented higher ability of the target discrimination. The use of Single-Polarization data (HH, HV or VV) is limited to separate different targets, unlike to Dual-, Multi- and Full-Polarization data. Primary forest and regeneration types were not satisfactorily discriminated. However, different agriculture types and pasture were well discriminated. The results showed that the discrimination capacity of targets with Multi- and Full-Polarization data does not provide considerable increase, when compared with results generated by HH+HV and HV+VV Dual-Polarization data. The HH+HV data, named ALOS PALSAR Operational Acquisition Mode, is designated to the study of the tropical forest monitoring using the L-band radars.

SUMÁRIO

Pág.

LISTA DE FIGURAS

LISTA DE TABELAS

LISTA DE ABREVIATURAS E SIGLAS

1 INTRODUÇÃO	29
2 FUNDAMENTAÇÃO TEÓRICA	31
2.1 Polarimetria	31
2.1.1 Polarização de Ondas Eletromagnéticas	31
2.1.2 Espalhamento das Ondas Eletromagnéticas	32
2.1.3 Convenções Adotadas	34
2.1.4 Teorema da Decomposição de Alvos em Autovalores e Autovetores	35
2.2 Classificação de Imagens SAR Polarimétricas	37
2.2.1 Os Métodos de Classificação por Máxima Verossimilhança e ICM	38
2.2.1.1 Funções Densidade de Probabilidade Derivadas do Modelo Multiplicativo	40
2.2.1.2 Funções Densidade de Probabilidade <i>Ad-Hoc</i>	43
2.2.2 O Método de Classificação K-Médias Wishart H/A/ $\bar{\alpha}$	44
2.3 Análise de Exatidão dos Resultados	45
3 MATERIAIS	49
3.1 Floresta Nacional de Tapajós – PA	49
3.2 Imagens do Sensor ALOS PALSAR	50
3.3 Precipitação Pluviométrica Ocorrida na Área de Estudo	52
3.4 Software Utilizados	52
4 METODOLOGIA	55
4.1 Pré-processamento dos Dados	58
4.1.1 Calibração da Imagem	59
4.1.2 Correção Geométrica	61
4.1.3 Seleção da Área de Estudo	64
4.1.4 Processamento <i>Multi-Look</i>	64
4.2 Seleção das Classes de Cobertura da Terra	66
4.3 Estruturação de Níveis de Discriminação das Classes de Cobertura da Terra	74
4.3.1 Cálculo da Medida de Dissimilaridade	74
4.3.2 Regra de Agrupamento Hierárquico	75
4.4 Classificação da Imagem ALOS PALSAR	76

4.4.1	Classificações Pelo Método MaxVer/ICM	76
4.4.2	Classificações Pelo Método K-Médias Wishart H/A/ $\bar{\alpha}$	77
4.5	Rotinas Auxiliares Implementadas	77
5	RESULTADOS	79
5.1	Análise Descritiva das Classes de Cobertura da Terra Selecionadas	79
5.2	Estrutura de Discriminação Obtida	86
5.3	Classificações MaxVer/ICM	89
5.4	Classificação K-Médias Wishart H/A/ $\bar{\alpha}$	92
5.5	Análise dos Resultados	96
5.5.1	Análise dos Resultados: Discriminação dos Alvos	96
5.5.2	Análise dos Resultados: Métodos de Classificação e Dados	98
6	CONCLUSÕES E PERSPECTIVAS	109
REFERÊNCIAS BIBLIOGRÁFICAS		111
A	DEFINIÇÃO DAS EQUAÇÕES UTILIZADAS	115
B	GRÁFICOS E TABELAS: COMPARAÇÃO ENTRE AS AMOSTRAS DE TREINAMENTO E VALIDAÇÃO	117
C	ESTIMAÇÃO DO NÚMERO EQUIVALENTE DE <i>LOOKS</i>	129
D	FUNÇÕES DENSIDADE DE PROBABILIDADE UTILIZADAS PELO MÉTODO MAXVER/ICM PARA AS DIFERENTES CLASSES DE COBERTURA DA TERRA NOS CASOS UNIVARIADO E POLARIMÉTRICO	135
E	MATRIZES DE CONFUSÃO DAS CLASSIFICAÇÕES REALIZADAS	137
F	CLASSIFICAÇÕES GERADAS PELO MÉTODO MAXVER/ICM	155

LISTA DE FIGURAS

	<u>Pág.</u>
2.1 Trajetória da extremidade do vetor campo elétrico e elipse de polarização.	32
2.2 O plano $H/\bar{\alpha}$.	37
2.3 Fluxograma do método de classificação K-Médias Wishart $H/A/\bar{\alpha}$.	46
3.1 Área abrangida pelo imagem PALSAR em modo de operação PLR 1.1 (área interna ao polígono de arestas vermelhas).	50
3.2 Precipitação acumulada ocorrida no mês de Abril, medida pelos PCDs disponíveis mais próximos a área de estudo.	53
4.1 Organização do desenvolvimento do trabalho.	56
4.2 Diagrama das etapas realizadas durante o pré-processamento dos dados.	57
4.3 Diagrama das etapas realizadas durante a seleção das classes de cobertura da terra e estruturação dos níveis de discriminação.	57
4.4 Diagrama da etapa da classificação pelo método MaxVer/ICM.	58
4.5 Diagrama da etapa da classificação pelo método K-Médias Wishart $H/A/\bar{\alpha}$.	58
4.6 Verificação do padrão da antena.	60
4.7 Relação entre as geometrias <i>Slant Range</i> e <i>Ground Range</i> .	61
4.8 Distorções causadas pela dimensão das feições: <i>Foreshortening</i> , <i>Layover</i> e <i>Shadowing</i> .	62
4.9 Altimetria referente a área de estudo.	63
4.10 Correção geométrica.	64
4.11 Seleção de uma sub-área para estudo.	65
4.12 Imagem resultante do processamento <i>Multi-Look</i> , composição (HH)R(HV)G(VV)B em Intensidade.	67
4.13 Amostras selecionadas.	72
4.14 Visualização das amostras selecionadas sobre a imagem ALOS PALSAR utilizada no estudo, em Amplitude e composição colorida (HH)R(HV)G(VV)B, e sobre uma imagem LANDSAT-5 TM, referente a 21 de Julho de 2007, em composição colorida (5)R(4)G(3)B.	73
4.15 Exemplo de Agrupamento Hierárquico segundo a regra de agrupamento proposta.	76
5.1 Gráfico <i>Boxplot</i> : Informação radiométrica em Amplitude da componente HH das diferentes classes.	82
5.2 Gráfico <i>Boxplot</i> : Informação radiométrica em Amplitude da componente HV das diferentes classes.	82
5.3 Gráfico <i>Boxplot</i> : Informação radiométrica em Amplitude da componente VV das diferentes classes.	83
5.4 Histograma Polar: Comparação entre as amostras de treinamento e validação das diferentes classes segundo a informação de diferença de fase entre as componentes HH e VV.	84

5.5	Dispersão das amostras das classes selecionadas no Plano H/ $\bar{\alpha}$	85
5.6	Estrutura dos níveis de discriminação obtido a partir das amostras selecionadas de cobertura da terra.	87
5.7	Legenda geral dos níveis de discriminação para as classificações MaxVer/ICM.	87
5.8	Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados e Multivariados para o nível de discriminação 1.	90
5.9	Classificações obtidas pelo método MaxVer/ICM a partir de dados Bivariados e Polarimétricos para o nível de discriminação 1.	91
5.10	Classificação obtida pelo método de classificação K-Médias Wishart H/A/ $\bar{\alpha}$, constituído de 16 classes.	93
5.11	Estrutura dos níveis de discriminação obtida, após interpretação dos resultados e adoção da metodologia proposta, para às classificações geradas pelo método K-Médias Wishart H/A/ $\bar{\alpha}$. O acrônimo IND refere-se as classes indefinidas.	94
5.12	Legenda geral definida para diferentes níveis de discriminação para as classificações K-Médias Wishart H/A/ $\bar{\alpha}$	94
5.13	Classificações obtidas após interpretação dos resultados gerados pelo método K-Médias Wishart H/A/ $\bar{\alpha}$ para os níveis 6, 7 e 8.	95
5.14	Desempenho das classificações a partir de dados Univariados nos diferentes níveis de discriminação segundo o Coeficiente de Concordância <i>Kappa</i>	99
5.15	Desempenho das classificações a partir de dados Bivariados nos diferentes níveis de discriminação segundo o Coeficiente de Concordância <i>Kappa</i>	100
5.16	Desempenho das classificações obtidas pelos métodos K-Médias Wishart H/A/ $\bar{\alpha}$ e MaxVer/ICM, associado a dados Multivariados e Polarimétricos, segundo o Coeficiente de Concordância <i>Kappa</i>	101
5.17	Desempenho das classificações com melhores resultados segundo Índice de Concordância <i>Kappa</i>	102
5.18	Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados HV, Bivariados HH+HV e Polarimétricos para o Nível 5.	103
5.19	Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados HV, Bivariados HH+HV e Polarimétricos para o Nível 7.	104
5.20	Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados HV, Bivariados HH+HV e Polarimétricos para um cenário definido intuitivamente.	105
B.1	Gráfico <i>Boxplot</i> : Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Floresta Primária	117
B.2	Gráfico <i>Boxplot</i> : Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Floresta Degradada	117
B.3	Gráfico <i>Boxplot</i> : Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Regeneração Antiga	118
B.4	Gráfico <i>Boxplot</i> : Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Regeneração Intermediária	118

B.5 Gráfico <i>Boxplot</i> : Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Regeneração Nova	119
B.6 Gráfico <i>Boxplot</i> : Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Pasto Limpoooo	119
B.7 Gráfico <i>Boxplot</i> : Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Pasto Sujo	120
B.8 Gráfico <i>Boxplot</i> : Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Agricultura Tipo 1	120
B.9 Gráfico <i>Boxplot</i> : Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Agricultura Tipo 2	121
B.10 Gráfico <i>Boxplot</i> : Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Agricultura Tipo 3	121
B.11 Gráfico <i>Boxplot</i> : Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Agricultura Tipo 4	121
B.12 Histograma: Comparação entre as amostras de treinamento e validação da classe Floresta Primária segundo a radiometria da Amplitude das componentes HH, HV e VV	122
B.13 Histograma: Comparação entre as amostras de treinamento e validação da classe Floresta Degradada segundo a radiometria da Amplitude das componentes HH, HV e VV	122
B.14 Histograma: Comparação entre as amostras de treinamento e validação da classe Regeneração Antiga segundo a radiometria da Amplitude das componentes HH, HV e VV	122
B.15 Histograma: Comparação entre as amostras de treinamento e validação da classe Regeneração Intermediária segundo a radiometria da Amplitude das componentes HH, HV e VV	122
B.16 Histograma: Comparação entre as amostras de treinamento e validação da classe Regeneração Nova segundo a radiometria da Amplitude das componentes HH, HV e VV	123
B.17 Histograma: Comparação entre as amostras de treinamento e validação da classe Pasto Limpoooo segundo a radiometria da Amplitude das componentes HH, HV e VV	123
B.18 Histograma: Comparação entre as amostras de treinamento e validação da classe Pasto Sujo segundo a radiometria da Amplitude das componentes HH, HV e VV	123
B.19 Histograma: Comparação entre as amostras de treinamento e validação da classe Agricultura Tipo 1 segundo a radiometria da Amplitude das componentes HH, HV e VV	123
B.20 Histograma: Comparação entre as amostras de treinamento e validação da classe Agricultura Tipo 2 segundo a radiometria da Amplitude das componentes HH, HV e VV	124
B.21 Histograma: Comparação entre as amostras de treinamento e validação da classe Agricultura Tipo 3 segundo a radiometria da Amplitude das componentes HH, HV e VV	124

B.22 Histograma: Comparação entre as amostras de treinamento e validação da classe Agricultura Tipo 4 segundo a radiometria da Amplitude das componentes HH, HV e VV	124
C.1 Alvos homogêneos utilizados para estimação de \hat{n}	131
C.2 Semivariogramas dos alvos homogêneos da compoenente HH	131
C.3 Semivariogramas dos alvos homogêneos da compoenente HV	132
C.4 Semivariogramas dos alvos homogêneos da compoenente VV	133
C.5 Teste de aderência χ^2 e \hat{n} para as regiões homogenas de HH	133
C.6 Teste de aderência χ^2 e \hat{n} para as regiões homogenas de HV	134
C.7 Teste de aderência χ^2 e \hat{n} para as regiões homogenas de VV	134
F.1 Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados HH para os níveis de discriminação 1 a 4.	155
F.2 Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados HH para os níveis de discriminação 5 a 8.	156
F.3 Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados HV para os níveis de discriminação 1 a 4.	157
F.4 Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados HV para os níveis de discriminação 5 a 8.	158
F.5 Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados VV para os níveis de discriminação 1 a 4.	159
F.6 Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados VV para os níveis de discriminação 5 a 8.	160
F.7 Classificações obtidas pelo método MaxVer/ICM a partir de dados Bivariados HH+HV para os níveis de discriminação 1 a 4.	161
F.8 Classificações obtidas pelo método MaxVer/ICM a partir de dados Bivariados HH+HV para os níveis de discriminação 5 a 8.	162
F.9 Classificações obtidas pelo método MaxVer/ICM a partir de dados Bivariados HV+VV para os níveis de discriminação 1 a 4.	163
F.10 Classificações obtidas pelo método MaxVer/ICM a partir de dados Bivariados HV+VV para os níveis de discriminação 5 a 8.	164
F.11 Classificações obtidas pelo método MaxVer/ICM a partir de dados Bivariados HH+VV para os níveis de discriminação 1 a 4.	165
F.12 Classificações obtidas pelo método MaxVer/ICM a partir de dados Bivariados HH+VV para os níveis de discriminação 5 a 8.	166
F.13 Classificações obtidas pelo método MaxVer/ICM a partir de dados Multivariados para os níveis de discriminação 1 a 4.	167
F.14 Classificações obtidas pelo método MaxVer/ICM a partir de dados Multivariados para os níveis de discriminação 5 a 8.	168
F.15 Classificações obtidas pelo método MaxVer/ICM a partir de dados Polaramétricos para os níveis de discriminação 1 a 4.	169
F.16 Classificações obtidas pelo método MaxVer/ICM a partir de dados Polaramétricos para os níveis de discriminação 5 a 8.	170

LISTA DE TABELAS

	<u>Pág.</u>
2.1 Indicadores de mecanismos de espalhamento de onda.	36
2.2 Elementos da Matriz de Confusão.	45
2.3 Níveis do índice <i>Kappa</i> associados a diferentes termos qualitativos.	47
3.1 Calendário agrícola seguido pelos produtores da região da Calha do Rio Amazonas (região de Santarém).	50
3.2 Características da imagem em modo de operação PLR nível 1.1.	51
3.3 Principais características da imagem utilizada para estudo e condições do sensor durante o imageamento.	51
3.4 Postos de coleta de dados meteorológicos utilizados para observação da pluviosidade do mês de Abril de 2007.	52
4.1 Série de imagens LANDSAT-5 TM e LANDSAT-7 ETM+ empregadas para o estudo da região da Floresta Nacional de Tapajós-PA.	68
4.2 Classes considerados, número de regiões selecionadas e quantidades destinadas para treinamento e validação dos resultados.	70
4.3 Histórico das mudanças de cobertura da terra das amostras selecionadas.	71
5.1 Matriz de dissimilaridade obtida a partir da distância de Bhattacharyya.	86
5.2 Relação entre as classes obtidas pelo método de classificação K-Médias Wishart H/A/ $\bar{\alpha}$ e as classes rotuladas, após a interpretação dos resultados.	92
5.3 Desempenho e qualificação dos resultados obtidos a partir do método Max-Ver/ICM com emprego de dados Univariados HH.	106
5.4 Desempenho e qualificação dos resultados obtidos a partir do método Max-Ver/ICM com emprego de dados Univariados HV.	106
5.5 Desempenho e qualificação dos resultados obtidos a partir do método Max-Ver/ICM com emprego de dados Univariados VV.	106
5.6 Desempenho e qualificação dos resultados obtidos a partir do método Max-Ver/ICM com emprego de dados Bivariados HH+HV.	106
5.7 Desempenho e qualificação dos resultados obtidos a partir do método Max-Ver/ICM com emprego de dados Bivariados HH+VV.	107
5.8 Desempenho e qualificação dos resultados obtidos a partir do método Max-Ver/ICM com emprego de dados Bivariados HV+VV.	107
5.9 Desempenho e qualificação dos resultados obtidos a partir do método Max-Ver/ICM com emprego de dados Multivariados.	107
5.10 Desempenho e qualificação dos resultados obtidos a partir do método Max-Ver/ICM com emprego de dados Polarimétricos.	107
5.11 Desempenho e qualificação dos resultados obtidos com emprego do método K-Médias Wishart H/A/ $\bar{\alpha}$	108
B.1 Estatística descritiva das classes sobre as diferentes componentes.	125

B.2	Estatística descritiva das classes selecionadas segundo a diferença de fase entre as componentes HH e VV, para os conjuntos de treinamento e validação.	127
C.1	Distância para descorrelação dos <i>pixels</i> das áreas homogêneas	130
D.1	FDP associada a cada uma das classes utilizando dados Univariados HH	135
D.2	FDP associada a cada uma das classes utilizando dados Univariados HV	135
D.3	FDP associada a cada uma das classes utilizando dados Univariados VV	136
D.4	FDP associada a cada uma das classes utilizando dados Polarimétricos .	136
E.1	Classificação MaxVer/ICM utilizando dados Univariados HH em nível de discriminação 1 (11 classes)	137
E.2	Classificação MaxVer/ICM utilizando dados Univariados HH em nível de discriminação 2 (10 classes)	137
E.3	Classificação MaxVer/ICM utilizando dados Univariados HH em nível de discriminação 3 (9 classes)	137
E.4	Classificação MaxVer/ICM utilizando dados Univariados HH em nível de discriminação 4 (8 classes)	138
E.5	Classificação MaxVer/ICM utilizando dados Univariados HH em nível de discriminação 5 (7 classes)	138
E.6	Classificação MaxVer/ICM utilizando dados Univariados HH em nível de discriminação 6 (6 classes)	138
E.7	Classificação MaxVer/ICM utilizando dados Univariados HH em nível de discriminação 7 (5 classes)	138
E.8	Classificação MaxVer/ICM utilizando dados Univariados HH em nível de discriminação 8 (4 classes)	138
E.9	Classificação MaxVer/ICM utilizando dados Univariados HV em nível de discriminação 1 (11 classes)	139
E.10	Classificação MaxVer/ICM utilizando dados Univariados HV em nível de discriminação 2 (10 classes)	139
E.11	Classificação MaxVer/ICM utilizando dados Univariados HV em nível de discriminação 3 (9 classes)	139
E.12	Classificação MaxVer/ICM utilizando dados Univariados HV em nível de discriminação 4 (8 classes)	140
E.13	Classificação MaxVer/ICM utilizando dados Univariados HV em nível de discriminação 5 (7 classes)	140
E.14	Classificação MaxVer/ICM utilizando dados Univariados HV em nível de discriminação 6 (6 classes)	140
E.15	Classificação MaxVer/ICM utilizando dados Univariados HV em nível de discriminação 7 (5 classes)	140
E.16	Classificação MaxVer/ICM utilizando dados Univariados HV em nível de discriminação 8 (4 classes)	140
E.17	Classificação MaxVer/ICM utilizando dados Univariados VV em nível de discriminação 1 (11 classes)	141

E.18 Classificação MaxVer/ICM utilizando dados Univariados VV em nível de discriminação 2 (10 classes)	141
E.19 Classificação MaxVer/ICM utilizando dados Univariados VV em nível de discriminação 3 (9 classes)	141
E.20 Classificação MaxVer/ICM utilizando dados Univariados VV em nível de discriminação 4 (8 classes)	142
E.21 Classificação MaxVer/ICM utilizando dados Univariados VV em nível de discriminação 5 (7 classes)	142
E.22 Classificação MaxVer/ICM utilizando dados Univariados VV em nível de discriminação 6 (6 classes)	142
E.23 Classificação MaxVer/ICM utilizando dados Univariados VV em nível de discriminação 7 (5 classes)	142
E.24 Classificação MaxVer/ICM utilizando dados Univariados VV em nível de discriminação 8 (4 classes)	142
E.25 Classificação MaxVer/ICM utilizando dados Bivariados HH+HV em nível de discriminação 1 (11 classes)	143
E.26 Classificação MaxVer/ICM utilizando dados Bivariados HH+HV em nível de discriminação 2 (10 classes)	143
E.27 Classificação MaxVer/ICM utilizando dados Bivariados HH+HV em nível de discriminação 3 (9 classes)	143
E.28 Classificação MaxVer/ICM utilizando dados Bivariados HH+HV em nível de discriminação 4 (8 classes)	144
E.29 Classificação MaxVer/ICM utilizando dados Bivariados HH+HV em nível de discriminação 5 (7 classes)	144
E.30 Classificação MaxVer/ICM utilizando dados Bivariados HH+HV em nível de discriminação 6 (6 classes)	144
E.31 Classificação MaxVer/ICM utilizando dados Bivariados HH+HV em nível de discriminação 7 (5 classes)	144
E.32 Classificação MaxVer/ICM utilizando dados Bivariados HH+HV em nível de discriminação 8 (4 classes)	144
E.33 Classificação MaxVer/ICM utilizando dados Bivariados HH+VV em nível de discriminação 1 (11 classes)	145
E.34 Classificação MaxVer/ICM utilizando dados Bivariados HH+VV em nível de discriminação 2 (10 classes)	145
E.35 Classificação MaxVer/ICM utilizando dados Bivariados HH+VV em nível de discriminação 3 (9 classes)	145
E.36 Classificação MaxVer/ICM utilizando dados Bivariados HH+VV em nível de discriminação 4 (8 classes)	146
E.37 Classificação MaxVer/ICM utilizando dados Bivariados HH+VV em nível de discriminação 5 (7 classes)	146
E.38 Classificação MaxVer/ICM utilizando dados Bivariados HH+VV em nível de discriminação 6 (6 classes)	146
E.39 Classificação MaxVer/ICM utilizando dados Bivariados HH+VV em nível de discriminação 7 (5 classes)	146

E.40 Classificação MaxVer/ICM utilizando dados Bivariados HH+VV em nível de discriminação 8 (4 classes)	146
E.41 Classificação MaxVer/ICM utilizando dados Bivariados HV+VV em nível de discriminação 1 (11 classes)	147
E.42 Classificação MaxVer/ICM utilizando dados Bivariados HV+VV em nível de discriminação 2 (10 classes)	147
E.43 Classificação MaxVer/ICM utilizando dados Bivariados HV+VV em nível de discriminação 3 (9 classes)	147
E.44 Classificação MaxVer/ICM utilizando dados Bivariados HV+VV em nível de discriminação 4 (8 classes)	148
E.45 Classificação MaxVer/ICM utilizando dados Bivariados HV+VV em nível de discriminação 5 (7 classes)	148
E.46 Classificação MaxVer/ICM utilizando dados Bivariados HV+VV em nível de discriminação 6 (6 classes)	148
E.47 Classificação MaxVer/ICM utilizando dados Bivariados HV+VV em nível de discriminação 7 (5 classes)	148
E.48 Classificação MaxVer/ICM utilizando dados Bivariados HV+VV em nível de discriminação 8 (4 classes)	148
E.49 Classificação MaxVer/ICM utilizando dados Multivariados em nível de discriminação 1 (11 classes)	149
E.50 Classificação MaxVer/ICM utilizando dados Multivariados em nível de discriminação 2 (10 classes)	149
E.51 Classificação MaxVer/ICM utilizando dados Multivariados em nível de discriminação 3 (9 classes)	149
E.52 Classificação MaxVer/ICM utilizando dados Multivariados em nível de discriminação 4 (8 classes)	150
E.53 Classificação MaxVer/ICM utilizando dados Multivariados em nível de discriminação 5 (7 classes)	150
E.54 Classificação MaxVer/ICM utilizando dados Multivariados em nível de discriminação 6 (6 classes)	150
E.55 Classificação MaxVer/ICM utilizando dados Multivariados em nível de discriminação 7 (5 classes)	150
E.56 Classificação MaxVer/ICM utilizando dados Multivariados em nível de discriminação 8 (4 classes)	150
E.57 Classificação MaxVer/ICM utilizando dados Polarimétricos em nível de discriminação 1 (11 classes)	151
E.58 Classificação MaxVer/ICM utilizando dados Polarimétricos em nível de discriminação 2 (10 classes)	151
E.59 Classificação MaxVer/ICM utilizando dados Polarimétricos em nível de discriminação 3 (9 classes)	151
E.60 Classificação MaxVer/ICM utilizando dados Polarimétricos em nível de discriminação 4 (8 classes)	152
E.61 Classificação MaxVer/ICM utilizando dados Polarimétricos em nível de discriminação 5 (7 classes)	152

E.62 Classificação MaxVer/ICM utilizando dados Polarimétricos em nível de discriminação 6 (6 classes)	152
E.63 Classificação MaxVer/ICM utilizando dados Polarimétricos em nível de discriminação 7 (5 classes)	152
E.64 Classificação MaxVer/ICM utilizando dados Polarimétricos em nível de discriminação 8 (4 classes)	152
E.65 Classificação K-Médias Wishart $H/A/\bar{\alpha}$ em nível de discriminação 6 (6 classes)	153
E.66 Classificação K-Médias Wishart $H/A/\bar{\alpha}$ em nível de discriminação 7 (5 classes)	153
E.67 Classificação K-Médias Wishart $H/A/\bar{\alpha}$ em nível de discriminação 8 (4 classes)	153

LISTA DE ABREVIATURAS E SIGLAS

PRODES	– Programa de Cálculo do Desflorestamento da Amazônia
DETER	– Sistema de Detecção de Desmatamento em Tempo Real
ZEE	– Zoneamento Ecológico-Econômico
SAR	– <i>Synthetic Aperture Radar</i>
ENVISAT	– <i>Environmental Satellite</i>
ESA	– <i>European Space Agency</i>
ALOS	– <i>Advanced Land Observing Satellite</i>
JAXA	– <i>Japan Aerospace Exploration Agency</i>
PALSAR	– <i>Phased Array Type L-Band SAR</i>
INPE	– Instituto Nacional de Pesquisas Espaciais
FDP	– Função Densidade de Probabilidade
NEL	– Número Equivalente de <i>Looks</i>
LANDSAT	– <i>Land Remote Sensing Satellite</i>
TM	– <i>Thematic Mapper</i>
JERS-1	– <i>Japanese Earth Resources Satellite 1</i>
ADEOS	– <i>Advanced Earth Observation Satellite</i>
PRISM	– <i>Panchromatic Remote-Sensing Instrument for Stereo Mapping</i>
AVNIR-2	– <i>Advanced Visible and Near Infrared Radiometer Type 2</i>
FBS	– <i>Fine Beam Single Polarization</i>
FBD	– <i>Fine Beam Double Polarization</i>
DSN	– <i>Direct Downlink</i>
WB1	– <i>Scan SAR Short Burst</i>
WB2	– <i>Scan SAR Long Burst</i>
PLR	– <i>Polarimetry</i>
PCD	– <i>Posto de Coleta de Dados</i>
SRTM	– <i>Shutter RADAR Topographic Mission</i>
USGS	– <i>U. S. Geological Survey</i>
ETM+	– <i>Enhanced Thematic Mapper Plus</i>

1 INTRODUÇÃO

Amazônia, ou Amazônia Continental, é uma região da América do Sul definida pela bacia do rio Amazonas e pela Floresta Amazônica, uma floresta tropical que estende-se por parte do território brasileiro e dos países Colômbia, Equador, Peru, Bolívia, Venezuela, Suriname, Guiana e Guiana Francesa.

Para fins governamentais, a região brasileira englobada pela Amazônia é denominada Amazônia Legal, com cerca de 5 milhões de km^2 . Originalmente, a cobertura florestal desta região ocupava aproximadamente 4 milhões de km^2 , dos quais atualmente 82,3% encontram-se preservados ([ALVES, 2007](#); [INPE, 2009](#)).

A Amazônia tem sido foco da atenção nacional e mundial no que diz respeito à natureza e à sociedade. Na condição de natureza, ressalta-se a importância da maior floresta tropical do planeta enquanto acervo de biodiversidade e como base de prestação de serviços ambientais para a estabilização do clima global. Na condição de sociedade, alerta-se para os riscos de uma utilização predatória da base natural da região que pode ameaçar tudo o que se poderá obter, no presente e no futuro, de uma utilização mais qualificada de seus atributos naturais e locacionais ([BRASIL, 2006](#)).

Frente a estes fatos, o governo nacional tem investido na criação de projetos de monitoramento e desenvolvimento sustentável desta região, dentre os quais podem ser citados os projetos PRO-DES, Programa de Cálculo do Desflorestamento da Amazônia, DETER, Sistema de Detecção de Desmatamento em Tempo Real, e ZEE, Zoneamento Ecológico-Econômico.

Atividades de monitoramento, realizadas por conveniência por meio de Sensoriamento Remoto devido à dimensão das áreas, requerem a freqüente aquisição de informação, pois assim as alterações causadas pela intervenção antrópica são detectadas e podem ser analisadas de maneira mais rápida e precisa.

No entanto, características atmosféricas típicas de florestas tropicais, como a intensa cobertura de nuvens predominante durante o ano, dificultam a obtenção de informações a partir de Sensoriamento Remoto por sensores ópticos.

Uma alternativa a este impasse é o emprego de radares imageadores, para os quais fatores atmosféricos como nuvens, neblina e até mesmo a ausência de luz solar não são capazes de influenciar terminantemente no processo de imageamento, realizado por microondas. A utilização de radares imageadores para o monitoramento de florestas tropicais, como apresentados em [Freitas et al. \(2008\)](#), [Santos et al. \(2008\)](#), [Suga e Takeuchi \(2000\)](#) e [Hoekman e Quiñones \(2000\)](#) comprovam a capacidade deste tipo de sensor para tal aplicação.

Imerso no campo de pesquisa sobre radares imageadores, a Polarimetria investiga os processos de aquisição, processamento e análise do estado de polarização de um campo eletromagnético ([BOERNER, 2007](#)).

Os dados adquiridos por sensores SAR, *Synthetic Aperture Radar*, polarimétricos possuem mais informação sobre a interação entre o sinal transmitido e o alvo, quando comparados com os sensores SAR convencionais ([GUERRA, 2008](#)). O acréscimo de informação contido neste tipo de dado reflete numa maior capacidade de caracterização dos alvos, que por sua vez, proporciona maior capacidade de discriminação dos alvos a partir de técnicas de classificação de imagens, como apresentado em [Correia \(1999\)](#), [Frery et al. \(2007\)](#) e [Guerra \(2008\)](#).

O primeiro SAR orbital polarimétrico operacional foi o ENVISAT, *Environmental Satellite*, lançado em 2002 pela ESA, *European Space Agency* (Agência Espacial Européia). Em janeiro de 2005 foi lançado o ALOS, *Advanced Land Observing Satellite*, pela JAXA, *Japan Aerospace Exploration Agency* (Agência Espacial do Japão), direcionado a problemas como monitoramento ambiental e cartografia de precisão. Este satélite possui três sensores de coleta de dados, sendo um deles o PALSAR, *Phased Array Type L-Band SAR*.

Em comparação ao ENVISAT, o PALSAR torna-se mais adequado ao monitoramento de florestas tropicais devido o maior comprimento de onda em que opera. O lançamento de satélites munidos de radares polarimétricos que operam em banda L, como é o caso do sensor PALSAR, pode representar um novo horizonte à aplicação de dados SAR no monitoramento de florestas deste tipo.

Sendo assim, o objetivo deste trabalho consiste em avaliar o potencial das imagens do sensor ALOS PALSAR para utilização em tarefas de mapeamento de classes de cobertura da terra na região Amazônica a partir de métodos de classificação de imagens.

Inserido neste objetivo, será verificada a capacidade de discriminação de diferentes alvos e testados métodos de classificação de imagens capazes de tratar dados polarimétricos, complexos ou não.

Como resultado deste estudo, torna-se possível a definição de uma metodologia para classificação da cobertura da terra na Amazônia utilizando radares orbitais em banda L.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Polarimetria

A Polarimetria é uma recente área de pesquisas sobre sistemas SAR que abrange estudos relacionados à orientação da onda eletromagnética com relação a superfície terrestre, ao espalhamento desta e à informação de fase obtida entre as polarizações de transmissão e recepção ([ULABY; ELACHI, 1990](#)).

Ao contrário dos sistemas SAR convencionais, capazes de sintetizar apenas a amplitude do sinal refletido em uma dada configuração de polarização da antena, os sistemas SAR polarimétricos, fundamentados a partir de propriedades da Polarimetria, são capazes de sintetizar a amplitude e a fase dos sinais refletidos em diferentes configurações de polarização da antena.

Para a compreensão dos sistemas SAR polarimétricos, é fundamental o conhecimento de algumas propriedades a respeito das ondas eletromagnéticas.

2.1.1 Polarização de Ondas Eletromagnéticas

Para o estudos de problemas que envolvem absorção e espalhamento das ondas eletromagnéticas, as Equações de Maxwell fornecem conveniente ponto de partida, uma vez que estas definem leis fundamentais que governam todos os aspectos do eletromagnetismo ([ULABY; ELACHI, 1990](#)).

Baseada nas Equações de Maxwell, nas relações constitutivas e sob as considerações de um meio linear, homogêneo, isotrópico e livre de influências emitidas pela fonte geradora de ondas, é definida a seguinte equação para modelagem do movimento das ondas eletromagnéticas ([ALBERGA, 2004](#)):

$$\nabla^2 \vec{E}(\vec{r}, t) - \frac{1}{\nu^2} \cdot \frac{\partial^2}{\partial t^2} \cdot \vec{E}(\vec{r}, t) = 0 \quad (2.1)$$

onde $\nu = \frac{1}{\sqrt{\mu\epsilon}}$ é a velocidade de propagação da onda, dado que μ e ϵ são respectivamente as constantes dielétrica e a permeabilidade eletromagnética do meio, para uma dada posição \vec{r} e tempo t .

Em consideração à maioria dos sistemas SAR polarimétricos, compostos por duas antenas ortogonais polarizadas linearmente (Horizontal/Vertical), a decomposição do vetor \vec{E} é dada por:

$$\vec{E} = \vec{h}E_h + \vec{v}E_v = \vec{h}a_h e^{i\phi_h} + \vec{v}a_v e^{i\phi_v} \quad (2.2)$$

onde $\mathbf{i} = \sqrt{-1}$, (\vec{h}) e (\vec{v}) representam as polarizações ortogonais horizontal e vertical e a_h , a_v , ϕ_h e ϕ_v são respectivamente as amplitudes e fases das polarizações horizontal e vertical.

Em função da posição (\vec{r}) e do tempo (t), a parte real das componentes do vetor complexo \vec{E} é definida por:

$$E_i(\vec{r}, t) = \Re \left\{ a_i e^{i\phi_i} e^{i(\omega t - \vec{k}\vec{r})} \right\} = a_i \cos(\phi_i + \tau); \tau = \omega t - \vec{k}\vec{r} \quad (2.3)$$

onde ω , \vec{k} , a_i e ϕ_i representam respectivamente a frequência angular, o vetor de propagação da onda, a amplitude e a fase na polarização i .

Com a projeção da extremidade de \vec{E} no plano perpendicular a \vec{k} é gerado um lugar geométrico que define características sobre a polarização da onda. Na maioria dos casos, este lugar geométrico é uma elipse, definindo esta onda como “elipticamente polarizada”, como ilustra a Figura 2.1. Os

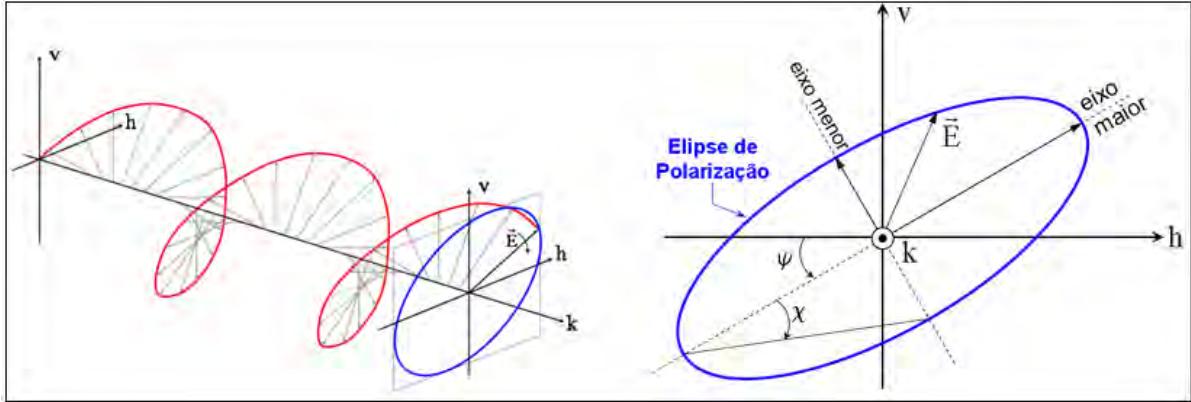


Figura 2.1 - Trajetória da extremidade do vetor campo elétrico e elipse de polarização.

Fonte: Adaptado de Hellmann (2001).

parâmetros inclinação (ψ) e elipticidade (χ) permitem descrever o estado de polarização da onda eletromagnética, dado que:

$$\tan(2\psi) = \tan\left(2\frac{a_v}{a_h}\right) \cos(\phi); \sin(2\chi) = \tan\left(2\frac{a_v}{a_h}\right) \sin(\phi); \phi = \phi_v - \phi_h \quad (2.4)$$

2.1.2 Espalhamento das Ondas Eletromagnéticas

Para o imageamento de uma área, o radar emite uma onda eletromagnética, a qual interage com os elementos que constituem os alvos na superfície terrestre, sofre alterações em suas características e retorna ao ponto de emissão por reflexão ou espalhamento. As alterações ocorridas estão diretamente relacionadas ao tipo do alvo imageado.

Uma forma de analisar as alterações ocorridas entre a onda transmitida e captada é relacioná-las através de uma transformação linear, dada pela seguinte equação:

$$\vec{J}^C = \frac{e^{ikR}}{R} [S] \vec{J}^E \quad (2.5)$$

sendo R a distância entre o alvo e o sensor, k o número de ondas compreendidas em R , os vetores

\vec{J}^C e \vec{J}^E são as ondas captadas e transmitidas na forma de Vetores de Jones¹, e $[S]$ é denominada Matriz de Espalhamento, definida por:

$$[S] = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix}; \quad S_{ij} = |S_{ij}|e^{i\varphi_{ij}}; \quad i, j \in \{H, V\} \quad (2.6)$$

onde $|S_{ij}|$ contém informação sobre a amplitude e φ_{ij} sobre a fase relativa em uma dada combinação entre as polarizações H e V .

De acordo com [Ulaby e Elachi \(1990\)](#), os elementos de $[S]$ podem ser função da orientação do espalhador em relação ao sistema de coordenadas e da freqüência do ângulo de incidência e de espalhamento.

O cálculo dos elementos dessa matriz consiste na combinação entre as polarizações que o sensor emprega para transmitir e captar as ondas eletromagnéticas.

Sob a consideração de um sensor cujo sistema de polarização é ortogonal linear (Horizontal e Vertical), ao transmitir uma onda polarizada horizontalmente, o sistema capta separadamente as ondas que retornam polarizadas horizontalmente e verticalmente, definindo respectivamente os elementos S_{HH} e S_{HV} . Ao transmitir uma onda polarizada verticalmente e captar separadamente as ondas que retornam nas diferentes polarizações, são definidos os elementos S_{VH} e S_{VV} . Cada um desses elementos obtidos são denominados “Componentes”.

Caso os alvos imageados apresentem comportamento determinístico, estes podem ser descritos a partir da matriz $[S]$. No entanto, para aplicações de Sensoriamento Remoto, não é válido supor o determinismo dos alvos, uma vez que a célula de resolução é bem maior que o comprimento de onda emitido pelo sensor e os alvos são compostos por muitos espalhadores determinísticos distribuídos espacialmente de forma aleatória ([ANDRADE et al., 2007](#)). Dentro da célula de resolução, o retorno é a soma vetorial da contribuição desses espalhadores elementares.

No entanto, para o tratamento do não determinismo dos espalhadores são empregadas as Matrizes de Covariância e Coerência ([CLOUDE; POTTIER, 1996](#)).

Para definição destas matrizes, são utilizados os vetores de Borgeaud, ou Lexicográfico, e Pauli, representações vetoriais de $[S]$, definidos respectivamente por:

$$\vec{k}_{4L} = [S_{HH} \quad S_{HV} \quad S_{VH} \quad S_{VV}]^T \quad (2.7)$$

$$\vec{k}_{4P} = 1/\sqrt{2} \left[S_{HH} + S_{VV} \quad S_{HH} - S_{VV} \quad S_{HV} + S_{VH} \quad \mathbf{i}(S_{VH} - S_{HV}) \right]^T \quad (2.8)$$

A Matriz de Covariância é obtida a partir do produto vetorial entre o Vetor de Borgeaud e seu complexo conjugado transposto. Da mesma forma, a Matriz de Coerência é obtida a partir do

¹Definido adequadamente no Anexo A.

produto vetorial entre o Vetor de Pauli e seu complexo conjugado transposto:

$$[C] = \vec{k}_{4L} \vec{k}_{4L}^\dagger \quad (2.9)$$

$$[T] = \vec{k}_{4P} \vec{k}_{4P}^\dagger \quad (2.10)$$

onde \vec{w}^\dagger representa o complexo conjugado transposto de um vetor complexo \vec{w} qualquer.

As matrizes definidas nas equações (2.9) e (2.10) são comumente denominadas $[C_4]$ e $[T_4]$, respectivamente. Quando é assumida a reciprocidade do meio ($S_{HV} = S_{VH}$), essas matrizes são definidas por $[C_3]$ e $[T_3]$, geradas a partir das seguintes representações vetoriais de $[S]$:

$$\vec{k}_{3L} = \begin{bmatrix} S_{HH} & S_{HV} & S_{VV} \end{bmatrix}^T \quad (2.11)$$

$$\vec{k}_{3P} = 1/\sqrt{2} \begin{bmatrix} S_{HH} + S_{VV} & S_{HH} - S_{VV} & 2S_{HV} \end{bmatrix}^T \quad (2.12)$$

2.1.3 Convenções Adotadas

- Imagens Polarimétricas: São imagens obtidas a partir de sensores polarimétricos. Estes sensores são capazes de emitir e captar uma onda eletromagnética em diferentes polarizações e sintetizar a informação de fase das ondas.
- Componente: É um conjunto de dados provenientes das Imagens Polarimétricas composto pela informação de amplitude e fase do sinal captado pelo sensor em uma determinada configuração de polarização de antenas. Desta forma, sob a consideração de um sistema linear de polarização de antenas (Horizontal/Vertical), as possíveis componentes em uma imagem polarimétrica são HH, HV, VH e VV. Sob a suposição de reciprocidade do meio, as componentes HV e VH serão consideradas iguais.
- Dados Univariados em Amplitude: É o conjunto de dados composto pela informação de amplitude de apenas uma componente. Por conveniência, tais conjuntos serão representados apenas por HH, HV e VV.
- Dados Bivariados em Intensidade: É o conjunto de dados composto pela combinação de informação de intensidade (informação de amplitude elevada ao quadrado) de duas componentes. Por conveniência, tais conjuntos serão representados por HH+HV, HH+VV e HV+VV.
- Dados Multivariados em Amplitude: É o conjunto de dados composto pelas amplitudes das componentes HH, HV e VV. Por conveniência, tal conjunto será representado por HH+HV+VV.
- Dados Polarimétricos: É o conjunto de dados composto pelas componentes HH, HV e VV. Este conjunto de dados será representado por PC (da sigla Polarimétrico Complexo).
- ALOS PALSAR: Se refere ao sensor PALSAR do satélite ALOS.

2.1.4 Teorema da Decomposição de Alvos em Autovalores e Autovetores

Baseado nas propriedades físicas dos dados polarimétricos complexos, os teoremas de Decomposição de Alvos tem o objetivo de expressar os mecanismos de espalhamento dos alvos como uma soma de diferentes mecanismos de espalhamento independentes. Mecanismos de espalhamento referem-se às características principais dos alvos, as quais provocam alterações típicas na onda emitida pelo radar.

Formulado por [Cloude e Pottier \(1996\)](#), o Teorema da Decomposição por Autovalores e Autovetores é capaz de representar mecanismos de espalhamento dos alvos a partir de informações extraídas dos autovalores e autovetores de $[T]$.

Sob a hipótese de reciprocidade do meio ($S_{HV} = S_{VH}$), a vetorização de $[S]$ na base de Pauli é definida por $\vec{k}_{3P} = 1/\sqrt{2}[S_{HH} + S_{VV} \ S_{HH} - S_{VV} \ 2S_{HV}]^T$, logo:

$$[T] = \langle \vec{k}_{3P} \vec{k}_{3P}^\dagger \rangle = \frac{1}{2} \begin{bmatrix} \langle |A|^2 \rangle & \langle AB^\dagger \rangle & \langle AC^\dagger \rangle \\ \langle A^\dagger B \rangle & \langle |B|^2 \rangle & \langle BC^\dagger \rangle \\ \langle A^\dagger C \rangle & \langle B^\dagger C \rangle & \langle |C|^2 \rangle \end{bmatrix}, \text{ onde } \begin{cases} A = S_{HH} + S_{VV} \\ B = S_{HH} - S_{VV} \\ C = 2S_{HV} \end{cases} \quad (2.13)$$

Por sua vez, a decomposição de $[T]$ por autovalores e autovetores é expressa por:

$$[T] = [U] \cdot [\Lambda] \cdot [U]^{-1} = [U] \cdot \begin{bmatrix} \lambda_1 & 0 & 0 \\ 0 & \lambda_2 & 0 \\ 0 & 0 & \lambda_3 \end{bmatrix} \cdot [U]^{-1}; \text{ onde } [U] = \begin{bmatrix} e_{11} & e_{12} & e_{13} \\ e_{21} & e_{22} & e_{23} \\ e_{31} & e_{32} & e_{33} \end{bmatrix} \quad (2.14)$$

sendo $[\Lambda]$ a matriz diagonal de autovalores, com $\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq 0$, e as colunas de $[U]$ os autovetores de $[T]$.

Assim, $[T]$ pode ser decomposta em três matrizes, ponderadas pelos respectivos autovalores:

$$[T] = \sum_{i=1}^3 \lambda_i (\vec{e}_i \vec{e}_i^\dagger) = \underbrace{\lambda_1 (\vec{e}_1 \vec{e}_1^\dagger)}_{T_{31}} + \underbrace{\lambda_2 (\vec{e}_2 \vec{e}_2^\dagger)}_{T_{32}} + \underbrace{\lambda_3 (\vec{e}_3 \vec{e}_3^\dagger)}_{T_{33}} \quad (2.15)$$

onde e_1 , e_2 e e_3 são seqüencialmente a primeira, segunda e terceira coluna de $[U]$.

A partir dessa decomposição são definidos dois indicadores relacionados ao processo de espalhamento da onda, a Entropia Polarimétrica (H) e a Anisotropia Polarimétrica (A):

$$H = \sum_{i=1}^3 -P_i \log_3 P_i, \text{ onde } P_i = \frac{\lambda_i}{\sum_{j=1}^3 \lambda_j} \quad (2.16)$$

$$A = \frac{\lambda_2 - \lambda_3}{\lambda_2 + \lambda_3} \quad (2.17)$$

Tabela 2.1 - Indicadores de mecanismos de espalhamento de onda.

H	A	Conclusão
Min.	Sem Informação	Um processo determinístico de espalhamento
Max.		Ruído aleatório
Baixa	Adicional	λ_1 e λ_2 próximos de zero
Média	Alta	O segundo mecanismo é importante
Média	Baixa	Há contribuições do terceiro mecanismo

A Entropia Polarimétrica indica o grau de aleatoriedade da distribuição dos mecanismos de espalhamento e a Anisotropia Polarimétrica a importância dos mecanismos secundários. A [Tabela 2.1](#) apresenta combinações de valores desses indicadores e conclusões superficiais a respeito dos mecanismos de espalhamento.

Quando os valores de Entropia são baixos ou próximos de -1 ou 1, a Anisotropia não fornece nenhuma informação adicional, no entanto, para valores médios de Entropia, a Anisotropia pode auxiliar na discriminação do alvo. Valores altos de Anisotropia indicam que apenas o segundo mecanismo de espalhamento é importante, por outro lado, valores baixos indicam que existe a contribuição do terceiro mecanismo de espalhamento ([HELLMANN, 2001](#)).

Para tarefas de classificação de imagem, não é suficiente a extração e separação dos diferentes mecanismos de espalhamento, mas sim a identificação desses mecanismos.

Quando múltiplos mecanismos de espalhamento estão presentes em $[T]$, é possível obter uma descrição geral a respeito do mecanismo de espalhamento através de α :

$$\bar{\alpha} = \sum_{i=1}^3 P_i \arccos(|e_{1i}|) \quad (2.18)$$

A partir dos indicadores H e $\bar{\alpha}$, [Cloude e Pottier \(1996\)](#) definem o “Plano $H/\bar{\alpha}$ ”, ilustrado na Figura 2.2. Este plano é composto por 9 zonas, onde cada uma, com exceção da Zona 3, é associada a um diferente mecanismo de espalhamento. São elas:

- Zona 1: Espalhamento múltiplo com alta Entropia. Está relacionada com camadas de vegetação com estruturas geométricas bem desenvolvidas;
- Zona 2: Espalhamento da vegetação com alta Entropia. Espalhamento volumétrico;
- Zona 3: Região inválida. SAR polarimétricos não são capazes de distinguir alvos dentro dos limites dessa partição;
- Zona 4: Espalhamento múltiplo com média Entropia. Mecanismos *Double-Bounce* em áreas urbanas estão relacionadas à esta zona;
- Zona 5: Espalhamento da vegetação com média Entropia. Relacionada a superfícies de

vegetação com média Entropia;

- Zona 6: Espalhamento de superfície com média Entropia. Propagação no dossel ou elevação da rugosidade da superfície;
- Zona 7: Espalhamento múltiplo com baixa Entropia. Relacionada aos espalhadores diédricos metálicos isolados;
- Zona 8: Espalhamento de dipolo com baixa Entropia. Áreas de vegetação com elementos de espalhamento anisotrópico altamente correlacionados;
- Zona 9: Espalhamento da superfície com baixa Entropia. Relacionada a corpos d'água e superfícies terrestres muito suaves.

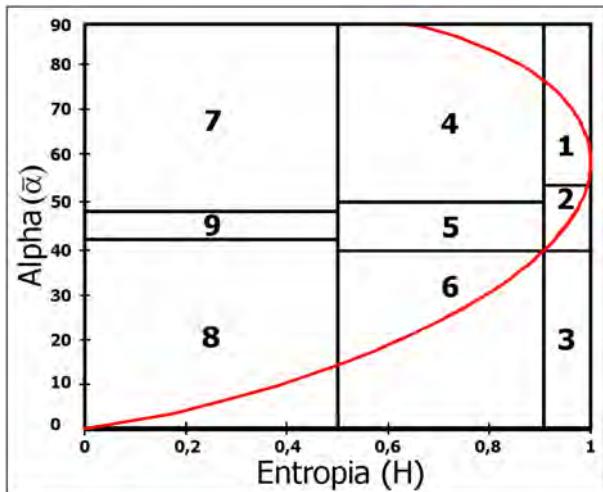


Figura 2.2 - O plano $H/\bar{\alpha}$.

2.2 Classificação de Imagens SAR Polarimétricas

Classificação de imagens é uma metodologia fundamentada em uma área de pesquisa denominada Reconhecimento de Padrões, cuja finalidade é identificar elementos de uma imagem.

Diante da importância e da necessidade de classificações cada vez mais precisas, diferentes métodos e variações de métodos já existentes são constantemente desenvolvidos. Neste contexto, métodos de classificação de imagens SAR não se tornam uma exceção.

Os métodos de classificação de imagens SAR podem ser divididos em quatro classes ([CORREIA, 2005](#)):

- Métodos de classificação supervisionada e não-supervisionada, sem modelagem estatística;

- Métodos de classificação supervisionada baseados em modelagem estatística;
- Métodos de classificação supervisionada e não-supervisionada baseados em mecanismos de espalhamento dos alvos;
- Métodos de classificação híbridos, supervisionada ou não, constituídos a partir da combinações entre as classes anteriores.

Neste trabalho serão empregados dois métodos, o método ICM, inicializado pelo método de classificação por Máxima Verossimilhança, e o método K-Médias Wishart H/A/ $\bar{\alpha}$, pertencentes respectivamente às classes de métodos de classificação supervisionada baseados em modelagem estatísticas e não-supervisionada híbrido.

2.2.1 Os Métodos de Classificação por Máxima Verossimilhança e ICM

Segundo [Richards \(1986\)](#), a classificação por Máxima Verossimilhança (MaxVer) é um dos métodos supervisionados mais comumente utilizado em imagens de Sensoriamento Remoto. As principais etapas desse método são:

- Seleção de amostras das classes envolvidas na tarefa de classificação, para o treinamento do classificador;
- Associação de uma distribuição de probabilidade para cada uma das classes;
- Classificação de cada *pixel* da imagem, considerando a informação radiométrica do alvo, segundo a classe com maior verossimilhança.

Partindo da teoria da classificação de Bayes, seja ω_i , $i = 1, \dots, M$, as classes definidas para partitionar um dado conjunto de dados em M partições. A pertinência de um dado elemento x a cada uma das classes é representada por meio de uma probabilidade condicional:

$$p(\omega_i | x), \quad i = 1, \dots, M \quad (2.19)$$

Assim:

$$x \in \omega_i \Rightarrow p(\omega_i | x) > p(\omega_j | x), \quad \forall j \neq i \quad (2.20)$$

A princípio, a probabilidade $p(\omega_i | x)$ é desconhecida, mas por outro lado, a informação contida nos dados de treinamento permite estimar uma distribuição de probabilidade para cada uma das classes, representada assim por $p(x | \omega_i)$.

De acordo com o teorema de Bayes, as probabilidades $p(\omega_i | x)$ e $p(x | \omega_i)$ estão relacionadas pela seguinte equação ([RICHARDS, 1986](#)):

$$p(\omega_i | x) = \frac{p(x | \omega_i)p(\omega_i)}{p(x)} \quad (2.21)$$

onde $p(\omega_i)$, denominada probabilidade *a priori*, representa a probabilidade pela qual a classe ω_i ocorre no conjunto de dados e $p(x)$ é a probabilidade de ocorrer o elemento x em qualquer uma

das classes.

Dessa maneira, a equação (2.20) pode ser reformulada para:

$$x \in \omega_i \Rightarrow p(x|\omega_i)p(\omega_i) > p(x|\omega_j)p(\omega_j), \forall j \neq i \quad (2.22)$$

O MaxVer é um método de classificação pontual, supervisionado, com baixo custo computacional de execução e implementação, no entanto, incapaz de incorporar a dependência espacial entre as classes.

O método ICM (*Iterated Conditional Modes*) é um meio de incorporar a dependência espacial gerada por classificadores pontuais, como por exemplo o método MaxVer. O ICM consiste em substituir a classe de cada elemento, de uma dada classificação, pela classe que maximiza a distribuição *a posteriori*, dada a influência das classes dos elementos vizinhos (CORREIA, 1999). Este método é descrito detalhadamente em Frery (1993).

Neste trabalho o método MaxVer será considerado uma etapa do método ICM. A partir desta consideração, o método resultante passa a ser denominado por “MaxVer/ICM”.

Um importante fator neste método são as distribuições de probabilidade utilizadas, pois a qualidade dos resultados obtidos estão diretamente relacionados com a capacidade com que elas descrevem o comportamento estatístico das diferentes classes.

Estudos realizados a respeito dos dados SAR propõem diferentes distribuições de probabilidade, com proposto em Freitas et al. (2005), Correia (1999), Frery et al. (2007), Frery et al. (1997), Lee et al. (1994a) e Lee et al. (1994b). Para determinados tipos de dado, como por exemplo, Amplitude, Intensidade e Polarimétrico Complexo, diferentes distribuições que modelam o comportamento dos alvos segundo o grau de homogeneidade foram desenvolvidas.

De acordo com Freitas et al. (2007), grande parte dos trabalhos desenvolvidos para modelagem de dados SAR consideraram o Modelo Multiplicativo ($Z = X \cdot Y$) mais adequado. Neste modelo, o valor de cada *pixel* é considerado uma ocorrência da variável aleatória (Z) resultante da multiplicação entre outras duas variáveis aleatórias, uma relacionada ao retroespalhamento do alvo (X) e outra relacionada ao ruído *speckle* (Y), que corrompe a cena. No entanto, segundo Vieira (1996), existem distribuições não provenientes do Modelo Multiplicativo, mas que eventualmente se adequam ao comportamento dos dados SAR, como por exemplo, as ditribuições Normal, Log-Normal, Gaussiana Multivariada e Weibull, denominadas, neste contexto, distribuições *ad-hoc*.

Nas próximas subseções são apresentadas diferentes funções de densidade de probabilidade empregadas pelo método MaxVer/ICM para modelagem de dados Polarimétricos Complexos, Univariados em Amplitude, Bivariados em Intensidade e Multivariados em Amplitude.

2.2.1.1 Funções Densidade de Probabilidade Derivadas do Modelo Multiplicativo

FDPs para Dados Polarimétricos

Como definido na Equação (2.6), cada célula de resolução em uma imagem polarimétrica pode ser representada por $[S]$. Sob consideração de reciprocidade do meio ($S_{HV} = S_{VH}$), a vetorização de $[S]$ a partir da base Bourgeaud fornece:

$$\vec{k}_{3L} = [S_{HH} \ S_{HV} \ S_{VV}] \quad (2.23)$$

Sendo:

$$Z = \langle \vec{k}_{3L} \vec{k}_{3L}^\dagger \rangle \quad (2.24)$$

onde $\langle \cdot \rangle$ representa o operador média espacial, as seguintes distribuições são associadas a Z segundo o grau de homogeneidade:

- Alvos Homogêneos: Distribuição de Wishart Complexa Multivariada ([SRIVASTAVA, 1963](#));

$$f(z; n, q) = \frac{n^{nq} |z|^{n-q} e^{-nTr([C_Z]^{-1} z)}}{M(n, q) |[C_z]|^n}; \ n, q > 0 \quad (2.25)$$

onde $[C_Z] = E(Z)$, q , n e $Tr(\cdot)$ representam respectivamente o número de componentes (de acordo com (2.23) $q = 3$), o número de equivalente de *looks* e o traço da matriz, $M(n, q) = \pi^{\frac{q(q-1)}{2}} \prod_{k=n-q-1}^n \Gamma(k)$, K_{a-qn} é a função de Bessel modificada de terceiro tipo e ordem $a - qn$ e $\Gamma(\cdot)$ é a função Gama de Euler. As funções mencionadas anteriormente são definidas no Anexo A.

- Alvos Heterogêneos: Distribuição K Complexa Multivariada *Multi-Look* ([LEE et al., 1994b](#));

$$f(z; a, n, q) = \frac{2|z|^{n-q} (na)^{\frac{a+qn}{2}} K_{a-qn} \left(2\sqrt{\left(naTr([C_Z]^{-1} z) \right)} \right)}{M(n, q) |[C_Z]|^n \Gamma(a) Tr([C_Z]^{-1} z)^{\frac{qn-a}{2}}}; \ a, n, q > 0 \quad (2.26)$$

cujo parâmetro a pode ser estimado por $\hat{a} = \frac{1}{3} \sum_{i=1}^3 \hat{a}_i$, sendo $\hat{a}_i = \frac{1}{\hat{m}_{i2} - \hat{m}_{i1}^2}$ e \hat{a}_1 , \hat{a}_2 e \hat{a}_3 estão relacionados respectivamente as componentes HH, HV e VV em Amplitude. \hat{m}_r é o momento amostral não centrado de ordem r , definido no Anexo A.

- Alvos Extremamente Heterogêneos: Distribuição G^0 Multivariada *Multi-Look* ([CORREIA, 1999](#)).

$$f(z; a, n, q) = \frac{n^{nq} |z|^{n-q} \Gamma(qn - a)}{-a^a \Gamma(-a) K(n, q) |[C_Z]|^n \left(nTr([C_Z]^{-1} z) - a \right)^{qn-a}}; \ -a, n, q > 0 \quad (2.27)$$

cujo parâmetro a é estimado por $\hat{a} = \frac{1}{3} \sum_{i=1}^3 \hat{a}_i$, onde:

$$\frac{\Gamma^2(-\hat{a}_i - \frac{1}{4}) \Gamma^2(n + \frac{1}{4})}{\Gamma(-\hat{a}_i - \frac{1}{2}) \Gamma(n + \frac{1}{2}) \Gamma(-\hat{a}_i) \Gamma(n)} - \frac{\hat{m}_{i1/2}^2}{\hat{m}_{i1}} = 0$$

sendo \hat{a}_1 , \hat{a}_2 e \hat{a}_3 as estimativas de a para as componentes HH, HV e VV em Amplitude, e \hat{m}_{ir} os estimadores dos momentos não centrados de ordem r para a componente i .

O número de *looks*, determinado durante o processo de aquisição e processamento dos dados, quando estimado sobre dados reais, raramente é um número inteiro. Isto se deve ao fato de que, entre outras razões, a média de intensidade é calculada sobre observações correlacionadas. Portanto, n é denominado número equivalente de *looks* ([FREITAS et al., 2007](#)).

FDPs para Dados Univariados em Amplitude

Como consequência das distribuições apresentadas pelas equações [2.25](#), [2.26](#) e [2.27](#), para dados univariados ($q = 1$), estas distribuições são reduzidas respectivamente as distribuições Γ , K Intensidade e G^0 Intensidade.

Com a transformação dessas distribuições para dados em Amplitude, são obtidas:

- Alvos Homogêneos: Distribuição Raiz da Gama ([VIEIRA, 1996](#));

$$f(z; n, b) = \frac{2b^n}{\Gamma(n)} z^{2n-1} e^{-bz^2}; \quad z, n, b > 0 \quad (2.28)$$

cujo estimador de b , obtido pelo método dos momentos, é dado por:

$$\hat{b} = \frac{n}{\hat{m}_2}$$

- Alvos Heterogêneos: Distibuição K Amplitude ([VIEIRA, 1996](#));

$$f(z; n, a, b) = \frac{4bnz}{b\Gamma(a)\Gamma(n)} \sqrt{\left(\frac{anz^2}{b}\right)^{a+n-2}} K_{a-n} \left(2z\sqrt{\frac{an}{b}}\right); \quad z, n, a, b > 0 \quad (2.29)$$

cujo estimador de a e b , obtidos pelo método dos momentos, são dados por:

$$\frac{\hat{m}_2}{\hat{a}n} \frac{\Gamma(\frac{1}{2} + \hat{a}) \Gamma(\frac{1}{2} + n)}{\Gamma(\hat{a}) \Gamma(n)} - \hat{m}_1 = 0 \quad \text{e} \quad \hat{b} = \hat{m}_2$$

- Alvos Extremamente Heterogêneos: Distribuição G^0 Amplitude ([VIEIRA, 1996](#)).

$$f(z; n, a, b) = \frac{2n^n \Gamma(n-a) z^{2n-1}}{b^a \Gamma(n) \Gamma(-a) (b + nz^2)^{n-a}}; \quad z, n, -a, b > 0 \quad (2.30)$$

cujo estimador de a e b , obtidos pelo método dos momentos, são dados por:

$$\frac{\Gamma^2(-\hat{a} - \frac{1}{4}) \Gamma^2(n + \frac{1}{4})}{\Gamma(-\hat{a} - \frac{1}{2}) \Gamma(n + \frac{1}{2}) \Gamma(-\hat{a}) \Gamma(n)} - \frac{\hat{m}_{1/2}^2}{\hat{m}_1} = 0$$

$$\hat{b} = n \left(\frac{\hat{m}_1 \Gamma(-\hat{a}) \Gamma(n)}{\Gamma(-\hat{a} - \frac{1}{2}) \Gamma(n + \frac{1}{2})} \right)^2$$

Em alguns casos, sob a hipótese do Modelo Multiplicativo, quando o número de *looks* é suficientemente grande, porém não o bastante para supor ausência de *speckle*, a distribuição Normal pode ser empregada na modelagem de regiões homogêneas (YANASSE et al., 1995).

Neste caso, para dados em Amplitude, são considerados que o *backscatter* e o *speckle* possuem distribuição Constante e Normal, respectivamente definidas por:

$$f(x; \sqrt{\beta}) = \sqrt{\beta} \quad \beta \in \mathbb{R}_+, \quad \forall x \in \mathbb{R} \quad (2.31)$$

$$f(y; \mu_y, \sigma_y^2) = \frac{1}{2\sqrt{\pi}\sigma_y} \exp - \frac{(y - \mu_y)^2}{2\sigma_y^2} \quad (2.32)$$

onde:

$$\mu_y = \frac{\Gamma(n+1/2)}{\Gamma(n)\sqrt{n}}$$

$$\sigma_y^2 = \frac{1}{2} \left(n - \left(\frac{\Gamma(n+1/2)}{\Gamma(n)} \right)^2 \right)$$

Dado que $Z = X \cdot Y$, obtém-se a Distribuição Normal Restrita:

$$f(z; \mu_z, \sigma_z^2) = \frac{1}{2\sqrt{\pi}\sigma_z} \exp - \frac{(z - \mu_z)^2}{2\sigma_z^2} \quad (2.33)$$

onde:

$$\mu_z = \sqrt{\frac{\beta}{n}} \left(\frac{\Gamma(n+1/2)}{\Gamma(n)} \right)$$

$$\sigma_z^2 = \frac{\beta}{n} \left(n - \left(\frac{\Gamma(n+1/2)}{\Gamma(n)} \right)^2 \right)$$

FDP para Dados Bivariados em Intensidade

De acordo com Lee et al. (1994b), sob a consideração de homogeneidade dos alvos, a partir de duas componentes de $[S]$, sejam elas S_1 e S_2 , são obtidas as imagens Z_1 e Z_2 em intensidade e n *looks*:

$$Z_1 = \frac{1}{n} \sum_{i=1}^n |S_1(i)| \quad Z_2 = \frac{1}{n} \sum_{i=1}^n |S_2(i)|$$

Para este par de imagens é dada a seguinte distribuição:

$$f(Z_1, Z_2) = \frac{n^{n+1} (Z_1 Z_2)^{\frac{n-1}{2}} e^{-\frac{n(Z_1/h_{11}+Z_2/h_{22})}{1-|\rho_C|^2}}}{(h_{11}h_{22})^{\frac{n+1}{n}} \Gamma(n) (1-|\rho_C|^2) |\rho_C|^{n-1}} I_{n-1} \left(\frac{2n|\rho_C|}{1-|\rho_C|^2} \sqrt{\frac{Z_1 Z_2}{h_{11}h_{22}}} \right) \quad (2.34)$$

onde $h_{11} = E(Z_1)$, $h_{22} = E(Z_2)$, $\rho = \frac{E(S_1 S_2^*)}{\sqrt{E(|S_1|^2)E(|S_2|^2)}} = |\rho_C| e^{i\epsilon}$, sendo $|\rho_C|$ a magnitude e ϵ a

fase do coeficiente de correlação complexo *Multi-Look*, e $I_{n-1}(\cdot)$ a função modificada de Bessel de ordem $n - 1$, definida no Apêndice A.

2.2.1.2 Funções Densidade de Probabilidade *Ad-Hoc*

FDPs para Dados Univariados em Amplitude

- Distribuição Normal ([VIEIRA, 1996](#));

$$f(z; \mu, \sigma^2) = \frac{1}{2\sqrt{\pi}\sigma} \exp - \frac{(z - \mu)^2}{2\sigma^2} \quad (2.35)$$

para o qual os parâmetros μ e σ^2 são estimados pelo método dos momentos por:

$$\hat{\mu} = \hat{m}_1 \quad \text{e} \quad \hat{\sigma}^2 = \hat{m}_2 - \hat{m}_1^2$$

- Distribuição Log-Normal ([VIEIRA, 1996](#));

$$f(z; \mu, \sigma) = \frac{1}{z\sigma\sqrt{2\pi}} \exp - \frac{1}{2} \left(\frac{\ln z - \mu}{\sigma} \right)^2 \quad (2.36)$$

para o qual os parâmetros μ e σ são estimados pelo método dos momentos por:

$$\hat{\mu} = \ln \left(\frac{\hat{m}_1^2}{\sqrt{\hat{m}_2}} \right) \quad \text{e} \quad \hat{\sigma}^2 = \ln \left(\frac{\hat{m}_2}{\hat{m}_1^2} \right)$$

- Distribuição Weibull ([VIEIRA, 1996](#));

$$f(z; a, b) = ab^a z^{a-1} e^{-(bz)^a} \quad (2.37)$$

onde os parâmetros a e b são estimados pelo método dos momentos com a resolução do seguinte sistema:

$$\begin{cases} \Gamma(2\hat{a}^{-1} + 1) - (\Gamma(\hat{a}^{-1} + 1))^2 \hat{m}_2 \hat{m}_1^{-2} = 0 \\ \hat{b} - \Gamma(\hat{a}^{-1} + 1) \hat{m}_1^{-1} = 0 \end{cases}$$

FDP para Dados Multivariados em Amplitude

Distribuição Gaussiana Multivariada ([RICHARDS, 1986](#));

$$f(z; \mu, \Phi) = \frac{1}{2\pi^{\frac{q}{2}} \|\Phi\|^{\frac{1}{2}}} e^{-\frac{1}{2}(Z-\mu)\Phi^{-1}(Z-\mu)} \quad (2.38)$$

onde $Z = (z_1, z_2, \dots, z_n)$, μ é o vetor de médias e $\Phi = E((Z - \mu)(Z - \mu)^T)$.

2.2.2 O Método de Classificação K-Médias Wishart $H/\bar{\alpha}$

Desenvolvido por [Lee et al. \(1999\)](#), o método K-Médias Wishart $H/\bar{\alpha}$ realiza o agrupamento dos *pixel* da imagem polarimétrica baseado na distribuição de Wishart, para Matriz de Covariância, e nos mecanismos de espalhamento indicados no Plano $H/\bar{\alpha}$ (Figura 2.2).

A inicialização deste método é dada pela classificação segundo as partições, ou zonas, do Plano H/α , como apresentado em [Cloude e Pottier \(1997\)](#).

Para cada uma das zonas é definido um centróide, isto é, um valor numérico empregado para representar determinado tipo de mecanismo, definido pela seguinte relação:

$$V_i = \frac{1}{N_i} \sum_{k=1}^{N_m} [T]_{k \in \omega_i} \quad (2.39)$$

onde V_i , N_i e $[T]_{k \in \omega_i}$ são o centróide, o número de elementos e o k -ésimo elemento referente à classe ω_i .

Em seguida, com base no método de agrupamento K-Médias, cuja métrica é obtida a partir da distribuição de Wishart, a classificação dos dados é realizada iterativamente.

Quando é suposta reciprocidade do meio, as matrizes $[C]$ e $[T]$, definidas em [2.9](#) e [2.10](#), são relacionadas a partir da seguinte transformação linear:

$$[T] = \begin{bmatrix} \frac{1}{\sqrt{2}} & 0 & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & 0 & -\frac{1}{\sqrt{2}} \\ 0 & 1 & 0 \end{bmatrix} \cdot [C] \cdot \begin{bmatrix} \frac{1}{\sqrt{2}} & 0 & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & 0 & -\frac{1}{\sqrt{2}} \\ 0 & 1 & 0 \end{bmatrix}^T \quad (2.40)$$

Isso permite afirmar que a Matriz de Coerência, assim como a Matriz de Covariância, possui distribuição de Wishart, dada por:

$$P([T]; V) = \frac{n^{nq} |[T]|^{n-q} e^{-nTr(V^{-1}[T])}}{\pi^{\frac{q(q-1)}{2}} \prod_{i=n-q+1}^L \Gamma(i) |V|^n} \quad (2.41)$$

onde $V = E([T])$, n representa o número equivalente de *looks* e q o número de componentes.

A partir desta distribuição, a distância entre uma dada amostras $[T]_\alpha$ e o conjunto ω_i é definida por:

$$d([T]_\alpha, V_i) = \ln |V_i| + Tr(V_i^{-1}[T]_\alpha) \quad (2.42)$$

E assim como no método de classificação por Máxima Verossimilhança, o elemento $[T]_\alpha$ será associado a classe ω_i se $d([T]_\alpha, V_i) < d([T]_\alpha, V_j) \quad \forall \omega_i \neq \omega_j$

Dessa forma, cada iteração deste processo consiste em associar cada amostra a uma determinada

classe cuja distância é mínima. Ao fim deste processo, o centróide de cada classe é atualizado pela a Equação 2.39. Este o processo é finalizado quando não há certo nível de modificações entre duas iterações ou após a realização de um número definido de iterações.

A partir desse método, Pottier e Lee (2000) ampliaram o número de classes obtidas pelo método K-Médias Wishart $H/\bar{\alpha}$ com a introdução da informação de Anisotropia, pois, ao fim da classificação gerada pelo método K-Médias Wishart $H/\bar{\alpha}$, cada uma das classes é subdividida segundo um limiar definido pela Anisotropia.

Assim, *pixels* que anteriormente eram associados a uma mesma classe, agora são divididos em duas sub-classes, onde, aqueles que apresentam Anisotropia maior que 0,5 serão discriminados daqueles com Anisotropia menor que 0,5.

As próximas etapas realizadas por este método são idênticas às descritas para o método K-Médias Wishart $H/\bar{\alpha}$. A Figura 2.3 apresenta um fluxograma referente ao método K-Médias Wishart $H/A/\bar{\alpha}$.

2.3 Análise de Exatidão dos Resultados

Segundo Congalton e Green (1999), independentemente dos métodos e dados utilizados, a acurácia dos resultados deve ser analisada, para que então seja possível julgar os confiáveis ou não.

A Matriz de Confusão, ou Matriz de Erros, é uma das formas mais eficientes de representar a exatidão de uma classificação, pois é capaz de descrever tanto os erros de inclusão como os de exclusão (CONGALTON; GREEN, 1999).

A Tabela 2.2 representa uma Matriz de Confusão genérica, onde, para uma dada classe ω_i , n_{ij} representa o número de amostras da classe i classificadas como sendo amostras da classe j , n_{i+} e n_{+i} representam respectivamente as proporções marginais com relação a coluna (referência) i e linha (classificação) i , e N o número total de amostras.

Tabela 2.2 - Elementos da Matriz de Confusão.

		Referência				
		ω_1	ω_2	\dots	ω_k	
C	ω_1	n_{11}	n_{12}	\dots	n_{1k}	n_{1+}
	ω_2	n_{21}	n_{22}	\dots	n_{2k}	n_{2+}
a	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
.	ω_k	n_{k1}	n_{k2}	\dots	n_{kk}	n_{k+}
		n_{+1}	n_{+2}	\dots	n_{+k}	N

No entanto, para a comparação de diferentes Matrizes de Confusão obtidas de diferentes resultados, são empregados medidas de concordância. Entre as medidas de concordância mais utilizadas está

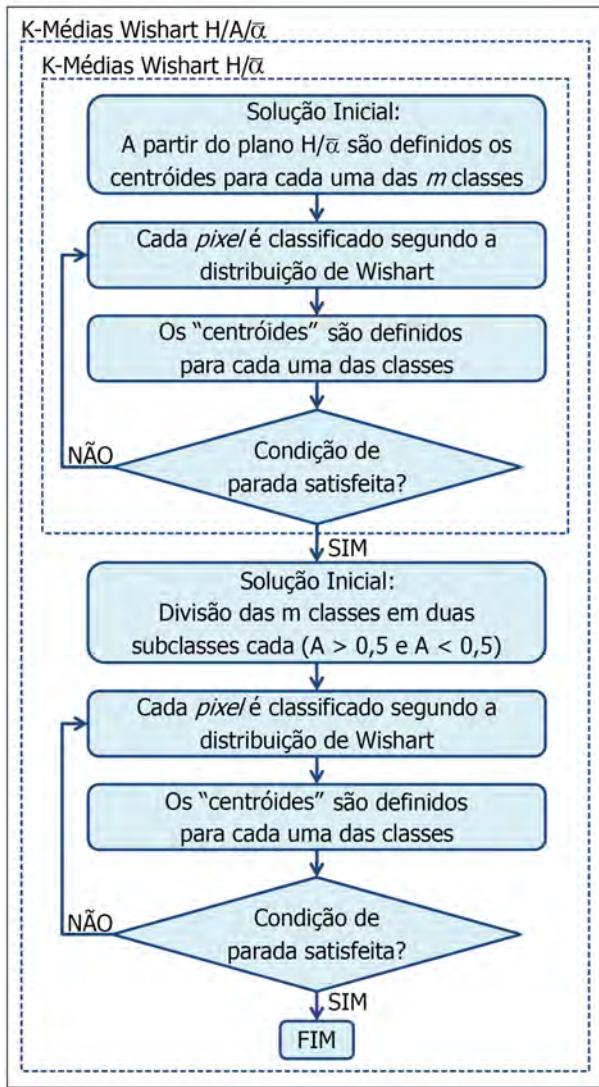


Figura 2.3 - Fluxograma do método de classificação K-Médias Wishart H/A/̄α.

o Coeficiente de Concordância *Kappa* ([GABOARDI, 2003](#)).

Calculado a partir dos elementos da Matriz de Confusão, o Coeficiente de Concordância *Kappa* e a variânciade este coeficiente são estimados por:

$$\hat{\kappa} = \frac{P_o - P_c}{1 - P_c} ; P_o = \frac{\sum_{i=1}^k n_{ii}}{N} ; P_c = \frac{\sum_{i=1}^k n_{i+}n_{+i}}{N^2} \quad (2.43)$$

$$\hat{\sigma}_{\hat{\kappa}}^2 = \frac{1}{N} \left(\frac{\phi_1(1-\phi_1)}{(1-\phi_1)^2} + \frac{2(1-\phi_1)(2\phi_1\phi_2 - \phi_3)}{(1-\phi_2)^3} + \frac{(1-\phi_1)^2(\phi_4 - 4\phi_2)^2}{(1-\phi_2)^4} \right) \quad (2.44)$$

onde:

$$\begin{aligned}\phi_1 &= \frac{1}{N} \sum_{i=1}^k n_{ii} \\ \phi_2 &= \frac{1}{N^2} \sum_{i=1}^k n_{i+} n_{+i} \\ \phi_3 &= \frac{1}{N^2} \sum_{i=1}^k n_{ii} (n_{i+} + n_{+i}) \\ \phi_4 &= \frac{1}{N^3} \sum_{i=1}^k \sum_{j=1}^k n_{ij} (n_{j+} + n_{+i})\end{aligned}$$

O Termo P_o é conhecido por Acurácia Global, e pode ser empregado no cálculo da porcentagem de amostras classificadas corretamente.

Embora este coeficiente seja comumente utilizado na análise da acurácia de classificações, não existem definições sobre níveis deste índice que permitam julgar determinado resultado. Uma forma de lidar com esta informação é relacionar diferentes intervalos deste índice a níveis nominais de qualificação, como o por exemplo, a relação definida por [Landis e Koch \(1977\)](#):

Tabela 2.3 - Níveis do índice *Kappa* associados a diferentes termos qualitativos.

Ind. Conc. <i>Kappa</i>	Qualificação
$\kappa \leq 0$	Péssimo
$0 < \kappa \leq 0,2$	Ruim
$0,2 < \kappa \leq 0,4$	Razoável
$0,4 < \kappa \leq 0,6$	Bom
$0,6 < \kappa \leq 0,8$	Muito Bom
$0,8 < \kappa \leq 1$	Excelente

3 MATERIAIS

3.1 Floresta Nacional de Tapajós – PA

A imagem selecionada para o estudo corresponde ao leste da Floresta Nacional de Tapajós, no Estado do Pará, aproximadamente entre as coordenadas S 2° 46' 32" e O 55° 16' 21", e S 3° 18' 24" e O 54° 47' 44".

De acordo com [ZEE BR-163 \(2008\)](#), esta região é caracterizada por clima quente e úmido. A média térmica máxima anual varia entre 31 a 33°C enquanto a média mínima varia entre 24 a 25°C.

O índice de precipitação pluviométrica anual varia entre 1800 a 2800 mm, com nítida divisão na distribuição das chuvas, sendo abundante no primeiro semestre e com baixa intensidade no restante do ano.

O relevo é composto em sua maioria por rochas sedimentares, sob forma de extensos chapadões e relevo de *cuesta*. Sua altimetria varia aproximadamente entre 50 a 200 m.

A vegetação é mais representativa pela formação de Florestas Ombrófila Densa, podendo apresentar cobertura florestal uniforme ou com presença de árvores emergentes. Em menor proporção podem ser encontradas Floresta Ombrófila Aberta, Floresta Estacional, Savana e Campinarana.

Em virtude das modificações antrópicas, principalmente nas duas últimas décadas, houve formação significativa de áreas de vegetação secundária, denominadas por “Capoeiras”. As áreas de desmate e formação de Capoeiras concentram-se principalmente ao longo da rodovia BR-163 e adjacências.

As regiões próximas à área de influência da rodovia BR-163 têm apresentado expansão da produção agrícola mecanizada. Com relação a microregião de Santarém, as atividades agrícolas são basicamente ligadas a produção de grãos, como o arroz, milho e soja. Outros grãos, como o feijão, são produzidos artesanalmente, principalmente pela agricultura familiar. A produção de soja tem aumentado nos últimos anos devido o crescimento na demanda do mercado exterior, principalmente com relação a China ([VENTURIERI, 2007](#)).

Segundo [Escada et al. \(2009\)](#), na região denominada Calha do Rio Amazonas, compreendida pelos municípios de Santarém, Belterra, Juriti e Prainha, existem dois principais esquemas de plantio, podendo ocorrer uma ou duas safras anuais, sempre com início no mês de Dezembro, devido o começo do período chuvoso. A Tabela 3.1 apresenta o calendário agrícola referente a estes dois esquemas de plantio.

A Figura 3.1 apresenta a partir de uma imagem do sensor LANDSAT-5 TM a área abrangida pela imagem PALSAR utilizada neste trabalho.

A escolha da região da Floresta Nacional de Tapajós como área de estudo se deve ao grande conhecimento acumulado devido a trabalhos realizados pelo INPE neste local, além da disponibilidade das imagens.

Tabela 3.1 - Calendário agrícola seguido pelos produtores da região da Calha do Rio Amazonas (região de Santarém).

Um plantio por ano			Dois plantios por ano
1ª Safra	Início	Meados de Dezembro	Meados de Dezembro
	Fim	Início de Abril	Entre fim de Março e início de Abril
Produtos		Arroz, Milho ou Soja	Arroz ou Milho
2ª Safra	Início		Meados de Abril
	Fim		Meados de Julho a Agosto
Produtos			Arroz, Milho, Soja, Sorgo ou Girassol

Fonte: Elaboração do autor a partir de dados de [Escada et al. \(2009\)](#).

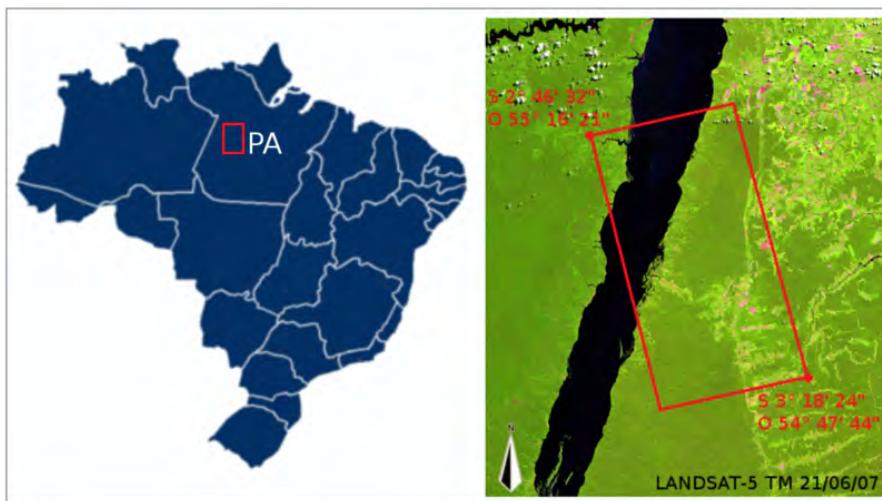


Figura 3.1 - Área abrangida pelo imagem PALSAR em modo de operação PLR 1.1 (área interna ao polígono de arestas vermelhas).

3.2 Imagens do Sensor ALOS PALSAR

O satélite ALOS foi desenvolvido para contribuir com pesquisas relacionadas ao monitoramento de desastres, análise de recursos naturais e de cobertura da terra, além de buscar a expansão de conhecimento sobre as tecnologias de observação da Terra adquiridas no desenvolvimento e utilização dos antecessores JERS-1 e ADEOS ([SHIMADA, 2007](#)).

Este satélite possui três sensores: *Panchromatic Remote-Sensing Instrument for Stereo Mapping* (PRISM), capaz de calcular com precisão a elevação da terra; *Advanced Visible and Near Infrared Radiometer Type 2* (AVNIR-2), com função de observar a cobertura da superfície terrestre; *Phased Array Type L-band Synthetic Aperture Radar* (PALSAR), um radar imageador.

O sensor PALSAR possui cinco modos de operação para coleta de dados: FBS (*Fine Beam Single Polarization*), FBD (*Fine Beam Double Polarization*), DSN (*Direct Downlink*), WB1/WB2 (*Scan*

SAR Short/Long Burst) e PLR (*Polarimetry*). Cada um dos modos de operação possuem características distintas, como por exemplo, a resolução nominal, o tamanho da cena imageada e a quantidade de componentes polarimétricas.

Os dados captados pelo modo de operação PLR são disponíveis em três níveis de processamento, 1.0, 1.1 e 1.5, onde cada um destes possuem diferentes graus de correção, tanto radiométrica, quanto geométrica. Os dados em nível 1.0 são os sinais captados pelo sensor sem processamento e reconstrução, no entanto, acompanhados pelos coeficientes de correção geométrica e radiométrica. O nível 1.1 apresenta os dados no formato complexo, isto é, contém informação sobre a radiometria e fase do sinal, em geometria *Slant Range* e processados com compressão nas direções de *Range* e Azimute. Já os dados em nível de processamento 1.5 possuem projeção cartográfica e processamento *Multi-Look*.

Neste estudo foi empregada uma imagem ALOS PALSAR em modo de operação PLR e nível de operação 1.1, cujas características padrão, de acordo com [Shimada \(2007\)](#) são:

Tabela 3.2 - Características da imagem em modo de operação PLR nível 1.1.

Processamento <i>Single Look</i>	Espaçamento entre <i>pixel</i> de 9,3 m em <i>Range</i>
Geometria <i>Slant Range</i>	Espaçamento entre <i>pixel</i> de 2,7 a 4,5 m em Azimute
Componentes HH, HV, VH e VV	Variação do ângulo de incidência de 9,7° a 29,1°
Resolução espacial de 10 m em <i>range</i>	Largura da faixa imageada igual a 34,8 km
Resolução espacial de 4,5 m em Azimute	
Informação de Amplitude e Fase	

A Tabela 3.3 apresenta as principais características da imagem utilizada neste estudo.

Tabela 3.3 - Principais características da imagem utilizada para estudo e condições do sensor durante o imageamento.

Data/Hora (GMT) de imageamento: 23/04/2007 02:21:56 ²
Data/Hora (Local) de imageamento: 22/04/2007 22:21:56 ²
Altitude do sensor (acima da superfície): 698,605 km
Passagem ascendente
Ângulo de incidência no centro da faixa: 24,233°
Resolução em direção de <i>Range</i> : 9,5 m
Resolução em direção de Azimute: 4,5 m
Espaçamento entre <i>pixel</i> em direção de <i>Range</i> : 9,369 m
Espaçamento entre <i>pixel</i> em direção de Azimute: 3,574 m
Largura aproximada da faixa imageada: 35,1 km
Comprimento aproximado da faixa imageada: 65,9 km

²Data e hora referente ao momento de imageamento no centro da faixa.

3.3 Precipitação Pluviométrica Ocorrida na Área de Estudo

Segundo [Ulaby et al. \(1996\)](#), determinados alvos, em condições iguais, porém, sob diferentes concentrações de umidade, podem produzir retroespalhamentos diferentes. Logo, este fator pode influenciar na capacidade de discriminação de determinados alvos. Em regiões de floresta tropical, a precipitação pluviométrica é uma das principais responsáveis pela concentração de unidade dos alvos.

Como meio de verificar a quantidade de precipitação ocorrida no período anterior à aquisição da imagem utilizada neste estudo, a Figura 3.2 informa a quantidade acumulada de precipitação pluviométrica em diferentes Posto de Coleta de Dados, PCD, localizados próximos da área de estudo. A Tabela 3.4 apresenta informações sobre os PCD analisados. Estes dados foram disponibilizados pelo CPTEC, Centro de Previsão de Tempo e Clima, mantido pelo INPE.

Tabela 3.4 - Postos de coleta de dados meteorológicos utilizados para observação da pluviosidade do mês de Abril de 2007.

Nome do PCD	ID	Município	Localização	Distância
Boca do Inferno	32207	Alenquer	O 54° 44' 00" / S 2° 25' 30"	140 km
Altamira	32227	Altamira	O 52° 26' 00" / S 3° 36' 00"	191 km

De acordo com [Moraes et al. \(2005\)](#), o trimestre compreendido entre fevereiro e abril é caracterizado como o mais chuvoso no Estado do Pará, concentrando 44% da precipitação anual. Além disso, é informado que as regiões próximas aos municípios de Alenquer e Altamira apresentam aproximadamente precipitação média anual de 1740 e 2550 mm.

Ao considerar que a aquisição da imagem de estudo foi realizada entre o trimestre mais chuvoso do ano, estima-se que no mês abril de 2007 os índices aproximados de precipitação acumulada nos municípios de Alenquer e Altamira são respectivamente de 252 e 375 mm.

A quantidade de precipitação acumulada até o dia 23 de Abril indica que a região de Alenquer ultrapassou a média de precipitação estimada, ao contrário de Altamira. Nos três dia antecedentes ao imageamento foram registrados índices acumulados entre 50 a 75 mm.

3.4 Software Utilizados

Para o desenvolvimento deste trabalho foram empregados os seguintes softwares:

- ENVI 4.5
- IDL 7.0
- PolSARpro 3.3
- *Polarimetric SAR Classifier 0.7*

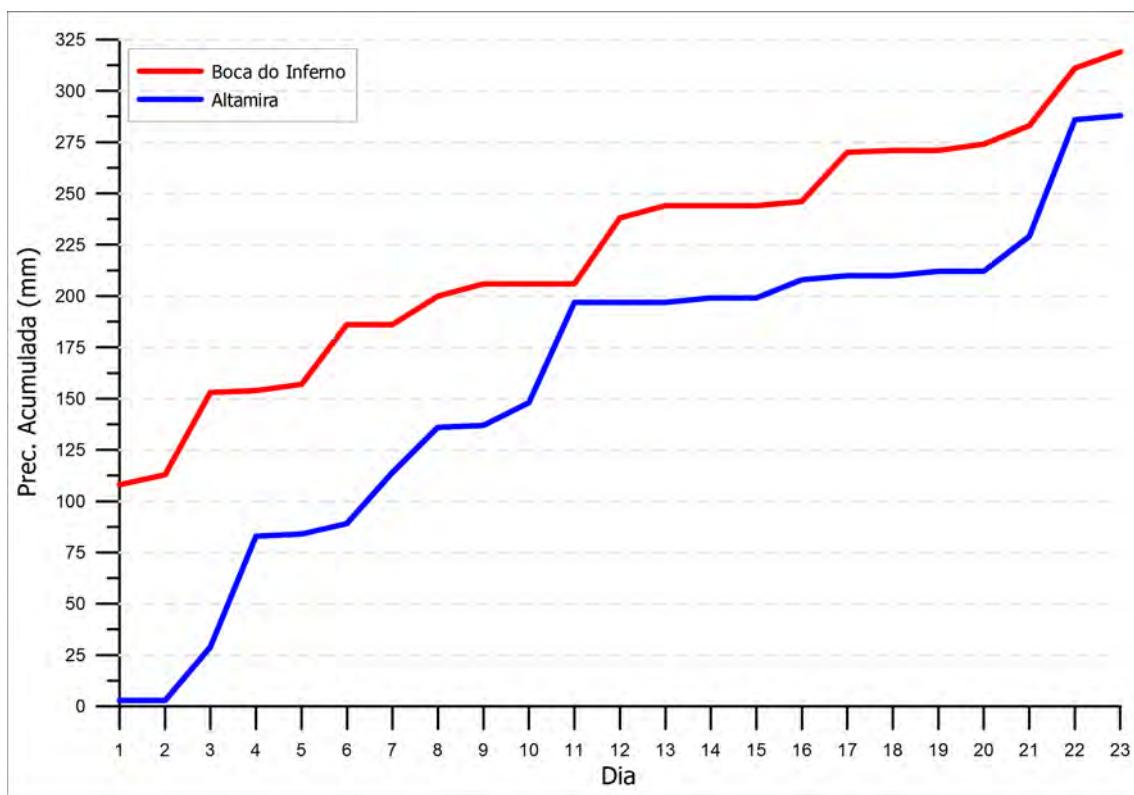


Figura 3.2 - Precipitação acumulada ocorrida no mês de Abril, medida pelos PCDs disponíveis mais próximos a área de estudo.

- SPRING 5.0
- Grapher 7.2

O ENVI 4.5 foi utilizado, como *software*, para a preparação das imagens para utilização nos *software* PolSARpro 3.3 e *Polarimetric SAR Classifier* 0.7, e como biblioteca, para implementação de rotinas auxiliares em IDL.

Os *software* PolSARpro 3.3 e *Polarimetric SAR Classifier* 0.7 foram empregados respectivamente para a realização das classificações segundo os métodos K-Médias Wishart H/A/ $\bar{\alpha}$ e MaxVer/ICM.

O SIG SPRING 5.0 foi empregado para análise de imagens LANDSAT-5 TM, utilizadas para a análise e estudo da região da Floresta Nacional de Tapajós.

O *software* Grapher 7.2 foi empregado, no geral, para construção de gráficos.

A linguagem de programação IDL 7.0 foi utilizada na construção de rotinas auxiliares.

4 METODOLOGIA

A Figura 4.1 apresenta um diagrama com a organização geral do trabalho, dividida em 6 etapas principais: pré-processamento dos dados, estudo sobre a região e seleção das classes de cobertura da terra, estruturação de níveis de discriminação da cena, classificação dos dados, validação dos resultados, análise dos resultados e conclusões.

As etapas de pré-processamento, estudo da região, definição dos níveis de discriminação e classificação são apresentadas em maiores detalhes nas figuras 4.2, 4.3, 4.4 e 4.5.

Na Seção 4.1 são descritas etapas de pré-processamento, composta pela verificação do estado de calibração da antena do sensor ALOS, correção geométrica da imagem de estudo, convertendo-a para geometria *Ground Range*, seleção de uma sub-área para realização do estudo e por fim, processamento *multi-look* da imagem.

Na Seção 4.2 são citados os dados que forneceram base para estudo da região e seleção de diferentes amostras de cobertura da terra.

Uma fundamentação a respeito de como foi realizada a estruturação dos níveis de discriminação da cena é descrita na Seção 4.3.

A Seção 4.4 expõe os procedimentos realizados para classificação da imagem ALOS PALSAR.

Por fim, na Seção 4.5 são mencionadas as rotinas auxiliares implementadas durante a realização deste trabalho.

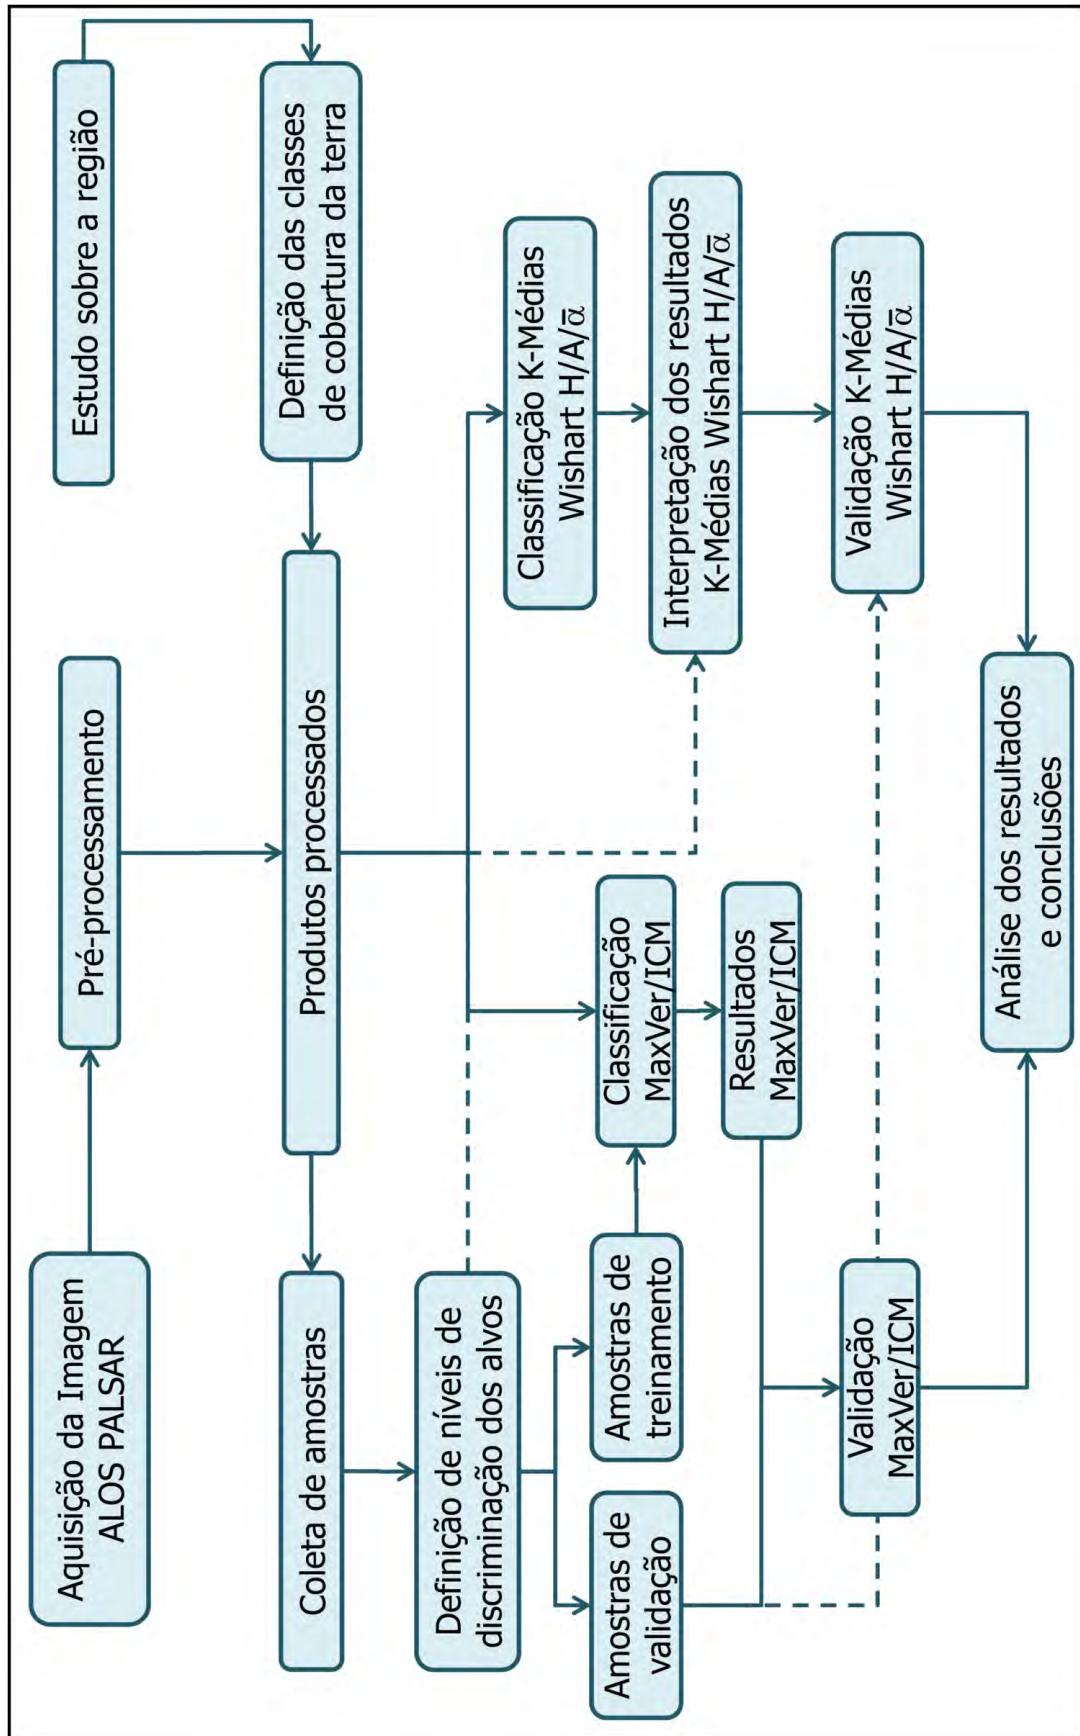


Figura 4.1 - Organização do desenvolvimento do trabalho.

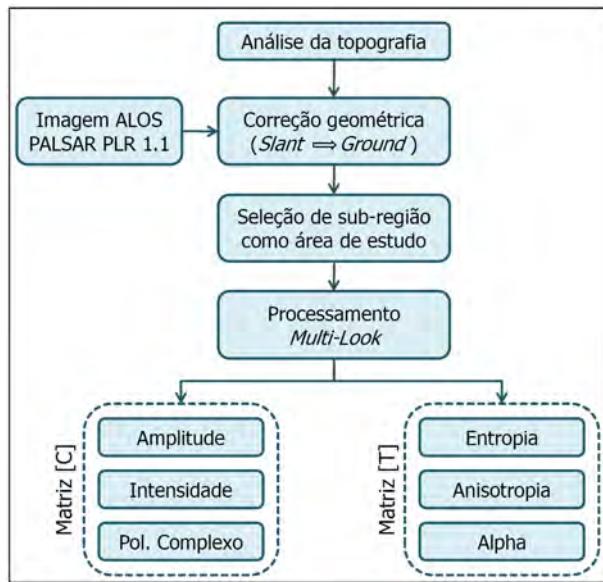


Figura 4.2 - Diagrama das etapas realizadas durante o pré-processamento dos dados.

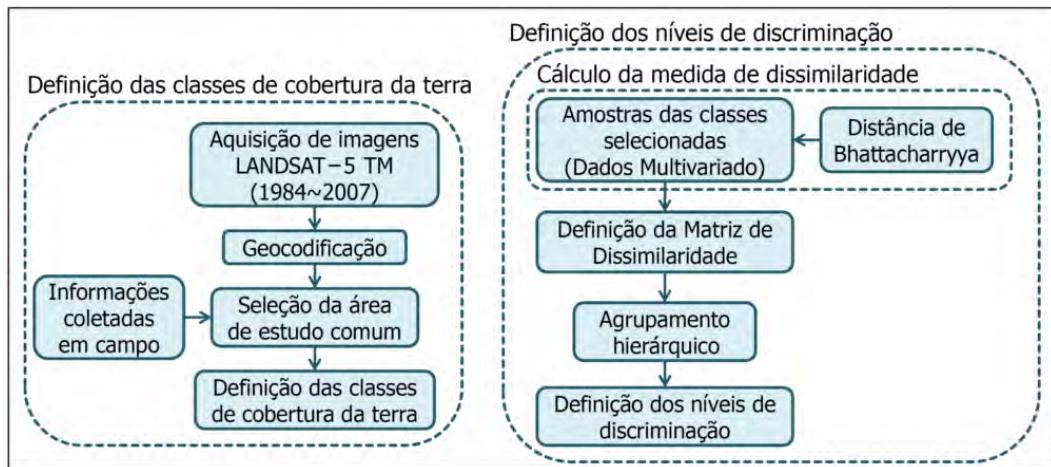


Figura 4.3 - Diagrama das etapas realizadas durante a seleção das classes de cobertura da terra e estruturação dos níveis de discriminação.

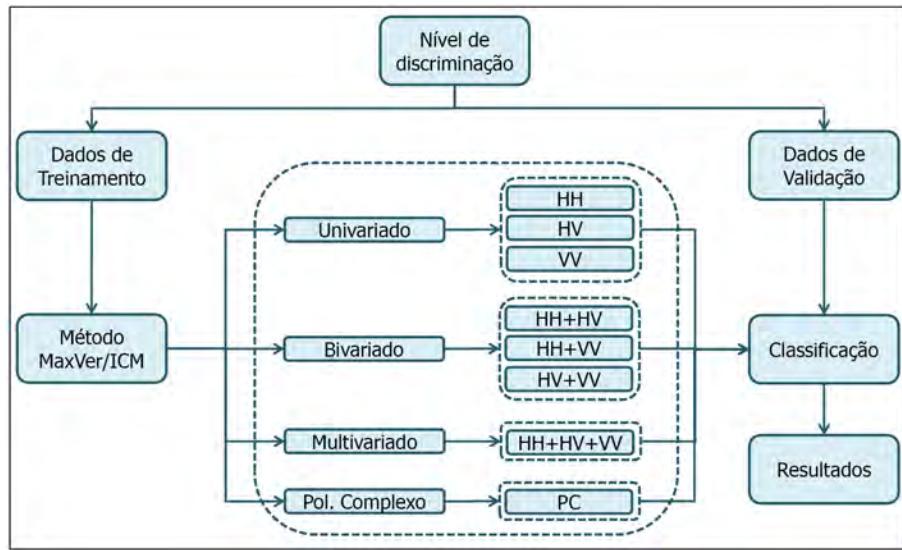


Figura 4.4 - Diagrama da etapa da classificação pelo método MaxVer/ICM.

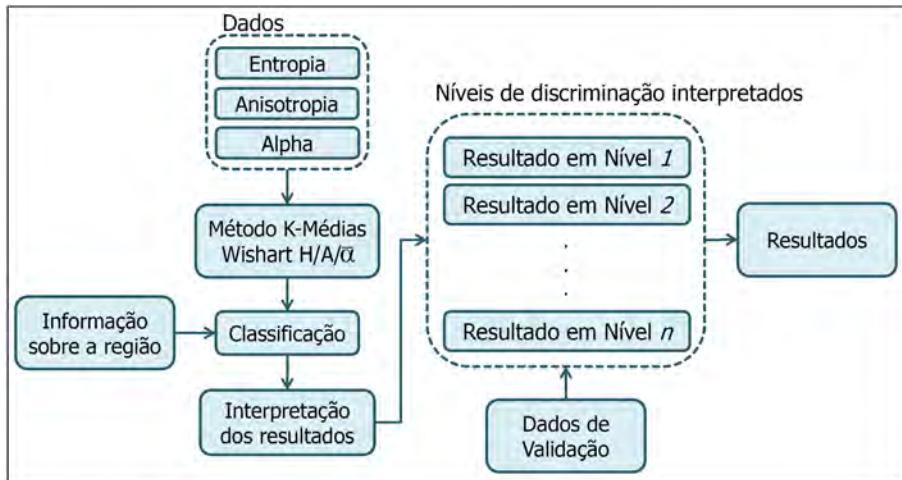


Figura 4.5 - Diagrama da etapa da classificação pelo método K-Médias Wishart H/A/̄α.

4.1 Pré-processamento dos Dados

O pré-processamento tem o objetivo de preparar os dados para as etapas seguintes. Neste processo são realizadas a calibração polarimétrica, a correção geométrica, a seleção da área de estudo e o processamento *Multi-Look*, como descritos nas subseções 4.1.1, 4.1.2, 4.1.3 e 4.1.4.

4.1.1 Calibração da Imagem

Ao contrário dos radares convencionais, imagens obtidas a partir de radares polarimétricos exigem como pré-processamento certas calibrações ([ULABY; ELACHI, 1990](#)).

Para a devida síntese do estado de polarização da onda, as informações de fase a amplitude captadas sob as diferentes configurações de polarização da antena devem ser adequadamente ponderadas.

O *Cross-Talk* é um tipo de interferência gerada por imperfeições existentes na antena do radar, as quais degradam o estado de polarização da onda para uma dada configuração de polarizações da antena.

Outro tipo de interferência é o *Channel Imbalance*, gerada a partir de desequilíbrios de fase e amplitude entre as componentes.

Um comportamento típico em imagens de radar é o “efeito do padrão da antena”, causado pela variação do ângulo incidência da onda entre o *Near Range* e o *Far Range*. O aumento do ângulo de incidência é proporcional ao aumento da distância entre o sensor e alvo imageado, provocando a distorção gradual na iluminação da imagem na direção de *Range*. O efeito do padrão de antena é mais intenso em imagens aerotransportadas do que em imagens orbitais, contudo, a correção deve ser efetuada em ambos os casos. Como um SAR orbital opera sobre uma faixa imageada com uma variação pequena entre os ângulos de incidência, a iluminação neste tipo de imagem é mais uniforme ([MORAIS, 1998](#)).

A JAXA periodicamente realiza a calibração do sensor PALSAR, o que torna suas imagens com baixo nível de interferências e efeitos indesejados.

De acordo com [Shimada \(2007\)](#), para cada modo de operação do sensor PALSAR são conduzidas análises detalhadas sobre as imagens, desenvolvidos e otimizados *softwares* para o processamento destas, além disso, estes modos de operação são continuamente monitorados para determinação de quais fatores do sensor têm mudado ao longo do tempo.

Em [Boerner et al. \(2007\)](#) e [Shimada et al. \(2007\)](#), são apresentadas análises sobre imagens do sensor PALSAR para os diferentes modos de operação, concluindo que as características deste sensor concordam com as especificações definidas em [Shimada \(2007\)](#).

Como forma de verificação, os gráficos da Figura 4.6 apresentam o comportamento do padrão da antena para as diferentes componentes da imagem PALSAR em amplitude utilizada neste estudo.

Para a construção desses gráficos foi selecionada uma faixa da imagem, em geometria *Slant Range*, que se estende do *Near Range* ao *Far Range*, contendo alvos que, teóricamente, possuem mesma resposta radiométrica, e então, foi calculada a média aritmética de cada coluna desta faixa.

É possível verificar que na extremidade direita da imagem existe uma diminuição atípica na resposta radiométrica dos alvos. Sendo assim, esta região não será considerada dentro da área de estudo.

Com relação ao *Cross-Talk* e *Channel Imbalance*, devido a inexistência de *Corner Reflectors* na imagem, não foi possível a aplicação de técnicas para confirmar o adequado estado de calibração polarimétrica da imagem.

Sendo assim, baseado nos resultados apresentados por Boerner et al. (2007) e Shimada et al. (2007), a imagem selecionada para este estudo foi considerada adequada.

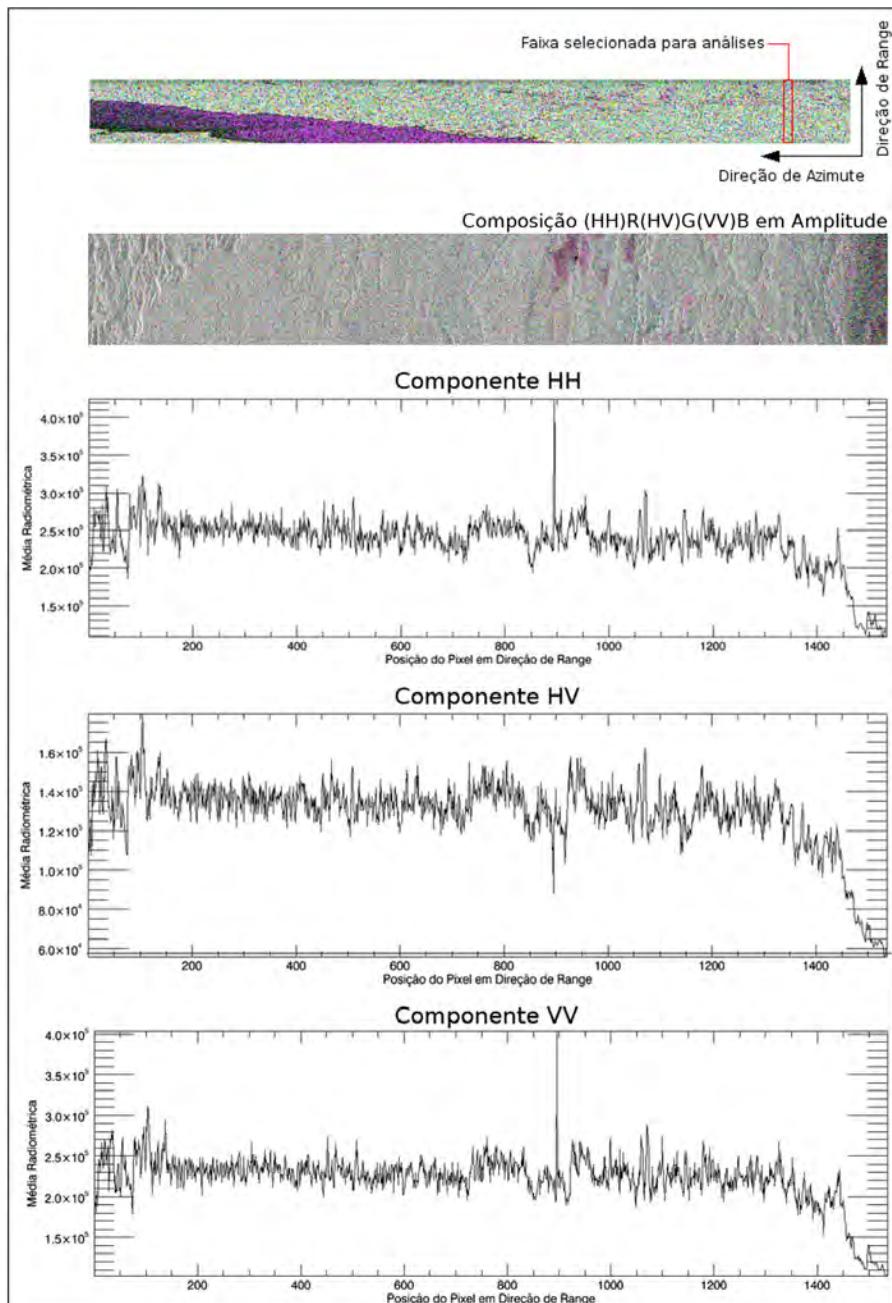


Figura 4.6 - Verificação do padrão da antena.

4.1.2 Correção Geométrica

Durante a etapa de aquisição, os dados sofrem distorções devidas a diferentes fatores, como por exemplo, as distorções causadas pelo movimento da plataforma, pelo modo de aquisição intrínseco dos radares e pela dimensão dos alvos.

As distorções resultantes do movimento da plataforma são agravantes para sensores aerotransportados, os quais sofrem influências de fatores como direção e velocidade do vento, e turbulências. Já para os sensores transportados por satélites, estes efeitos são praticamente imperceptíveis, uma vez que o caminho orbital realizado é relativamente suave e varia lentamente (WOODHOUSE, 2006).

Em função do modo como a aquisição de imagens é realizada pelo radar, surgem distorções características, como por exemplo, a perda de resolução gradativa em direção ao *Near Range*. Para correção deste tipo de distorção é necessário que os *pixels* sejam projetados sobre o plano que, teoricamente, contém a superfície imageada, e então re amostrados de forma regularmente espaçada.

É denominada por *Slant Range* a geometria da imagem captada pelo radar e *Ground Range* a geometria da imagem após o processo de correção mencionado. A Figura 4.7 ilustra a relação existente entre as geometrias apresentadas.

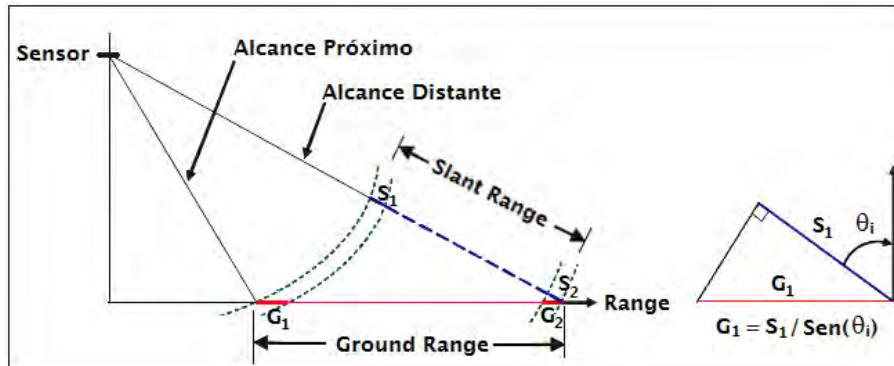


Figura 4.7 - Relação entre as geometrias *Slant Range* e *Ground Range*.

As distorções causadas pela topografia do terreno imageado são divididas em três tipos: *Foreshortening* (Encurtamento), *Layover* (Inversão) e *Shadowing* (Sombreamento).

Quando ocorre o imageamento de regiões com elevações, todas as feições que possuem vertentes voltadas para o sensor provocam o fenômeno denominado Encurtamento, causando o deslocamento dos alvos para a direção de *Near Range*. Esta distorção apresenta acentuação diretamente proporcional ao grau de elevação da feição.

As distorções do tipo Inversão, considerada um caso especial de Encurtamento, são ocasionadas quando os elementos da parte superior da feição refletem as ondas eletromagnéticas antes que os

elementos localizados nas parte inferior da feição, proporcionando a inversão do alvo. Este fenômeno é agravante em ocasiões quando o ângulo de incidência ou a distância entre o sensor e o alvo são pequenas.

As distorções conhecidas por Sombreamento ocorrem quando o sensor não é capaz de atingir determinadas partes do alvo, ocasionando regiões escuras na imagem, tornando-se mais intenso em alvos mais afastados do sensor ou quando os ângulos de incidência são menores. A Figura 4.8 exemplifica estes tipos de distorção.

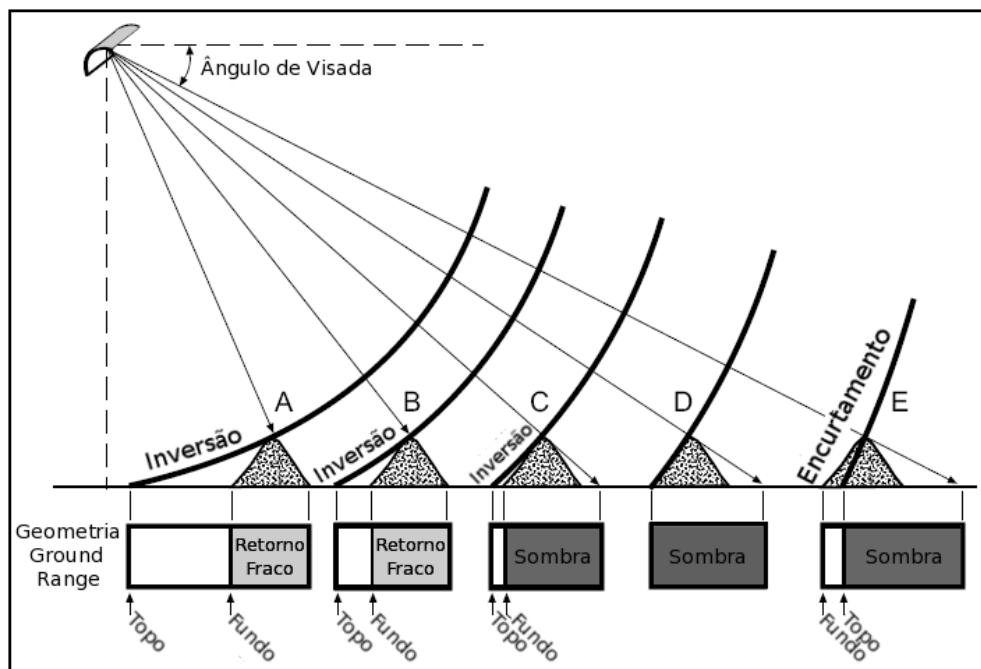


Figura 4.8 - Distorções causadas pela dimensão das feições: *Foreshortening*, *Layover* e *Shadowing*.

Fonte: Adaptado de [Lusch \(1999\)](#).

Uma limitação existente no processo de correção geométrica de uma imagem SAR é a superfície de referência utilizada para realizar a projeção para a geometria *Ground Range*. As distorções causadas pelas dimensões dos alvos são produzidos quando a superfície imageada é projetada como uma superfície plana. A maneira ideal para realizar esta projeção é considerar a informação topográfica do local, para que cada *pixel* seja projetado sobre sua verdadeira coordenada (latitudinal, longitudinal e altimétrica), cujo produto resultante é denominado “imagem geocodificada”. Para áreas predominantemente “achatadas”, os erros locais causados pela topografia são relativamente insignificantes, no entanto, com o aumento da variabilidade topográfica, estes erros tornam-se piores ([WOODHOUSE, 2006](#)).

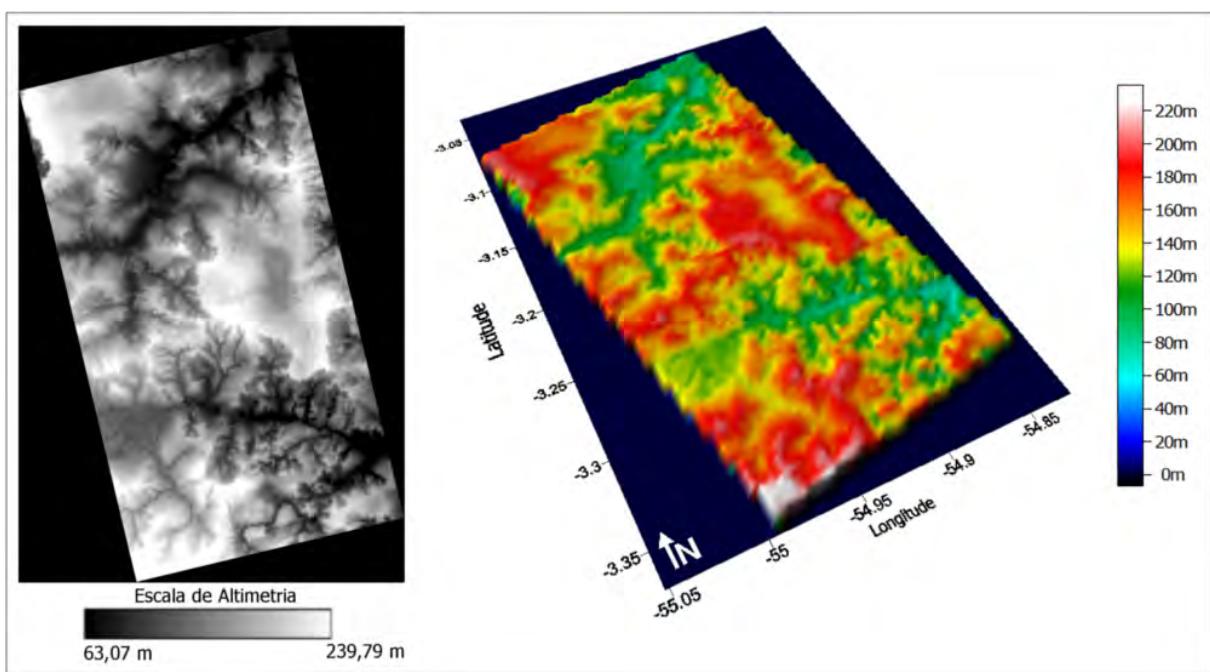


Figura 4.9 - Altimetria referente a área de estudo.

A análise de mapas altimétricos é uma maneira de averiguar as características topográficas da área de estudo. O projeto TOPODATA, desenvolvido pelo INPE, oferece informação topográfica em cobertura nacional, obtidos a partir de dados SRTM (*Shuttle RADAR Topographic Mission*), disponibilizado pela USGS, *U. S. Geological Survey*.

Na Figura 4.9 são exibidos mapas altimétricos da área de estudo, onde é possível observar que não existem diferenças abruptas de elevação, que por sua vez causariam distorções devido à dimensão das feições. Baseado nesta justificativa, não torna-se necessária a geocodificação dos dados como forma de correção geométrica. Assim, a conversão entre as geometrias *Slant Range* e *Ground Range* a partir de uma superfície plana para projeção dos dados é considerada suficiente.

Para a correção geométrica dos dados foi empregado o *software* ENVI 4.5, associado aos dados apresentados na Tabela 3.3, adotando como método de re-amostragem o interpolador de convolução cúbica. A imagem resultante deste processo possui espaçamento entre *pixel* de aproximadamente 3,6 m em ambas direções (Azimute e *Range*), indicando assim que houve uma super amostragem na direção de *Range*.

A justificativa da adoção do interpolador de convolução cubica e da super amostragem dos dados é que, baseado na teoria de processamento de sinais, um sinal super amostrado reconstruído por este interpolador possui maior fidelidade às características do sinal original.

Embora estes procedimentos tenham sido realizados, neste trabalho não será verificado os possíveis efeitos causados, principalmente sobre a informação de fase, com a realização das correções

geométricas e re-amostragem dos dados.

A Figura 4.10 ilustra a imagem de estudo na geometria *Slant Range* e após o processo de correção geométrica, em *Ground Range*.

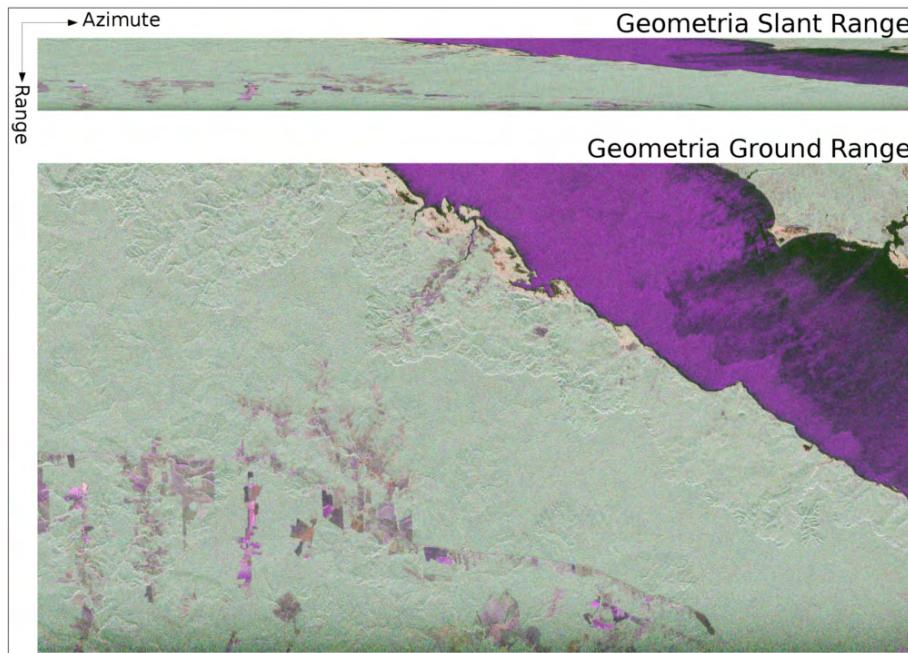


Figura 4.10 - Correção geométrica.

4.1.3 Seleção da Área de Estudo

Considerando que a imagem adotada neste trabalho estende-se além da região onde foram realizados os trabalhos de campo, que ela possui degradações na iluminação (descrito na Seção 4.1.1), grandes extensões da classe de cobertura “Floresta Primária” e “Rio”, torna-se conveniente a seleção uma sub-região para a realização do estudo.

A Figura 4.11 apresenta a imagem PALSAR em geometria *Ground Range* juntamente com a sub-região selecionada para o estudo. A imagem que comprehende toda a faixa imageada possui dimensão equivalente a 10343×18432 pixels, já a sub-região selecionada possui 4500×9000 pixels, dado espaçamento entre pixel de aproximadamente 3,6 m nas direções de Azimute e Range. Sendo assim, a área de estudo foi reduzida de uma região de aproximadamente $35\text{km} \times 65,9\text{km}$ para região de aproximadamente $18,7\text{km} \times 32,2\text{km}$.

4.1.4 Processamento *Multi-Look*

A correção geométrica realizada na Subseção 4.1.2 transformou a imagem original para geometria *Ground Range*.

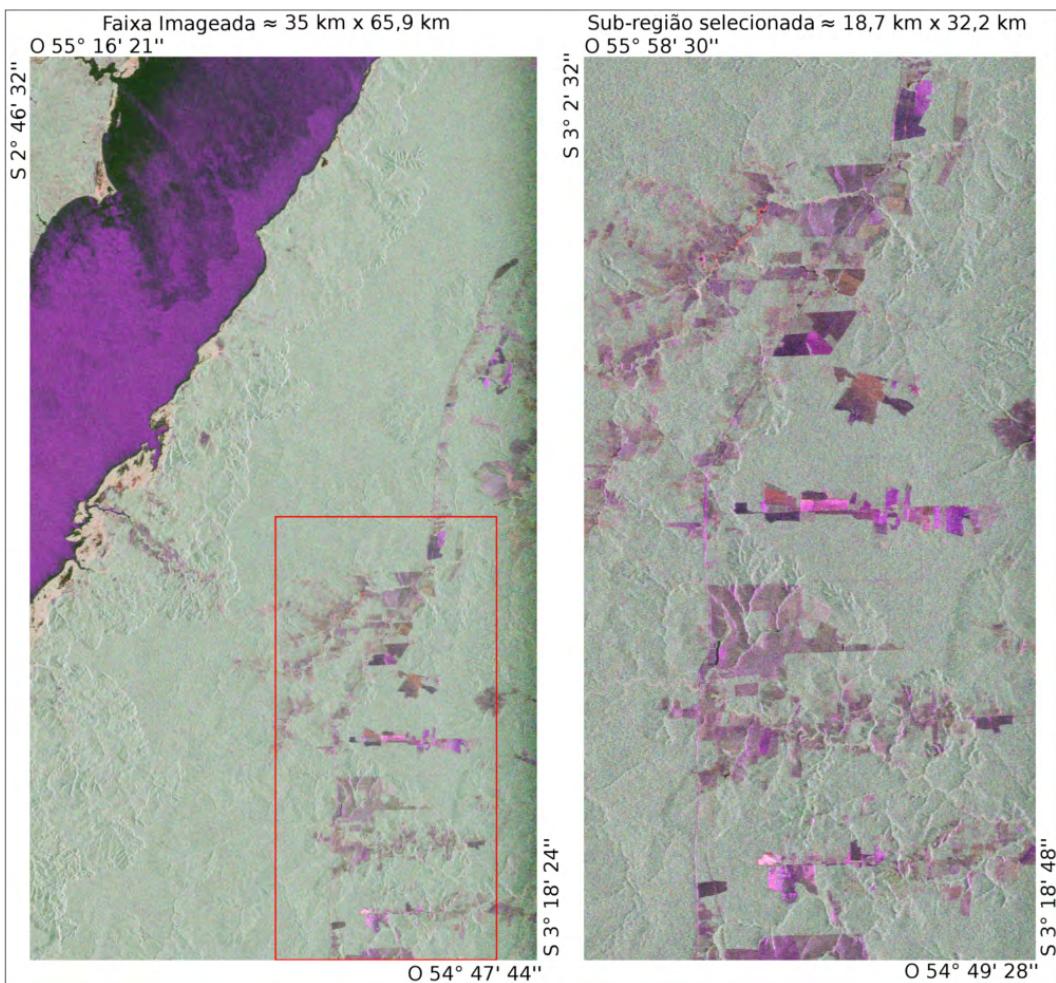


Figura 4.11 - Seleção de uma sub-área para estudo.

Como resultado deste procedimento, foi obtida uma imagem cujos elementos de resolução possuem geometria quadrada, com pequeno espaçamento entre *pixels* ($\approx 3,57\text{ m}$), no entanto, com resolução espacial aproximadamente três vezes menor³ ($\approx 9,5\text{ m}$), uma vez que este parâmetro permaneceu inalterado durante o processo de correção geométrica. A diferença entre estes parâmetros indica a existência de redundância de informação nos dados.

Este efeito poder ser reduzido a partir da aplicação de métodos de re-amostragem. Outro meio é o processamento *Multi-Look*, que, além de proporcionar resultados semelhantes a um método de re-amostragem, é capaz de reduzir a quantidade de ruído *speckle*.

Esta técnica, durante o processo de aquisição dos dados, consiste em dividir a abertura sintética do sistema SAR em visadas (*looks*). A imagem final é composta pela média das imagens de cada *look*,

³A diminuição da resolução espacial provoca a diminuição da precisão de separação de dois alvos.

geradas separadamente. Para uma imagem já adquirida e processada, o *Multi-Look* ainda pode ser realizado. Para isto, a cena deve ser particionada em “janelas” de mesma dimensão, e então, para cada uma destas, é calculada a média entre os elementos que a compõem.

Este processamento pode ser representado pela Equação 4.1, onde é definida a matriz [C] em processamento *Multi-Look*:

$$[C_{MLC}]_{ij} = E \left(\frac{\sum_{m=L_x}^{U_x} \sum_{n=L_y}^{U_y} (\vec{k}_{4L_{mn}} \vec{k}_{4L_{mn}}^\dagger)}{(N_x + 1) \cdot (N_y + 1)} \right) \quad (4.1)$$

onde $[C_{MLC}]_{ij}$ representa cada *pixels* da imagem resultante, $\vec{k}_{4L_{mn}}$ é a vetorização de $[S]$ na base de Pauli para um dado elemento (m, n) , N_x e N_y são respectivamente o número de *pixel* em direção de *Range* e Azimute que definem o processamento *Multi-Look*,

$L_x = i \cdot N_x + 1$, $L_y = j \cdot N_y + 1$, $U_x = L_x + (N_x - 1)$ e $U_y = L_y + (N_y - 1)$ para $i, j \in \mathbb{N}$.

O processamento *Multi-Look* aplicado sobre a imagem tornará o espaçamento entre *pixels* em direção de *Range* e Azimute aproximadamente igual a 10,7 m, a partir da média espacial obtida por uma janela de tamanho 3×3 *pixels*.

Outra característica resultante deste procedimento é que a área de estudo, cuja dimensão era 4500×9000 *pixels*, após o processamento possui dimensão de 1500×3000 *pixel*.

A Figura 4.12 apresenta a imagem da área de estudo após os procedimentos descritos.

4.2 Seleção das Classes de Cobertura da Terra

O conhecimento de diferentes tipos de uso e cobertura do solo distribuídos na área de estudo é essencial para o desenvolvimento do trabalho, uma vez que estes definem classes para quais os diferentes alvos da imagem serão discriminados.

Para definição destas classes foram utilizadas imagens dos sensor LANDSAT-5 TM do período compreendido entre os anos de 1984 a 2007, com exceção dos anos 1985, 1986, 1988, 1994 e 2002, devido a indisponibilidade de imagens ou pela intensa presença de nuvens sobre a área de estudo. A Tabela 4.1 indica as datas de imageamento das imagens utilizadas. Além destes dados, foram utilizadas informações obtidas em um trabalho de campo, realizado em outubro de 2005, nas informações sobre áreas empregadas para agropecuária, obtidas de Coelho (2009), e no calendário agrícola regional, definido na Tabela 3.1.

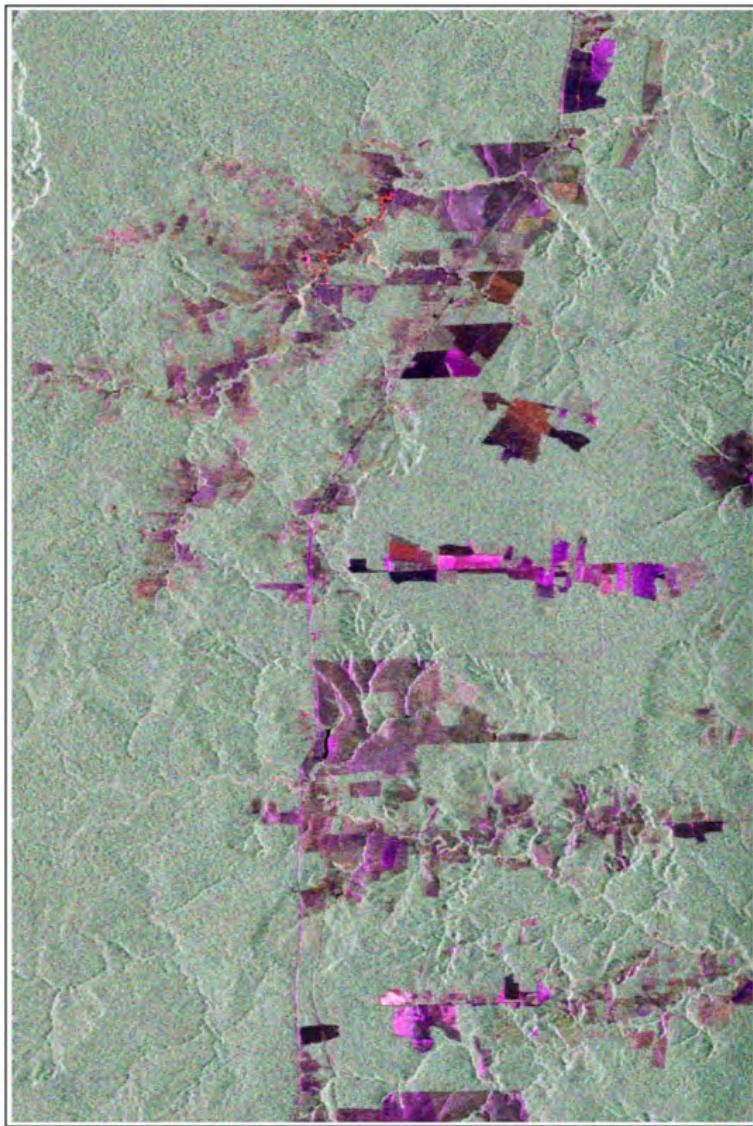


Figura 4.12 - Imagem resultante do processamento *Multi-Look*, composição (HH)R(HV)G(VV)B em Intensidade.

Tabela 4.1 - Série de imagens LANDSAT-5 TM e LANDSAT-7 ETM+ empregadas para o estudo da região da Floresta Nacional de Tapajós-PA.

Imagens LANDSAT-5 TM		
21/06/1984	04/06/1995	29/08/2003
30/06/1987	08/07/1996	31/08/2004
22/08/1989	27/07/1997	01/07/2005
09/08/1990	27/07/1998	21/08/2006
25/06/1991	02/08/1999	21/06/2007
29/07/1992	05/09/2000	
29/05/1993	30/07/2001 ⁴	

A análise conjunta destas informações permitiu definir as seguintes amostras⁵:

- Amostras 1, 16, 19: Floresta Primária. Em nenhum momento do período compreendido entre 1984 e 2007 foi observada a alteração da cobertura do solo nestas áreas.
- Amostras 2 e 14: Regeneração Antiga (mais que 23 anos em regeneração): O último desmatamento ocorrido nestas áreas ocorreu antes de 1984. Até o ano de 2007 estas áreas continuaram em processo de regeneração.
- Amostras 20: Regeneração Intermediária (entre 10 e 23 anos em regeneração): No ano de 1987 esta área já se encontrava em processo de regeneração, quando novamente sofreu desmatamento. Após esta data até 2007 a área permaneceu em estado de regeneração.
- Amostras 11: Regeneração Nova (menos de 10 anos em regeneração): Entre o segundo semestre de 2004 e o primeiro semestre de 2005 ocorreu a remoção de toda a cobertura vegetal desta área. Nos anos seguintes esta área permaneceu em estado de regeneração. Anteriormente, estas foram áreas de Floresta Primária.
- Amostras 8 e 9: Floresta Degradada. No ano de 2005 esta área sofreu degradação, aparentemente, com características de desmatamento seletivo. Anteriormente, esta era uma área de Floresta Primária.
- Amostras 3 e 5, e 4: Pasto Sujo e Pasto Limpo, respectivamente. Estas amostras pertencem a um área de desmatamento que se expandiu ao longo dos anos devido a extração de recursos ou para realização de atividades econômicas. No primeiro semestre de 2007 estas áreas foram associadas a pastagem. No entanto há um diferença entre estes dois conjuntos de amostras. As amostras 3 e 5 são caracterizadas como áreas de Pasto Sujo, devido a maior presença de vegetação na superfície, ao contrário das amostras 4, caracterizadas como áreas de Pasto Limpo, devido a menor concentração de vegetação na superfície. Estas conclusões foram baseadas na análise visual de uma imagem LANDSAT-5

⁴Imagen LANDSAT-7 ETM+.

⁵Os conjuntos de amostras foram organizados e enumerados considerando a ordem “cima-baixo/esquerda-direita” de acordo com sua disposição espacial na área de estudo, como ilustra a Figura 4.11.

TM com data de imageamento (21/06/07) próxima a data de imageamento da imagem PALSAR.

- Amostras 15 e 17: Pasto Sujo. Entre o segundo semestre de 1987 e o primeiro semestre de 1989 esta área, que inicialmente era uma área de Floresta Primária, sofreu um processo de desmatamento. No primeiro semestre de 2007 o uso desta área foi associada a pastagem. Devido a maior presença de vegetação na superfície, estas amostras são definidas como áreas de Pasto Sujo.
- Amostras 18: Pasto Limpo. Entre o segundo semestre de 1987 e o primeiro semestre de 1989 esta área, inicialmente Floresta Primária, sofreu desmatamento para então a realização de atividades econômicas. No primeiro semestre de 2007 o uso desta área foi associada a pastagem. Devido a menor presença de vegetação na superfície, estas amostras são definidas como áreas de Pasto Limpo.
- Amostras 10 e 7: Agricultura Tipo 1 e Tipo 2, respectivamente. Entre os anos de 2001 e 2003 estas áreas foram desmatadas com finalidade de realização de atividades agrícolas. A diferença entre estas duas classes de agricultura pode ser relacionada a diferentes fatores, com por exemplo, diferentes estágios de crescimento ou diferentes tipos de cultura, uma vez que, como definido pelo calendário agrícola usualmente adotado pelos produtores regionais (Tabela 3.1), o mês de aquisição é um período de transição entre colheitas e plantios.
- Amostras 12: Agricultura Tipo 3: Inicialmente uma área de Floresta Primária, entre o segundo semestre de 2003 e o primeiro semestre de 2004, então, sofreram desmatamento para realização de atividades agrícolas.
- Amostras 6 e 13: Agricultura Tipo 4. Estas áreas sofreram os mesmos processos descritos para as amostras 7 e 12, respectivamente, no entanto, devido aos ciclos agrícolas realizados nestas áreas na data da aquisição da imagem (23/04/07), aparentemente ambas áreas não possuíam cobertura vegetal em função de colheitas recém realizadas ou preparação do solo para plantio. Áreas como estas são comumente denominadas como Solo Exposto.

A Tabela 4.2 apresenta um levantamento a respeito das amostras consideradas, juntamente com as quantidades destinadas para o treinamento do classificador MaxVer/ICM e validação dos resultados. A seleção das amostras que compõem os conjuntos de treinamento e validação foi realizada aleatoriamente. Na Tabela 4.3 é exibido um histórico, das amostras selecionadas, relacionado as mudanças de cobertura da terra observadas a partir da análise da série temporal de imagens LANDSAT. Na Figura 4.13 é ilustrada a área de estudo juntamente com as amostras selecionadas de cobertura da terra, e na Figura 4.14 são apresentadas e comparadas estas amostras nas imagens ALOS PALSAR, utilizada neste estudo, e LANDSAT-5 TM, com imageamento referente a 21 de Junho de 2006.

Tabela 4.2 - Classes considerados, número de regiões selecionadas e quantidades destinadas para treinamento e validação dos resultados.

Classes	Acrônimo	Quantidade Total Regiões	<i>Pixel</i>	Quantidade de Treinamento Regiões	<i>Pixel</i>	Proporção (%)	Quantidade de Validação Regiões	<i>Pixel</i>	Proporção (%)
Floresta Primária	FP	6	3050	4	1966	64,46	2	1084	35,54
Floresta Degradada	FD	3	1758	2	1162	66,61	1	596	33,39
Regeneração Antiga	RA	6	2909	4	1921	66,04	2	988	33,96
Regeneração Intermediária	RI	3	3248	2	2236	68,84	1	1012	31,16
Regeneração Nova	RN	5	2788	3	1836	65,85	2	952	34,15
Pasto Limpo	PL	5	2979	3	1978	66,40	2	1001	33,60
Pasto Sujo	PS	3	3062	2	1826	59,63	1	1236	40,37
Agricultura Tipo 1	AG1	2	849	1	590	69,49	1	259	30,51
Agricultura Tipo 2	AG2	3	2459	2	1659	67,47	1	800	32,53
Agricultura Tipo 3	AG3	3	1437	2	953	66,32	1	484	33,68
Agricultura Tipo 4	AG4	3	1396	2	906	64,90	1	490	35,10

Tabela 4.3 - Histórico das mudanças de cobertura da terra das amostras selecionadas.

Amostras/Ano	'84	'85	'86	'87	'88	'89	'90	'91	'92	'93	'94	'95	'96	'97	'98	'99	'00	'01	'02	'03	'04	'05	'06	'07
1	FL	•	•	FL	•	FL	FL	FL	FL	•	FL													
2	RG	•	•	RG	•	RG	RG	RG	RG	•	RG	•	RG	RG	RG	RG	RG							
3	DM	•	•	DM	•	DM	DM	DM	DM	•	DM	•	DM	DM	DM	DM	DM							
4	DM	•	•	DM	•	DM	DM	DM	DM	•	DM	•	DM	DM	DM	DM	DM							
5	DM	•	•	DM	•	DM	DM	DM	DM	•	DM	•	DM	DM	DM	DM	DM							
6	FL	•	•	FL	FL	FL	FL	FL	FL	•	FL	•	FL	FL	FL	FL	FL							
7	FL	•	•	FL	FL	FL	FL	FL	FL	•	FL	•	FL	FL	FL	FL	FL							
8	FL	•	•	FL	FL	FL	FL	FL	FL	•	FL	•	FL	FL	FL	FL	FL							
9	FL	•	•	FL	•	FL	FL	FL	FL	•	FL	•	FL	FL	FL	FL	FL							
10	FL	•	•	FL	•	FL	FL	FL	FL	•	FL	•	DG	DM	DM	DM	DM							
11	FL	•	•	FL	FL	FL	FL	FL	FL	•	FL	•	FL	RG	RG	RG	RG							
12	FL	•	•	FL	FL	FL	FL	FL	FL	•	FL	•	DG	RG	RG	RG	RG							
13	FL	•	•	FL	•	FL	FL	FL	FL	•	FL	•	DG	DM	DM	DM	DM							
14	RG	•	•	RG	•	RG	RG	RG	RG	•	RG	•	RG	RG	RG	RG	RG							
15	FL	•	•	FD	•	DM	DM	DM	DM	•	DM	•	DM	DM	DM	DM	DM							
16	FL	•	•	FL	•	FL	FL	FL	FL	•	FL	•	FL	FL	FL	FL	FL							
17	FL	•	•	FD	•	DM	DM	DM	DM	•	DM	•	DM	DM	DM	DM	DM							
18	FL	•	•	FD	•	DM	DM	DM	DM	•	DM	•	DM	DM	DM	DM	DM							
19	FL	•	•	FL	FL	FL	FL	FL	FL	•	FL	•	FL	FL	FL	FL	FL							
20	RG	•	•	DG	•	RG	RG	RG	RG	•	RG	•	RG	RG	RG	RG	RG							

FL: Área de floresta. RG: Área em regeneração. DG: Área desmatada. DM: Área sob degradação. •: Sem informação.

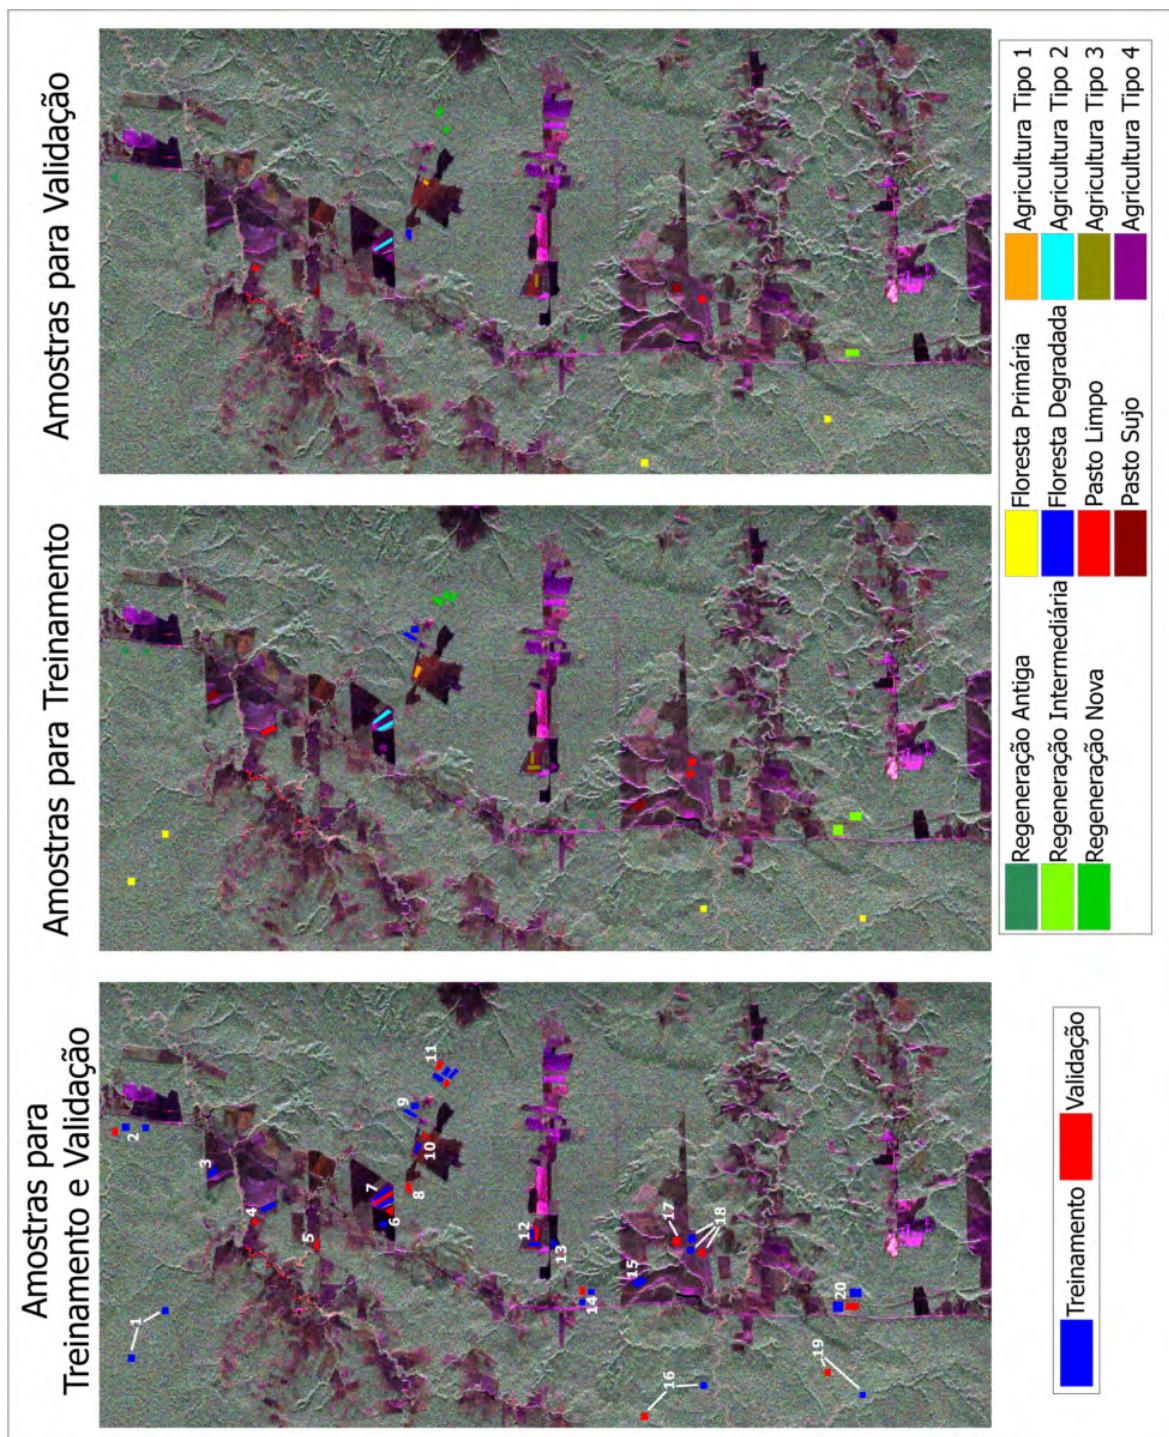


Figura 4.13 - Amostras selecionadas.

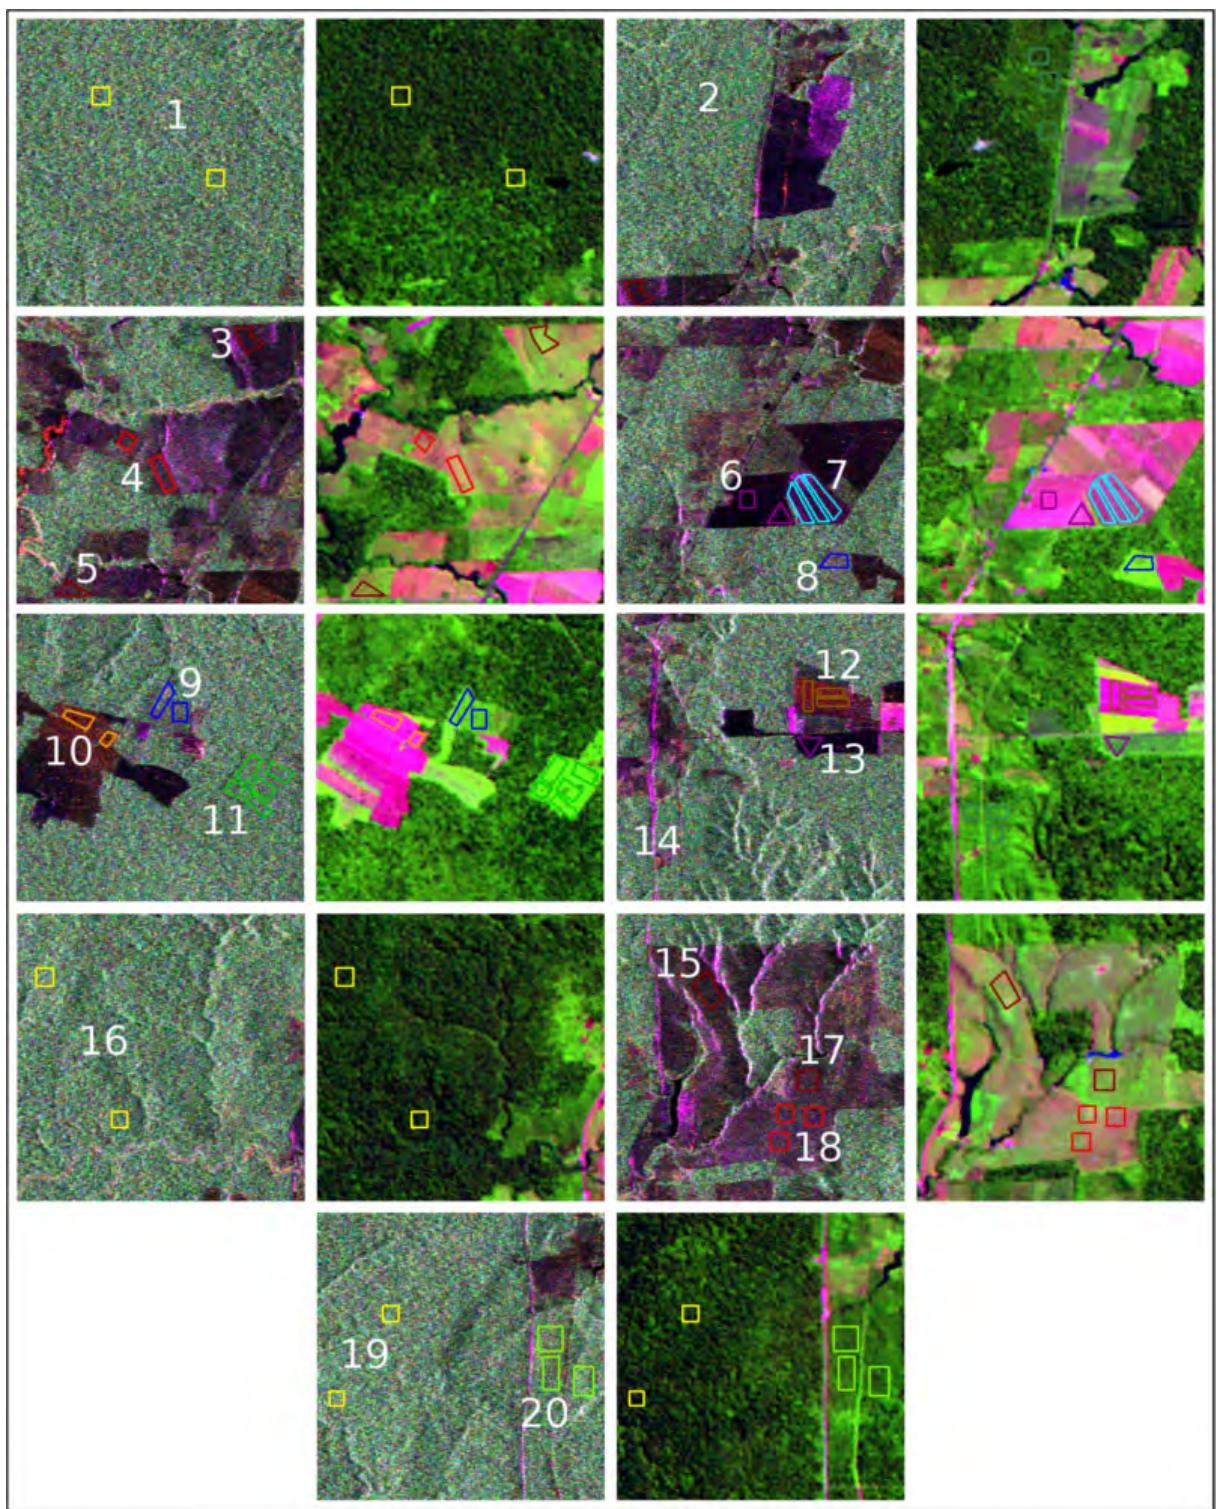


Figura 4.14 - Visualização das amostras selecionadas sobre a imagem ALOS PALSAR utilizada no estudo, em Amplitude e composição colorida (HH)R(HV)G(VV)B, e sobre uma imagem LANDSAT-5 TM, referente a 21 de Julho de 2007, em composição colorida (5)R(4)G(3)B.

4.3 Estruturação de Níveis de Discriminação das Classes de Cobertura da Terra

Ressaltando que um dos objetivos deste trabalho é avaliar a capacidade de discriminação de alvos a partir de imagens do sensor ALOS PALSAR, torna-se conveniente a definição de níveis de discriminação com respeito às classes de cobertura da terra, o que permite analisar esta imagem sob diferentes focos, em função das classes de cobertura da terra.

O aumento do nível de discriminação está relacionado ao aumento do número de classes envolvidas no problema de classificação. Por outro lado, a diminuição do nível de discriminação, ou aumento do nível de generalização, está relacionado com a diminuição do número de classes. Partindo de um número definido de classes, a diminuição do nível de discriminação exige o agrupamento entre duas ou mais classes.

Uma ferramenta útil nas tarefas de estruturação de diferentes níveis de discriminação são os Algoritmos de Agrupamento Hierárquicos. Especificamente, ao invés de produzir um único agrupamento, é produzida uma hierarquia de agrupamentos ([THEODORIDIS; KOUTROUMBAS, 2006](#)). Para construção deste tipo de agrupamento, comumente são adotadas as medidas de proximidade, ou de dissimilaridade, entre classes.

As Matrizes de Dissimilaridade são uma forma simples de representar a dissimilaridade entre classes. Estas matrizes contém as medidas de dissimilaridade para cada par de classes, dentre todas envolvidas no problema. Na Equação 4.2 é definida esta matriz, cujos elementos $d(\omega_i, \omega_j)$ representam a medida de dissimilaridade entre as classes ω_i e ω_j .

$$D = (d(\omega_i, \omega_j))_{n \times n} \in \mathbb{R} \quad i = 1, 2, \dots, n \quad (4.2)$$

Neste trabalho, esta medida é definida pela distância entre funções densidade de probabilidade.

4.3.1 Cálculo da Medida de Dissimilaridade

Distância entre distribuições estatísticas têm sido empregados em algoritmos de agrupamento, classificação, compressão, reconstrução de sinais, entre outros ([NASCIMENTO, 2008](#)).

Existem inúmeras maneiras de realizar o cálculo da distância entre modelos estatísticos, dentre elas, a medida de Bhattacharyya, comumente empregada em aplicação de processamento de imagens. Esta distância é definida por:

$$B(\Theta_X, \Theta_Y) = -\log \left(\int_{x \in S(x)} \sqrt{f_X(x; \Theta_X) f_Y(x; \Theta_Y)} dx \right) \quad (4.3)$$

onde $f_X(\cdot)$ e $f_Y(\cdot)$ são funções densidade de probabilidade, de mesma família, relacionadas respectivamente as variáveis aleatórias X e Y , Θ_X e Θ_Y são parâmetros associados as funções $f_X(\cdot)$ e $f_Y(\cdot)$ e $S(x)$ é o domínio definido para o cálculo integral.

Para a obtenção da medida de dissimilaridade entre as diferentes classes de cobertura da terra foi utilizada a informação radiométrica das componentes HH, HV e VV em Amplitude, conjuntamente, supondo que estes dados são modelados pela função densidade de probabilidade Gaussiana Multivariada. A escolha desta função é justificada por sua capacidade de generalização, que possibilita o ajuste de uma função densidade de probabilidade para as informações selecionadas, além da simples estimativa dos parâmetros necessários.

Como apresentado em [Richards \(1986\)](#), quando a função Gaussiana Multivariada é empregada, a Equação 4.3, após um série de operações algébricas, é simplificada para:

$$B(\Psi_X, \Psi_Y) = \frac{1}{2}(\mu_X - \mu_Y)^T \left(\frac{\Sigma_X + \Sigma_Y}{2} \right)^{-1} (\mu_X - \mu_Y) + \frac{1}{2} \ln \left(\frac{\sqrt{\Sigma_X + \Sigma_Y}}{\sqrt{\Sigma_X} + \sqrt{\Sigma_Y}} \right); \quad \Psi_i = \{\mu_i, \Sigma_i\} \quad (4.4)$$

onde μ_i e Σ_i representam respectivamente o vetor média e a matriz de covariância de um conjunto i qualquer.

Após definida a medida de dissimilaridade, é necessária a definição de uma Regra de Agrupamento, empregada pelo Algoritmo de Agrupamento Hierárquico.

4.3.2 Regra de Agrupamento Hierárquico

O processo de agrupamento realizado por um Algoritmo de Agrupamento Hierárquico ocorre em função de uma regra de agrupamento. Diferentes regras podem ser definidas de acordo com o objetivo em questão.

Fundamentado na idéia proposta pelo Algoritmo de Ligação Única (*Single Link Algorithm*), pertencente à classe dos algoritmos aglomerativos baseados na teoria de grafos, onde um nó (classe) torna-se parte de um agrupamento quando este possuir dissimilaridade, entre qualquer um dos nós que compõem o agrupamento, menor que determinado limiar, é definida a seguinte regra:

Seja Ω o conjunto de partições $\zeta_{p\alpha}$, ω_i ($i = 1, \dots, n$) as classes envolvidas no problema, onde $\bigcup_{i=1}^n \omega_i = \Omega$ e $\bigcap_{i=1}^n \omega_i = \emptyset$, sendo p o índice da partição e α o índice de um limiar de dissimilaridade $l_\alpha \in \mathbb{R}$.

As classes ω_i e ω_j compõem uma partição $\zeta_{p\alpha}$ se a medida de similaridade entre elas é menor que um dado l_α , isto é:

$$d(\omega_i, \omega_j) \leq l_\alpha \Rightarrow \zeta_{p\alpha} = \omega_i \cup \omega_j \quad (4.5)$$

Ainda, para que um determinado conjunto ω_i componha a partição $\zeta_{q\beta}$, basta que:

$$d(\omega_i, \varrho) \leq l_\beta \quad \forall \varrho \subset \zeta_{q\beta} \quad (4.6)$$

A Figura 5.6 ilustra um exemplo relacionado a regra de agrupamento definida.

Neste exemplo, ω_1 possui dissimilaridade entre ω_2 ou ω_3 menor ou igual ao limiar L_1 , e *vice-versa*. Por outro lado, as classes ω_4 e ω_5 não possuem entre si dissimilaridade menor ou igual a L_1 ,

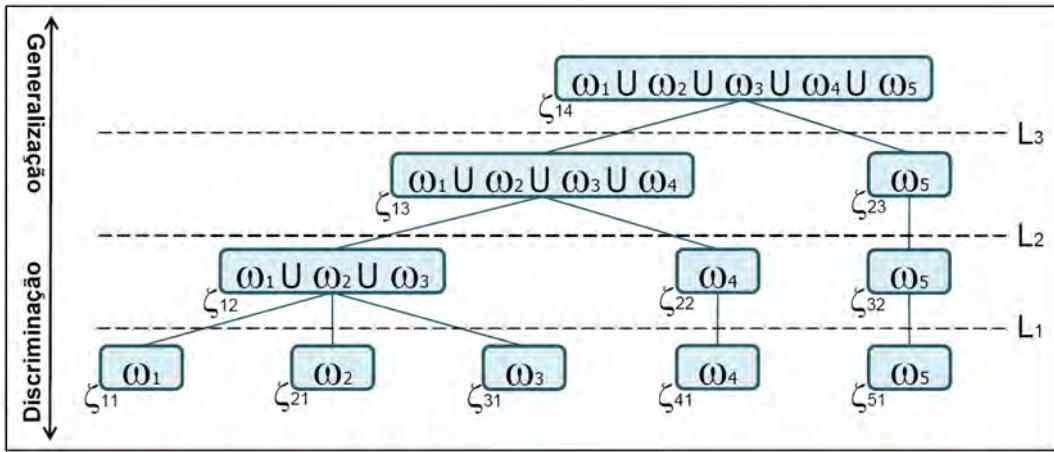


Figura 4.15 - Exemplo de Agrupamento Hierárquico segundo a regra de agrupamento proposta.

nem com nenhuma das classes ω_1 , ω_2 e ω_3 . No próximo nível da hierarquia, a classe ω_4 possui dissimilaridade entre qualquer uma das classes ω_1 , ω_2 e ω_3 menor ou igual a L_2 , ao contrário de ω_5 . Por fim, a classe ω_5 possui dissimilaridade menor ou igual a L_3 entre qualquer uma das classes ω_1 , ω_2 , ω_3 ou ω_4 .

4.4 Classificação da Imagem ALOS PALSAR

4.4.1 Classificações Pelo Método MaxVer/ICM

Para realização das classificações a partir do método MaxVer/ICM, foi adotado o *software Polarmetric Classifier 0.7*, desenvolvido por [Correia \(1999\)](#).

Estas classificações partiram da utilização de dados Univariados, Bivariados, Multivariados e Polarimétricos. Os conjuntos de dados Univariados são representados por HH, HV e VV, Bivariados por HH+HV, HH+VV e HV+VV, Multivariados por HH+HV+VV e Polarimétricos por PC.

Para estes 8 conjuntos de dados mencionados, foram realizadas classificações em cada um dos diferentes níveis de discriminação.

Em especial, para classificações realizadas a partir de dados Univariados e Polarimétricos, é possível associar diferentes funções densidade de probabilidade para cada uma das classes, como descrito nas seções 2.2.1.1 e 2.2.1.1. As funções associadas às classes são identificadas no Apêndice D. Ao contrário dos dados Univariados e Polarimétricos, para os dados Bivariados e Multivariados são adotadas para quaisquer tipo de alvo, a função densidade de probabilidade desenvolvida por [Lee et al. \(1994b\)](#) e a Gaussiana Multivariada, respectivamente.

4.4.2 Classificações Pelo Método K-Médias Wishart $H/A/\bar{\alpha}$

Para realização da classificação K-Médias Wishart $H/A/\bar{\alpha}$ foi adotado o *software* PolSARpro 3.3.

Sendo este um método não-supervisionado, a rotulação das classes discriminadas por este método foi inferida manualmente.

Para fins de comparação com os resultados obtidos pelo método MaxVer/ICM, é possível definir para o método K-Médias Wishart $H/A/\bar{\alpha}$ diferentes níveis de discriminação. A interpretação dos resultados gerados pelo método K-Médias Wishart $H/A/\bar{\alpha}$ define o primeiro nível de discriminação, composto pelas classes identificadas na fase de interpretação. Com a estrutura de níveis de discriminação calculada (Seção 5.2), é definida a relação de similaridade entre as classes. Assim, dado um nível de discriminação inicial (obtido via interpretação) e a relação entre as diferentes classes (estrutura de níveis de discriminação) são determinados os níveis de discriminação do resultado gerado pelo método K-Médias Wishart $H/A/\bar{\alpha}$.

4.5 Rotinas Auxiliares Implementadas

Para realização de algumas etapas deste trabalho foi necessário a implementação, em linguagem IDL, de algumas rotinas para suprir a não disponibilidade de certas funções nos *softwares* empregados. Foram elas:

- Verificação do Padrão da Antena. Subseção 4.1.1
- Cálculo da Medida de Dissimilaridade. Subseção 4.3.1.
- Regra de Agrupamento Hierárquico. Subseção 4.3.2.
- Dispersão das amostras selecionadas no Plano $H/\bar{\alpha}$. Seção 5.1 e Anexo B.
- Cálculo das medidas descritivas das amostras selecionadas. Seção 5.1.
- Rotulação das classificações K-Médias Wishart $H/A/\bar{\alpha}$ nos diferentes níveis de discriminação. Seção 5.4.

5 RESULTADOS

5.1 Análise Descritiva das Classes de Cobertura da Terra Selecionadas

Após o estudo de certas características da região abrangida pela imagem e então a seleção de diferentes amostras de classes de cobertura da terra, torna-se importante analisar estas informações, principalmente, com a finalidade de compará-las e verificar as relações entre elas.

Dentre as amostras selecionadas, parte destas foram destinadas à etapa de treinamento e o restante à validação das classificações obtidas pelos métodos empregados. As amostras de treinamento foram utilizadas apenas pelo método MaxVer/ICM, ao contrário das amostras de validação, utilizadas pelos métodos MaxVer/ICM e K-Médias Wishart H/A/ $\bar{\alpha}$.

Outro fator que deve ser verificado é a consistência entre amostras de classes diferentes, isto é, constatar a diferença ou semelhança esperada entre determinadas classes, como por exemplo, a diferença entre as classes Floresta Primária e Agricultura Tipo 1 e a semelhança entre as classes Floresta Primária e Regeneração Antiga.

Para esta tarefa foram empregados gráficos do tipo *Boxplot*, Histogramas, Histogramas Polares e o Plano H/ $\bar{\alpha}$. Foram utilizadas nestas análises as informações radiométricas das componentes HH, HV e VV em Amplitude, a diferença de fase entre as componentes HH e VV e os indicadores de espalhamento Entropia e Ângulo Alfa.

Segundo [Henderson e Lewis \(1998\)](#), apenas o par de bandas HH e VV apresenta informação relevante de diferença de fase entre os pares polarimétricos, em virtude das componentes co-polarizadas apresentarem mais fortes retroespelhamentos dos alvos do que as polarizações cruzadas. As diferenças de fase entre os sinais HV e HH, e VH e VV apresentam-se ruidosas devido aos retroespelhamentos irregulares decorrentes dos espelhamentos volumétricos, que são observados predominantemente em regiões de floresta. Esta razão justifica o emprego da informação da diferença de fase entre as componentes HH e VV, apenas, e não nas demais combinações.

Nos gráficos e tabelas seguintes os prefixos “Tre” e “Val” indicam respectivamente amostras de treinamento e validação, “Amp” refere-se à informação radiométrica em Amplitude e “HH”, “HV” e “VV” às diferentes Componentes. As diferentes classes são referenciadas pelos acrônimos definidos na Tabela [4.2](#).

Cabe ressaltar que a informação sobre diferença de fase dos alvos deve ser analisadas estatisticamente segundo medidas próprias para este tipo de dado (circular), como discutido em [Fisher \(1993\)](#).

Nos gráficos *Boxplot* das figuras [5.1](#), [5.2](#), [5.3](#) e do Anexo B, referentes ao comportamento da radiometria em amplitude dos alvos nas componentes HH, HV e VV, os segmentos de reta vertical indicam os menores e maiores valores dentro dos limites inferior, $Q_1 - 1,5(Q_3 - Q_1)$, e superior, $Q_3 + 1,5(Q_3 - Q_1)$, sendo Q_1 e Q_3 o primeiro e terceiro quartil, por sua vez, representados respectivamente pelos lados inferior e superior do retângulo contido nestes gráficos, já o segmento de

reta interno ao retângulo representa a mediana dos dados. Por fim, os pontos que podem estar alinhados acima ou abaixo dos segmentos de retas dos limites inferior e superior, são considerados dados discrepantes.

Para comparação entre classes nas diferentes componentes, realizadas a partir dos gráficos *Boxplot* das figuras 5.1, 5.2 e 5.3, a informação contidas nas amostras de treinamento e validação, definidas na Seção 4.2, foram utilizadas conjuntamente. É possível verificar nestes gráficos que as classes Floresta Primária, Regeneração Antiga, Intermediária e Nova, e Floresta Degradada, possuem comportamentos semelhantes nas diferentes Componentes, com exceção da classe Floresta Degradada, cujas variações dos valores de radiométricos diferem das demais apenas na Componente HV.

Da mesma forma, as variações de valores radiométricos entre as classes Pasto Limpo e Pasto Sujo são próximas nas diferentes componentes.

As diferentes classes de agricultura, ao contrário das demais classes analisadas anteriormente, apresentam comportamentos diferentes em cada uma das componentes. Para a Componente HH as variações entre classes são menores, sendo que as classes Agricultura Tipo 2 e 4 possuem menores índices radiométricos. Já para a Componente VV, os menores índices radiométricos ocorrem nas classes Agricultura Tipo 1 e 3, quando comparadas com as classes Agricultura Tipo 2 e 4. No entanto, a Componente HV apresenta baixas variações nos quatro tipos de agricultura.

A presença de dados discrepantes ocorre com maior freqüência nas classes Agricultura Tipo 2 e 4, nas componentes HH e VV. Para a Componente HV, a ocorrência de discrepâncias é maior nas classes Floresta Primária, Floresta Degradada e Regenerações Antiga, Intermediária e Nova.

Estas análises são capazes de indicar características sobre a separabilidade entre determinadas classes para as diferentes componentes polarimétricas. Por exemplo, as classes de floresta e regeneração⁶ apresentam comportamentos muito semelhantes, que por sua vez podem proporcionar difícil separação a partir de técnicas de classificação de imagens.

Os gráficos *Boxplot* e histogramas apresentados nas figuras B.1 a B.11 e B.12 a B.22 do Anexo B, evidenciam que as amostras de treinamento e validação, quando comparadas separadamente segundo as mesmas classes nas diferentes componentes, apresentam variações semelhantes, o que mostra que o procedimento de seleção e coleta das amostras na imagem foi realizado adequadamente. As maiores diferenças constatadas encontram-se na classe Pasto Sujo, onde ocorrem índices radiométricos pouco maiores na amostra de validação, em relação à amostra de treinamento, o que pode ser verificado a partir do gráfico da Figura B.18.

Relacionados aos gráficos das figuras 5.1, 5.2 e 5.3, e B.1 a B.22, é apresentada na Tabela B.1 medidas descritivas a respeito dos diferentes conjuntos de treinamento e validação de cada uma das classes

⁶Classes de floresta e regeneração se referem as classes Floresta Primária e Degradada, e as Regenerações Antiga, Intermediária e Nova, assim como classes de pastagem se referem as classes Pasto Limpo e Sujo, e classes de agricultura aos diferentes tipos de agricultura.

Os histogramas polares apresentados na Figura 5.4 permitiram comparar as amostras de treinamento e validação segundo a Diferença de Fase entre as componentes HH e VV. Em todas as comparações há concordância entre a mediana e o desvio padrão, as quais são exibidas na Tabela B.2. Em especial, a classe Agricultura Tipo 3 apresentou um comportamento diferenciado das demais. Tal comportamento pode estar relacionado à orientação dos alvos.

Para a análise das diferentes classes segundo os atributos Entropia e Ângulo *Alpha*, foram observadas cada uma das dispersões no Plano H/ $\bar{\alpha}$, como ilustrado na Figura 5.5. Para comparação entre classes a partir destes gráficos, foi utilizada a informação das amostras de treinamento e validação, conjuntamente.

Esta análise permitiu indicar grupos de classes com comportamento semelhante, segundo as características definidas por [Cloud e Pottier \(1996\)](#). Para estes atributos é observada a difícil discriminação entre certas classes, o que será refletido no processo de discriminação destas pelo métodos K-Médias Wishart H/A/ $\bar{\alpha}$.

As classes de floresta e regeneração apresentam baixa e média Entropia, estão relacionadas com áreas de espalhamento múltiplo, com mecanismos *Double-Bounce*, superficial de vegetação, suaves, e suaves com espalhamento anisotrópico correlacionado.

As classes de pastagem apresentam baixa e média Entropia, compostas por espalhamento superficial e de vegetação, com espalhamento anisotrópico correlacionado.

A classe Agricultura Tipo 1 apresenta baixa Entropia, com espalhamento anisotrópico correlacionado e superfícies suaves e de vegetação.

A classe Agricultura Tipo 3 apresenta baixa entropia, com espalhamento múltiplo e superficial.

A classe Agricultura Tipo 2 e 4 apresenta baixa e média entropia, com grande concentração de espalhamento de vegetação, anisotrópico altamente correlacionado.

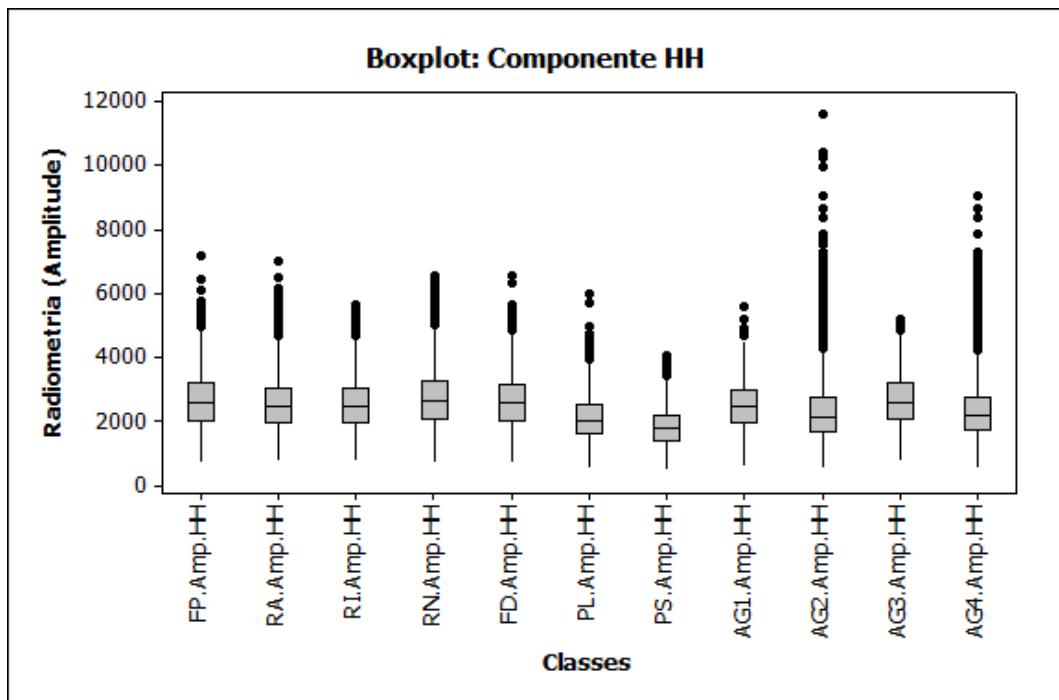


Figura 5.1 - Gráfico Boxplot: Informação radiométrica em Amplitude da componente HH das diferentes classes.

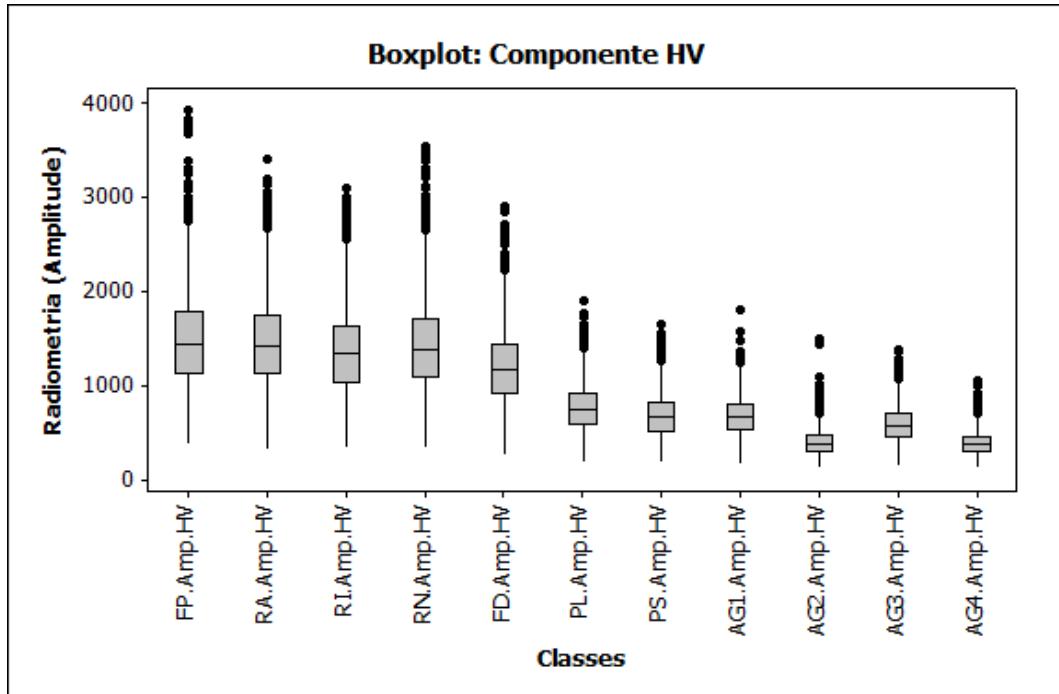


Figura 5.2 - Gráfico Boxplot: Informação radiométrica em Amplitude da componente HV das diferentes classes.

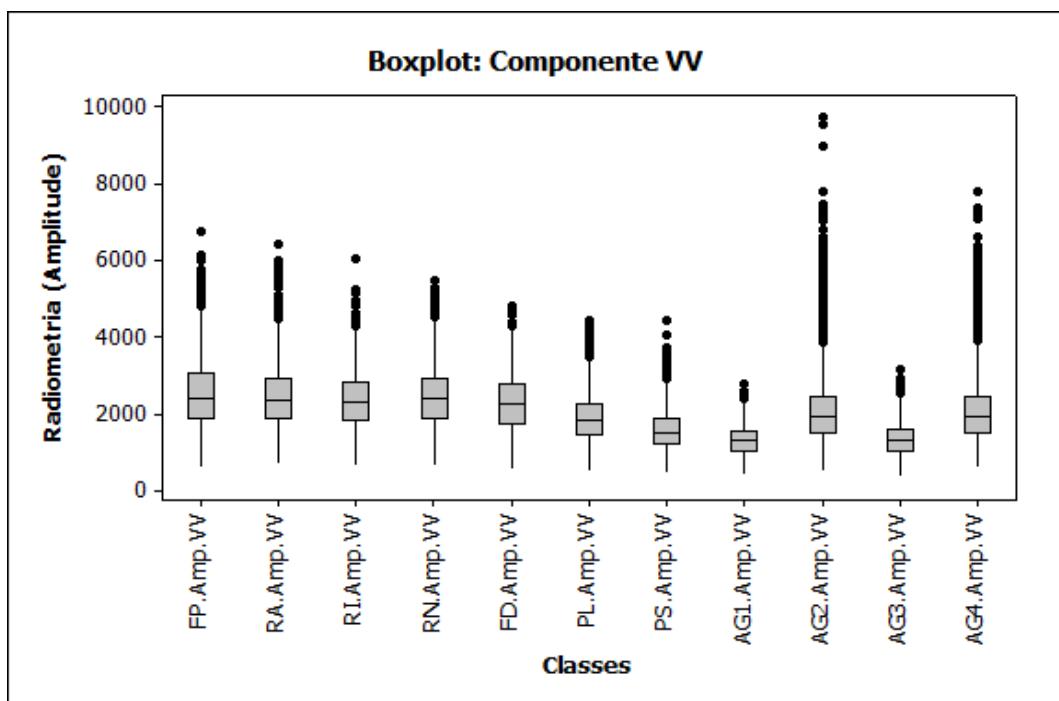


Figura 5.3 - Gráfico Boxplot: Informação radiométrica em Amplitude da componente VV das diferentes classes.

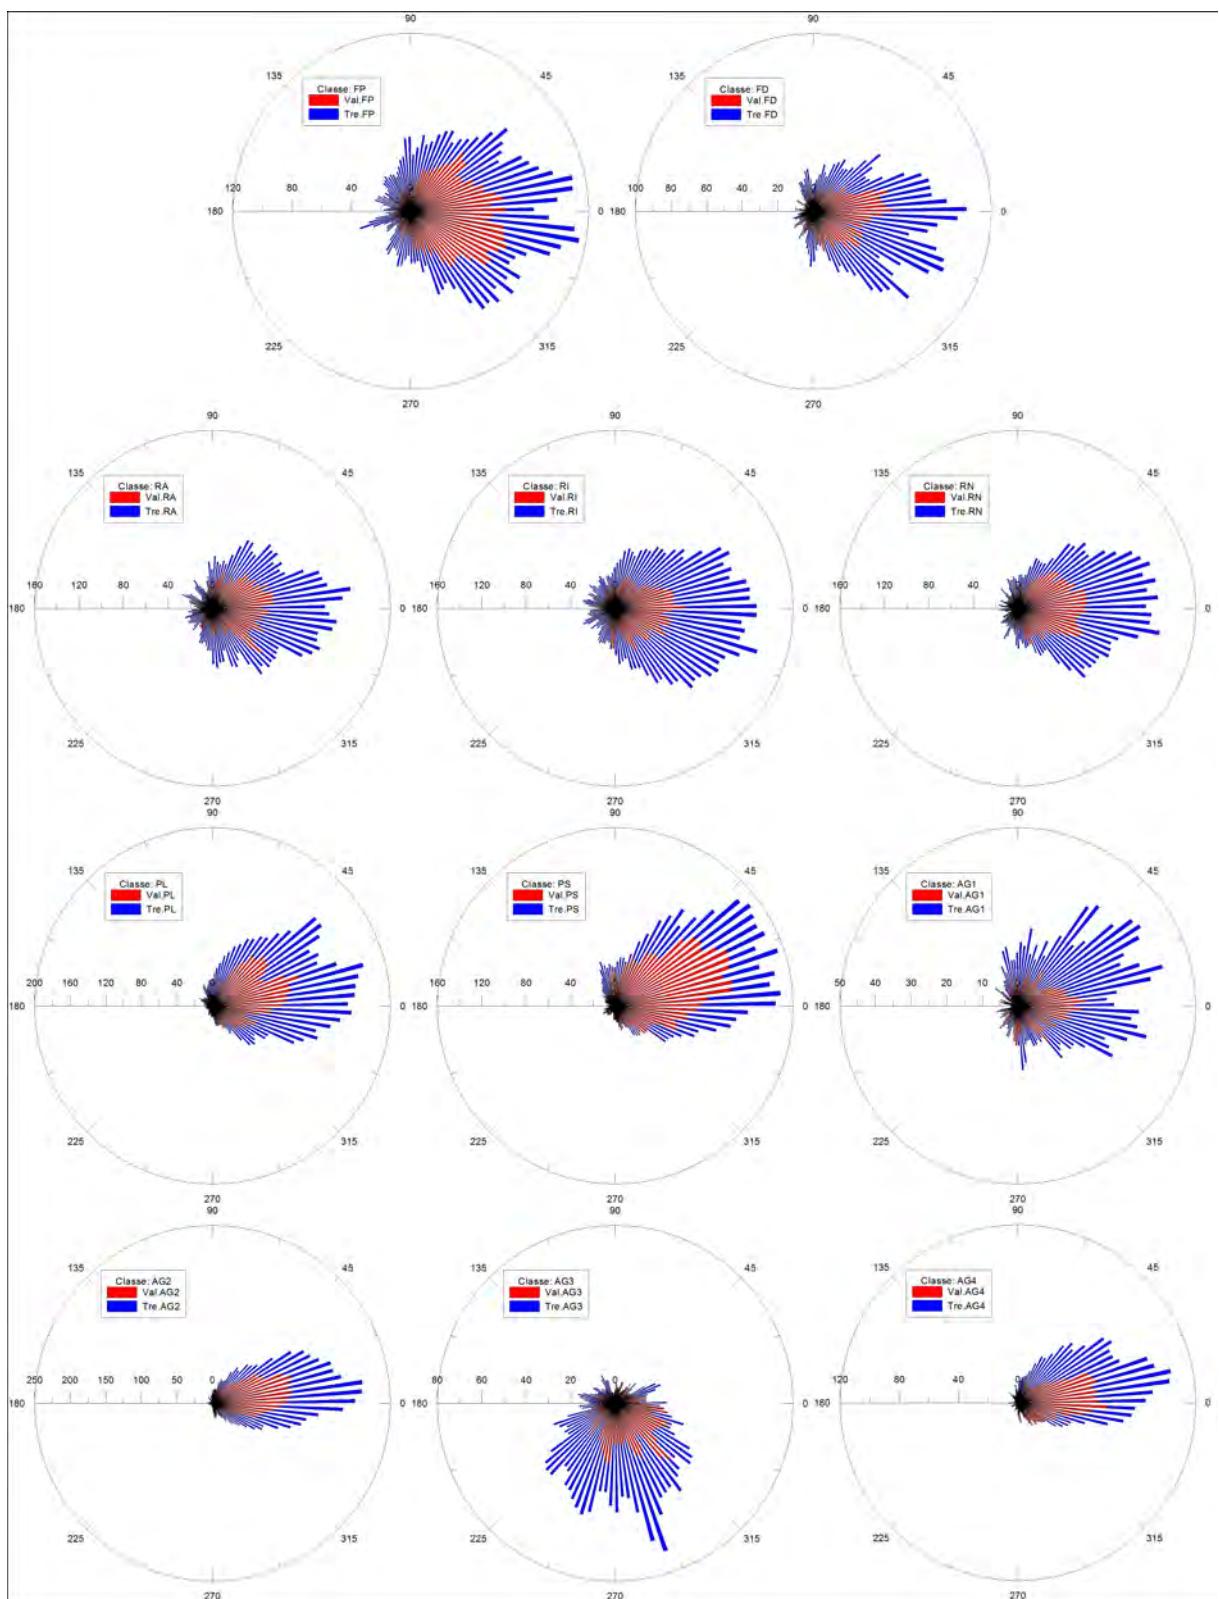


Figura 5.4 - Histograma Polar: Comparação entre as amostras de treinamento e validação das diferentes classes segundo a informação de diferença de fase entre as componentes HH e VV.

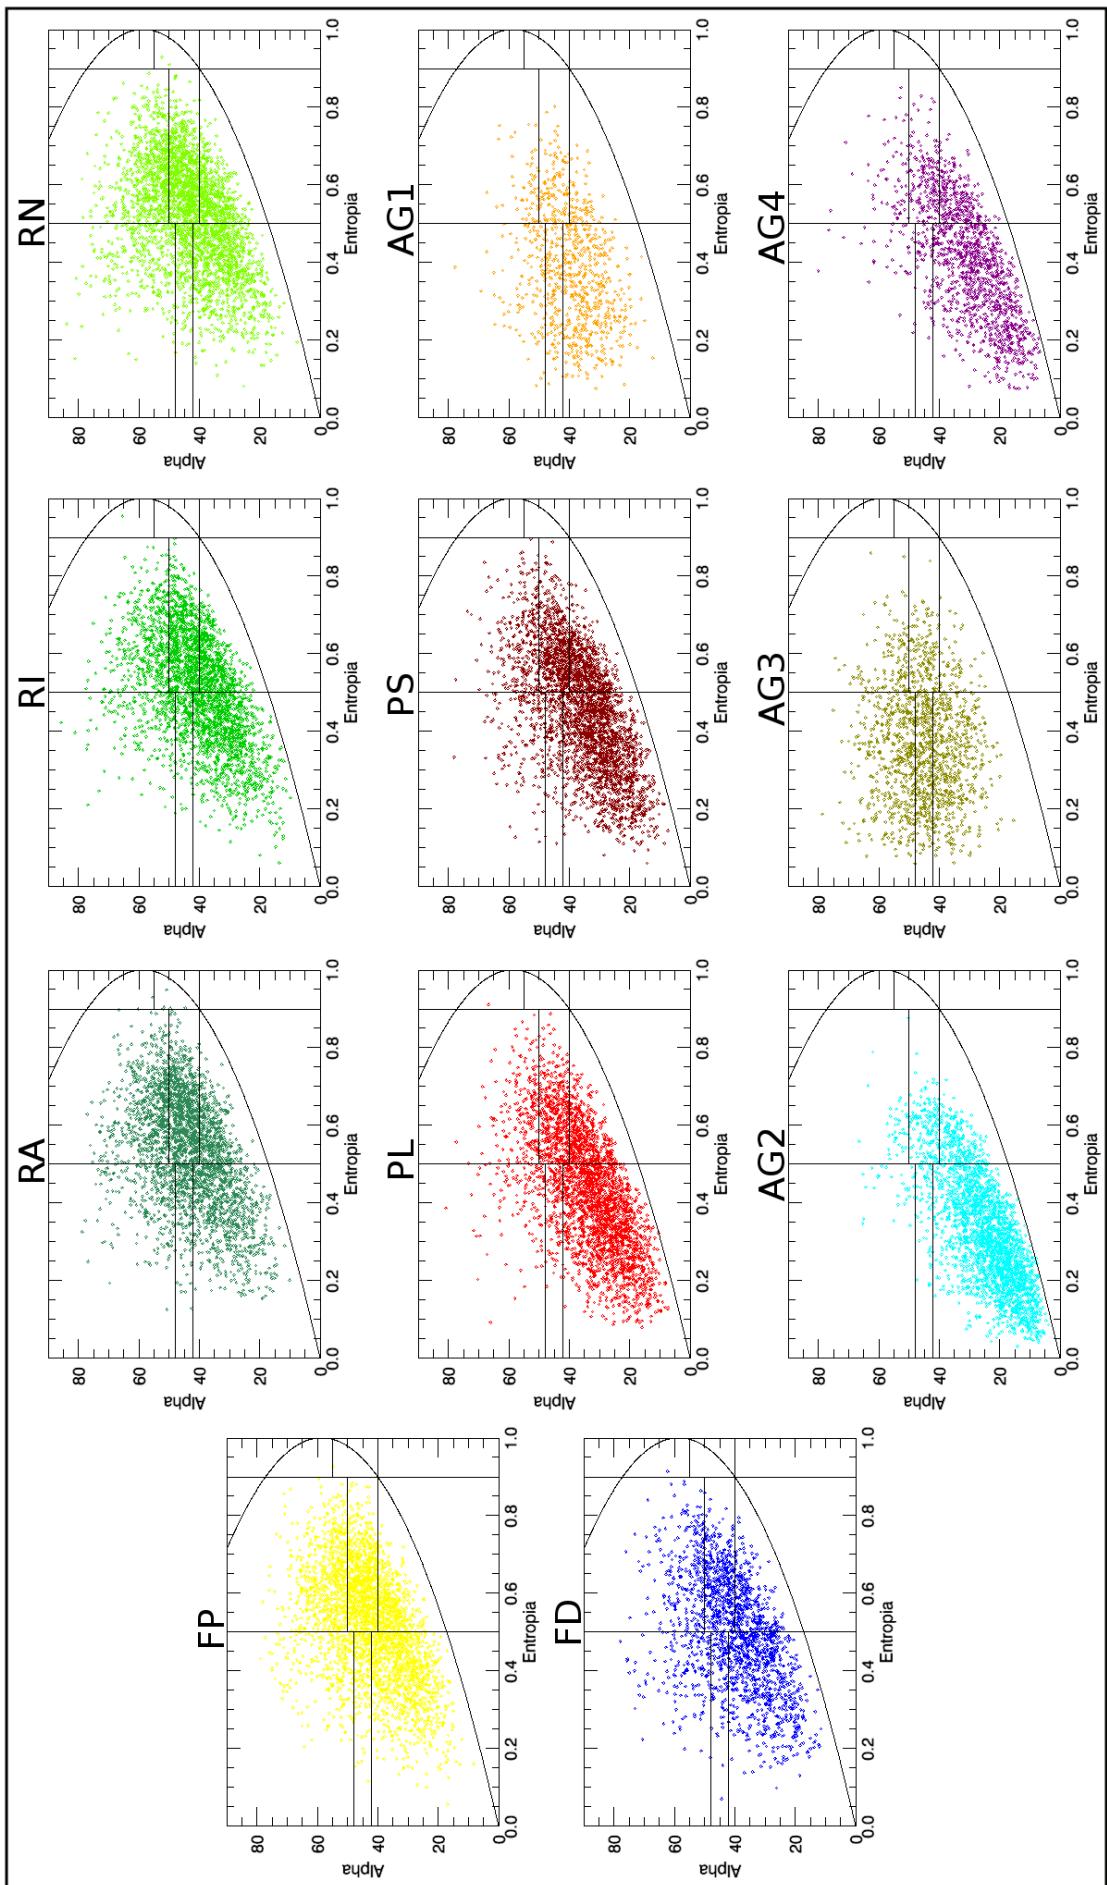


Figura 5.5 - Dispersão das amostras das classes selecionadas no Plano H/ $\bar{\alpha}$.

5.2 Estrutura de Discriminação Obtida

A partir da informação Radiométrica em Amplitude das componentes HH, HV e VV de todas as amostras selecionadas na área de estudo, para cada classe, e da adoção distância da Bhattacharyya considerando a função densidade de probabilidade Gaussiana Multivariada, foi obtida a Matriz de Dissimilaridade apresentada na Tabela 5.1

Tabela 5.1 - Matriz de dissimilaridade obtida a partir da distância de Bhattacharyya.

	FP	FD	RA	RI	RN	PL	PS	AG1	AG2	AG3	AG4
FP	0.000	0.073	0.009	0.010	0.027	0.656	0.963	1.126	1.538	1.282	2.656
FD	0.073	0.000	0.057	0.046	0.027	0.378	0.670	0.815	1.280	0.955	2.465
RA	0.009	0.057	0.000	0.008	0.009	0.660	0.998	1.216	1.679	1.397	2.931
RI	0.010	0.046	0.008	0.000	0.016	0.619	0.939	1.092	1.524	1.241	2.727
RN	0.027	0.027	0.009	0.016	0.000	0.534	0.858	1.065	1.520	1.230	2.805
PL	0.656	0.378	0.660	0.619	0.534	0.000	0.074	0.324	0.640	0.393	1.342
PS	0.963	0.670	0.998	0.939	0.858	0.074	0.000	0.257	0.626	0.321	0.821
AG1	1.126	0.815	1.216	1.092	1.065	0.324	0.257	0.000	0.872	0.042	1.297
AG2	1.538	1.280	1.679	1.524	1.520	0.640	0.626	0.872	0.000	0.728	0.674
AG3	1.282	0.955	1.397	1.241	1.230	0.393	0.321	0.042	0.728	0.000	1.312
AG4	2.656	2.465	2.932	2.727	2.805	1.342	0.821	1.297	0.674	1.312	0.000

Dada esta Matriz de Dissimilaridade foi possível definir diferentes níveis de discriminação ao aplicar o Algoritmo de Agrupamento Hierárquico segundo a regra de agrupamento proposta, como definido na Subseção 4.3.2. A Figura 5.6 apresenta a estruturação dos níveis de discriminação obtidos ao aplicar esta metodologia.

Diante os resultados obtidos, os dois últimos níveis de discriminação, compostos respectivamente por três e duas classes, não apresentam significados práticos para aplicações relacionadas à classificação da cobertura da terra, portanto, estes níveis serão desconsiderados.

Em função destes resultados, torna-se possível, e conveniente, a construção de uma legenda geral capaz de auxiliar na identificação das classes, ou agrupamento de classes, em cada um dos níveis de discriminação. A Figura 5.7 ilustra esta legenda.

Em um primeiro momento, a classificação de um determinado conjunto de dados em diferentes níveis de discriminação mostra-se factível apenas quando são empregados métodos de classificação supervisionados, pois para estes, é possível definir em quais classes os dados serão classificados, ao contrário dos métodos não-supervisionados.

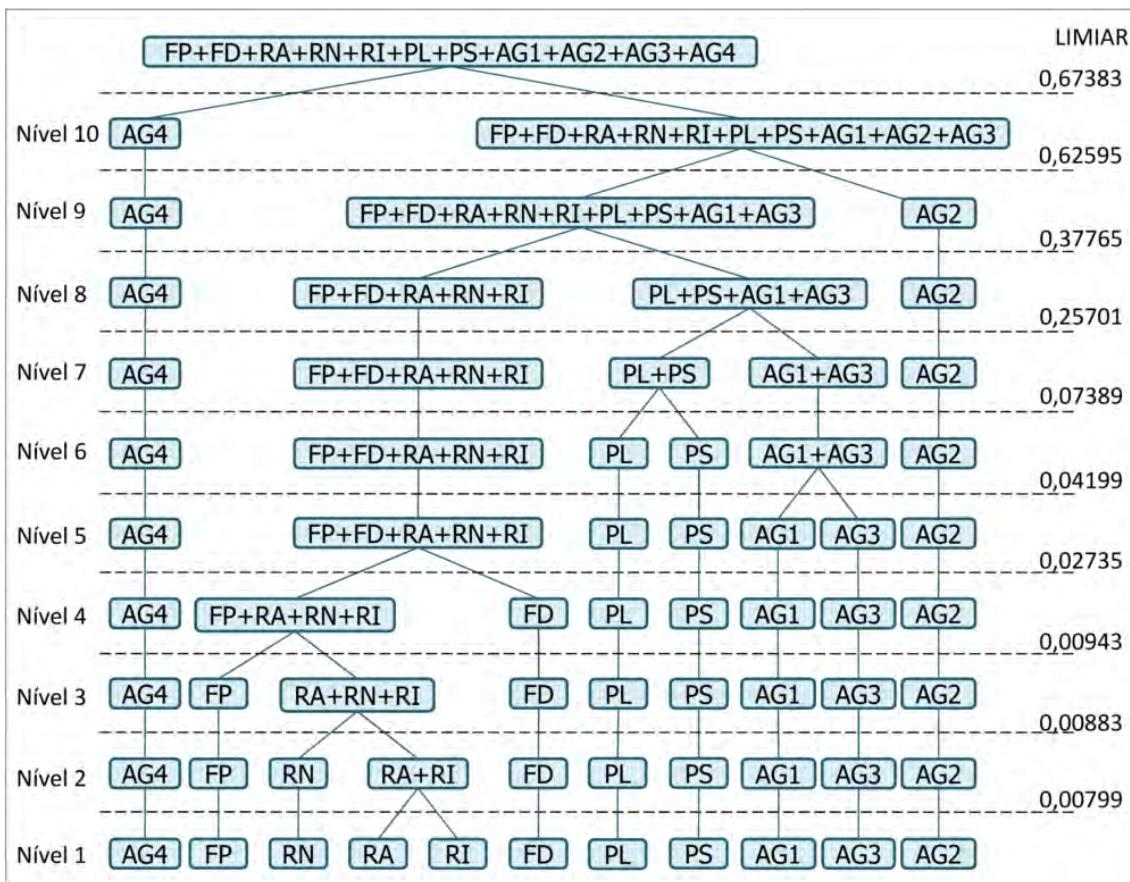


Figura 5.6 - Estrutura dos níveis de discriminação obtido a partir das amostras selecionadas de cobertura da terra.

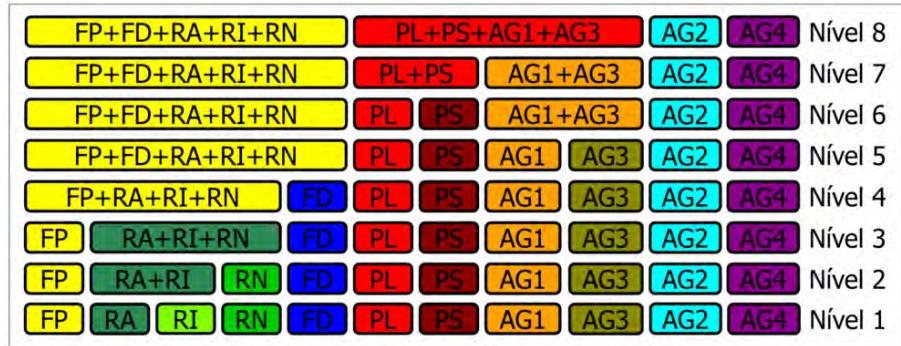


Figura 5.7 - Legenda geral dos níveis de discriminação para as classificações MaxVer/ICM.

Entretanto, é possível estruturar uma classificação não-supervisionada em diferentes níveis de discriminação. Para isso, um exemplo de metodologia seria, após a definição de um nível de discriminação “inicial”, obtido com a interpretação e rotulação dos resultados dentre as possíveis classes, os

demais níveis são obtidos com a aplicação da regra de Agrupamento Hierárquico definida e utilização da Matriz de Dissimilaridade calculada. Cabe ressaltar que, durante a etapa de interpretação das classes existe a possibilidade do intérprete não possuir informações a respeito de determinados alvos discriminados na cena. Em ocasiões como esta, tais alvos podem ser denominados como “indefinidos”.

5.3 Classificações MaxVer/ICM

Com as amostras de classes de cobertura da terra selecionadas (Seção 4.2) e definição dos níveis de discriminação (Seção 5.2), foram geradas 64 classificações pelo método MaxVer/ICM, cada uma destas geradas a partir de um dos oito diferentes conjunto de dados considerados neste trabalho (HH, HV, VV, HH+HV, HH+VV, HV+VV, HH+HV+VV, PC), para cada um dos 8 níveis de discriminação considerados.

Diante do grande número de mapas gerados, para efeito de apresentação, as figuras 5.8 e 5.9 ilustram os resultados obtidos a partir dos diferentes conjuntos de dados apenas para o primeiro nível de discriminação, composto por 11 classes.

Para as classificações geradas a partir de dados Univariados e Polarimétricos, o Apêndice D informa as funções densidade de probabilidade adotadas, após realização do teste de aderência χ^2 , para modelagem das diferentes classes.

A análise visual destes resultados, sem considerações a respeito de sua exatidão, permite verificar certas características a respeito dos dados e alvos, como por exemplo:

- Dados Univariados, no geral, não foram capazes de discriminar a maioria das classes de agricultura;
- Dados Bivariados HH+HV apresentam melhor discriminação dos alvos com relação aos demais conjuntos Bivariados;
- Dados Multivariados e Polarimétricos apresentaram resultados superiores com relação aos demais;
- Dados Polarimétricos proporcionam melhor separação entre as classes de pastagem e agricultura em relação aos dados Multivariados;
- Independente dos dados empregados, também é possível verificar que as diferentes classes de regeneração e florestas não são discriminadas entre si satisfatoriamente.

A discussão detalhada destes resultados a respeito das diferentes classes, conjuntos de dados e níveis de discriminação é realizada na Seção 5.5.

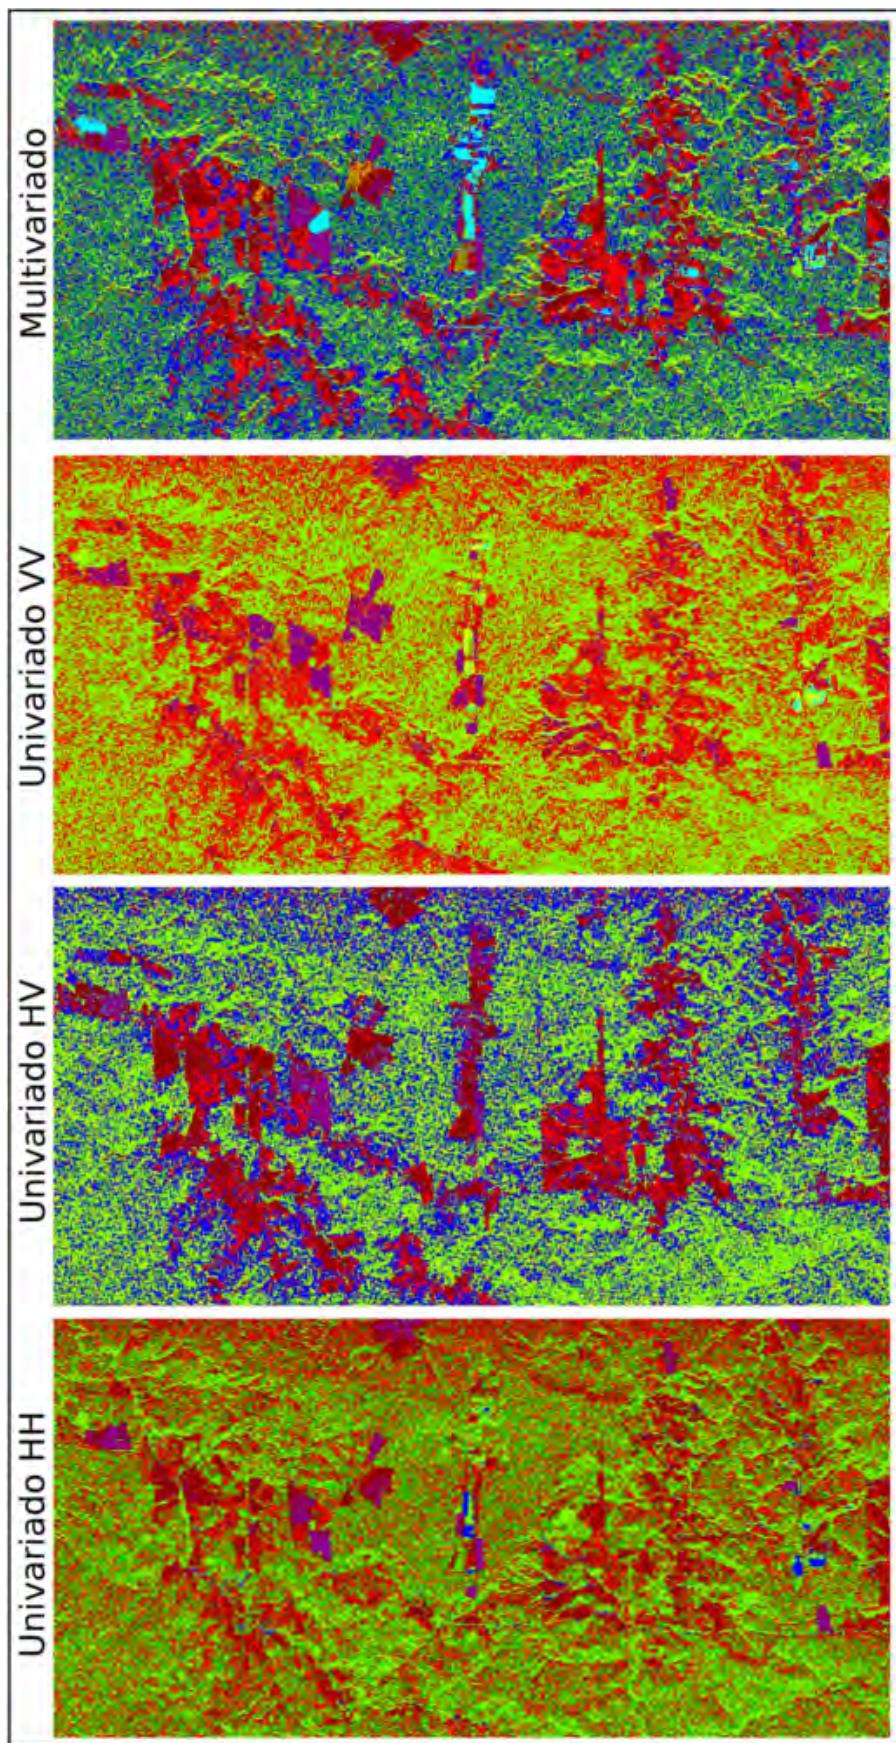


Figura 5.8 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados e Multivariados para o nível de discriminação 1.

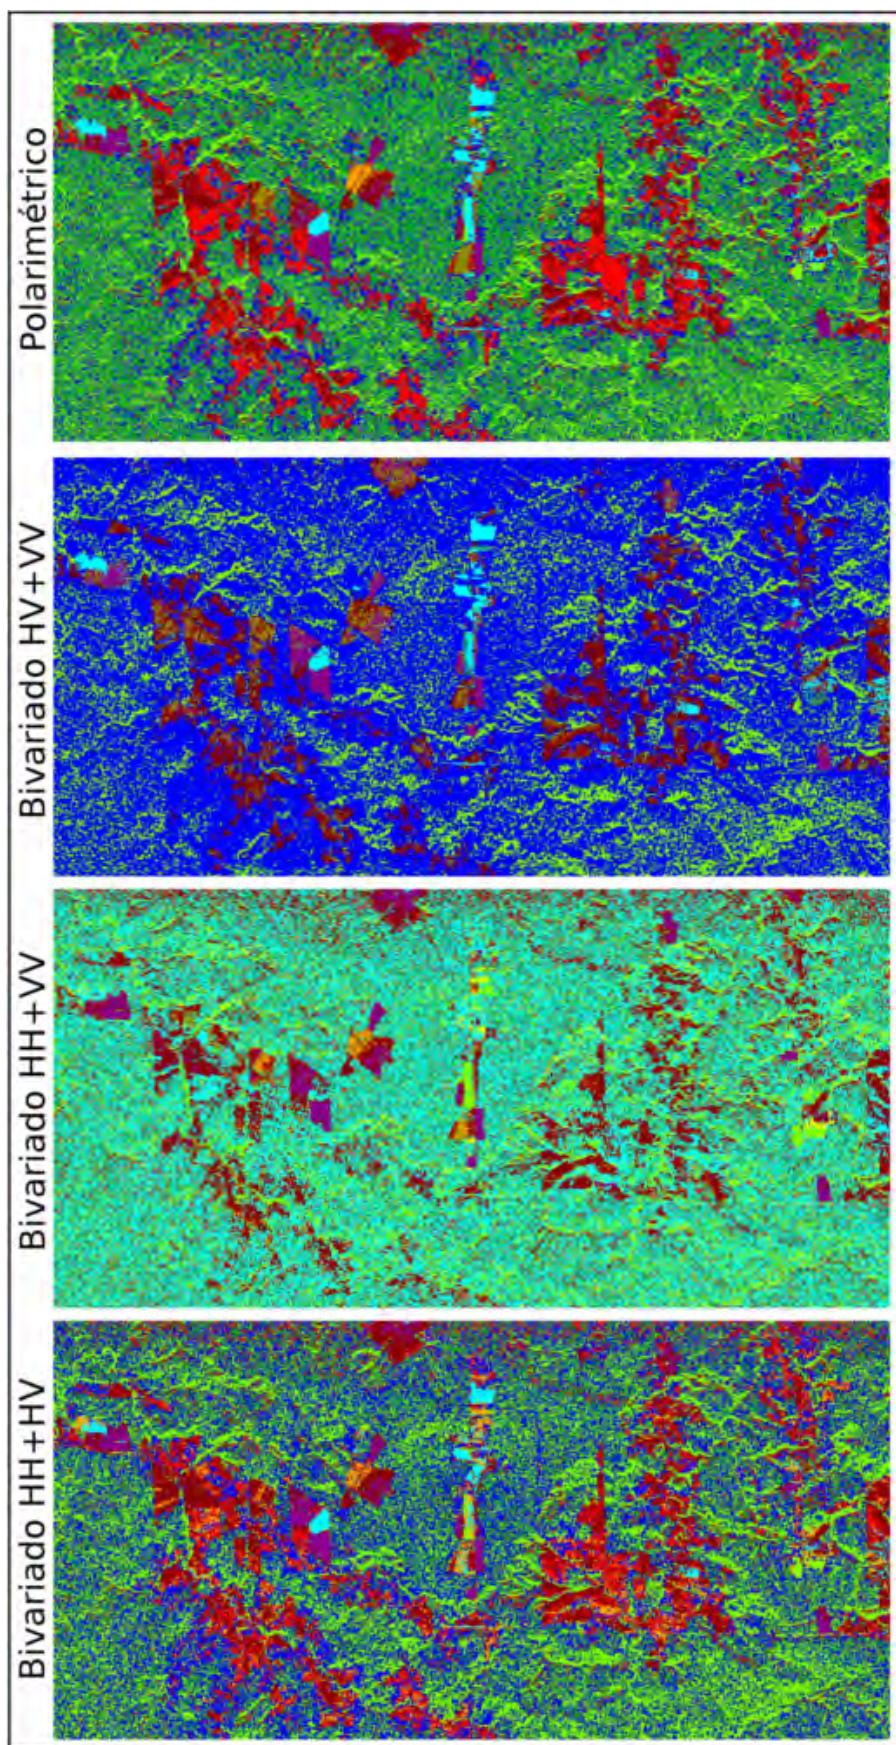


Figura 5.9 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Bivariados e Polarimétricos para o nível de discriminação 1.

5.4 Classificação K-Médias Wishart H/A/ $\bar{\alpha}$

Quando um método de classificação não-supervisionado é adotado, o resultado obtido é um mapa de classes “não rotuladas”, ou seja, as diferentes classes discriminadas não possuem um nome, que inserido num determinado contexto, as distingue das demais. No entanto, com o conhecimento prévio a respeito dos dados classificados, é possível associar cada uma das classes discriminadas a um rótulo.

A Figura 5.10 apresenta a classificação obtida pelo método K-Médias Wishart H/A/ $\bar{\alpha}$, composta por 16 classes. Baseado nas diferentes classes de cobertura da terra identificadas na Seção 4.2, é obtido um novo mapa de classes, resultante da interpretação. A Tabela 5.2 relaciona as diferentes cores (classes não rotuladas) do mapa obtido com as classes de cobertura da terra consideradas neste trabalho.

Como discutido ao fim da Seção 5.2, após a interpretação dos resultados há como definir, também neste caso, uma estrutura de níveis de discriminação dos alvos, utilizando as mesmas informações sobre dissimilaridade e regra de agrupamento, porém, partindo de um nível de discriminação inicial diferente, obtido a partir da interpretação do resultado fornecido pelo método K-Médias Wishart H/A/ $\bar{\alpha}$.

Sob essas considerações, as figuras 5.11 e 5.12 ilustram respectivamente a estrutura de agrupamento hierárquica e a legenda geral para as classificações K-Médias Wishart H/A/ $\bar{\alpha}$ interpretadas. A Figuras 5.13 apresenta os resultados de cada um dos níveis de discriminação considerados.

Tabela 5.2 - Relação entre as classes obtidas pelo método de classificação K-Médias Wishart H/A/ $\bar{\alpha}$ e as classes rotuladas, após a interpretação dos resultados.

Classes (Rótulos)	Representação Inicial (Cor)	Rep. Pós Interpretação (Cor)
PL+PS+AG1	Vermelho	Vermelho
FD	Amarelo e Laranja	Azul
AG2	Azul Claro	Ciano
AG3	Azul Escuro	Laranja Escuro
AG4	Ciano Escuro	Roxo
INDEFINIDA	Magenta	Branco
FP+RA+RI+RN	Classes Remanescentes	Amarelo

Para que os resultados obtidos por este método sejam comparados com os resultados obtidos pelo método MaxVer/ICM, foi determinado que o primeiro nível de discriminação neste caso equivale ao nível 6 definido na Seção 5.2, devido ao mesmo número de classes. Da mesma forma, o último nível de discriminação considerado deve possuir 4 classes.

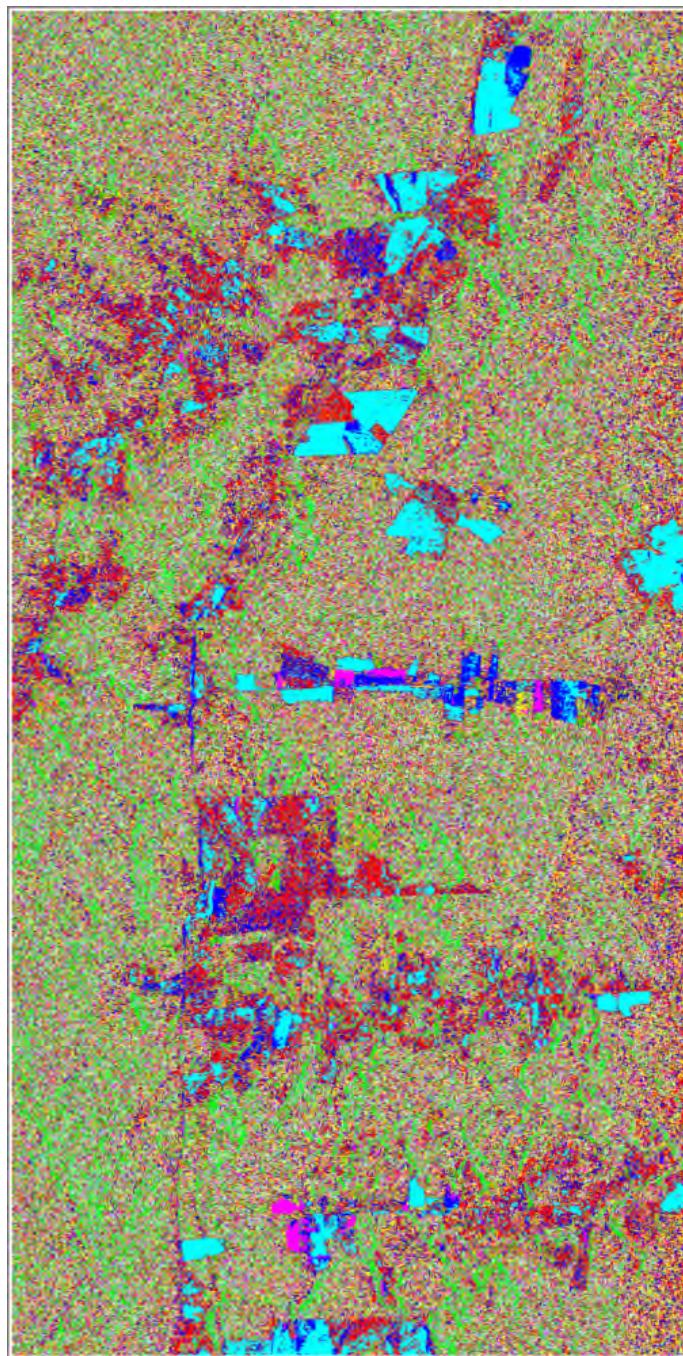


Figura 5.10 - Classificação obtida pelo método de classificação K-Médias Wishart H/A/ $\bar{\alpha}$, constituído de 16 classes.

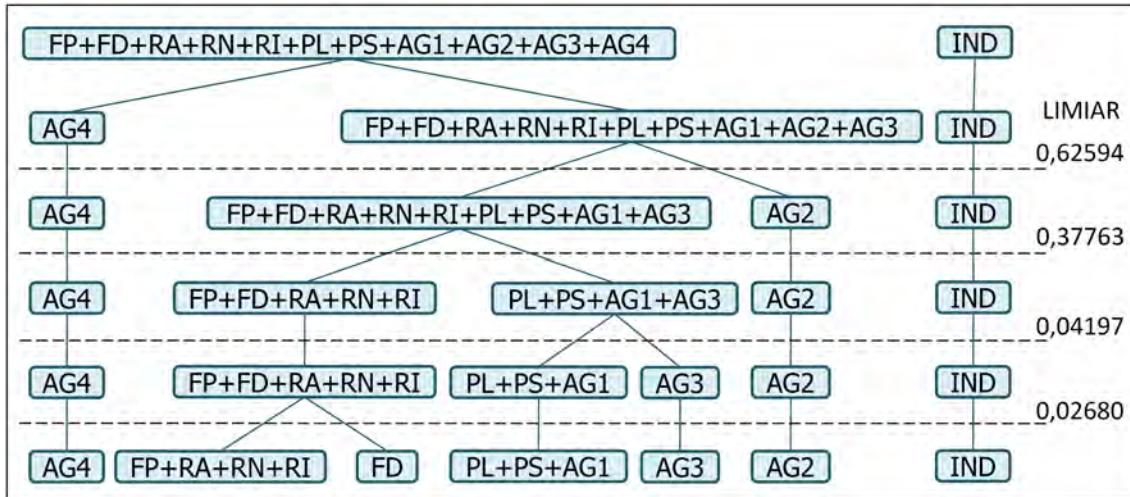


Figura 5.11 - Estrutura dos níveis de discriminação obtida, após interpretação dos resultados e adoção da metodologia proposta, para às classificações geradas pelo método K-Médias Wishart H/A/ $\bar{\alpha}$. O acrônimo IND refere-se as classes indefinidas.

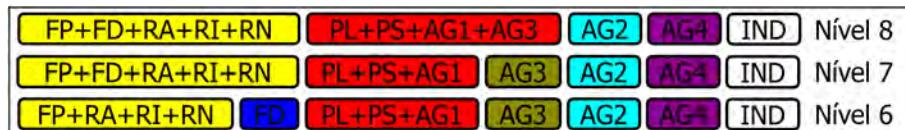


Figura 5.12 - Legenda geral definida para diferentes níveis de discriminação para as classificações K-Médias Wishart H/A/ $\bar{\alpha}$.

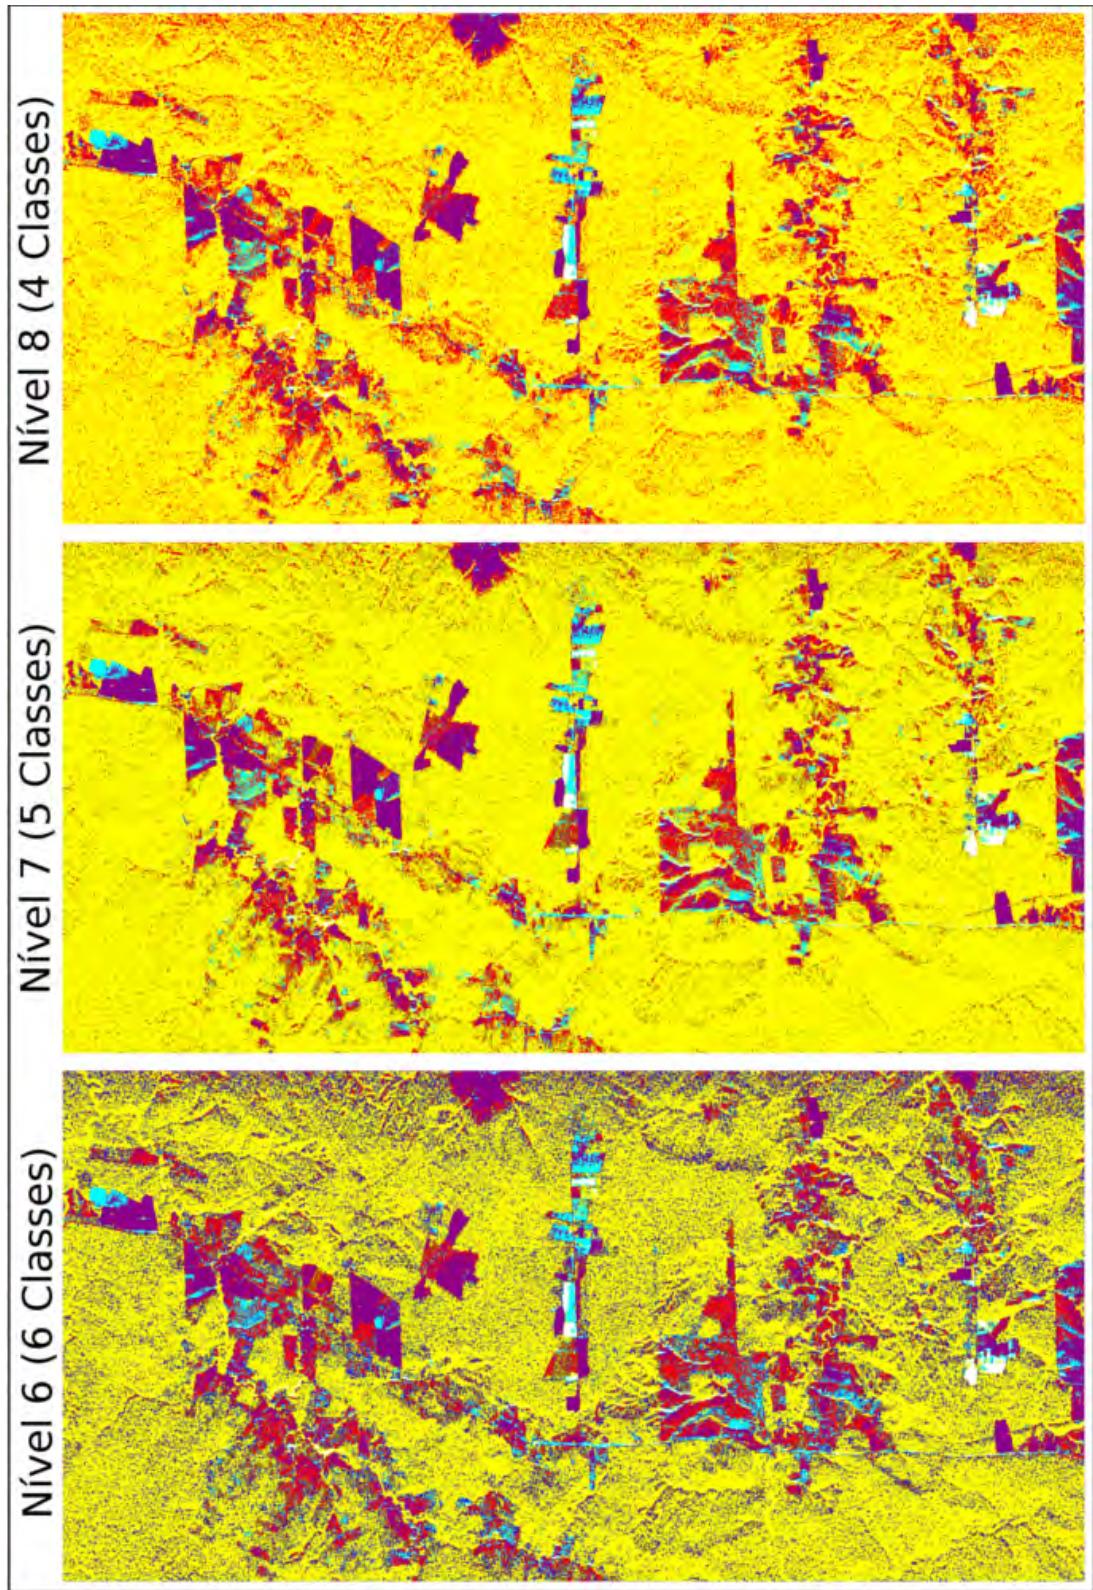


Figura 5.13 - Classificações obtidas após interpretação dos resultados gerados pelo método K-Médias Wishart $H/A/\bar{\alpha}$ para os níveis 6, 7 e 8.

5.5 Análise dos Resultados

Para a análise e discussão dos resultados foram observadas cada uma das imagens classificadas juntamente com as respectivas matrizes de confusão, apresentadas no Apêndice E, e Coeficientes de Concordância *Kappa*⁷.

Para comparar a exatidão da classificação de determinadas classes separadamente, ou ainda, verificar o quanto de erro houve na classificação de uma determinada classe, foram calculadas, a partir das matrizes de confusão, as porcentagens de acertos e erros. Quando uma determinada classe foi analisada perante diferentes níveis de discriminação, estas porcentagens foram calculadas a partir da média das porcentagens destes diferentes níveis.

Em um primeiro momento, o foco da análise dos resultados concentrou-se em descrever a discriminação das diferentes classes de cobertura da terra, como por exemplo, quais conjuntos de dados proporcionaram a discriminação de determinada classe das demais.

Posteriormente, foi analisado o desempenho de forma geral segundo os diferentes conjuntos de dados e métodos de classificação de imagens. Nestas análises o principal indicador de desempenho utilizado foi o índice *kappa*.

Durante a análise destes resultados, quando os diferentes conjuntos Univariados, Bivariados, Multivariados e Polarimétricos são mencionados, imediatamente sabe-se que estes se referem a resultados ou comportamentos relacionados ao método de classificação MaxVer/ICM.

5.5.1 Análise dos Resultados: Discriminação dos Alvos

Inicialmente, foram verificados que os baixos índices *kappa* alcançados nos primeiros níveis de discriminação pelo método MaxVer/ICM é justificado pela “confusão” existente, principalmente, entre as classes RA, RI e RN. É dita que uma classe sofreu confusão quando ocorre a classificação errônea desta por outra classe. Este comportamento pode ser observado nas colunas de referência das matrizes de confusão.

Para as classificações MaxVer/ICM, independente dos conjuntos de dados utilizados, um aumento considerável na exatidão foi proporcionado após a junção das classes FP, FD, RA, RN e RI, a qual ocorre no nível 5.

A análise visual das classificações permitiu concluir que a classe FD é discriminada das demais apenas quando não são empregados os conjuntos HH e HH+VV. Além deste comportamento, verificou-se que a partir do momento em que esta classe é discriminada, ela passa a interferir na classificação das classes FP, RA, RI, RN e suas variações. Para quantificação desta interferência, foram analisadas as matrizes de confusão das classificações que houve discriminação de FD, para os quatro primeiros níveis de discriminação. Em média, foi computado que aproximadamente 25%

⁷A partir deste ponto, por conveniência, o Coeficientes de Concordância *Kappa* será denominada apenas por índices *kappa*

das amostras referentes à classe FP foi classificada erroneamente como sendo da classe FD, para a classe RA esta freqüência foi de 29,2%, 51,9% para RI, 53,7% para RN, 35% para RA+RI, 21,7% para RA+RI+RN e 31,8% para FP+RA+RI+RN. A maior porcentagem média de erro gerado pela classe FD sobre as classes analisadas foi de 62,2%, resultado este gerado pelo conjunto HV+VV. Por outro lado, o conjunto PC proporcionou a menor porcentagem média de erro, dada por aproximadamente 16,2%.

De acordo com o comportamento apresentado pelas classes nas figuras 5.8 e 5.9 é possível verificar que dados Univariados e Bivariados, com exceção do conjunto HH+VV, são incapazes de discriminar as classes AG1 e AG3. Dentre os conjuntos que são capazes de realizar essa discriminação, PC discriminou a classe AG1 com aproximadamente 85% de acerto, e AG3 com 91%, resultados estes extraídos das matrizes de confusão apresentadas nas tabelas E.57 a E.61.

A utilização de dados Polarimétricos, em comparação com dados Multivariados, proporcionou em média a redução de aproximadamente 10% da confusão entre as classes AG1 e AG3. Este comportamento pode estar relacionado a informação de diferença de fase contida nos dados Polarimétricos. Como já apresentado na Figura 5.4, a classe AG3 apresenta um comportamento distinto das demais classes quando analisado o atributo diferença de fase entre HH e VV.

Com relação às classes PS e PL, para discriminação simultânea entre elas, o uso dos conjuntos VV, HH+VV e HV+VV mostraram-se inadequados. Os conjuntos HH+VV e HV+VV não foram capazes de proporcionar uma discriminação satisfatória da classe PL, cujo índice máximo de acerto nesta classe, independente do nível de discriminação analisado e em ambos os conjuntos, foi de 7%. No entanto, o menor índice de acerto referente à classe PS foi de 57%. Já as classificações obtidas pelo conjunto VV, os baixos índices de acerto ocorrem na classe PS, cuja porcentagem média de acerto é de 18,5%. Com relação aos demais conjuntos de dados, os menores índices de acerto com relação às classes PL e PS são obtidos pelo conjunto HH, cuja porcentagem média de acerto é aproximadamente igual a 44% em ambas as classes. Estes resultados podem ser verificados não só visualmente, por exemplo, pelas figuras 5.8 e 5.9, mas também a partir das matrizes de confusão referentes as classificações nos seis primeiros níveis de discriminação, níveis em que as classes PL e PS são classificadas separadamente.

Segundo as classificações apresentadas nas figuras 5.8 e 5.9, pode-se concluir que a discriminação da classe AG2 foi obtida com emprego de quaisquer conjunto composto por duas ou mais componentes. Em praticamente todos os casos, independentemente dos dados utilizados, a classe AG4 foi discriminada de forma satisfatória, com porcentagem de acerto variando entre 67,6 a 100%.

Diante das comparações realizadas na Seção 5.1, verificou-se que as classes AG2 e AG4, assim com as classes de floresta e regenerações, possuem variações de valores radiométricos muito semelhantes, no entanto, ao contrário das classes de floresta e regeneração, estas classes de agricultura foram discriminadas entre si a partir do uso de dados Bivariados, Multivariados e Polarimétricos.

Nos resultados obtidos com a interpretação da classificação gerada pelo método K-Médias Wishart H/A/ $\bar{\alpha}$, não foi possível distinguir entre si as classes RA, RI e RN, e FP, fato este observado durante

a etapa de rotulação das classes (Seção 5.4). Além de a classe FD confundir-se freqüentemente com as classes FP+RA+RI+RN e PL+PS+AG1.

Este método foi incapaz de realizar a discriminação entre as classes PL e PS. Este comportamento torna-se previsto a partir da análise da separabilidade entre estas classes, como apresentado na Figura 5.5.

Embora as classes AG2 e AG3 tenham sido identificadas durante a etapa de interpretação, elas apresentam altos níveis de confusão com as demais classes, ao contrário da classe AG4, discriminada com 100% de acerto. Estas características podem ser verificadas principalmente na Tabela E.65.

Algumas classes discriminadas por este método não puderam ser rotuladas devido a ausência de informação. Nestes casos foram associados à estas classes o rótulo IND (Indefinido). Como durante a validação destes resultados a classe IND não foi detectada, por conveniência, as mesmas não foram inclusas nas Matrizes de Confusão.

5.5.2 Análise dos Resultados: Métodos de Classificação e Dados

Ao analisar os resultados sob o ponto de vista dos conjuntos de dados, conclui-se que a utilização de dados Univariados, como apresentado na Subseção anterior, não é suficiente para distinção de diferentes tipos de classes de cobertura da terra, como por exemplo, AG1, AG2 e AG3. No geral, os mais baixos níveis de exatidão foram obtidos com emprego de dados Univariados HH e VV, como exibido no gráfico da Figura 5.14. O melhor desempenho apresentado pelo conjunto HV é justificado pela capacidade de distinguir um número maior de classes, o que pode ser verificado com a análise visual dos resultados apresentados na Figura 5.8.

Com relação aos dados Bivariados, os conjuntos HH+HV e HV+VV proporcionam bons resultados. Os resultados obtidos a partir desses conjuntos são considerados estatisticamente iguais segundo um Intervalo de Confiança de 95%, definido por um intervalo de dois desvios padrões do índice *kappa*. O desempenho das classificações geradas pelo conjunto HH+VV foram inferiores àquelas geradas pelos conjuntos HH+HV e HV+VV, ao nível de significância de 5%. A diferença absoluta média de índice *kappa* foi de 0,165 para os três primeiros níveis de discriminação (níveis 1 a 3), e de 0,315 para os cinco próximos níveis (níveis 4 a 8). Estes comportamentos podem ser verificados no gráfico da Figura 5.15.

Os resultados gerados a partir de dados Multivariados e Polarimétricos apresentaram entre si maiores diferenças de índice *kappa* nos quatro primeiros níveis de discriminação, cuja diferença absoluta média foi 0,092. Embora o desempenho obtido a partir de dados Polarimétricos seja superior, em ambos os casos as classificações foram qualificadas, segundo Landis e Koch (1977), entre “Bom”, “Muito Bom” e “Excelente” para todos os níveis analisados, ao contrário das demais classificações.

As classificações obtidas a partir do método K-Médias Wishart H/A/ $\bar{\alpha}$, apresentou apenas no nível 6 desempenho superior ao método MaxVer/ICM associado a dados Univariados HV. No entanto,

quando o método MaxVer/ICM foi associado a dados Bivariados HH+HV e Polarimétricos, o desempenho apresentado pelo método K-Médias Wishart H/A/ $\bar{\alpha}$ foi inferior em todos os níveis de discriminação.

O gráfico da Figura 5.16 compara o desempenho dos classificadores MaxVer/ICM, associado a dados Multivariados e Polarimétricos, e K-Médias Wishart H/A/ $\bar{\alpha}$.

Os maiores desvios padrões do Coeficiente de Concordância *Kappa* ocorreram nas classificações K-Médias Wishart H/A/ $\bar{\alpha}$ e MaxVer/ICM, associado ao conjunto de dados Bivariados HH+HV e HV+VV.

Os Coeficientes de Concordância *Kappa* obtidos com uso de dados Univariados VV e Bivariados HH+VV são próximos, com diferença absoluta média de 0,03. Porém, esta comparação faz sentido apenas quando comparados os resultados dos níveis 7 e 8. Como já mencionado, os níveis 1 a 6 possuem certas classes que não são discriminadas a partir de dados Univariados VV.

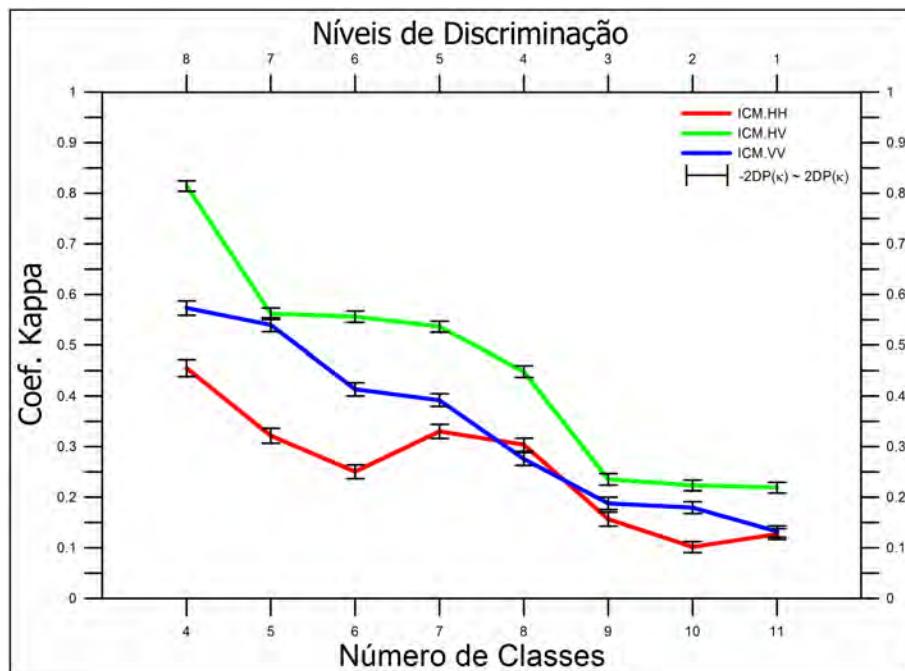


Figura 5.14 - Desempenho das classificações a partir de dados Univariados nos diferentes níveis de discriminação segundo o Coeficiente de Concordância *Kappa*.

O gráfico da Figura 5.17 apresenta os melhores casos, dentre todos analisados. Neste gráfico é possível verificar que o método MaxVer/ICM associado a dados Polarimétricos, além de apresentar resultados superiores, para os três primeiros níveis de discriminação (níveis 1, 2 e 3), a separação entre as classes aumentou gradativamente, ao contrário dos dados Univariados HV e Bivariados HH+HV. A partir do nível 5, a diferença de exatidão entre os resultados gerados com o emprego

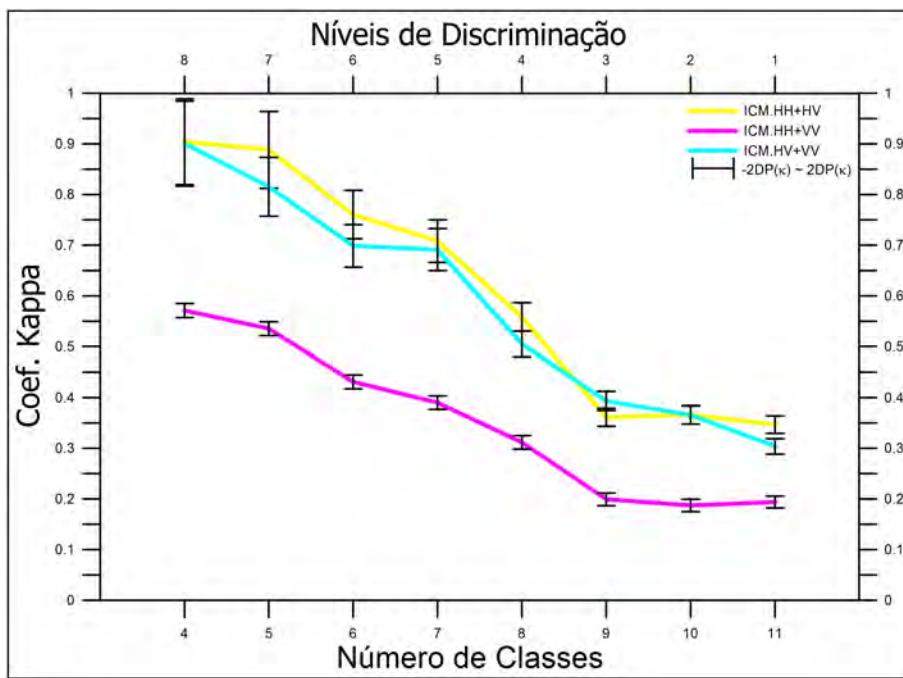


Figura 5.15 - Desempenho das classificações a partir de dados Bivariados nos diferentes níveis de discriminação segundo o Coeficiente de Concordância *Kappa*.

de dados Bivariados HH+HV e Polarimétricos diminui. Além disso, é possível afirmar que os resultados de ambos os casos a partir do nível 6 são estatisticamente iguais. Com relação aos dados Univariados HV, seu desempenho é inferior em todos os níveis de discriminação.

As tabelas 5.3 a 5.11 fornecem numericamente os índices de exatidão indicados nos gráficos das figuras 5.14 a 5.17, juntamente com o índice de Acurácia Global e qualificação nominal, proposta por Landis e Koch (1977), para cada um dos níveis de discriminação.

As matrizes de confusão das classificações realizadas são apresentadas no Apêndice E. Os mapas gerados pelas classificações estão disponíveis no Apêndice F.

As figuras 5.18 e 5.19 ilustram as classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados HV, Bivariados HH+HV e Polarimétricos segundo os níveis de discriminação indicados 5 e 7.

Para efeito de comparação, a Figura 5.20 apresenta resultados obtidos pelos dados Univariados HV, Bivariados HH+HV e Polarimétricos, porém, para uma configuração de classes definida empiricamente. Para isso, foram consideradas as seguintes classes: Floresta Primária (Amarelo), Floresta degradada (Azul), Regeneração Nova (Verde), Solo Exposto (Roxo - equivalente à classe AG4), Agricultura (Laranja Escuro - equivalente à classe AG1+AG2+AG3) e Pastagem (Vermelho - equivalente à classe PL+PS).

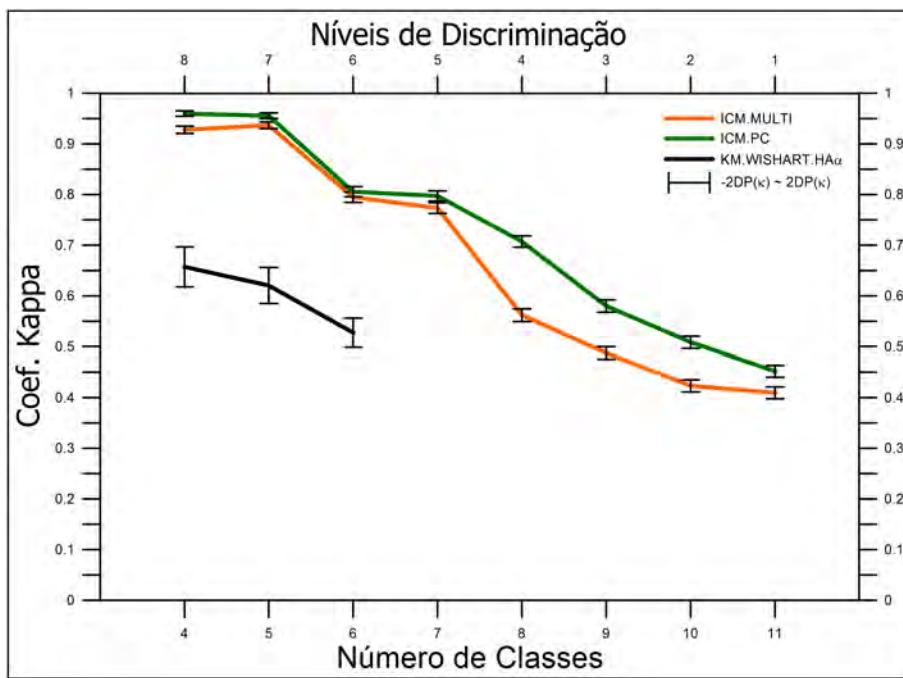


Figura 5.16 - Desempenho das classificações obtidas pelos métodos K-Médias Wishart H/A/ $\bar{\alpha}$ e MaxVer/ICM, associado a dados Multivariados e Polarimétricos, segundo o Coeficiente de Concordância *Kappa*.

Nestes casos os índices *kappa* foram de 0,497; 0,728 e 0,784 respectivamente para os conjuntos HH, HH+HV e PC. Comparando a acurácia destes resultados com as acuráncias do nível de discriminação 6, uma vez que ambos possuem o mesmo número de classes, verifica-se que esta configuração proporciona desempenho pior independente do conjunto de dados. Este breve resultado ilustra a importância de um estudo sobre a relações existentes entre as classes utilizadas em tarefas de classificação, pois, é garantida a consistência entre as classes e por sua vez, são proporcionados melhores resultados.

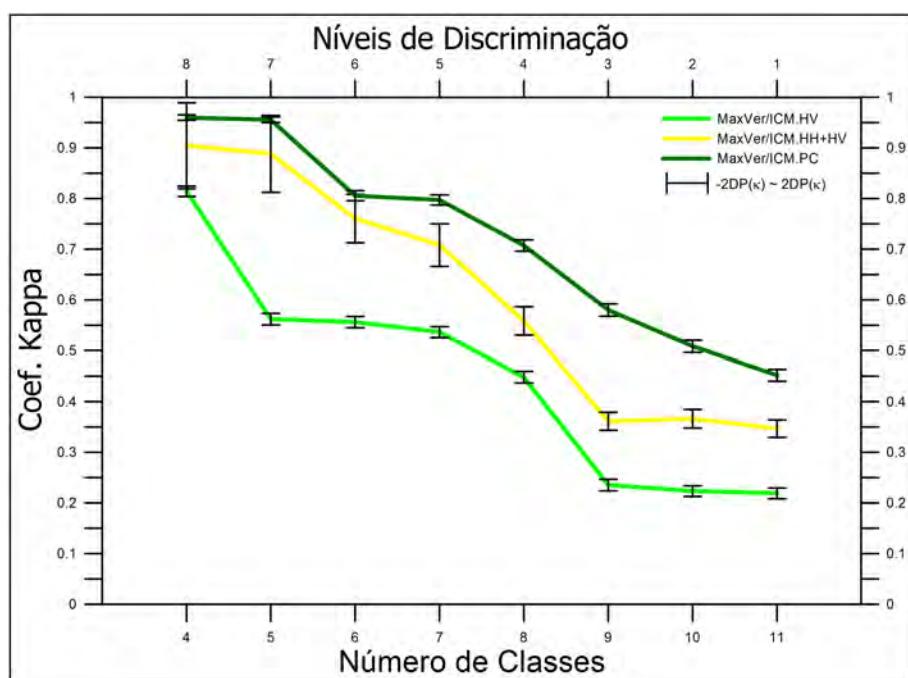


Figura 5.17 - Desempenho das classificações com melhores resultados segundo Índice de Concordância *Kappa*.

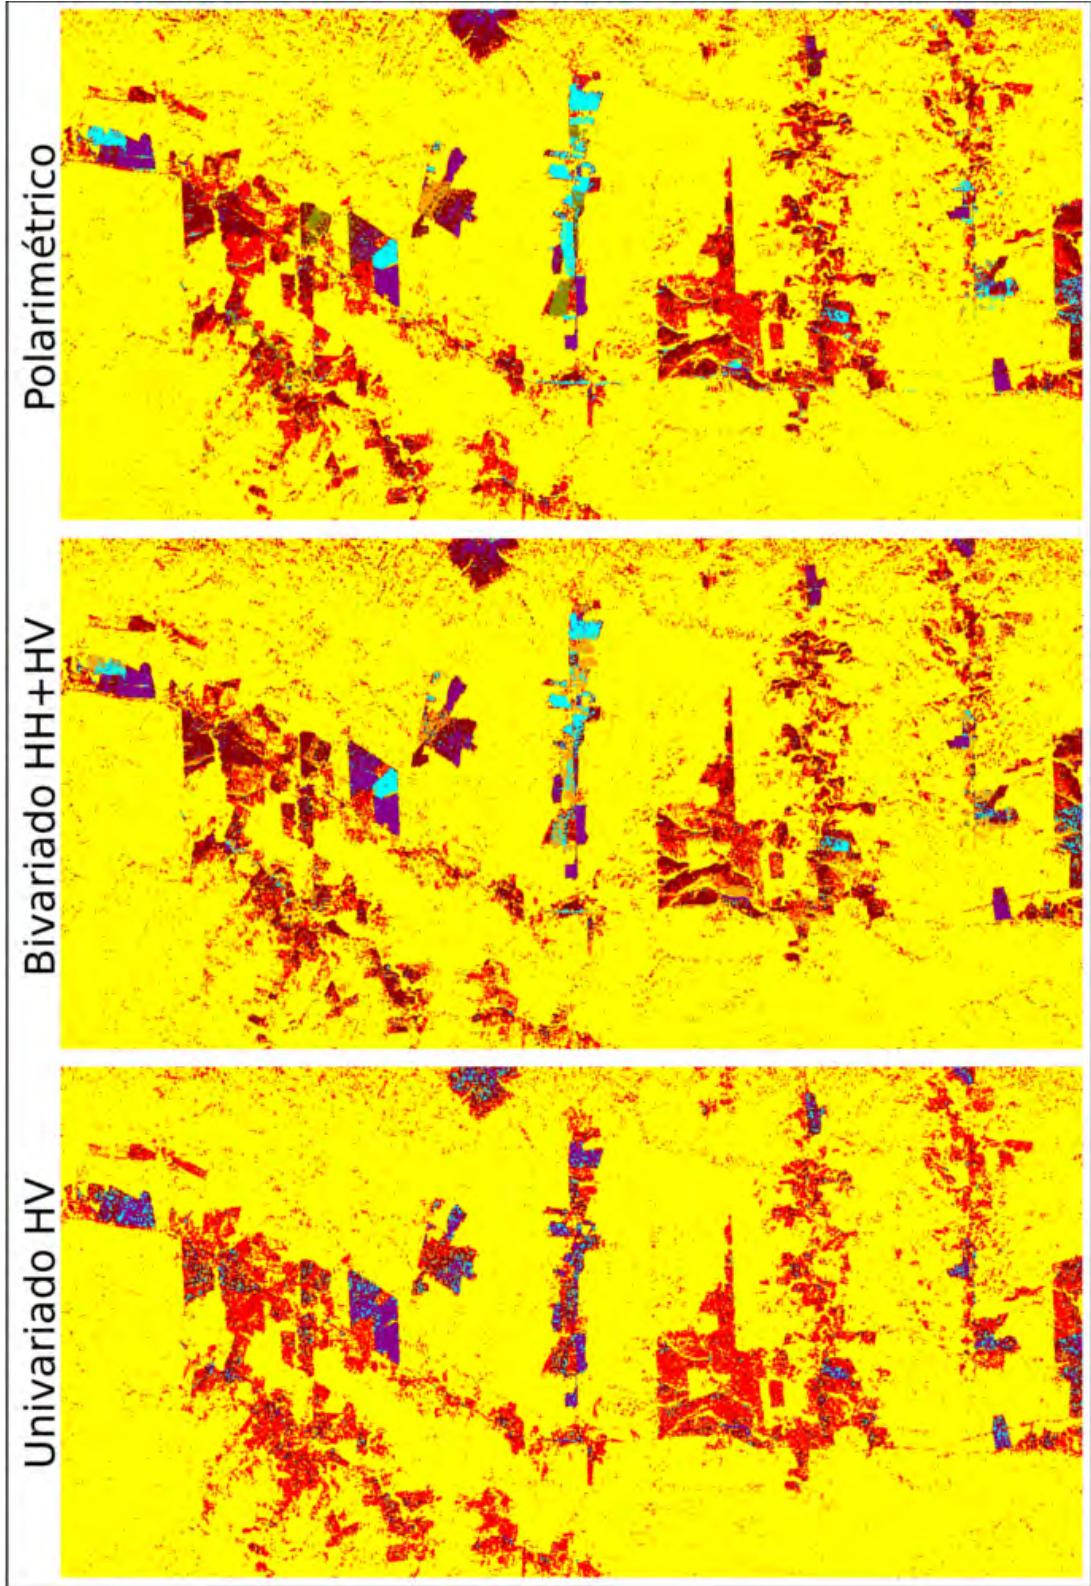


Figura 5.18 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados HV, Bivariados HH+HV e Polarimétricos para o Nível 5.

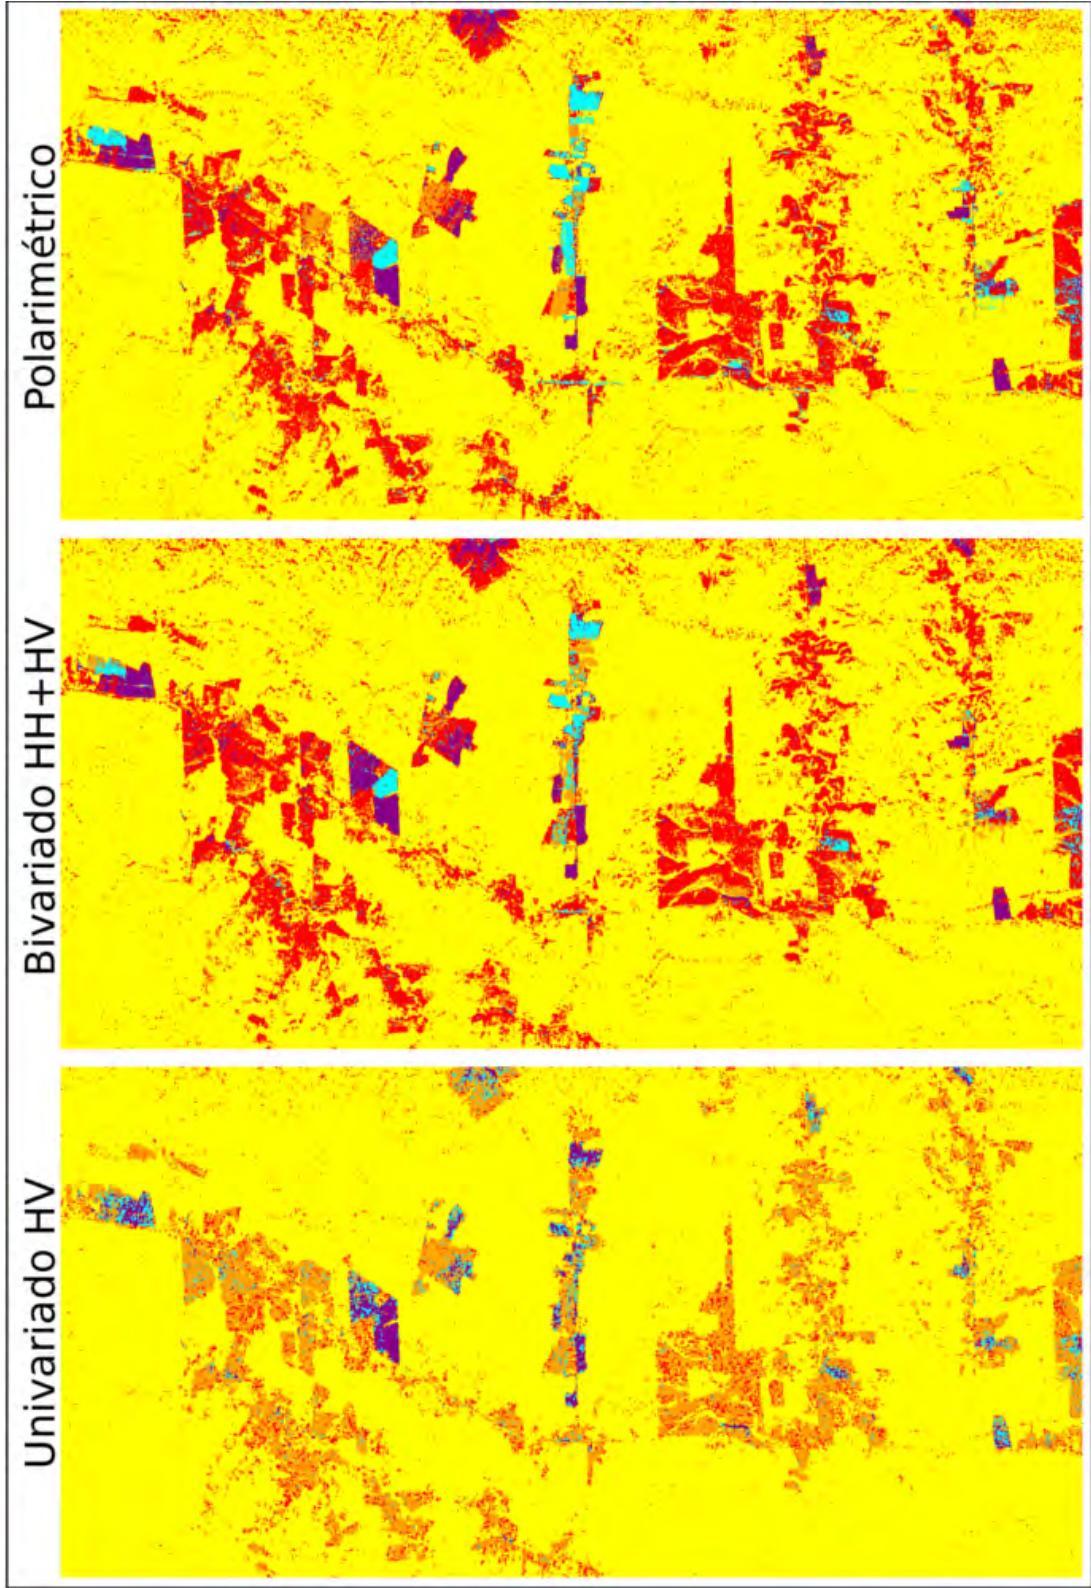


Figura 5.19 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados HV, Bivariados HH+HV e Polarimétricos para o Nível 7.

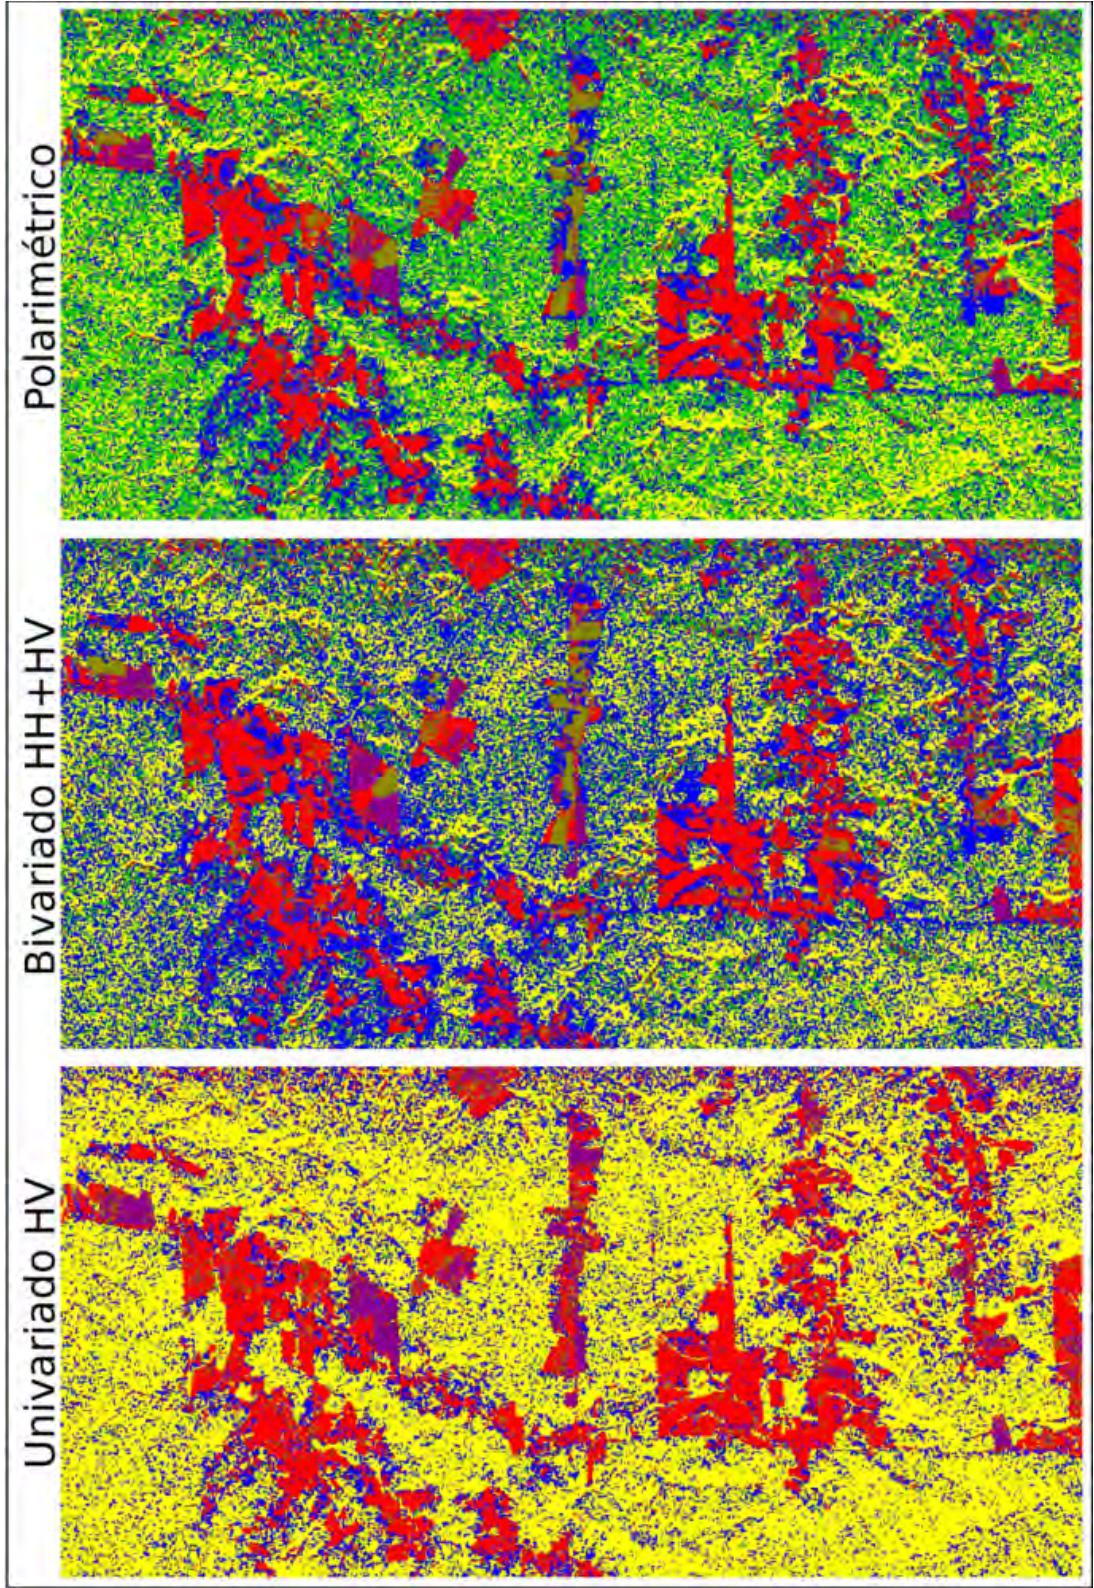


Figura 5.20 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados HV, Bivariados HH+HV e Polarimétricos para um cenário definido intuitivamente.

Tabela 5.3 - Desempenho e qualificação dos resultados obtidos a partir do método Max-Ver/ICM com emprego de dados Univariados HH.

Num. Classes	Nível	Coef. Kappa	Var. Kappa	Ac. Global (%)	Qualificação
4	8	0,455	0,0000694	68,749	Bom
5	7	0,322	0,0000551	50,663	Razoável
6	6	0,251	0,0000462	42,193	Razoável
7	5	0,330	0,0000464	53,370	Razoável
8	4	0,304	0,0000420	49,989	Razoável
9	3	0,157	0,0000474	25,837	Ruim
10	2	0,102	0,0000294	21,815	Ruim
11	1	0,128	0,0000283	22,602	Ruim

Tabela 5.4 - Desempenho e qualificação dos resultados obtidos a partir do método Max-Ver/ICM com emprego de dados Univariados HV.

Num. Classes	Nível	Coef. Kappa	Var. Kappa	Ac. Global (%)	Qualificação
4	8	0,814	0,0000252	88,621	Excelente
5	7	0,562	0,0000322	70,321	Bom
6	6	0,556	0,0000315	69,681	Bom
7	5	0,536	0,0000292	68,030	Bom
8	4	0,448	0,0000321	57,425	Bom
9	3	0,235	0,0000327	30,948	Razoável
10	2	0,224	0,0000284	29,712	Razoável
11	1	0,219	0,0000279	29,847	Razoável

Tabela 5.5 - Desempenho e qualificação dos resultados obtidos a partir do método Max-Ver/ICM com emprego de dados Univariados VV.

Num. Classes	Nível	Coef. Kappa	Var. Kappa	Ac. Global (%)	Qualificação
4	8	0,573	0,0000504	74,972	Bom
5	7	0,540	0,0000464	71,501	Bom
6	6	0,413	0,0000412	58,964	Bom
7	5	0,392	0,0000398	57,268	Razoável
8	4	0,276	0,0000418	40,384	Razoável
9	3	0,188	0,0000377	31,016	Ruim
10	2	0,180	0,0000344	30,162	Ruim
11	1	0,132	0,0000320	22,377	Ruim

Tabela 5.6 - Desempenho e qualificação dos resultados obtidos a partir do método Max-Ver/ICM com emprego de dados Bivariados HH+HV.

Num. Classes	Nível	Coef. Kappa	Var. Kappa	Ac. Global (%)	Qualificação
4	8	0,904	0,0017954	94,114	Excelente
5	7	0,888	0,0014346	92,743	Excelente
6	6	0,761	0,0005733	83,734	Muito Bom
7	5	0,708	0,0004409	80,004	Muito Bom
8	4	0,558	0,0001994	64,514	Bom
9	3	0,361	0,0000779	42,024	Razoável
10	2	0,367	0,0000841	43,271	Razoável
11	1	0,347	0,0000744	40,508	Razoável

Tabela 5.7 - Desempenho e qualificação dos resultados obtidos a partir do método Max-Ver/ICM com emprego de dados Bivariados HH+VV.

Num. Classes	Nível	Coef. Kappa	Var. Kappa	Ac. Global (%)	Qualificação
4	8	0,571	0,0000473	71,231	Bom
5	7	0,535	0,0000468	66,120	Bom
6	6	0,431	0,0000465	56,785	Bom
7	5	0,390	0,0000455	53,336	Razoável
8	4	0,312	0,0000446	43,215	Razoável
9	3	0,199	0,0000392	27,814	Ruim
10	2	0,187	0,0000371	26,713	Ruim
11	1	0,194	0,0000344	27,185	Ruim

Tabela 5.8 - Desempenho e qualificação dos resultados obtidos a partir do método Max-Ver/ICM com emprego de dados Bivariados HV+VV.

Num. Classes	Nível	Coef. Kappa	Var. Kappa	Ac. Global (%)	Qualificação
4	8	0,901	0,0017564	93,990	Excelente
5	7	0,815	0,0008431	88,272	Excelente
6	6	0,698	0,0004398	79,993	Muito Bom
7	5	0,691	0,0004250	79,477	Muito Bom
8	4	0,505	0,0001587	59,548	Bom
9	3	0,393	0,0000902	45,922	Razoável
10	2	0,366	0,0000793	43,024	Razoável
11	1	0,304	0,0000587	36,789	Razoável

Tabela 5.9 - Desempenho e qualificação dos resultados obtidos a partir do método Max-Ver/ICM com emprego de dados Multivariados.

Num. Classes	Nível	Coef. Kappa	Var. Kappa	Ac. Global (%)	Qualificação
4	8	0,928	0,0000127	95,608	Excelente
5	7	0,937	0,0000104	95,889	Excelente
6	6	0,795	0,0000260	85,947	Muito Bom
7	5	0,773	0,0000274	84,386	Muito Bom
8	4	0,562	0,0000387	63,930	Bom
9	3	0,487	0,0000382	54,898	Bom
10	2	0,423	0,0000357	47,967	Bom
11	1	0,410	0,0000341	46,405	Bom

Tabela 5.10 - Desempenho e qualificação dos resultados obtidos a partir do método Max-Ver/ICM com emprego de dados Polarimétricos.

Num. Classes	Nível	Coef. Kappa	Var. Kappa	Ac. Global (%)	Qualificação
4	8	0,960	0,0000073	97,551	Excelente
5	7	0,955	0,0000075	97,113	Excelente
6	6	0,806	0,0000243	86,756	Excelente
7	5	0,797	0,0000250	86,104	Muito Bom
8	4	0,707	0,0000311	77,410	Muito Bom
9	3	0,580	0,0000374	64,997	Bom
10	2	0,508	0,0000369	56,954	Bom
11	1	0,452	0,0000347	50,517	Bom

Tabela 5.11 - Desempenho e qualificação dos resultados obtidos com emprego do método K-Médias Wishart H/A/ $\bar{\alpha}$.

Num. Classes	Nível	Coef. <i>Kappa</i>	Var. <i>Kappa</i>	Ac. Global (%)	Qualificação
4	8	0,657	0,0003898	78,084	Muito Bom
5	7	0,620	0,0003167	74,579	Muito Bom
6	6	0,527	0,0002011	65,390	Bom

6 CONCLUSÕES E PERSPECTIVAS

O objetivo deste trabalho foi avaliar o potencial das imagens do sensor ALOS PALSAR para utilização em tarefas de mapeamento de classes de cobertura da terra na Amazônia.

Tendo isso em vista, foi necessário avaliar uma série de informações, coletar diferentes amostras de classes de cobertura da terra e definir diferentes níveis de discriminação, o que por fim permitiu verificar a capacidade dos dados e métodos de classificação utilizados em separar diferentes classes de cobertura da terra.

Com relação aos métodos de classificação de imagens SAR empregados, o método K-Médias Wishart H/A/ $\bar{\alpha}$ proporcionou bons resultados, porém, os melhores Coeficientes de Concordância *Kappa* foram alcançados pelo método MaxVer/ICM.

Dentre todas as classificações analisadas, considerando o número de classes discriminadas e o nível de exatidão das classificações, são indicados os níveis de discriminação 5, 6 e 7, definidos pelas classes compostas pelos diferentes tipos de florestas e regenerações, Pasto Limpo, Sujo e sua combinação, Agricultura Tipo 1, Tipo 3 e sua combinação, Agricultura Tipo 2 e Agricultura Tipo 4.

As diferentes classes de regeneração selecionadas, independente de métodos e dados, não foram discriminados entre si, e foram associadas por sua vez as classes de Floresta Primária e Degrada. Este resultado fortalece as evidências de que esses alvos dificilmente são discriminados com uso de imagens polarimétricas em banda L, como mencionado por [Guerra \(2008\)](#).

O emprego da informação de fase pelo método MaxVer/ICM proporcionou melhor discriminação entre determinadas classes de Agricultura (Agricultura Tipo 1 e 3), o que justifica sua importância como atributo polarimétrico.

O uso de apenas uma Componente pelo método MaxVer/ICM foi insuficiente para discriminação, principalmente das diferentes classes de Pastagem e Agricultura.

Já o uso da informação de duas componentes, ambas não co-polarizadas, pelo método MaxVer/ICM mostra-se suficiente para discriminação de alvos englobados pelos níveis de discriminação indicados (níveis 5, 6 e 7), uma vez que os resultados obtidos com emprego de dados Multivariados e Polarimétricos, nestes níveis, são próximos.

Dessa forma, considerando o custo inserido, seja computacional, relacionado a complexidade e processamento, ou quanto à disponibilidade de dados Polarimétricos, o emprego de dados Bivariados HH+HV, denominado “Modo Operacional⁸”, é o conjunto de dados indicado para estudos relacionados ao mapeamento de florestas tropicais.

Como perspectiva para trabalhos futuros, pode-se listar:

⁸Modo Operacional é a configuração de polarização padrão utilizada pelo sensor para aquisição freqüente de dados. A coleta de informações nas demais configurações de polarizações ocorre esporadicamente, portanto, não é operacional.

- Desenvolvimento de FDPs para dados Bivariados que modele alvos segundo diferentes graus de homogeneidade;
- Desenvolvimento de medidas de dissimilaridade que sejam calculadas a partir de dados Polarimétricos Complexos;
- Estudo e desenvolvimento de métodos de classificação de imagens SAR baseados na informação textural dos alvos;
- Utilização de imagens de alta resolução como fonte de informação para seleção de classes de cobertura da terra;
- Estudo detalhado sobre efeitos causados, principalmente sobre a informação de fase, quando realizadas correções geométricas e re-amostragem dos dados;
- Desenvolver e testar métodos de classificação que utilizem outros atributos polarimétricos, como por exemplo, a Superfícies de Resposta Polarimétrica.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALBERGA, V. **Comparison of polarimetric methods in image classification and SAR interferometry.** Tese (Doutorado) — Tech. University of Chemnitz, 2004. 31
- ALVES, D. S. Science and technology and sustainable development in Brazilian Amazon In: TSCHARNTKE T; LEUSCHNER C; ZELLER M; GUHARDJA E; BIDIN A. (Orgs.). **The stability of tropical rainforest margins, linking ecological, economic and social constraints of land use and conservation.** Verlag - Berlin: Springer, 2007. 493-512 p. 29
- ANDRADE, N. S. O.; SANTA ROSA, A. N. C.; FARIA, P. C. C. Matrizes de espalhamento utilizadas na polarimetria sar e o teorema da reciprocidade. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis - Brasil. **Anais...** Florianópolis: SBSR, 2007. p. 4783–4790. 33
- BOERNER, T.; PAPATHANASSIOU, K. P.; MARQUART, N.; ZINK, M.; MEININGER, M.; MEADOWS, P. J.; RYE, A. J.; WRIGHT, P.; TELL, B. R. ALOS PALSAR product verification. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS'07), 2007, Barcelona. **Proceedings...** Barcelona: IEEE, 2007. 59, 60
- BOERNER, W. M. **Basics concepts in radar polarimetry.** 2007. Disponível em: <http://earth.esa.int/landtraining07/polsar_basic_concepts.pdf>. 29
- BRASIL. **Plano Amazônia Sustentável.** Brasília: Presidência da República, Maio 2006. 102 p. 29
- CAMARGO, E. C. G.; DRUCK, S.; CÂMARA, G. **Análise de superfícies por geoestatística linear.** [S.l.]: Platina - Embrapa Cerrados, 2004. 129
- CLOUDE, S. R.; POTTIER, E. A review of target decomposition theorems in radar polarimetry. **IEEE Transaction on Geoscience and Remote Sensing**, v. 34, n. 2, p. 498–518, 1996. 33, 35, 36, 81
- _____. An entropy based classification scheme for land applications of polarimetric SAR. **IEEE Transaction on Geoscience and Remote Sensing**, v. 35, n. 1, p. 68–78, 1997. 44
- COELHO, A. S. **Modelagem de dinâmica do uso da terra na região de Santarém.** Mestrado em Ciências Ambientais — Universidade Federal do Pará, 2009. 66
- CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices.** New York: Lewis Publisher, 1999. 137 p. 45
- CORREIA, A. H. **Desenvolvimento de classificadores de máxima verossimilhança e ICM para imagens SAR polarimétricas.** 275 p. Tese (Mestrado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1999. 30, 39, 40, 76, 115
- CORREIA, A. H. **Polarimetria e interferometria de dados SAR: fundamentos e aplicações para uso e cobertura da terra.** 193 p. Exame de Qualificação de Doutorado — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005. 37

ESCADA, M. I. S.; KAMPEL, S. A.; RENNÓ, C. D.; PINHEIRO, T. F. **Levantamento do uso e cobertura da terra e da rede de infra-estrutura no distrito florestal da BR-163.**

Instituto Nacional de Pesquisas Espaciais, 2009. Projeto Integrado de Modelagem da Cobertura da Terra no Pará. 49, 50

FISHER, N. I. **Statistical analysis of circular data.** Cambridge: University Press, 1993. 79

FREITAS, C. C.; FRERY, A. C.; CORREIA, A. H. The polarimetric G distribution for SAR data analysis. **Environmetrics**, v. 16, p. 13–31, 2005. 39

FREITAS, C. C.; SANT'ANNA, S. J. S.; RENNÓ, C. D.; CORREIA, A. H. **Utilização de imagens de radar de abertura sintética na classificação de uso e ocupação do solo.** São José dos Campos: [s.n.], 2007. Disponível em:
[39, 41](http://sid.inpe.br/mtc-m17@80/2007/08.10.18.20)

FREITAS, C. C.; SOLER, L. S.; SANT'ANNA, S. J. S.; DUTRA, L. V.; SANTOS, J. R.; MURA, J. C.; CORREIA, A. H. Land use and land cover mapping in brazilian Amazon using polarimetric P-band SAR data. **IEEE Transactions on Geoscience and Remote Sensing**, 2008. Inpress. 29

FRERY, A. C. **Algumas ferramentas estatísticas na síntese, processamento e análise de imagens de radar de abertura sintética.** 127 p. Tese (Doutorado em Computação Aplicada) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1993. 39

FRERY, A. C.; CORREIA, A. H.; FREITAS, C. C. Classifying multifrequency fully polarimetric imagery with multiple sources of statistical evidence and contextual information. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, n. 10, p. 3098–3108, October 2007. 30, 39, 129, 130

FRERY, A. C.; MÜLLER, H. J.; YANASSE, C. C. F.; SANT'ANNA, S. J. S. A model for extremely heterogeneous clutter. **IEEE Transaction on Geoscience and Remote Sensing**, v. 35, n. 3, p. 648–659, 1997. 39

GABOARDI, C. **Utilização de imagem de coerência SAR para classificação do uso da terra: Floresta Nacional de Tapajós.** 139 p. Tese (Mestrado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2003. 46

GUERRA, J. B. **Avaliação do potencial de dados SAR R99B para discriminar incremento de desflorestamento na Amazônia.** 127 p. Tese (Mestrado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2008. 30, 109

HALLIDAY, D.; RESNICK, R.; WALKER, J. **Fundamentos de física:** gravitação, ondas e termodinâmica. 7. ed. [S.l.]: LTC, 2006. 304 p. 115

HELLMANN, M. **SAR polarimetry tutorial.** 2001. 2007 October. Disponível em:
[32, 36](http://www.fpk.tuberlin.de/~anderl/epsilon/polarimetrtutorial.pdf)

HENDERSON, F. M.; LEWIS, A. J. **Manual of remote sensing:** principles and applications of imaging radar. 3. ed. New York: John Wiley & Sons, 1998. 868 p. 79

- HOEKMAN, D. H.; QUIÑONES, M. J. Land cover type and biomass classification using AirSAR data for evaluation of monitoring scenarios in the colombian Amazon. **IEEE Transaction on Geoscience and Remote Sensing**, v. 38, n. 2, p. 685–695, 2000. [29](#)
- INPE. **Programa de cálculo do desflorestamento da Amazônia**. Fevereiro 2009. Disponível em: <<http://www.obt.inpe.br/prodes/>>. [29](#)
- LANDIS, J. R.; KOCH, C. H. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 3, p. 159–174, Mar 1977. [47](#), [98](#), [100](#)
- LEE, J. S.; GRUNES, M. R.; AINSWORTH, T. L.; LI-JEN, D.; SCHULER, D. L.; CLOUDE, S. R. Unsupervised classification using polarimetric decomposition and the complex Wishart classifier. **IEEE Transaction on Geoscience and Remote Sensing**, v. 37, n. 5, p. 2249–2258, Sept. 1999. [44](#)
- LEE, J. S.; MILLER, A.; HOPPEL, K. Statistics of phase difference and product magnitude of multi-look processed gaussian signals. **Waves in Random Media**, v. 4, p. 3007–319, 1994. [39](#)
- LEE, J. S.; SCHULER, D. L.; LANG, R. H.; RANSON, K. J. K distribution for multilook processed polarimetric SAR imagery. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS'94), 1994, Pasadena. **Proceedings...** Pasadena: IEEE, 1994. p. 2179–2181. [39](#), [40](#), [42](#), [76](#)
- LUSCH, D. P. **Introduction to microwave remote sensing**. [S.l.], 1999. [62](#)
- MORAES, B. C.; COSTA, J. M. N.; COSTA, A. C. L.; COSTA, M. H. Variação espacial e temporal da precipitação no Estado do Pará. **Acta Amazonica**, v. 35, n. 2, p. 207–214, 2005. [52](#)
- MORAIS, M. C. **Discriminação de lateritas mineralizadas em ferro no depósito N1 (Carajás-PA) por radar imageador: uma avaliação através de classificação textural**. 193 p. Dissertação de Mestrado em Sensoriamento Remoto — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1998. [59](#)
- NASCIMENTO, A. D. C. **Contrast measure and stochastic distances in a model for speckled data**. 161 p. Dissertation of Masters in Statistics — Department of Statistics at Federal University of Pernambuco, Recife, 2008. [74](#)
- POTTIER, E.; LEE, J. S. Application of the H/A/ $\bar{\alpha}$ polarimetric decomposition theorem for unsupervised classification of fully polarimetric SAR data based on the Wishart distribution. In: Harris, R. A.; Ouwehand, L. (Ed.). **SAR workshop: CEOS Committee on Earth Observation Satellites**. [s.n.], 2000. (ESA Special Publication, v. 450), p. 335. Provided by the SAO/NASA Astrophysics Data System. Disponível em: <<http://adsabs.harvard.edu/abs/2000ESASP..450..335P>>. [45](#)
- RICHARDS, J. A. **Remote sensing digital image analysis**. Berlim: Springer-Verlag, 1986. 357 p. [38](#), [43](#), [75](#)
- SANTOS, J. R.; MURA, J. C.; PARADELLA, W. R.; DUTRA, L. V.; GONÇALVES, F. G. Mapping recent deforestation in the brazilian Amazon using simulated L-band MAPSAR images. **International Journal of Remote Sensing**, v. 29, n. 16, p. 4879–4884, 2008. [29](#)

- SHIMADA, M. **ALOS handbook**. 2007. Acesso em Fevereiro de 2008. Disponível em: <http://www.eorc.jaxa.jp/ALOS/doc/alon_userhb_en.pdf>. 50, 51, 59
- SHIMADA, M.; ISOGUCHI, O.; TADONO, T.; HIGUCHI, R.; ISONO, K. PALSAR CALVAL summary and update 2007. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS'07), 2007, Barcelona. **Proceedings...** Barcelona: IEEE, 2007. 59, 60
- SRIVASTAVA, M. On the complex Wishart distribution. **Annals of Mathematical Statistics**, v. 36, p. 313–315, 1963. 40
- SUGA, Y.; TAKEUCHI, S. Application of JERS-1 InSAR for monitoring deforestation of tropical rain forest. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS'00), 2000, Hawaii. **Proceedings...** Hawaii: IEEE, 2000. p. 432–434. 29
- THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern recognition**. 4. ed. San Diego: Academic Press, 2006. 74
- ULABY, F. T.; DUBOIS, P. C.; van Zyl, J. Radar mapping of surface soil moisture. **Journal of Hydrology**, v. 184, p. 57–84, 1996. 52
- ULABY, F. T.; ELACHI, C. **Radar polarimetry for geoscience applications**. [S.l.]: Norwood Artech House Inc, 1990. 364 p. 31, 33, 59
- VENTURIERI, A. **Zoneamento ecológico-econômico da área de influência da rodovia BR-163 (Cuiabá-Santarém)**: diagnóstico do meio socioeconômico, jurídico e arqueologia. Belém: Embrapa Amazônia Oriental, 2007. 229-252 p. 49
- VIEIRA, P. R. **Desenvolvimento de classificadores de máxima verossimilhança e ICM para imagens SAR**. 251 p. Dissertação de Mestrado em Sensoriamento Remoto — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1996. 39, 41, 43
- WOODHOUSE, I. H. **Introduction to microwave remote sensing**. The University of Edinburg - Scotland: Taylor & Francis, 2006. 370 p. 61, 62
- YANASSE, C. C. F.; FRERY, A. C.; SANT'ANNA, S. J. S. **Stochastic distribution and the multiplicative model**: relation, properties, estimators and applications to SAR image analysis. São José dos Campos, 1995. INPE-5630-NTC/318. 42
- ZEE BR-163. **Zoneamento ecológico-econômico da rodovia BR-163**: caracterização da área de estudo. 2008. Acesso em Janeiro de 2008. Disponível em: <<http://zeebr163.cpatu.embrapa.br>>. 49

A DEFINIÇÃO DAS EQUAÇÕES UTILIZADAS

- Momento amostral não centrado de ordem r

Seja $\mathbf{x} = \{x_1, \dots, x_n\}$ um conjunto de amostras, com $n > 1$. O momento amostral não centrado de ordem r de \mathbf{x} , dado que $n > r$, é denotado por \hat{m}_r , é definido por ([CORREIA, 1999](#)):

$$\hat{m}_r = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i^r. \quad (\text{A.1})$$

- Função Gamma de Euler

Para qualquer $v > -1$, a Função Gamma de Euler é dada por ([CORREIA, 1999](#)):

$$\Gamma(v+1) = \int_{\mathbb{R}_+} t^v e^{-t} dt. \quad (\text{A.2})$$

- Função K_v de Bessel de Terceiro Tipo e Ordem v

Definida por ([CORREIA, 1999](#)):

$$K_v(x) = \int_{\mathbb{R}_+} e^{-x \cosh(t)} \cosh(vt) dt, \quad (\text{A.3})$$

onde $\cosh(\cdot)$ é a função cosseno hiperbólico.

- Função Modificada de Bessel de Ordem v

Dado $v \in \mathbb{C}$ sendo que $\Re(v + 1/2) > 0$, a Função Modificada de Bessel de Ordem v é dada por ([CORREIA, 1999](#)):

$$I_v(x) = \frac{\left(\frac{x}{2}\right)^v}{\Gamma(v + \frac{1}{2}) \Gamma(\frac{1}{2})} \int_0^\pi \cosh(x \cos \theta) \sin^{2v}(\theta) d\theta. \quad (\text{A.4})$$

- Vetor de Jones

O estado de polarização de uma onda eletromagnética \vec{E} em um dado instante t e posição \vec{k} pode ser representado por ([HALLIDAY et al., 2006](#)):

$$\vec{E} = \hat{i}a_i e^{i(\vec{k}\vec{z} - \omega t + \phi_i)} + \hat{j}a_j e^{i(\vec{k}\vec{z} - \omega t + \phi_j)}, \quad (\text{A.5})$$

onde \hat{i} e \hat{j} compõem a base vetorial adotada para representação da polarização da onda, a_i , a_j , ϕ_i e ϕ_j indicam as amplitudes e fases relativas, ω a freqüencia angular e \vec{z} o vetor de propagação da onda.

Assim, \vec{E} , equivalentemente, pode ser representado por:

$$\vec{E} = \underbrace{\left[\hat{i}a_i e^{i(\phi_i)} + \hat{j}a_j e^{i(\phi_j)} \right]}_{\tilde{E}} e^{i(\vec{k}\vec{z} - \omega t)}. \quad (\text{A.6})$$

A representação vetorial de \tilde{E} é conhecida por Vetor de Jones:

$$\tilde{E} = \begin{bmatrix} a_i e^{\mathbf{i}(\phi_i)} \\ a_j e^{\mathbf{i}(\phi_j)} \end{bmatrix} \quad (\text{A.7})$$

B GRÁFICOS E TABELAS: COMPARAÇÃO ENTRE AS AMOSTRAS DE TREINAMENTO E VALIDAÇÃO

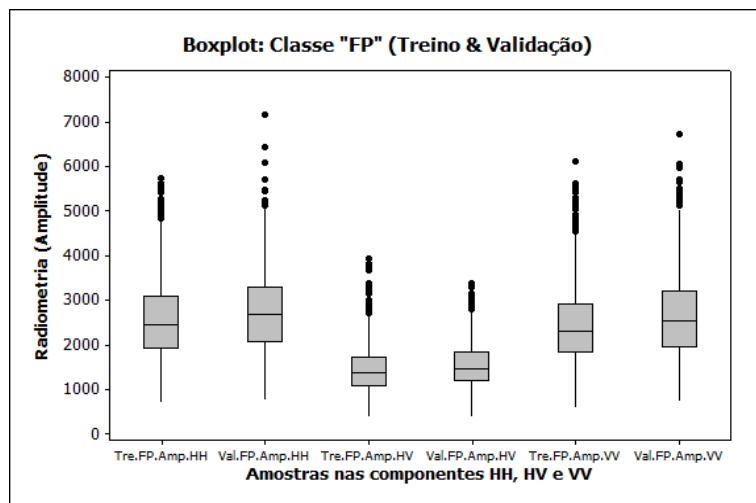


Figura B.1 - Gráfico *Boxplot*: Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Floresta Primária

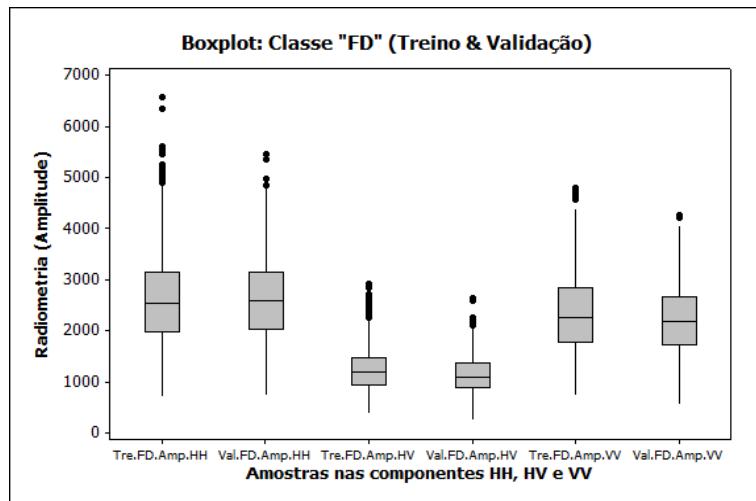


Figura B.2 - Gráfico *Boxplot*: Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Floresta Degrada

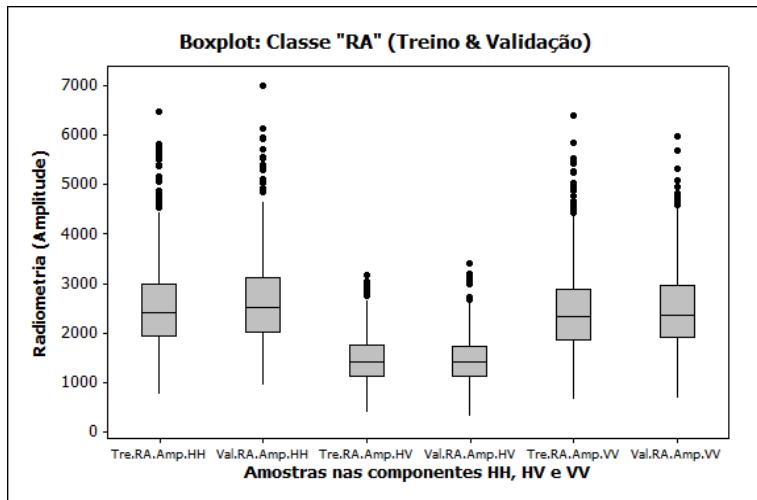


Figura B.3 - Gráfico *Boxplot*: Informação radiométrica em Amplitude das amostras da classe Regeneração Antiga

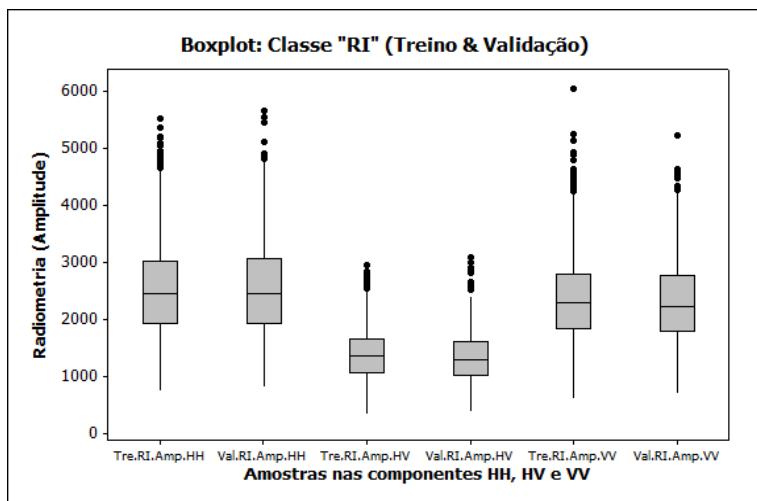


Figura B.4 - Gráfico *Boxplot*: Informação radiométrica em Amplitude das amostras da classe Regeneração Intermediária

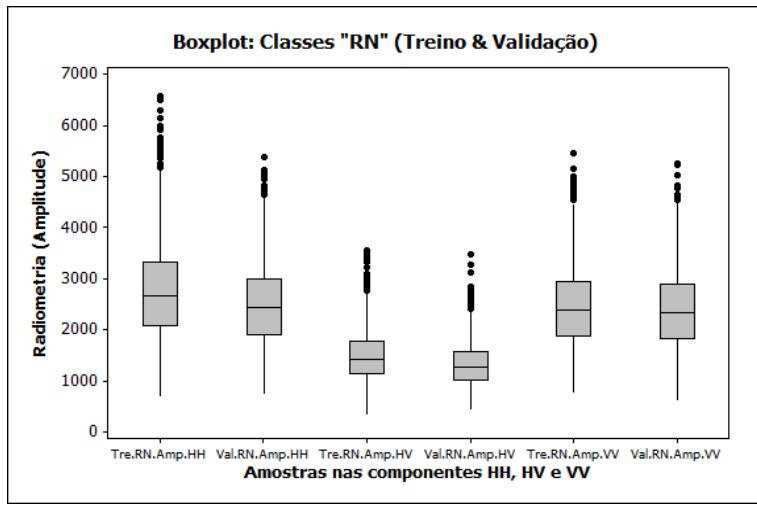


Figura B.5 - Gráfico *Boxplot*: Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Regeneração Nova

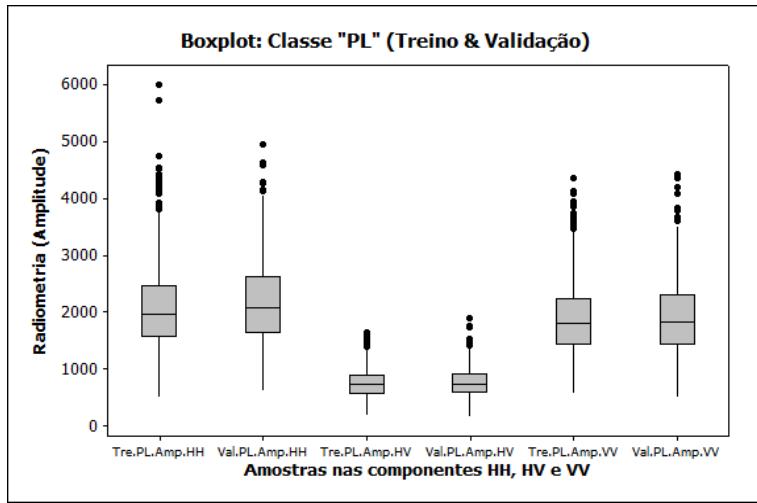


Figura B.6 - Gráfico *Boxplot*: Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Pasto Limpo

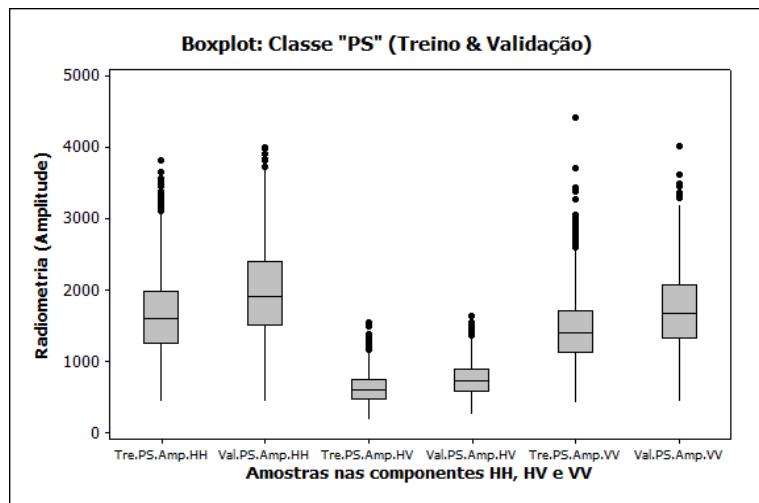


Figura B.7 - Gráfico *Boxplot*: Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Pastro Sujo

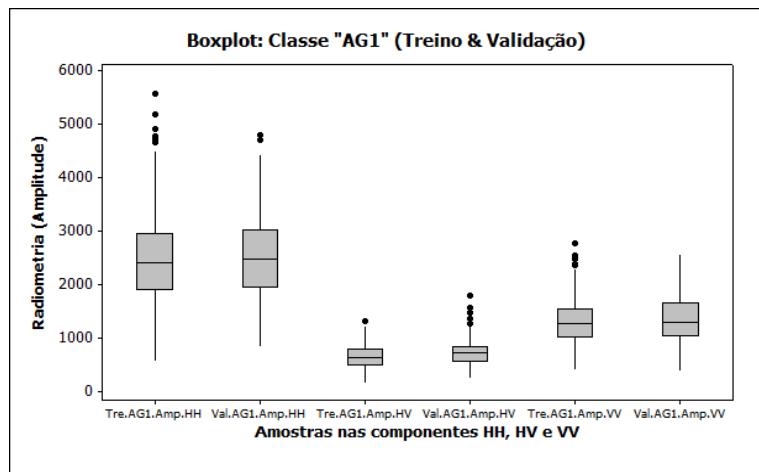


Figura B.8 - Gráfico *Boxplot*: Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Agricultura Tipo 1

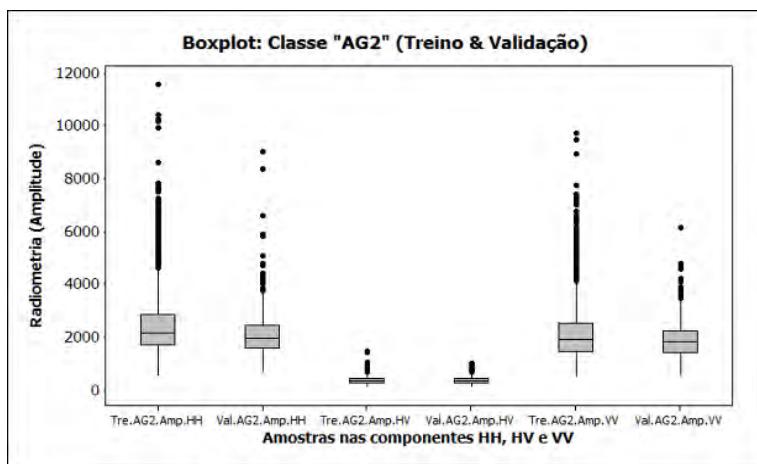


Figura B.9 - Gráfico Boxplot: Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Agricultura Tipo 2

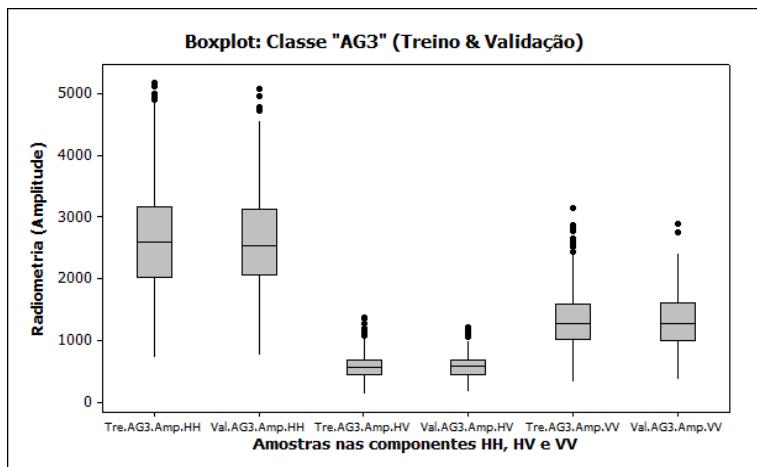


Figura B.10 - Gráfico Boxplot: Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Agricultura Tipo 3

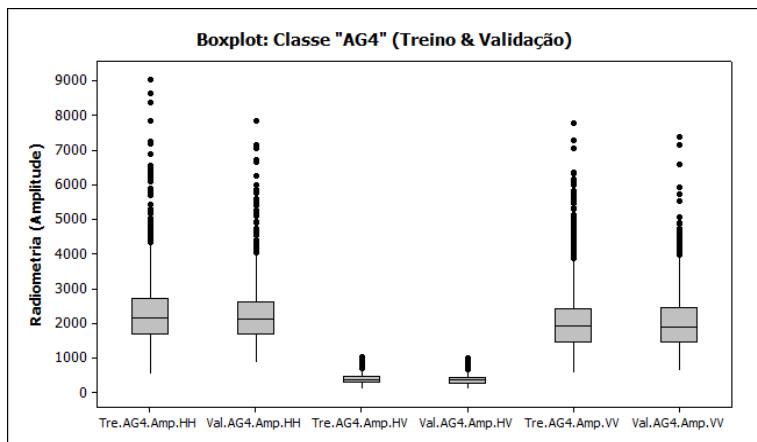


Figura B.11 - Gráfico Boxplot: Informação radiométrica em Amplitude das componentes HH, HV e VV das amostras da classe Agricultura Tipo 4

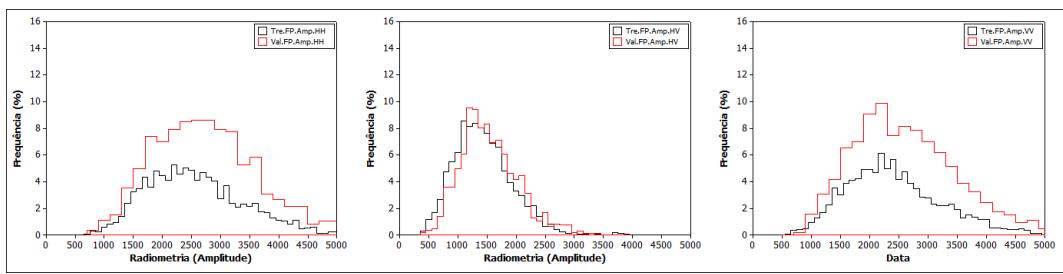


Figura B.12 - Histograma: Comparação entre as amostras de treinamento e validação da classe Floresta Primária segundo a radiometria da Amplitude das componentes HH, HV e VV

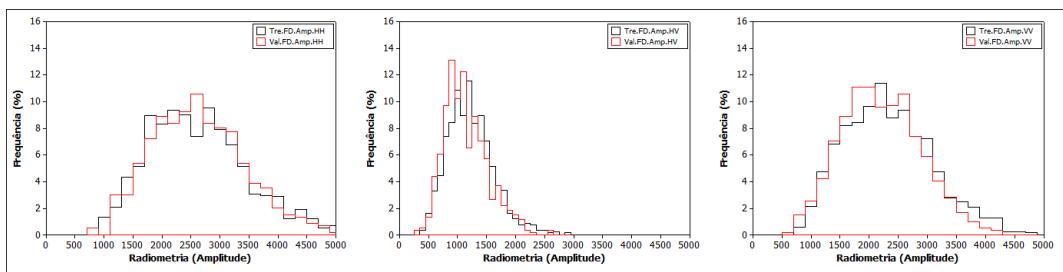


Figura B.13 - Histograma: Comparação entre as amostras de treinamento e validação da classe Floresta Degradada segundo a radiometria da Amplitude das componentes HH, HV e VV

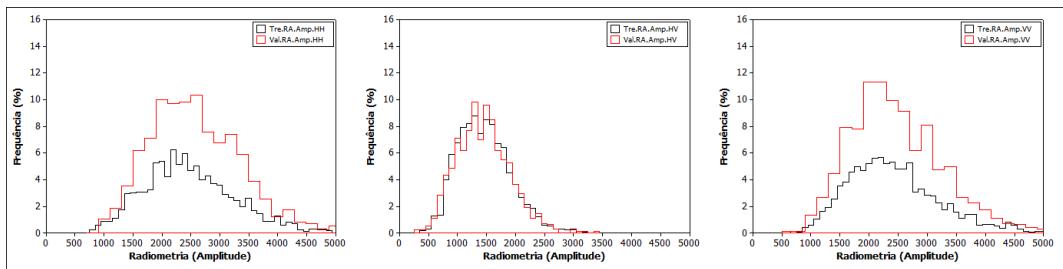


Figura B.14 - Histograma: Comparação entre as amostras de treinamento e validação da classe Regeneração Antiga segundo a radiometria da Amplitude das componentes HH, HV e VV

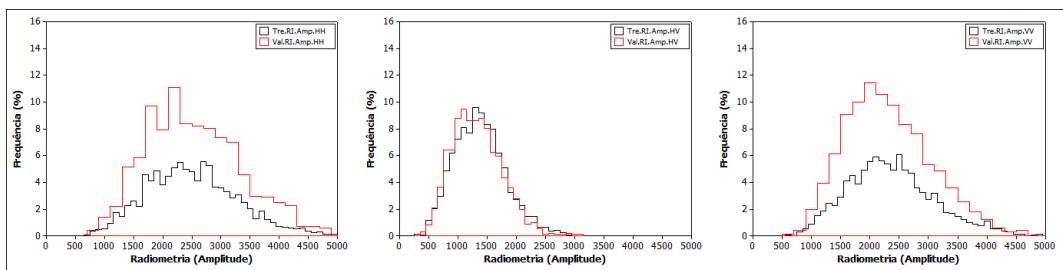


Figura B.15 - Histograma: Comparação entre as amostras de treinamento e validação da classe Regeneração Intermediária segundo a radiometria da Amplitude das componentes HH, HV e VV

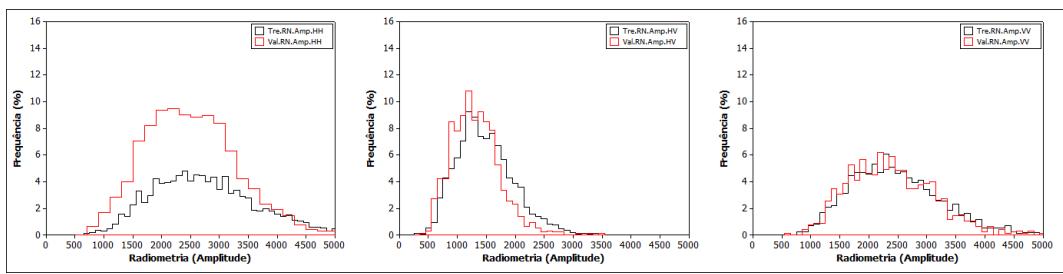


Figura B.16 - Histograma: Comparação entre as amostras de treinamento e validação da classe Regeneração Nova segundo a radiometria da Amplitude das componentes HH, HV e VV

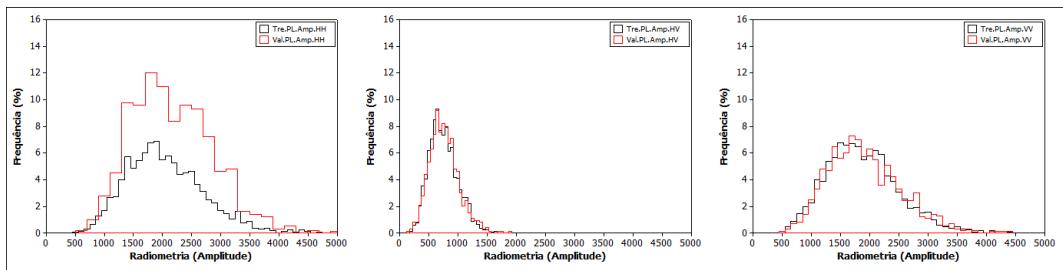


Figura B.17 - Histograma: Comparação entre as amostras de treinamento e validação da classe Pastro Limpo segundo a radiometria da Amplitude das componentes HH, HV e VV

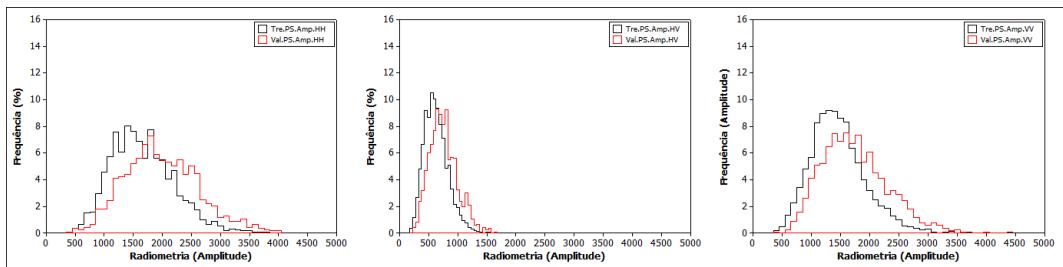


Figura B.18 - Histograma: Comparação entre as amostras de treinamento e validação da classe Pastro Sujo segundo a radiometria da Amplitude das componentes HH, HV e VV

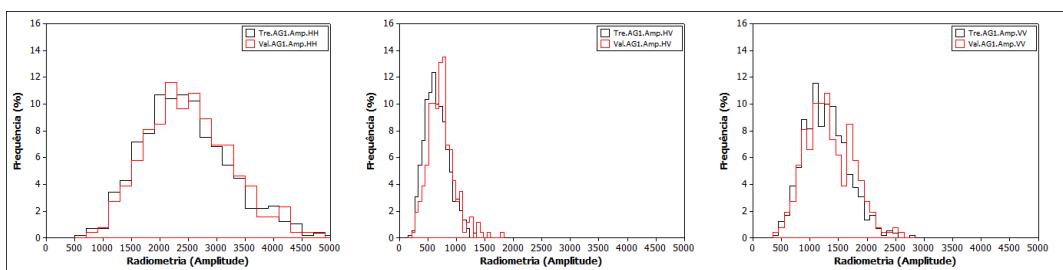


Figura B.19 - Histograma: Comparação entre as amostras de treinamento e validação da classe Agricultura Tipo 1 segundo a radiometria da Amplitude das componentes HH, HV e VV

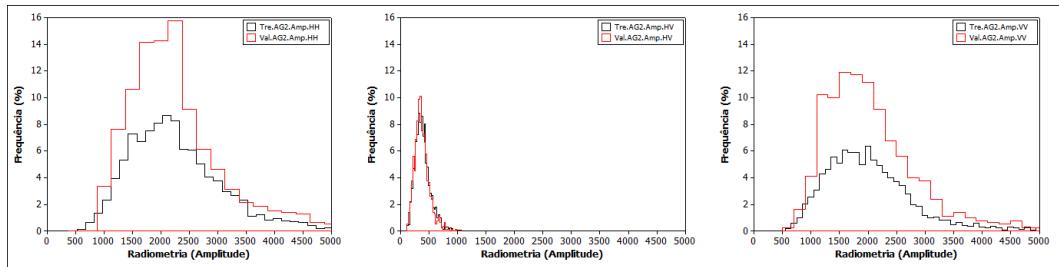


Figura B.20 - Histograma: Comparação entre as amostras de treinamento e validação da classe Agricultura Tipo 2 segundo a radiometria da Amplitude das componentes HH, HV e VV

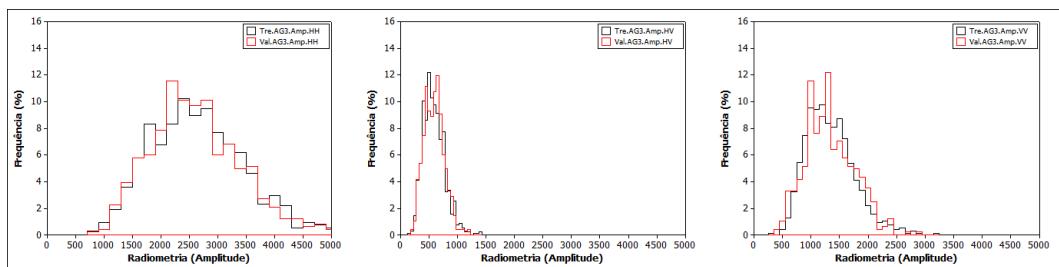


Figura B.21 - Histograma: Comparação entre as amostras de treinamento e validação da classe Agricultura Tipo 3 segundo a radiometria da Amplitude das componentes HH, HV e VV

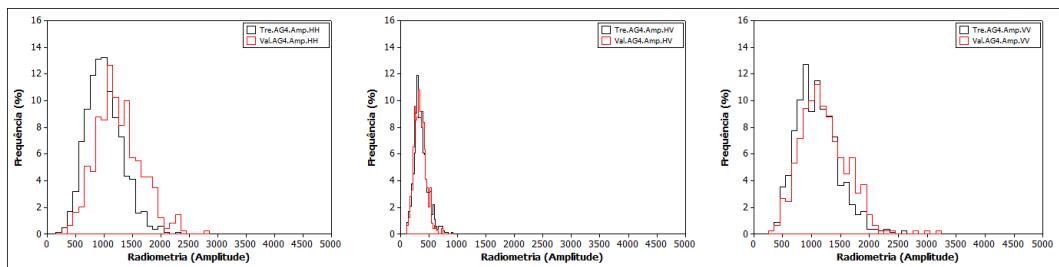


Figura B.22 - Histograma: Comparação entre as amostras de treinamento e validação da classe Agricultura Tipo 4 segundo a radiometria da Amplitude das componentes HH, HV e VV

Tabela B.1 - Estatística descritiva das classes sobre as diferentes componentes.

		Média	Desvio Padrão	Mínimo	Mediana	Máximo
FP	HH	2569,3	848,6	702,6	2462,3	5734,2
	Tre.	HV	1435,8	497,7	377,3	1381,4
		VV	2429,1	844,7	592,7	2320,1
		HH	2749,1	912,7	780,5	2685,3
	Val.	HV	1541,5	490,2	397,6	1476,5
		VV	2639,2	935,2	732,1	2536,1
FD	HH	2626,6	879,8	711,8	2532,3	6563,1
	Tre.	HV	1227,7	402,2	388,9	1181,3
		VV	2334,3	758,4	733,8	2251,4
		HH	2637,2	813,5	748,6	2592,3
	Val.	HV	1144,2	377,6	261,2	1084,0
		VV	2209,7	679,1	563,3	2184,5
RA	HH	2506,2	820,0	765,3	2419,8	6471,7
	Tre.	HV	1454,5	449,3	389,1	1419,7
		VV	2421,2	788,7	662,1	2321,7
		HH	2611,0	845,6	948,7	2515,9
	Val.	HV	1442,9	455,1	312,3	1423,9
		VV	2468,0	790,6	676,6	2352,9
RI	HH	2513,3	783,1	736,9	2453,8	5514,1
	Tre.	HV	1374,6	438,0	338,6	1350,1
		VV	2366,7	743,1	612,9	2295,6
		HH	2539,9	827,2	810,0	2454,0
	Val.	HV	1325,4	425,8	375,2	1295,4
		VV	2314,8	734,7	699,7	2229,4
RN	HH	2757,9	920,2	675,7	2665,7	6556,5
	Tre.	HV	1479,9	493,7	336,2	1428,0
		VV	2459,3	770,0	757,7	2386,5
		HH	2503,7	798,6	726,1	2440,5
	Val.	HV	1314,4	419,7	443,3	1277,7
		VV	2392,2	740,7	612,4	2332,0
PL	HH	2048,1	666,9	513,7	1966,6	5982,6
	Tre.	HV	753,5	241,1	181,7	727,5
		VV	1869,5	607,9	569,4	1813,7
		HH	2163,0	690,9	623,2	2083,5
	Val.	HV	763,7	252,1	171,9	742,9
		VV	1912,7	624,6	514,5	1836,9
PS	HH	1657,1	536,0	444,8	1604,7	3825,5
	Tre.	HV	627,4	202,8	179,9	606,3
		VV	1459,8	469,0	433,3	1404,3
		HH	1989,8	632,8	446,9	1924,2

			Média	Desvio Padrão	Mínimo	Mediana	Máximo
	Val.	HV	750,8	236,8	258,9	726,5	1648,9
		VV	1739,5	556,0	449,1	1684,8	4030,2
AG1		HH	2469,0	788,6	564,8	2396,8	5571,1
	Tre.	HV	651,1	207,1	164,2	629,6	1316,5
		VV	1283,6	385,4	412,9	1265,1	2763,0
		HH	2527,2	747,0	846,3	2480,5	4780,3
	Val.	HV	731,8	233,5	247,2	722,7	1795,0
		VV	1336,3	413,4	388,1	1297,8	2566,9
AG2		HH	2482,0	1215,5	540,5	2198,9	11604,8
	Tre.	HV	387,3	137,7	116,6	367,0	1486,3
		VV	2189,8	1096,9	507,5	1945,0	9730,7
		HH	2096,5	789,7	695,0	1970,0	9033,3
	Val.	HV	390,0	136,6	114,4	365,6	1012,7
		VV	1903,8	640,0	549,7	1844,4	6151,1
AG3		HH	2644,1	821,3	724,6	2599,0	5166,1
	Tre.	HV	584,7	189,2	145,9	564,1	1383,0
		VV	1339,5	422,4	345,7	1281,2	3152,3
		HH	2613,2	790,9	762,1	2535,6	5081,7
	Val.	HV	589,3	177,0	181,4	586,7	1216,2
		VV	1329,3	427,0	373,2	1288,3	2896,2
AG4		HH	2319,8	968,6	540,5	2154,0	9033,3
	Tre.	HV	388,9	135,0	114,4	371,7	1039,6
		VV	2069,4	888,1	579,2	1928,0	7791,5
		HH	2305,5	962,8	883,8	2124,9	7837,6
	Val.	HV	372,8	128,1	116,6	357,3	985,4
		VV	2067,7	861,4	622,7	1903,4	7382,0

Tabela B.2 - Estatística descritiva das classes selecionadas segundo a diferença de fase entre as componentes HH e VV, para os conjuntos de treinamento e validação.

		Média	Desvio Padrão	Mínimo	Mediana	Máximo
FP	Tre.	-0,00824	0,91083	-3,13641	-0,04737	3,13743
	Val.	-0,14021	0,77381	-3,13757	-0,09727	3,13661
FD	Tre.	-0,04317	0,88354	-3,13858	-0,13541	3,13385
	Val.	0,01561	0,75615	-3,12176	-0,14982	3,13262
RA	Tre.	-0,06570	0,87757	-3,13304	-0,03851	3,13492
	Val.	0,27909	0,61154	-3,12376	0,02510	3,13946
RI	Tre.	0,38332	0,62460	-3,12943	-0,05199	3,13940
	Val.	0,24828	0,78438	-2,93254	-0,02828	3,01100
RN	Tre.	0,15780	0,47019	-3,09823	0,02282	3,04391
	Val.	-0,78352	0,83136	-3,13783	-0,02828	3,13619
PL	Tre.	0,24917	0,54602	-3,12720	0,27087	3,09473
	Val.	-0,07992	0,80412	-3,06028	0,25196	3,13951
PS	Tre.	-0,21167	0,84393	-3,12987	0,39878	3,13967
	Val.	0,02196	0,88149	-3,13186	0,37215	3,12236
AG1	Tre.	0,42880	1,73303	-3,13571	0,26869	3,13365
	Val.	-0,04588	0,76313	-3,13999	0,34397	3,12940
AG2	Tre.	0,20344	0,59285	-3,13231	0,15831	3,13431
	Val.	0,35229	0,63898	-3,04967	0,17868	3,12568
AG3	Tre.	0,03201	0,86369	-3,03826	-1,02173	3,08153
	Val.	0,18260	0,35255	-2,98597	-1,09134	2,83739
AG4	Tre.	-0,73539	0,91481	-3,13359	0,24282	3,13405
	Val.	0,04151	0,49279	-2,85423	0,05142	2,83502

C ESTIMAÇÃO DO NÚMERO EQUIVALENTE DE *LOOKS*

Todas as distribuições estatísticas apresentadas nas subseções 2.2.1.1, 2.2.1.1 e 2.2.1.1 requerem o conhecimento do parâmetro n , denominado número equivalente de *looks* (NEL).

De acordo com Frery et al. (2007), sob a consideração de que os dados seguem o modelo multiplicativo, sabe-se que a informação, em amplitude, proveniente de alvos homogêneos pode ser modelado segundo a distribuição Raiz Quadrada da *Gamma*. Com posse de dados em Amplitude provenientes de regiões homogêneas, um estimador do NEL, \hat{n} , é dado pela solução de:

$$\sqrt{\frac{\hat{m}_{1/2}}{\hat{n}}} \frac{\Gamma(\hat{n} + \frac{1}{2})}{\Gamma(\hat{n})} - \hat{m}_4 = 0 \quad (\text{C.1})$$

Necessariamente, o comportamento dos dados utilizados neste processo deve apresentar distribuição Raiz Quadrada da *Gamma*, o que pode ser verificado com a aplicação de um teste de aderência estatístico.

Outra consideração fundamental é que este método supõe que as amostras são independentes. A dependência entre os dados pode causar estimação inadequada de \hat{n} .

A função Semivariograma é uma forma de verificar a existência de dependência, ou independência, espacial entre as amostras (*pixel*) de determinada região de uma imagem. Esta função exibe, para uma dada direção, a correlação espacial em função da distância.

Sendo assim, para uma dada amostra de imagem cujo comportamento da correlação espacial é conhecida, é possível definir uma grade de reamostragem, que por sua vez deve proporcionar um novo conjunto cujos dados descorrelacionados.

A função Semivariograma é definida por Camargo et al. (2004):

$$\hat{\sigma}(h) = \frac{1}{2} \sum_{i=1}^{N(h)} (Z(x_i) - Z(x_i + h))^2 \quad (\text{C.2})$$

onde $\hat{\sigma}(h)$ representa a semivariância estimada, $N(h)$ o número de pares separados por uma distância h , e $Z(x)$ e $Z(x + h)$ são eventos separados por uma distância h .

Cabe ressaltar que esta função calcula a correlação entre amostras para uma dada direção, em função da distância h (*Lag*). No caso da análise dos *pixel* de uma imagem, torna-se conveniente o emprego das direções horizontal e vertical.

Sendo assim, o parâmetro \hat{n} será calculado a partir de alvos homogêneos, cujas amostras são obtidas por uma grade de reamostragem definida pela análise das funções Semivariograma destes alvos. O espaçamento que define a grade de reamostragem, nas direções horizontal e vertical, é baseado na distância de maior semivariância.

Tabela C.1 - Distância para descorrelação dos *pixels* das áreas homogêneas

Componente	Direção	Regiões Homogeneas							
		1	2	3	4	5	6	7	8
HH	Horizontal	3	3	3					
	Vertical	2	3	2					
HV	Horizontal	3			3	3	3		
	Vertical	2			4	2	2		
VV	Horizontal	3						3	3
	Vertical	3						3	3

Ainda, como proposto em ([FRERY et al., 2007](#)), o parâmetro \hat{n} de cada Componente em Amplitude é calculado a partir da média de diferentes estimativas, obtidos de diferentes alvos.

A Figura C.1 ilustra as áreas homogêneas selecionadas em cada uma das Componentes em Amplitude, as figuras C.2, C.3 e C.4 apresentam as funções Semivariograma para cada um dos alvos, calculadas para as direções horizontal e vertical. A Tabela C.1 apresenta o espaçamento que proporciona independência, ou reduz significativamente a dependência, entre os *pixel*, para cada componente.

As figuras C.5, C.6 e C.7 ilustram o ajuste da função Raiz Quadrada da *Gamma*, para cada um dos alvos selecionados e reamostrados, onde são apresentados o teste de aderência χ^2 com nível de significância de 5% e o respectivo \hat{n} estimado.

Após estes procedimentos, foi constatado que o NEL das componentes HH, HV e VV são, respectivamente, 2,1005; 2,1516 e 2,2969.

Quando utilizados conjuntos de dados compostos por mais de uma componente, seu NEL é dado pela média dos NELs das componentes que compõem este conjunto.

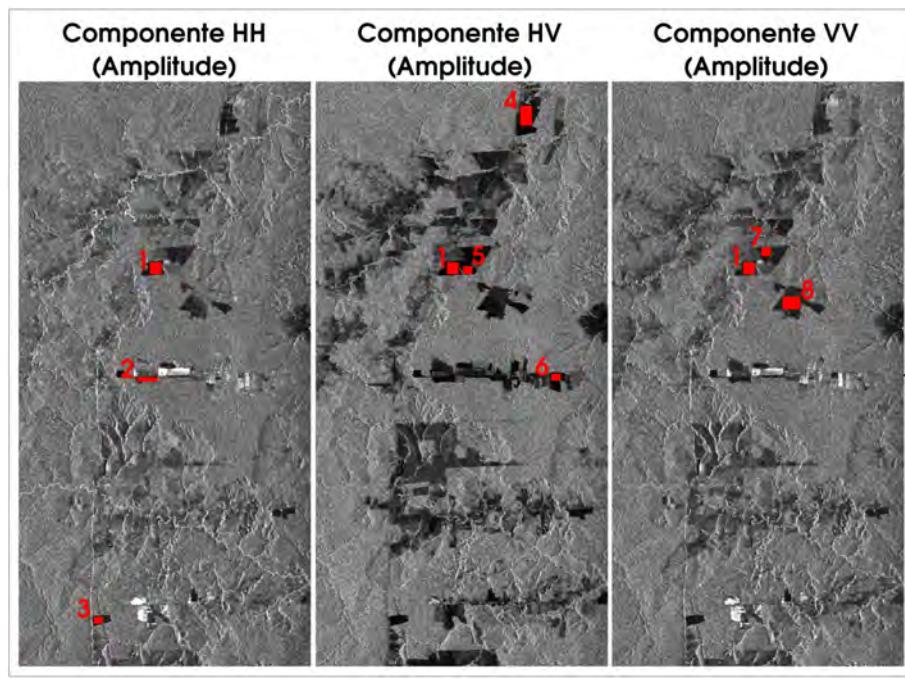


Figura C.1 - Alvos homogêneos utilizados para estimação de \hat{n}

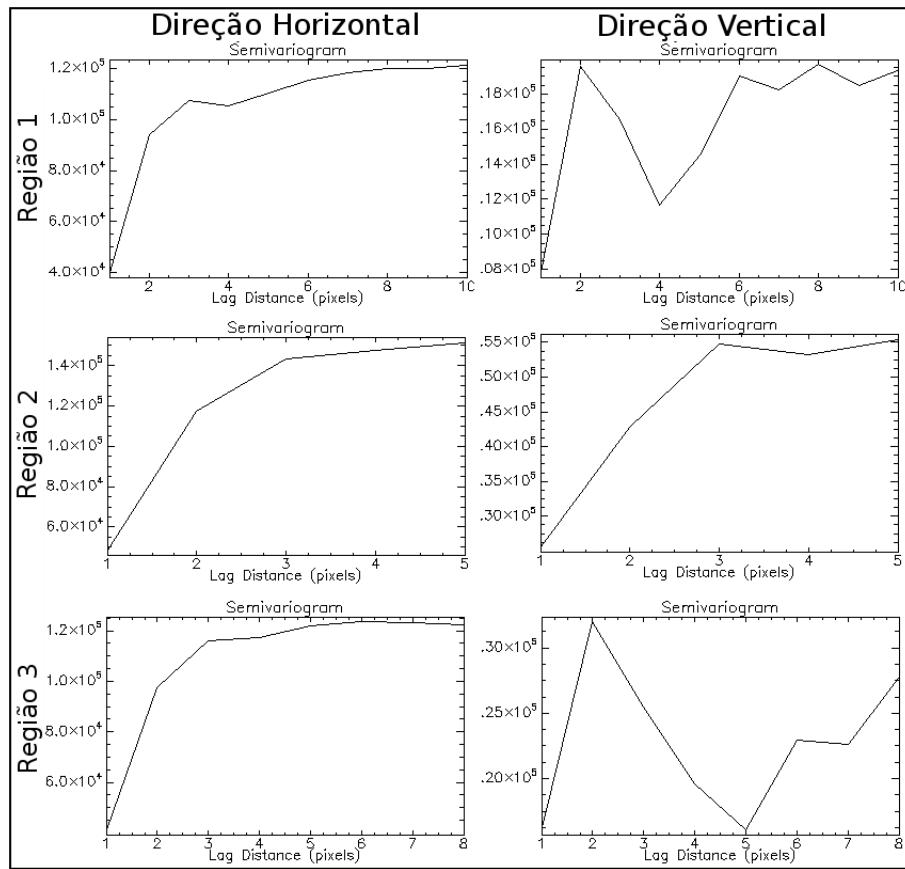


Figura C.2 - Semivariogramas dos alvos homogêneos da componente HH

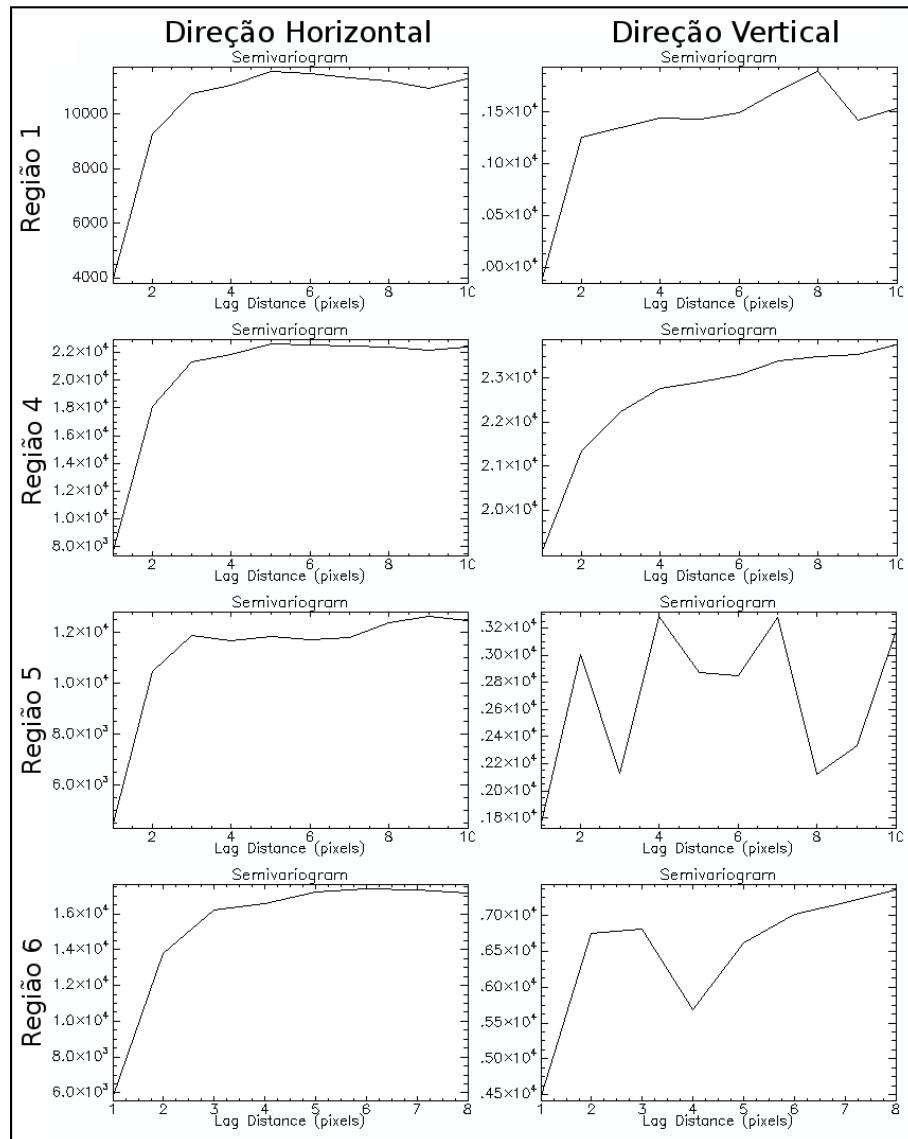


Figura C.3 - Semivariogramas dos alvos homogêneos da componente HV

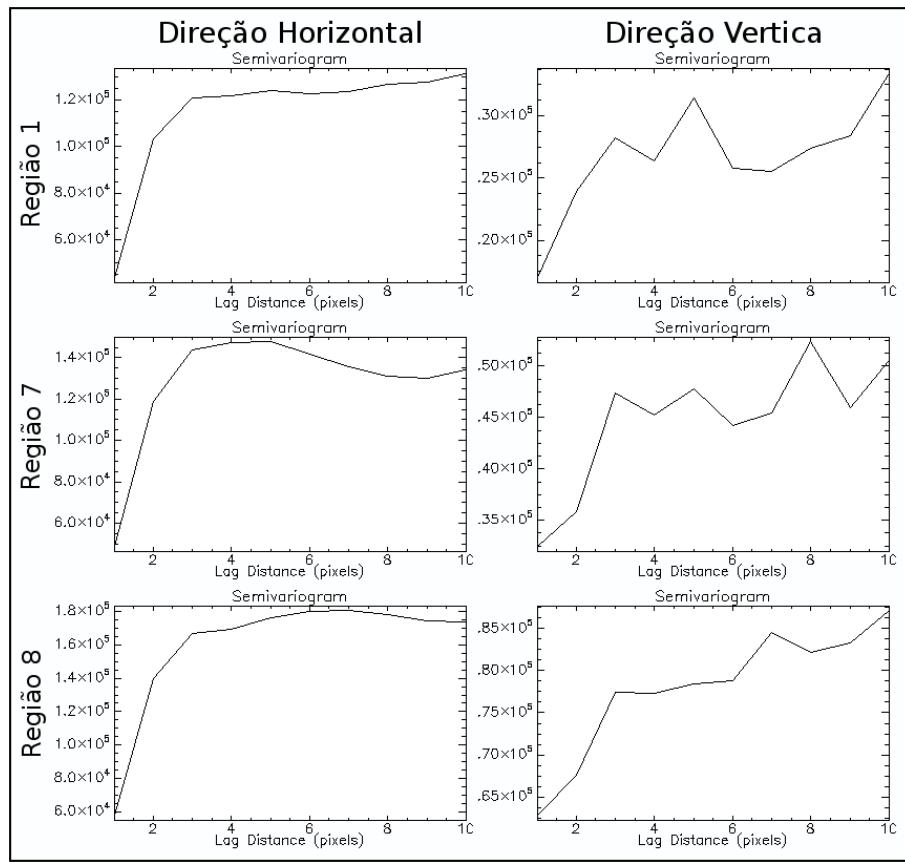


Figura C.4 - Semivariogramas dos alvos homogêneos da componente VV

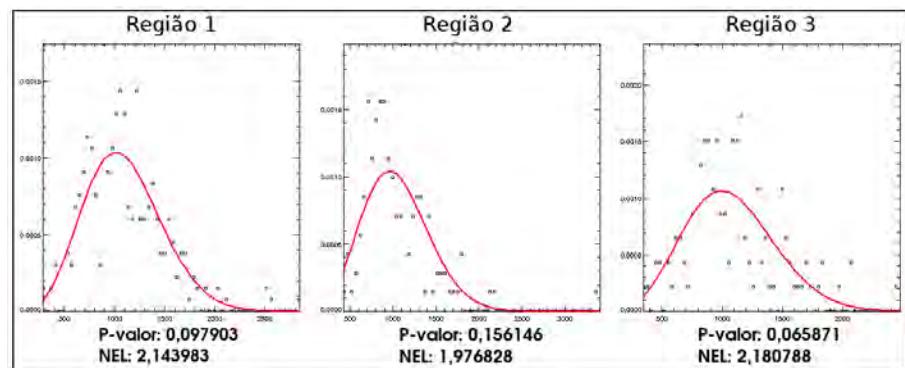


Figura C.5 - Teste de aderência χ^2 e \hat{n} para as regiões homogenas de HH

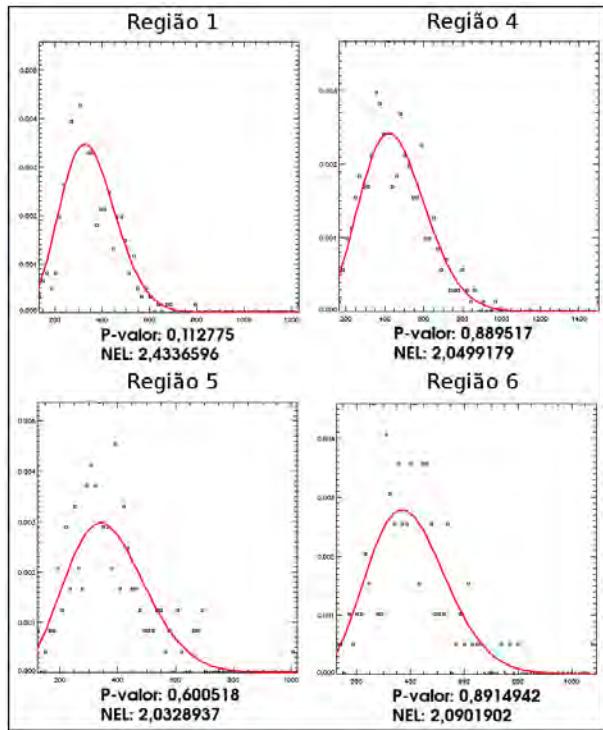


Figura C.6 - Teste de aderência χ^2 e \hat{n} para as regiões homogenas de HV

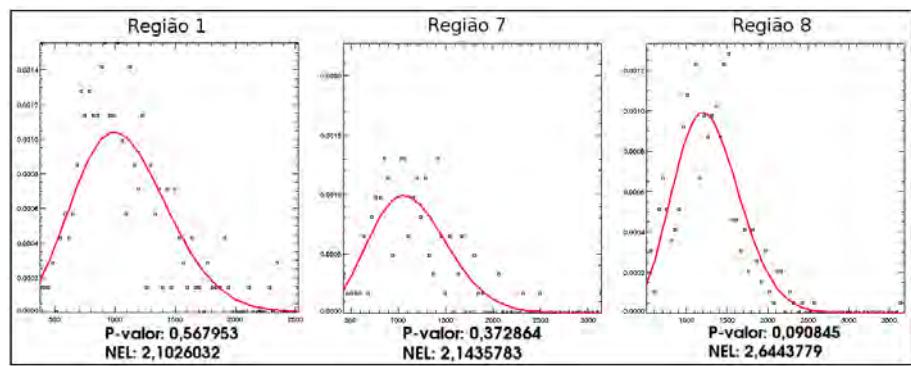


Figura C.7 - Teste de aderência χ^2 e \hat{n} para as regiões homogenas de VV

D FUNÇÕES DENSIDADE DE PROBABILIDADE UTILIZADAS PELO MÉTODO MAXVER/ICM PARA AS DIFERENTES CLASSES DE COBERTURA DA TERRA NOS CASOS UNIVARIADO E POLARIMÉTRICO

Tabela D.1 - FDP associada a cada uma das classes utilizando dados Univariados HH

Classes	FDP
FP	Weibull
FD	<i>Log</i> Normal
RA	Raiz da <i>Gamma</i>
RI	Weibull
RN	Weibull
PL	Weibull
PS	<i>K</i> Amplitude
AG1	Raiz da <i>Gamma</i>
AG2	<i>K</i> Amplitude
AG3	<i>K</i> Amplitude
AG4	<i>Log</i> Normal
PL+PS	<i>K</i> Amplitude
RA+RI	<i>K</i> Amplitude
AG1+AG3	<i>Log</i> Normal
RA+RI+RN	<i>K</i> Amplitude
FP+RA+RI+RN	<i>K</i> Amplitude
PL+PS+AG1+AG3	<i>G⁰</i> Amplitude
FP+FD+RA+RI+RN	<i>K</i> Amplitude
FP+FD+RA+RI+RN+PL+PS+AG1+AG3	<i>K</i> Amplitude
FP+FD+RA+RI+RN+PL+PS+AG1+AG2+AG3	<i>K</i> Amplitude

Tabela D.2 - FDP associada a cada uma das classes utilizando dados Univariados HV

Classes	FDP
FP	Weibull
FD	<i>G⁰</i> Amplitude
RA	Raiz da <i>Gamma</i>
RI	Weibull
RN	<i>K</i> Amplitude
PL	<i>G⁰</i> Amplitude
PS	<i>Log</i> Normal
AG1	<i>Log</i> Normal
AG2	<i>K</i> Amplitude
AG3	<i>K</i> Amplitude
AG4	<i>Log</i> Normal
PL+PS	<i>K</i> Amplitude
RA+RI	<i>G⁰</i> Amplitude
AG1+AG3	Weibull
RA+RI+RN	<i>K</i> Amplitude
FP+RA+RI+RN	<i>K</i> Amplitude
PL+PS+AG1+AG3	<i>K</i> Amplitude
FP+FD+RA+RI+RN	<i>K</i> Amplitude
FP+FD+RA+RI+RN+PL+PS+AG1+AG3	Weibull
FP+FD+RA+RI+RN+PL+PS+AG1+AG2+AG3	Weibull

Tabela D.3 - FDP associada a cada uma das classes utilizando dados Univariados VV

Classes	FDP
FP	G^0 Amplitude
FD	K Amplitude
RA	K Amplitude
RI	K Amplitude
RN	Raiz da <i>Gamma</i>
PL	Normal Restrita
PS	Raiz da <i>Gamma</i>
AG1	Raiz da <i>Gamma</i>
AG2	G^0 Amplitude
AG3	Raiz da <i>Gamma</i>
AG4	<i>Log</i> Normal
PL+PS	K Amplitude
RA+RI	K Amplitude
AG1+AG3	Raiz da <i>Gamma</i>
RA+RI+RN	G^0 Amplitude
FP+RA+RI+RN	G^0 Amplitude
PL+PS+AG1+AG3	K Amplitude
FP+FD+RA+RI+RN+PL+PS+AG1+AG3	K Amplitude
FP+FD+RA+RI+RN+PL+PS+AG1+AG2+AG3	K Amplitude

Tabela D.4 - FDP associada a cada uma das classes utilizando dados Polarimétricos

Classes	FDP
FP	G^0 Multivariada <i>Multi-Look</i>
FD	G^0 Multivariada <i>Multi-Look</i>
RA	Wishart Complexa Multivariada
RI	G^0 Multivariada <i>Multi-Look</i>
RN	Wishart Complexa Multivariada
PL	Wishart Complexa Multivariada
PS	Wishart Complexa Multivariada
AG1	Wishart Complexa Multivariada
AG2	K Complexa Multivariada <i>Multi-Look</i>
AG3	Wishart Complexa Multivariada
AG4	Wishart Complexa Multivariada
PL+PS	K Complexa Multivariada <i>Multi-Look</i>
RA+RI	Wishart Complexa Multivariada
AG1+AG3	Wishart Complexa Multivariada
RA+RI+RN	Wishart Complexa Multivariada
FP+RA+RI+RN	G^0 Multivariada <i>Multi-Look</i>
PL+PS+AG1+AG3	G^0 Multivariada <i>Multi-Look</i>
FP+FD+RA+RI+RN	G^0 Multivariada <i>Multi-Look</i>
FP+FD+RA+RI+RN+PL+PS+AG1+AG3	K Complexa Multivariada <i>Multi-Look</i>
FP+FD+RA+RI+RN+PL+PS+AG1+AG2+AG3	K Complexa Multivariada <i>Multi-Look</i>

E MATRIZES DE CONFUSÃO DAS CLASSIFICAÇÕES REALIZADAS

Tabela E.1 - Classificação MaxVer/ICM utilizando dados Univariados HH em nível de discriminação 1 (11 classes)

Cla./Ref.	RA	RN	PL	FD	AG4	PS	RI	AG3	AG1	FP	AG2	Σ Lin.
RA	0	0	0	0	0	0	0	0	0	0	0	0
RN	330	507	238	358	0	114	408	231	74	318	45	2623
PL	369	220	405	82	3	605	279	79	120	87	432	2681
FD	0	0	0	0	0	0	0	0	0	0	3	3
AG4	0	4	10	0	331	6	0	0	0	0	0	351
PS	19	45	325	9	156	501	57	6	3	51	184	1356
RI	270	176	23	147	0	10	268	168	62	628	136	1888
AG3	0	0	0	0	0	0	0	0	0	0	0	0
AG1	0	0	0	0	0	0	0	0	0	0	0	0
FP	0	0	0	0	0	0	0	0	0	0	0	0
AG2	0	0	0	0	0	0	0	0	0	0	0	0
Σ Col.	988	952	1001	596	490	1236	1012	484	259	1084	800	8902

Tabela E.2 - Classificação MaxVer/ICM utilizando dados Univariados HH em nível de discriminação 2 (10 classes)

Cla./Ref.	RA+RI	RN	PL	FD	AG4	PS	AG3	AG1	FP	AG2	Σ Lin.
RA+RI	114	68	2	19	0	6	48	0	231	52	540
RN	47	31	15	8	0	8	6	0	31	9	155
PL	738	257	386	148	0	410	190	180	159	258	2726
FD	5	0	0	0	0	0	0	0	0	34	39
AG4	0	0	0	0	0	0	0	0	0	0	0
PS	170	194	496	40	490	801	13	3	53	388	2648
AG3	0	0	0	0	0	0	0	0	0	0	0
AG1	0	0	0	0	0	0	0	0	0	0	0
FP	926	402	102	381	0	11	227	76	610	59	2794
AG2	0	0	0	0	0	0	0	0	0	0	0
Σ Col.	2000	952	1001	596	490	1236	484	259	1084	800	8902

Tabela E.3 - Classificação MaxVer/ICM utilizando dados Univariados HH em nível de discriminação 3 (9 classes)

Cla./Ref.	RA+RI+RN	PL	FD	AG4	PS	AG3	AG1	FP	AG2	Σ Lin.
RA+RI+RN	33	11	0	0	0	0	0	7	26	77
PL	609	406	16	0	629	65	93	59	332	2209
FD	2	0	0	0	0	0	0	0	52	54
AG4	0	1	0	370	19	0	0	0	0	390
PS	109	322	15	120	489	2	6	16	272	1351
AG3	0	0	0	0	0	0	0	0	0	0
AG1	0	0	0	0	0	0	0	0	0	0
FP	2199	261	565	0	99	417	160	1002	118	4821
AG2	0	0	0	0	0	0	0	0	0	0
Σ Col.	2952	1001	596	490	1236	484	259	1084	800	8902

Tabela E.4 - Classificação MaxVer/ICM utilizando dados Univariados HH em nível de discriminação 4 (8 classes)

Cla./Ref.	PL	FD	AG4	PS	AG3	AG1	FP+RA+RI+RN	AG2	Σ Lin.
PL	525	114	0	729	113	139	749	324	2693
FD	0	15	0	0	0	0	41	30	86
AG4	8	0	360	9	0	0	1	0	378
PS	309	22	130	461	2	2	156	274	1356
AG3	0	0	0	0	0	0	0	0	0
AG1	0	0	0	0	0	0	0	0	0
FP+RA+RI+RN	159	445	0	37	369	118	3089	172	4389
AG2	0	0	0	0	0	0	0	0	0
Σ Col.	1001	596	490	1236	484	259	4036	800	8902

Tabela E.5 - Classificação MaxVer/ICM utilizando dados Univariados HH em nível de discriminação 5 (7 classes)

Cla./Ref.	PL	AG4	PS	AG3	AG1	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL	595	0	789	171	144	1072	398	3169
AG4	6	360	6	0	0	0	0	372
PS	270	130	416	0	2	180	211	1209
AG3	0	0	0	0	0	0	0	0
AG1	0	0	0	0	0	0	0	0
FP+FD+RA+RI+RN	130	0	25	313	113	3380	191	4152
AG2	0	0	0	0	0	0	0	0
Σ Col.	1001	490	1236	484	259	4632	800	8902

Tabela E.6 - Classificação MaxVer/ICM utilizando dados Univariados HH em nível de discriminação 6 (6 classes)

Cla./Ref.	PL	AG4	PS	AG1+AG3	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL	326	0	453	227	652	291	1949
AG4	5	340	5	0	3	0	353
PS	426	150	608	4	314	261	1763
AG1+AG3	196	0	158	249	1430	174	2207
FP+FD+RA+RI+RN	48	0	12	263	2233	74	2630
AG2	0	0	0	0	0	0	0
Σ Col.	1001	490	1236	743	4632	800	8902

Tabela E.7 - Classificação MaxVer/ICM utilizando dados Univariados HH em nível de discriminação 7 (5 classes)

Cla./Ref.	PL+PS	AG4	AG1+AG3	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL+PS	1474	107	42	541	475	2639
AG4	18	383	0	8	0	409
AG1+AG3	721	0	314	1744	208	2987
FP+FD+RA+RI+RN	24	0	387	2339	117	2867
AG2	0	0	0	0	0	0
Σ Col.	2237	490	743	4632	800	8902

Tabela E.8 - Classificação MaxVer/ICM utilizando dados Univariados HH em nível de discriminação 8 (4 classes)

Cla./Ref.	PL+PS+AG1+AG3	AG4	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL+PS+AG1+AG3	1869	45	825	576	3315
AG4	25	445	1	0	471
FP+FD+RA+RI+RN	1086	0	3806	224	5116
AG2	0	0	0	0	0
Σ Col.	2980	490	4632	800	8902

Tabela E.9 - Classificação MaxVer/ICM utilizando dados Univariados HV em nível de discriminação 1 (11 classes)

Cla./Ref.	RA	RN	PL	FD	AG4	PS	RI	AG3	AG1	FP	AG2	Σ Lin.
RA	0	0	0	0	0	0	0	0	0	0	0	0
RN	44	78	2	75	0	0	76	0	0	32	0	307
PL	11	20	557	169	0	464	11	0	123	0	0	1355
FD	257	532	40	287	0	18	504	0	0	220	0	1858
AG4	0	0	11	0	490	0	0	9	0	0	670	1180
PS	0	0	391	0	0	754	0	458	136	0	88	1827
RI	386	134	0	45	0	0	296	0	0	679	0	1540
AG3	0	0	0	0	0	0	0	0	0	0	0	0
AG1	0	0	0	0	0	0	0	0	0	0	0	0
FP	290	188	0	20	0	0	125	0	0	153	0	776
AG2	0	0	0	0	0	0	0	17	0	0	42	59
Σ Col.	988	952	1001	596	490	1236	1012	484	259	1084	800	8902

Tabela E.10 - Classificação MaxVer/ICM utilizando dados Univariados HV em nível de discriminação 2 (10 classes)

Cla./Ref.	RA+RI	RN	PL	FD	AG4	PS	AG3	AG1	FP	AG2	Σ Lin.
RA+RI	16	0	0	0	0	0	0	0	54	0	70
RN	122	58	0	53	0	0	0	0	29	0	262
PL	42	10	734	180	0	782	62	183	0	0	1993
FD	606	528	47	303	0	18	0	0	235	0	1737
AG4	0	0	7	0	490	0	41	0	0	683	1221
PS	0	0	107	0	0	158	209	11	0	62	547
AG3	0	0	0	0	0	0	0	0	0	0	0
AG1	0	5	100	2	0	271	148	65	0	0	591
FP	1214	351	0	58	0	0	0	0	766	0	2389
AG2	0	0	6	0	0	7	24	0	0	55	92
Σ Col.	2000	952	1001	596	490	1236	484	259	1084	800	8902

Tabela E.11 - Classificação MaxVer/ICM utilizando dados Univariados HV em nível de discriminação 3 (9 classes)

Cla./Ref.	RA+RI+RN	PL	FD	AG4	PS	AG3	AG1	FP	AG2	Σ Lin.
RA+RI+RN	88	0	16	0	0	0	0	36	0	140
PL	19	747	123	0	828	63	179	0	0	1959
FD	1250	54	388	0	3	0	0	264	0	1959
AG4	0	7	0	490	0	32	0	0	684	1213
PS	0	100	0	0	145	210	15	0	68	538
AG3	0	0	0	0	0	0	0	0	0	0
AG1	0	87	0	0	253	150	65	0	0	555
FP	1595	0	69	0	0	0	0	784	0	2448
AG2	0	6	0	0	7	29	0	0	48	90
Σ Col.	2952	1001	596	490	1236	484	259	1084	800	8902

Tabela E.12 - Classificação MaxVer/ICM utilizando dados Univariados HV em nível de discriminação 4 (8 classes)

Cla./Ref.	PL	FD	AG4	PS	AG3	AG1	FP+RA+RI+RN	AG2	ΣLin.
PL	764	149	0	834	62	179	3	0	1991
FD	23	290	0	3	0	0	717	0	1033
AG4	7	0	490	0	38	0	0	689	1224
PS	107	0	0	137	207	15	0	61	527
AG3	0	0	0	0	0	0	0	0	0
AG1	91	0	0	255	148	65	0	0	559
FP+RA+RI+RN	3	157	0	0	0	0	3316	0	3476
AG2	6	0	0	7	29	0	0	50	92
ΣCol.	1001	596	490	1236	484	259	4036	800	8902

Tabela E.13 - Classificação MaxVer/ICM utilizando dados Univariados HV em nível de discriminação 5 (7 classes)

Cla./Ref.	PL	AG4	PS	AG3	AG1	FP+FD+RA+RI+RN	AG2	ΣLin.
PL	827	0	851	76	182	112	0	2048
AG4	14	490	0	40	0	0	689	1233
PS	74	0	112	204	15	0	59	464
AG3	0	0	0	0	0	0	0	0
AG1	56	0	233	139	62	4	3	497
FP+FD+RA+RI+RN	24	0	33	0	0	4516	0	4573
AG2	6	0	7	25	0	0	49	87
ΣCol.	1001	490	1236	484	259	4632	800	8902

Tabela E.14 - Classificação MaxVer/ICM utilizando dados Univariados HV em nível de discriminação 6 (6 classes)

Cla./Ref.	PL	AG4	PS	AG1+AG3	FP+FD+RA+RI+RN	AG2	ΣLin.
PL	691	0	756	162	98	4	1711
AG4	16	490	0	36	0	685	1227
PS	263	0	341	427	0	54	1085
AG1+AG3	5	0	100	90	0	0	195
FP+FD+RA+RI+RN	26	0	35	3	4534	0	4598
AG2	0	0	4	25	0	57	86
ΣCol.	1001	490	1236	743	4632	800	8902

Tabela E.15 - Classificação MaxVer/ICM utilizando dados Univariados HV em nível de discriminação 7 (5 classes)

Cla./Ref.	PL+PS	AG4	AG1+AG3	FP+FD+RA+RI+RN	AG2	ΣLin.
PL+PS	444	0	23	24	0	491
AG4	3	490	21	0	629	1143
AG1+AG3	1623	0	612	24	41	2300
FP+FD+RA+RI+RN	158	0	13	4584	0	4755
AG2	9	0	74	0	130	213
ΣCol.	2237	490	743	4632	800	8902

Tabela E.16 - Classificação MaxVer/ICM utilizando dados Univariados HV em nível de discriminação 8 (4 classes)

Cla./Ref.	PL+PS+AG1+AG3	AG4	FP+FD+RA+RI+RN	AG2	ΣLin.
PL+PS+AG1+AG3	2791	0	140	49	2980
AG4	27	467	0	612	1106
FP+FD+RA+RI+RN	64	0	4492	0	4556
AG2	98	23	0	139	260
ΣCol.	2980	490	4632	800	8902

Tabela E.17 - Classificação MaxVer/ICM utilizando dados Univariados VV em nível de discriminação 1 (11 classes)

Cla./Ref.	RA	RN	PL	FD	AG4	PS	RI	AG3	AG1	FP	AG2	Σ Lin.
RA	0	0	0	0	0	0	0	0	0	0	0	0
RN	0	0	0	0	0	0	0	0	0	0	0	0
PL	347	262	727	325	4	881	425	38	13	174	500	3696
FD	1	0	0	0	0	3	0	0	0	0	0	4
AG4	0	0	44	0	467	37	0	319	183	0	16	1066
PS	0	14	82	22	12	191	2	68	31	16	63	501
RI	640	676	117	249	5	29	574	0	0	894	192	3376
AG3	0	0	16	0	0	5	0	1	0	0	0	22
AG1	0	0	15	0	2	90	11	58	32	0	13	221
FP	0	0	0	0	0	0	0	0	0	0	16	16
AG2	0	0	0	0	0	0	0	0	0	0	0	0
Σ Col.	988	952	1001	596	490	1236	1012	484	259	1084	800	8902

Tabela E.18 - Classificação MaxVer/ICM utilizando dados Univariados VV em nível de discriminação 2 (10 classes)

Cla./Ref.	RA+RI	RN	PL	FD	AG4	PS	AG3	AG1	FP	AG2	Σ Lin.
RA+RI	1263	688	99	259	5	35	0	0	918	213	3480
RN	0	0	0	0	0	0	0	0	0	0	0
PL	713	240	740	314	4	859	33	15	154	496	3568
FD	11	0	0	0	0	3	0	0	0	0	14
AG4	0	0	54	3	466	42	317	207	0	15	1104
PS	1	24	80	20	13	209	69	31	12	62	521
AG3	0	0	13	0	0	6	1	0	0	0	20
AG1	12	0	15	0	2	82	64	6	0	14	195
FP	0	0	0	0	0	0	0	0	0	0	0
AG2	0	0	0	0	0	0	0	0	0	0	0
Σ Col.	2000	952	1001	596	490	1236	484	259	1084	800	8902

Tabela E.19 - Classificação MaxVer/ICM utilizando dados Univariados VV em nível de discriminação 3 (9 classes)

Cla./Ref.	RA+RI+RN	PL	FD	AG4	PS	AG3	AG1	FP	AG2	Σ Lin.
RA+RI+RN	1126	24	54	5	4	0	0	764	132	2109
PL	1114	714	283	8	840	33	16	216	500	3724
FD	662	91	233	0	45	0	0	84	87	1202
AG4	1	56	2	464	45	314	208	0	16	1106
PS	38	91	22	11	219	69	31	12	39	532
AG3	0	12	2	0	6	1	0	0	0	21
AG1	11	13	0	2	77	67	4	8	26	208
FP	0	0	0	0	0	0	0	0	0	0
AG2	0	0	0	0	0	0	0	0	0	0
Σ Col.	2952	1001	596	490	1236	484	259	1084	800	8902

Tabela E.20 - Classificação MaxVer/ICM utilizando dados Univariados VV em nível de discriminação 4 (8 classes)

Cla./Ref.	PL	FD	AG4	PS	AG3	AG1	FP+RA+RI+RN	AG2	Σ Lin.
PL	736	255	7	802	30	20	1304	476	3630
FD	100	281	0	51	0	0	817	96	1345
AG4	47	2	468	44	324	181	3	16	1085
PS	70	15	10	243	68	35	48	42	531
AG3	5	2	0	6	1	2	0	4	20
AG1	14	0	0	86	61	21	19	29	230
FP+RA+RI+RN	29	41	5	4	0	0	1845	137	2061
AG2	0	0	0	0	0	0	0	0	0
Σ Col.	1001	596	490	1236	484	259	4036	800	8902

Tabela E.21 - Classificação MaxVer/ICM utilizando dados Univariados VV em nível de discriminação 5 (7 classes)

Cla./Ref.	PL	AG4	PS	AG3	AG1	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL	685	0	807	43	22	905	455	2917
AG4	53	473	48	319	165	3	15	1076
PS	67	12	220	49	33	42	38	461
AG3	10	0	7	4	0	0	3	24
AG1	14	0	71	69	39	5	25	223
FP+FD+RA+RI+RN	172	5	83	0	0	3677	264	4201
AG2	0	0	0	0	0	0	0	0
Σ Col.	1001	490	1236	484	259	4632	800	8902

Tabela E.22 - Classificação MaxVer/ICM utilizando dados Univariados VV em nível de discriminação 6 (6 classes)

Cla./Ref.	PL	AG4	PS	AG1+AG3	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL	688	0	698	48	880	422	2736
AG4	47	446	25	445	3	10	976
PS	78	13	289	112	49	62	603
AG1+AG3	26	25	137	137	11	24	360
FP+FD+RA+RI+RN	162	6	87	1	3689	282	4227
AG2	0	0	0	0	0	0	0
Σ Col.	1001	490	1236	743	4632	800	8902

Tabela E.23 - Classificação MaxVer/ICM utilizando dados Univariados VV em nível de discriminação 7 (5 classes)

Cla./Ref.	PL+PS	AG4	AG1+AG3	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL+PS	1386	23	133	300	355	2197
AG4	55	425	387	0	10	877
AG1+AG3	247	41	223	1	51	563
FP+FD+RA+RI+RN	549	1	0	4331	384	5265
AG2	0	0	0	0	0	0
Σ Col.	2237	490	743	4632	800	8902

Tabela E.24 - Classificação MaxVer/ICM utilizando dados Univariados VV em nível de discriminação 8 (4 classes)

Cla./Ref.	PL+PS+AG1+AG3	AG4	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL+PS+AG1+AG3	1929	87	305	395	2716
AG4	485	398	2	14	899
FP+FD+RA+RI+RN	530	5	4325	369	5229
AG2	36	0	0	22	58
Σ Col.	2980	490	4632	800	8902

Tabela E.25 - Classificação MaxVer/ICM utilizando dados Bivariados HH+HV em nível de discriminação 1 (11 classes)

Cla./Ref.	RA	RN	PL	FD	AG4	PS	RI	AG3	AG1	AG2	FP	Σ Lin.
RA	373	140	0	1	0	2	236	0	0	0	161	913
RN	313	104	0	13	0	0	147	0	0	0	705	1282
PL	6	7	426	27	0	376	8	5	25	0	1	881
FD	209	602	39	522	0	11	561	0	1	0	189	2134
AG4	0	0	0	0	490	0	0	0	0	0	0	490
PS	0	0	338	4	0	626	0	5	7	16	0	996
RI	87	98	12	19	0	0	55	0	0	0	28	299
AG3	0	0	0	0	0	0	0	0	0	0	0	0
AG1	0	1	155	10	0	221	5	312	226	1	0	931
AG2	0	0	31	0	0	0	0	162	0	783	0	976
FP	0	0	0	0	0	0	0	0	0	0	0	0
Σ Col.	988	952	1001	596	490	1236	1012	484	259	800	1084	8902

Tabela E.26 - Classificação MaxVer/ICM utilizando dados Bivariados HH+HV em nível de discriminação 2 (10 classes)

Cla./Ref.	RA+RI	RN	PL	FD	AG1	AG2	PS	AG4	AG3	FP	Σ Lin.
RA+RI	506	121	0	29	0	0	0	0	0	653	1309
RN	411	237	14	28	0	0	1	0	0	83	774
PL	26	0	453	23	25	0	378	0	5	0	910
FD	983	590	34	506	1	0	4	0	0	331	2449
AG1	5	1	156	10	226	1	220	0	325	0	944
AG2	0	0	29	0	0	783	0	0	154	0	966
PS	0	0	315	0	7	16	633	0	0	0	971
AG4	0	0	0	0	0	0	0	490	0	0	490
AG3	0	0	0	0	0	0	0	0	0	0	0
FP	69	3	0	0	0	0	0	0	0	17	89
Σ Col.	2000	952	1001	596	259	800	1236	490	484	1084	8902

Tabela E.27 - Classificação MaxVer/ICM utilizando dados Bivariados HH+HV em nível de discriminação 3 (9 classes)

Cla./Ref.	RA+RI+RN	PL	FD	AG4	PS	AG3	AG1	FP	AG2	Σ Lin.
RA+RI+RN	35	0	0	0	0	0	0	76	0	111
PL	2	447	22	0	363	5	14	0	0	853
FD	1643	76	542	0	60	0	3	428	0	2752
AG4	0	0	0	490	0	0	0	0	0	490
PS	0	314	2	0	638	0	17	0	16	987
AG3	0	0	0	0	0	0	0	0	0	0
AG1	0	125	15	0	166	335	225	0	1	867
FP	1272	3	15	0	4	0	0	580	0	1874
AG2	0	36	0	0	5	144	0	0	783	968
Σ Col.	2952	1001	596	490	1236	484	259	1084	800	8902

Tabela E.28 - Classificação MaxVer/ICM utilizando dados Bivariados HH+HV em nível de discriminação 4 (8 classes)

Cla./Ref.	FP+RA+RI+RN	AG2	AG1	AG3	PS	PL	AG4	FD	Σ Lin.
FP+RA+RI+RN	2662	0	1	0	6	5	0	65	2739
AG2	0	783	0	144	0	38	0	0	965
AG1	0	1	227	335	158	126	0	9	856
AG3	0	0	0	0	0	0	0	0	0
PS	0	16	7	0	642	312	0	0	977
PL	9	0	19	5	379	445	0	29	886
AG4	0	0	0	0	0	0	490	0	490
FD	1365	0	5	0	51	75	0	493	1989
Σ Col.	4036	800	259	484	1236	1001	490	596	8902

Tabela E.29 - Classificação MaxVer/ICM utilizando dados Bivariados HH+HV em nível de discriminação 5 (7 classes)

Cla./Ref.	PL	AG4	AG3	AG1	AG2	FP+FD+RA+RI+RN	PS	Σ Lin.
PL	492	0	5	27	0	29	464	1017
AG4	0	482	0	0	1	0	0	483
AG3	0	0	0	0	0	0	0	0
AG1	189	0	332	212	9	15	154	911
AG2	37	8	147	6	773	0	4	975
FP+FD+RA+RI+RN	47	0	0	5	0	4588	40	4680
PS	236	0	0	9	17	0	574	836
Σ Col.	1001	490	484	259	800	4632	1236	8902

Tabela E.30 - Classificação MaxVer/ICM utilizando dados Bivariados HH+HV em nível de discriminação 6 (6 classes)

Cla./Ref.	PL	AG4	PS	AG1+AG3	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL	492	0	464	32	29	0	1017
AG4	0	482	0	0	0	1	483
PS	236	0	574	9	0	17	836
AG1+AG3	189	0	154	544	15	9	911
FP+FD+RA+RI+RN	47	0	40	5	4588	0	4680
AG2	37	8	4	153	0	773	975
Σ Col.	1001	490	1236	743	4632	800	8902

Tabela E.31 - Classificação MaxVer/ICM utilizando dados Bivariados HH+HV em nível de discriminação 7 (5 classes)

Cla./Ref.	PL+PS	AG4	AG1+AG3	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL+PS	1913	0	90	20	17	2040
AG4	0	485	0	0	6	491
AG1+AG3	212	0	490	14	8	724
FP+FD+RA+RI+RN	86	0	6	4598	0	4690
AG2	26	5	157	0	769	957
Σ Col.	2237	490	743	4632	800	8902

Tabela E.32 - Classificação MaxVer/ICM utilizando dados Bivariados HH+HV em nível de discriminação 8 (4 classes)

Cla./Ref.	PL+PS+AG1+AG3	FP+FD+RA+RI+RN	AG2	AG4	Σ Lin.
PL+PS+AG1+AG3	2576	66	20	3	2665
FP+FD+RA+RI+RN	85	4566	0	0	4651
AG2	317	0	770	22	1109
AG4	2	0	10	465	477
Σ Col.	2980	4632	800	490	8902

Tabela E.33 - Classificação MaxVer/ICM utilizando dados Bivariados HH+VV em nível de discriminação 1 (11 classes)

Cla./Ref.	RA	RN	PL	FD	AG4	PS	RI	AG3	AG1	FP	AG2	Σ Lin.
RA	288	257	36	35	0	10	220	0	0	151	19	1016
RN	0	2	2	0	0	0	0	0	0	12	0	16
PL	27	0	54	7	0	64	113	0	0	7	27	299
FD	0	0	0	0	0	0	0	0	0	0	0	0
AG4	0	0	0	0	374	1	0	0	0	0	2	377
PS	6	16	264	18	116	691	17	10	0	6	289	1433
RI	136	56	3	45	0	0	45	0	0	221	29	535
AG3	6	4	16	45	0	40	31	223	121	31	0	517
AG1	0	0	23	4	0	33	4	251	138	3	2	458
FP	47	37	0	0	0	0	39	0	0	174	1	298
AG2	478	580	603	442	0	397	543	0	0	479	431	3953
Σ Col.	988	952	1001	596	490	1236	1012	484	259	1084	800	8902

Tabela E.34 - Classificação MaxVer/ICM utilizando dados Bivariados HH+VV em nível de discriminação 2 (10 classes)

Cla./Ref.	RA+RI	RN	PL	FD	AG4	PS	AG3	AG1	FP	AG2	Σ Lin.
RA+RI	23	14	0	6	0	0	0	0	93	12	148
RN	255	121	43	37	0	11	0	0	56	0	523
PL	114	0	31	10	0	59	0	0	18	22	254
FD	37	26	8	14	0	0	0	0	42	0	127
AG4	0	0	0	0	383	1	0	0	0	2	386
PS	22	31	288	18	107	666	10	0	4	287	1433
AG3	51	1	5	48	0	37	228	121	33	1	525
AG1	4	0	26	5	0	30	239	138	3	1	446
FP	469	136	0	24	0	1	0	0	317	18	965
AG2	1025	623	600	434	0	431	7	0	518	457	4095
Σ Col.	2000	952	1001	596	490	1236	484	259	1084	800	8902

Tabela E.35 - Classificação MaxVer/ICM utilizando dados Bivariados HH+VV em nível de discriminação 3 (9 classes)

Cla./Ref.	RA+RI+RN	PL	FD	AG4	PS	AG3	AG1	FP	AG2	Σ Lin.
RA+RI+RN	0	0	0	0	0	0	0	13	0	13
PL	103	45	10	0	72	0	0	21	27	278
FD	154	12	42	0	2	0	0	60	18	288
AG4	0	0	0	386	1	0	0	0	2	389
PS	35	272	14	104	665	10	0	0	288	1388
AG3	55	5	44	0	37	245	124	28	1	539
AG1	7	21	5	0	26	222	135	0	3	419
FP	1264	61	60	0	22	0	0	524	27	1958
AG2	1334	585	421	0	411	7	0	438	434	3630
Σ Col.	2952	1001	596	490	1236	484	259	1084	800	8902

Tabela E.36 - Classificação MaxVer/ICM utilizando dados Bivariados HH+VV em nível de discriminação 4 (8 classes)

Cla./Ref.	PL	FD	AG4	PS	AG3	AG1	FP+RA+RI+RN	AG2	Σ Lin.
PL	46	8	0	72	0	0	109	31	266
FD	13	40	0	0	0	0	168	17	238
AG4	0	0	380	1	0	0	2	2	385
PS	266	14	110	670	10	0	30	293	1393
AG3	16	42	0	37	251	124	89	1	560
AG1	38	5	0	30	219	135	7	3	437
FP+RA+RI+RN	51	73	0	23	0	0	1890	18	2055
AG2	571	414	0	403	4	0	1741	435	3568
Σ Col.	1001	596	490	1236	484	259	4036	800	8902

Tabela E.37 - Classificação MaxVer/ICM utilizando dados Bivariados HH+VV em nível de discriminação 5 (7 classes)

Cla./Ref.	PL	AG4	PS	AG3	AG1	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL	73	0	71	0	0	73	31	248
AG4	0	393	0	0	0	0	2	395
PS	272	97	704	7	0	59	299	1438
AG3	14	0	40	265	122	115	0	556
AG1	31	0	18	207	137	5	4	402
FP+FD+RA+RI+RN	84	0	24	0	0	2778	66	2952
AG2	527	0	379	5	0	1602	398	2911
Σ Col.	1001	490	1236	484	259	4632	800	8902

Tabela E.38 - Classificação MaxVer/ICM utilizando dados Bivariados HH+VV em nível de discriminação 6 (6 classes)

Cla./Ref.	PL	AG4	PS	AG1+AG3	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL	55	0	34	0	95	29	213
AG4	0	382	1	0	0	2	385
PS	292	108	704	0	43	307	1454
AG1+AG3	55	0	94	743	121	0	1013
FP+FD+RA+RI+RN	68	0	56	0	2782	73	2979
AG2	531	0	347	0	1591	389	2858
Σ Col.	1001	490	1236	743	4632	800	8902

Tabela E.39 - Classificação MaxVer/ICM utilizando dados Bivariados HH+VV em nível de discriminação 7 (5 classes)

Cla./Ref.	PL+PS	AG4	AG1+AG3	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL+PS	1482	28	0	146	376	2032
AG4	2	462	0	0	2	466
AG1+AG3	180	0	743	139	14	1076
FP+FD+RA+RI+RN	100	0	0	2867	76	3043
AG2	473	0	0	1480	332	2285
Σ Col.	2237	490	743	4632	800	8902

Tabela E.40 - Classificação MaxVer/ICM utilizando dados Bivariados HH+VV em nível de discriminação 8 (4 classes)

Cla./Ref.	PL+PS+AG1+AG3	AG4	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL+PS+AG1+AG3	2416	28	274	317	3035
AG4	9	462	1	4	476
FP+FD+RA+RI+RN	98	0	3078	94	3270
AG2	457	0	1279	385	2121
Σ Col.	2980	490	4632	800	8902

Tabela E.41 - Classificação MaxVer/ICM utilizando dados Bivariados HV+VV em nível de discriminação 1 (11 classes)

Cla./Ref.	AG2	AG3	AG1	RI	FP	RA	RN	PL	FD	AG4	PS	Σ Lin.
AG2	770	0	0	0	0	0	0	30	0	5	2	807
AG3	4	219	57	0	0	0	0	0	0	0	31	311
AG1	0	0	0	0	0	0	0	0	0	0	0	0
RI	0	0	2	0	22	29	8	0	0	0	0	61
FP	0	0	0	1	0	0	1	0	0	0	0	2
RA	0	0	0	13	25	0	0	0	0	0	0	38
RN	0	0	0	131	638	337	69	0	0	0	0	1175
PL	0	0	0	0	0	0	0	0	0	0	0	0
FD	0	0	0	867	399	622	874	283	596	0	68	3709
AG4	24	50	0	0	0	0	0	0	0	485	0	559
PS	2	215	200	0	0	0	0	688	0	0	1135	2240
Σ Col.	800	484	259	1012	1084	988	952	1001	596	490	1236	8902

Tabela E.42 - Classificação MaxVer/ICM utilizando dados Bivariados HV+VV em nível de discriminação 2 (10 classes)

Cla./Ref.	FD	RA+RI	AG3	AG4	AG2	AG1	PS	PL	FP	RN	Σ Lin.
FD	588	1534	0	0	0	0	68	282	409	866	3747
RA+RI	8	292	0	0	0	0	0	0	332	39	671
AG3	0	0	219	0	4	58	26	0	0	0	307
AG4	0	0	50	481	24	0	0	0	0	0	555
AG2	0	0	0	9	770	0	0	34	0	0	813
AG1	0	0	0	0	0	0	0	0	0	0	0
PS	0	0	215	0	2	199	1142	685	0	0	2243
PL	0	0	0	0	0	0	0	0	0	0	0
FP	0	136	0	0	0	0	0	0	329	39	504
RN	0	38	0	0	0	2	0	0	14	8	62
Σ Col.	596	2000	484	490	800	259	1236	1001	1084	952	8902

Tabela E.43 - Classificação MaxVer/ICM utilizando dados Bivariados HV+VV em nível de discriminação 3 (9 classes)

Cla./Ref.	RA+RI+RN	PL	FD	AG4	PS	AG3	AG1	AG2	FP	Σ Lin.
RA+RI+RN	380	0	0	0	0	0	2	0	202	584
PL	0	0	0	0	0	0	0	0	0	0
FD	2242	284	596	0	66	0	0	0	379	3567
AG4	0	0	0	481	0	50	0	24	0	555
PS	0	682	0	0	1137	214	199	2	0	2234
AG3	0	0	0	0	31	220	58	4	0	313
AG1	0	0	0	0	0	0	0	0	0	0
AG2	0	35	0	9	2	0	0	770	0	816
FP	330	0	0	0	0	0	0	0	503	833
Σ Col.	2952	1001	596	490	1236	484	259	800	1084	8902

Tabela E.44 - Classificação MaxVer/ICM utilizando dados Bivariados HV+VV em nível de discriminação 4 (8 classes)

Cla./Ref.	PL	FD	AG4	PS	AG3	AG1	AG2	FP+RA+RI+RN	Σ Lin.
PL	0	0	0	0	0	0	0	0	0
FD	289	569	0	98	0	1	0	1824	2781
AG4	0	0	476	0	51	2	35	0	564
PS	667	1	0	1075	220	192	3	1	2159
AG3	2	0	0	51	213	62	6	0	334
AG1	0	0	0	0	0	0	0	0	0
AG2	43	0	14	10	0	0	756	0	823
FP+RA+RI+RN	0	26	0	2	0	2	0	2211	2241
Σ Col.	1001	596	490	1236	484	259	800	4036	8902

Tabela E.45 - Classificação MaxVer/ICM utilizando dados Bivariados HV+VV em nível de discriminação 5 (7 classes)

Cla./Ref.	PL	AG4	AG3	AG1	AG2	FP+FD+RA+RI+RN	PS	Σ Lin.
PL	0	0	0	0	0	0	0	0
AG4	3	468	64	6	51	0	3	595
AG3	7	0	191	46	10	7	51	312
AG1	0	0	0	0	0	0	0	0
AG2	65	18	5	0	731	1	13	833
FP+FD+RA+RI+RN	189	0	0	5	1	4607	92	4894
PS	737	4	224	202	7	17	1077	2268
Σ Col.	1001	490	484	259	800	4632	1236	8902

Tabela E.46 - Classificação MaxVer/ICM utilizando dados Bivariados HV+VV em nível de discriminação 6 (6 classes)

Cla./Ref.	PL	AG1+AG3	FP+FD+RA+RI+RN	AG2	PS	AG4	Σ Lin.
PL	0	0	0	0	0	0	0
AG1+AG3	7	237	7	10	51	0	312
FP+FD+RA+RI+RN	189	5	4607	1	92	0	4894
AG2	65	5	1	731	13	18	833
PS	737	426	17	7	1077	4	2268
AG4	3	70	0	51	3	468	595
Σ Col.	1001	743	4632	800	1236	490	8902

Tabela E.47 - Classificação MaxVer/ICM utilizando dados Bivariados HV+VV em nível de discriminação 7 (5 classes)

Cla./Ref.	PL+PS	AG4	AG1+AG3	AG2	FP+FD+RA+RI+RN	Σ Lin.
PL+PS	1814	4	426	7	17	2268
AG4	6	468	70	51	0	595
AG1+AG3	58	0	237	10	7	312
AG2	78	18	5	731	1	833
FP+FD+RA+RI+RN	281	0	5	1	4607	4894
Σ Col.	2237	490	743	800	4632	8902

Tabela E.48 - Classificação MaxVer/ICM utilizando dados Bivariados HV+VV em nível de discriminação 8 (4 classes)

Cla./Ref.	PL+PS+AG1+AG3	AG4	AG2	FP+FD+RA+RI+RN	Σ Lin.
PL+PS+AG1+AG3	2561	4	19	22	2606
AG4	45	468	52	0	565
AG2	96	18	728	1	843
FP+FD+RA+RI+RN	278	0	1	4609	4888
Σ Col.	2980	490	800	4632	8902

Tabela E.49 - Classificação MaxVer/ICM utilizando dados Multivariados em nível de discriminação 1 (11 classes)

Cla./Ref.	RA	RN	PL	FD	AG4	PS	RI	AG3	AG1	FP	AG2	Σ Lin.
RA	247	118	0	4	0	7	165	0	0	314	0	855
RN	303	191	0	114	0	0	112	0	2	100	0	822
PL	11	0	808	80	0	722	56	7	1	4	0	1689
FD	263	619	20	383	0	9	605	0	0	238	0	2137
AG4	0	0	0	0	484	0	0	0	0	0	0	484
PS	0	0	128	0	0	477	0	0	10	0	9	624
RI	129	14	0	11	0	0	67	0	0	354	0	575
AG3	0	0	4	4	0	0	0	434	71	0	0	513
AG1	0	0	27	0	0	16	0	43	175	0	0	261
FP	35	10	0	0	0	0	7	0	0	74	0	126
AG2	0	0	14	0	6	5	0	0	0	0	791	816
Σ Col.	988	952	1001	596	490	1236	1012	484	259	1084	800	8902

Tabela E.50 - Classificação MaxVer/ICM utilizando dados Multivariados em nível de discriminação 2 (10 classes)

Cla./Ref.	RA+RI	RN	PL	FD	AG4	PS	AG3	AG1	FP	AG2	Σ Lin.
RA+RI	149	29	0	10	0	0	0	0	138	0	326
RN	1075	365	3	136	0	9	0	2	362	0	1952
PL	55	24	771	77	0	710	10	8	5	0	1660
FD	619	506	24	357	0	12	0	1	272	0	1791
AG4	1	0	0	0	472	0	0	0	0	0	473
PS	0	3	145	4	0	476	3	9	0	13	653
AG3	0	0	5	4	0	5	420	73	0	0	507
AG1	0	0	27	8	0	18	51	166	0	0	270
FP	101	25	0	0	0	0	0	0	307	0	433
AG2	0	0	26	0	18	6	0	0	0	787	837
Σ Col.	2000	952	1001	596	490	1236	484	259	1084	800	8902

Tabela E.51 - Classificação MaxVer/ICM utilizando dados Multivariados em nível de discriminação 3 (9 classes)

Cla./Ref.	RA+RI+RN	PL	FD	AG4	PS	AG3	AG1	FP	AG2	Σ Lin.
RA+RI+RN	928	0	34	0	9	0	2	262	0	1235
PL	28	750	55	0	706	12	8	4	0	1563
FD	1850	32	491	0	12	0	1	427	0	2813
AG4	1	0	0	471	0	0	0	0	0	472
PS	0	157	4	1	478	4	9	0	13	666
AG3	1	4	4	0	7	414	62	0	0	492
AG1	0	27	8	0	18	54	177	0	0	284
FP	144	0	0	0	0	0	0	391	0	535
AG2	0	31	0	18	6	0	0	0	787	842
Σ Col.	2952	1001	596	490	1236	484	259	1084	800	8902

Tabela E.52 - Classificação MaxVer/ICM utilizando dados Multivariados em nível de discriminação 4 (8 classes)

Cla./Ref.	PL	FD	AG4	PS	AG3	AG1	FP+RA+RI+RN	AG2	Σ Lin.
PL	750	66	0	707	12	9	30	0	1574
FD	28	462	0	15	0	1	1838	0	2344
AG4	0	0	469	0	0	0	1	0	470
PS	153	4	1	472	4	9	0	16	659
AG3	4	5	0	7	411	62	0	0	489
AG1	27	8	0	20	57	176	0	0	288
FP+RA+RI+RN	3	51	0	9	0	2	2167	0	2232
AG2	36	0	20	6	0	0	0	784	846
Σ Col.	1001	596	490	1236	484	259	4036	800	8902

Tabela E.53 - Classificação MaxVer/ICM utilizando dados Multivariados em nível de discriminação 5 (7 classes)

Cla./Ref.	PL	AG4	PS	AG3	AG1	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL	722	0	662	11	8	134	0	1537
AG4	0	465	1	0	0	0	6	472
PS	170	1	498	7	9	6	17	708
AG3	6	1	7	391	62	7	0	474
AG1	27	0	29	75	174	0	0	305
FP+FD+RA+RI+RN	36	0	28	0	6	4485	0	4555
AG2	40	23	11	0	0	0	777	851
Σ Col.	1001	490	1236	484	259	4632	800	8902

Tabela E.54 - Classificação MaxVer/ICM utilizando dados Multivariados em nível de discriminação 6 (6 classes)

Cla./Ref.	PL	AG4	PS	AG1+AG3	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL	715	0	691	7	132	0	1545
AG4	0	465	1	0	0	6	472
PS	169	1	483	2	7	18	680
AG1+AG3	33	1	26	727	8	0	795
FP+FD+RA+RI+RN	42	0	24	7	4485	0	4558
AG2	42	23	11	0	0	776	852
Σ Col.	1001	490	1236	743	4632	800	8902

Tabela E.55 - Classificação MaxVer/ICM utilizando dados Multivariados em nível de discriminação 7 (5 classes)

Cla./Ref.	PL+PS	AG4	AG1+AG3	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL+PS	2034	1	15	70	14	2134
AG4	2	461	0	0	9	472
AG1+AG3	70	2	720	17	0	809
FP+FD+RA+RI+RN	92	0	8	4545	1	4646
AG2	39	26	0	0	776	841
Σ Col.	2237	490	743	4632	800	8902

Tabela E.56 - Classificação MaxVer/ICM utilizando dados Multivariados em nível de discriminação 8 (4 classes)

Cla./Ref.	PL+PS+AG1+AG3	AG4	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL+PS+AG1+AG3	2790	3	129	18	2940
AG4	4	453	0	16	473
FP+FD+RA+RI+RN	119	0	4503	1	4623
AG2	67	34	0	765	866
Σ Col.	2980	490	4632	800	8902

Tabela E.57 - Classificação MaxVer/ICM utilizando dados Polarimétricos em nível de discriminação 1 (11 classes)

Cla./Ref.	RA	RN	PL	FD	AG4	PS	RI	AG3	AG1	FP	AG2	Σ Lin.
RA	383	241	0	64	0	0	267	0	0	319	0	1274
RN	272	432	0	49	0	6	447	0	0	246	0	1452
PL	0	14	855	64	0	856	6	2	8	8	0	1813
FD	93	239	16	379	0	3	189	0	0	151	0	1070
AG4	0	0	0	0	482	0	0	0	0	0	0	482
PS	0	2	125	1	0	368	0	0	0	0	7	503
RI	235	19	0	33	0	0	97	0	0	351	0	735
AG3	0	0	0	0	0	0	0	471	23	0	0	494
AG1	0	0	5	0	0	3	0	11	228	0	0	247
FP	5	5	0	6	0	0	6	0	0	9	0	31
AG2	0	0	0	0	8	0	0	0	0	0	793	801
Σ Col.	988	952	1001	596	490	1236	1012	484	259	1084	800	8902

Tabela E.58 - Classificação MaxVer/ICM utilizando dados Polarimétricos em nível de discriminação 2 (10 classes)

Cla./Ref.	RA+RI	RN	PL	FD	AG4	PS	AG3	AG1	FP	AG2	Σ Lin.
RA+RI	1033	234	0	194	0	0	0	0	633	0	2094
RN	712	481	0	44	0	10	0	0	279	0	1526
PL	2	9	855	56	0	848	5	9	0	0	1784
FD	247	211	16	302	0	2	1	0	114	0	893
AG4	0	0	0	0	482	0	0	0	0	0	482
PS	0	6	125	0	0	372	0	0	0	10	513
AG3	0	0	0	0	0	0	469	22	0	0	491
AG1	0	0	5	0	0	4	9	228	0	0	246
FP	6	11	0	0	0	0	0	0	58	0	75
AG2	0	0	0	0	8	0	0	0	0	790	798
Σ Col.	2000	952	1001	596	490	1236	484	259	1084	800	8902

Tabela E.59 - Classificação MaxVer/ICM utilizando dados Polarimétricos em nível de discriminação 3 (9 classes)

Cla./Ref.	RA+RI+RN	PL	FD	AG4	PS	AG3	AG1	FP	AG2	Σ Lin.
RA+RI+RN	1974	0	158	0	4	0	0	686	0	2822
PL	7	832	48	0	857	2	10	1	0	1757
FD	661	34	390	0	15	0	0	140	0	1240
AG4	0	0	0	482	0	0	0	0	0	482
PS	3	128	0	0	360	0	0	0	10	501
AG3	0	0	0	0	0	471	19	0	0	490
AG1	0	7	0	0	0	11	230	0	0	248
FP	307	0	0	0	0	0	0	257	0	564
AG2	0	0	0	8	0	0	0	0	790	798
Σ Col.	2952	1001	596	490	1236	484	259	1084	800	8902

Tabela E.60 - Classificação MaxVer/ICM utilizando dados Polarimétricos em nível de discriminação 4 (8 classes)

Cla./Ref.	PL	FD	AG4	PS	AG3	AG1	FP+RA+RI+RN	AG2	Σ Lin.
PL	815	38	0	856	4	9	4	0	1726
FD	37	449	0	20	0	0	711	0	1217
AG4	0	0	481	0	0	0	0	0	481
PS	138	0	0	350	0	0	3	10	501
AG3	0	1	0	2	466	27	0	0	496
AG1	4	0	0	2	14	222	0	0	242
FP+RA+RI+RN	0	108	0	6	0	1	3318	0	3433
AG2	7	0	9	0	0	0	0	790	806
Σ Col.	1001	596	490	1236	484	259	4036	800	8902

Tabela E.61 - Classificação MaxVer/ICM utilizando dados Polarimétricos em nível de discriminação 5 (7 classes)

Cla./Ref.	PL	AG4	PS	AG3	AG1	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL	818	0	858	9	1	33	0	1719
AG4	0	478	0	0	0	0	6	484
PS	149	0	328	0	0	0	11	488
AG3	0	0	2	445	30	1	0	478
AG1	3	0	24	30	220	4	0	281
FP+FD+RA+RI+RN	24	0	16	0	8	4593	0	4641
AG2	7	12	8	0	0	1	783	811
Σ Col.	1001	490	1236	484	259	4632	800	8902

Tabela E.62 - Classificação MaxVer/ICM utilizando dados Polarimétricos em nível de discriminação 6 (6 classes)

Cla./Ref.	PL	AG4	PS	AG1+AG3	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL	810	0	858	8	33	0	1709
AG4	0	478	0	0	0	6	484
PS	150	0	341	8	0	19	518
AG1+AG3	9	0	19	722	1	0	751
FP+FD+RA+RI+RN	25	0	10	5	4597	0	4637
AG2	7	12	8	0	1	775	803
Σ Col.	1001	490	1236	743	4632	800	8902

Tabela E.63 - Classificação MaxVer/ICM utilizando dados Polarimétricos em nível de discriminação 7 (5 classes)

Cla./Ref.	PL+PS	AG4	AG1+AG3	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL+PS	2108	1	32	30	18	2189
AG4	0	471	0	0	14	485
AG1+AG3	32	0	701	3	0	736
FP+FD+RA+RI+RN	85	0	10	4597	0	4692
AG2	12	18	0	2	768	800
Σ Col.	2237	490	743	4632	800	8902

Tabela E.64 - Classificação MaxVer/ICM utilizando dados Polarimétricos em nível de discriminação 8 (4 classes)

Cla./Ref.	PL+PS+AG1+AG3	AG4	FP+FD+RA+RI+RN	AG2	Σ Lin.
PL+PS+AG1+AG3	2853	1	41	16	2911
AG4	0	471	0	15	486
FP+FD+RA+RI+RN	99	0	4591	0	4690
AG2	28	18	0	769	815
Σ Col.	2980	490	4632	800	8902

Tabela E.65 - Classificação K-Médias Wishart H/A/ $\bar{\alpha}$ em nível de discriminação 6 (6 classes)

Cla./Ref.	FP+RA+RI+RN	PL+PS+AG1	FD	AG3	AG2	AG	Σ Lin.
FP+RA+RI+RN	3378	24	364	24	0	0	3790
PL+PS+AG1	10	1405	8	137	3	0	1563
FD	454	105	113	0	0	0	672
AG3	186	175	93	210	0	0	664
AG2	8	421	18	53	224	0	724
AG4	0	366	0	60	573	490	1489
Σ Col.	4036	2496	596	484	800	490	8902

Tabela E.66 - Classificação K-Médias Wishart H/A/ $\bar{\alpha}$ em nível de discriminação 7 (5 classes)

Cla./Ref.	FP+FD+RA+RI+RN	PL+PS+AG1	AG3	AG2	AG4	Σ Lin.
FP+FD+RA+RI+RN	4309	129	24	0	0	4462
PL+PS+AG1	18	1405	137	3	0	1563
AG3	279	175	210	0	0	664
AG2	26	421	53	224	0	724
AG4	0	366	60	573	490	1489
Σ Col.	4632	2496	484	800	490	8902

Tabela E.67 - Classificação K-Médias Wishart H/A/ $\bar{\alpha}$ em nível de discriminação 8 (4 classes)

Cla./Ref.	FP+FD+RA+RI+RN	PL+PS+AG1+AG3	AG2	AG4	Σ Lin.
FP+FD+RA+RI+RN	4309	153	0	0	4462
PL+PS+AG1+AG3	297	1927	3	0	2227
AG2	26	474	224	0	724
AG4	0	426	573	490	1489
Σ Col.	4632	2980	800	490	8902

F CLASSIFICAÇÕES GERADAS PELO MÉTODO MAXVER/ICM

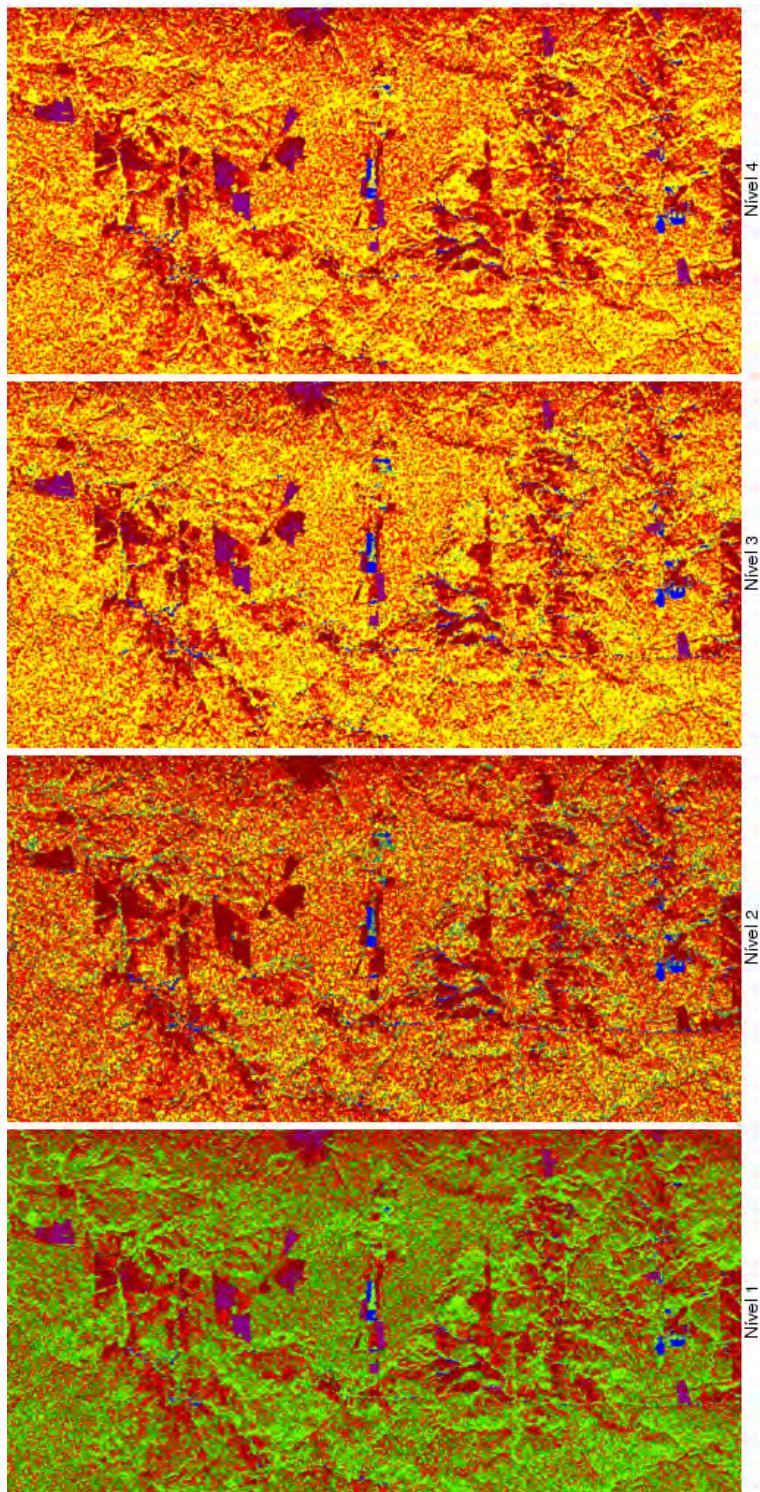


Figura F.1 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados HH para os níveis de discriminação 1 a 4.

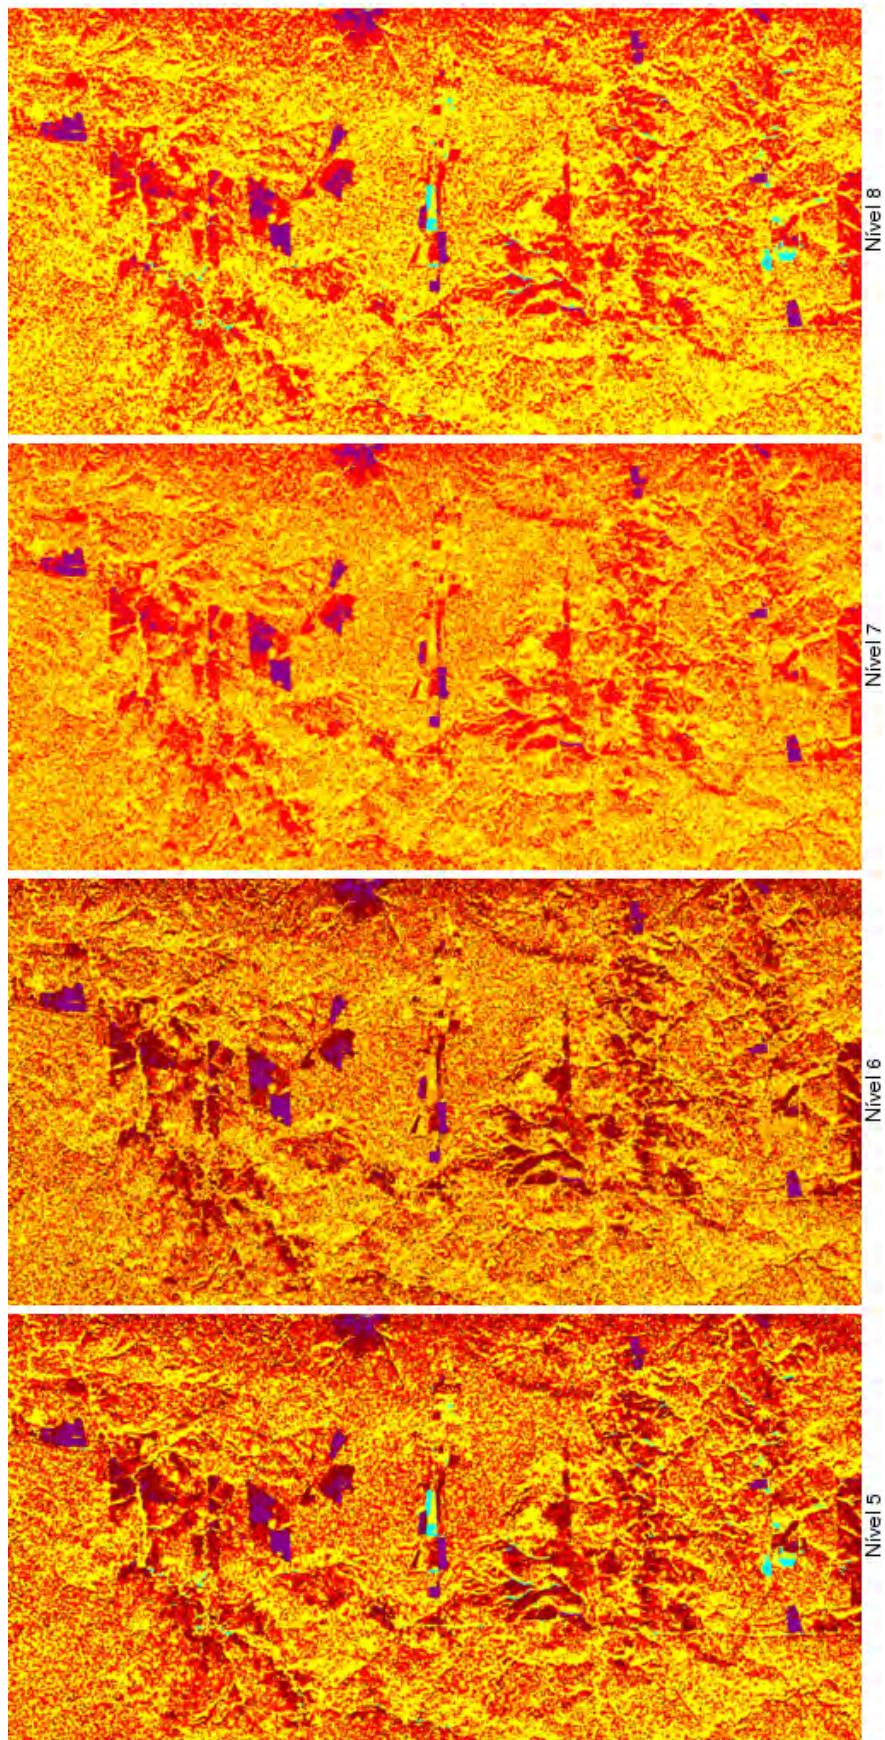


Figura F.2 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados HH para os níveis de discriminação 5 a 8.

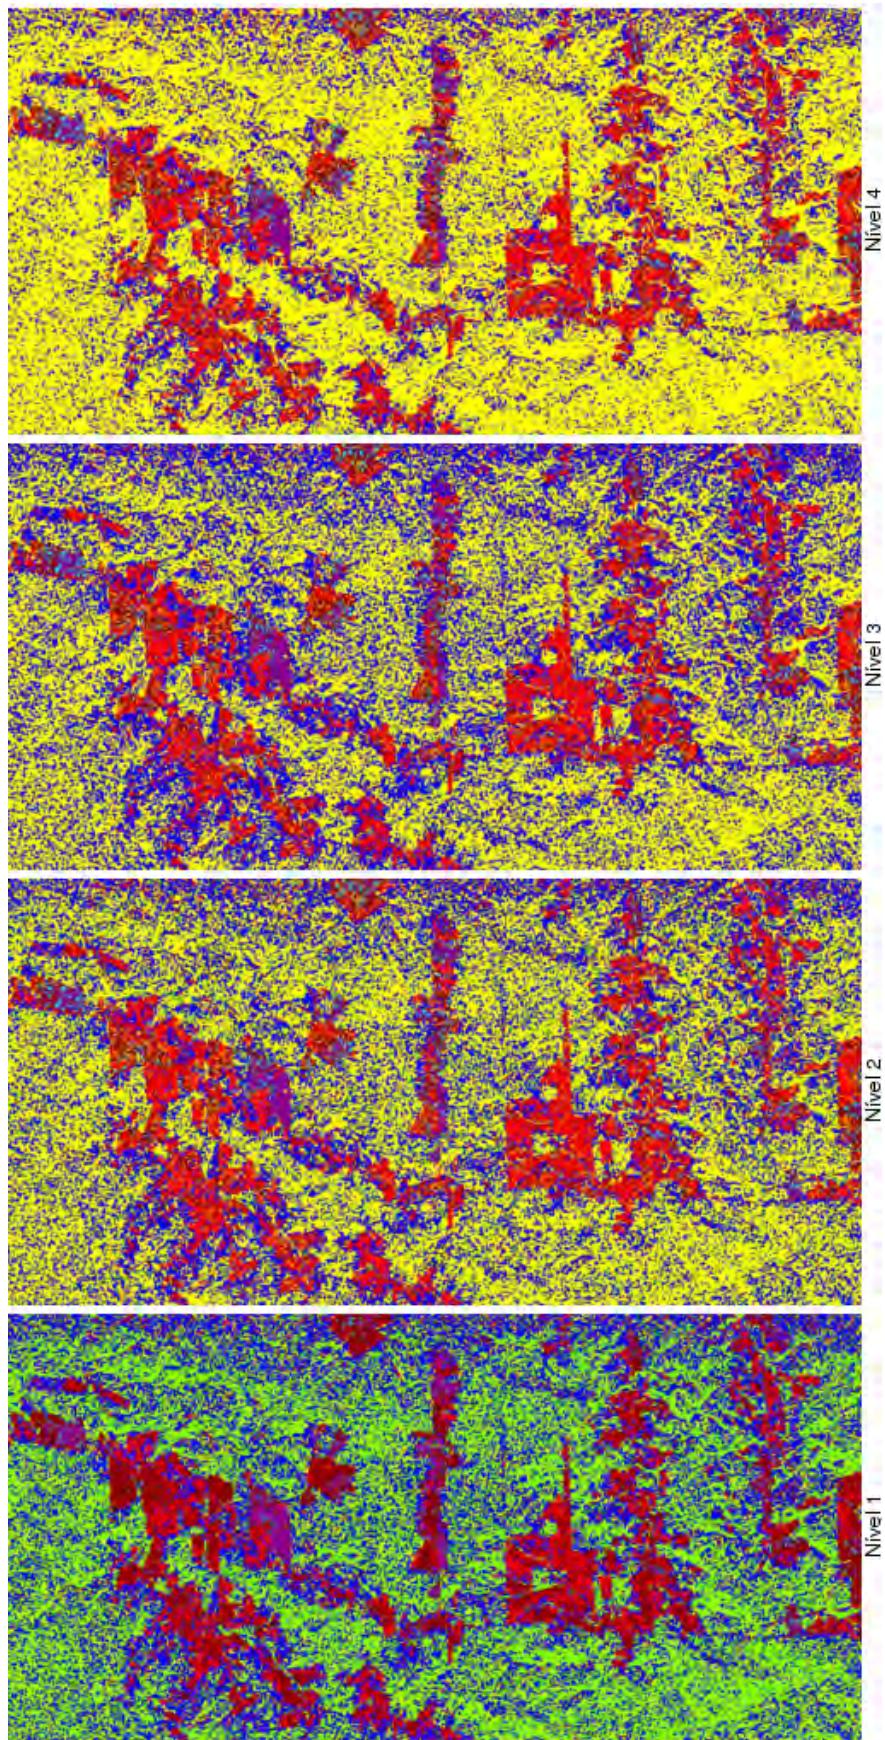


Figura F.3 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados HV para os níveis de discriminação 1 a 4.

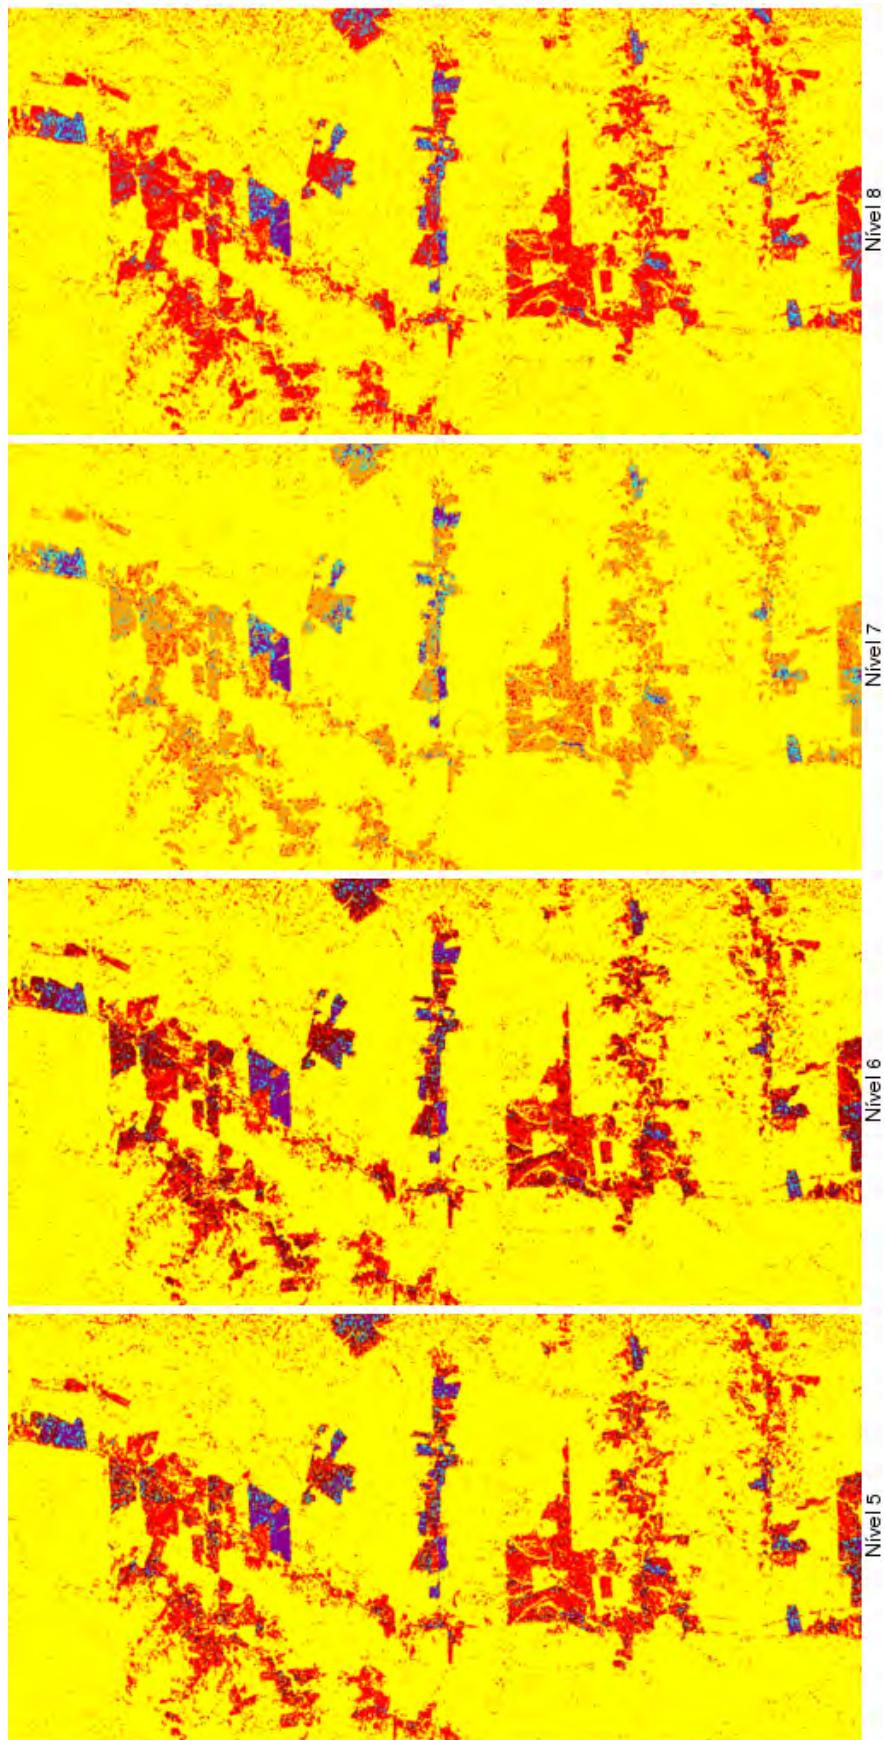


Figura F.4 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados HV para os níveis de discriminação 5 a 8.

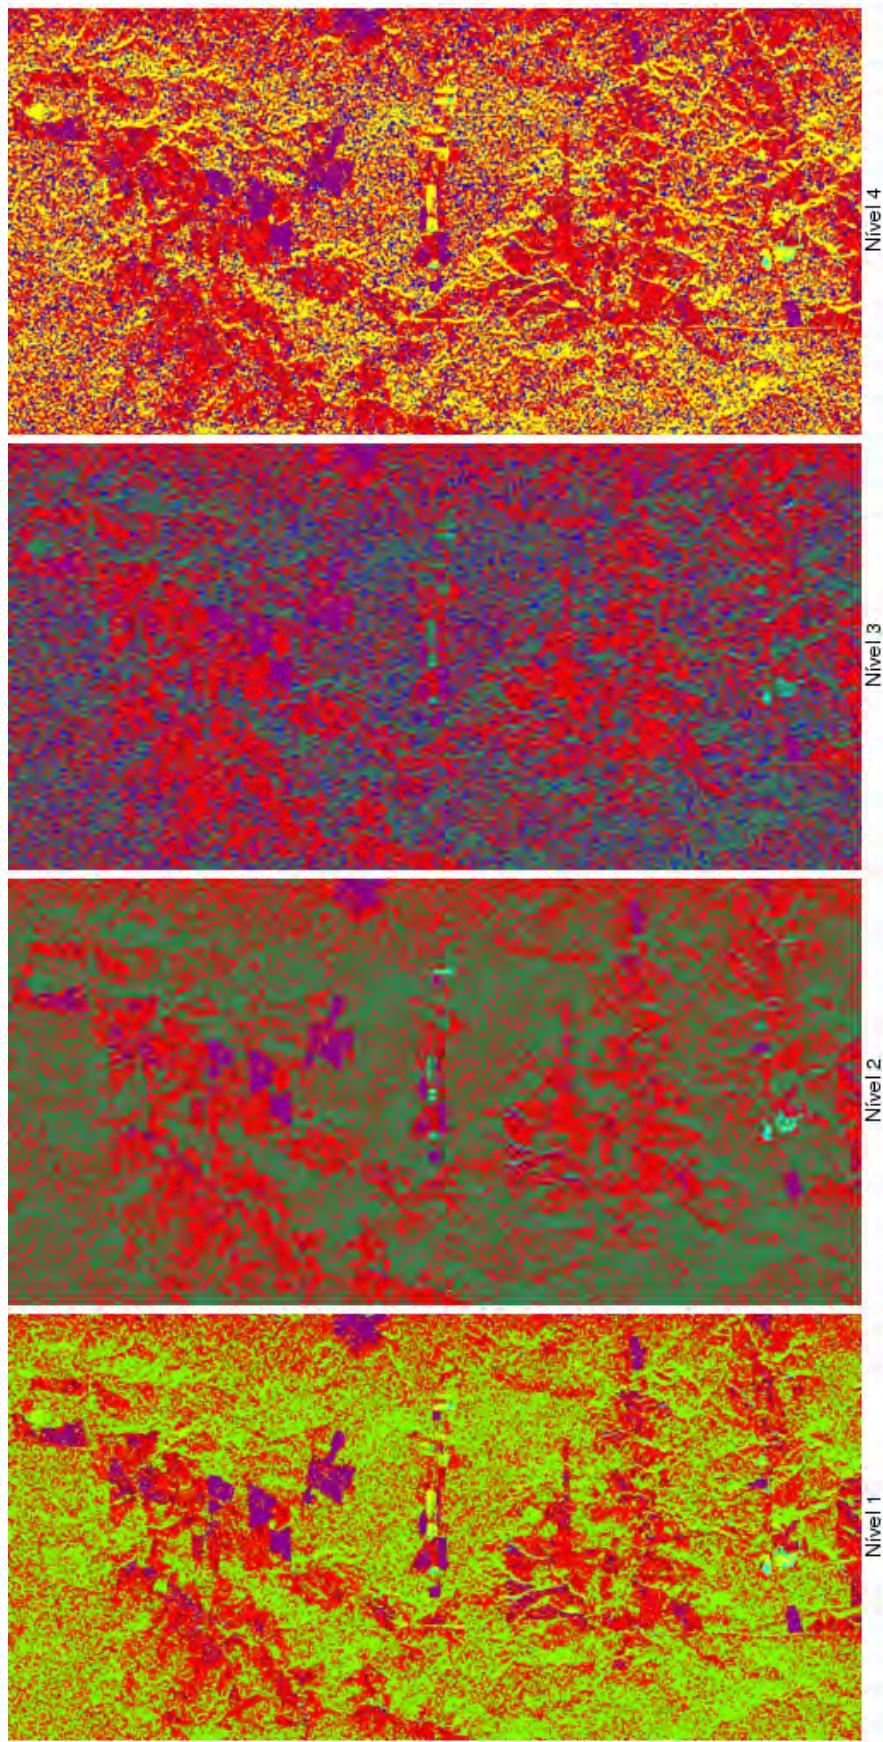


Figura F.5 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados VV para os níveis de discriminação 1 a 4.

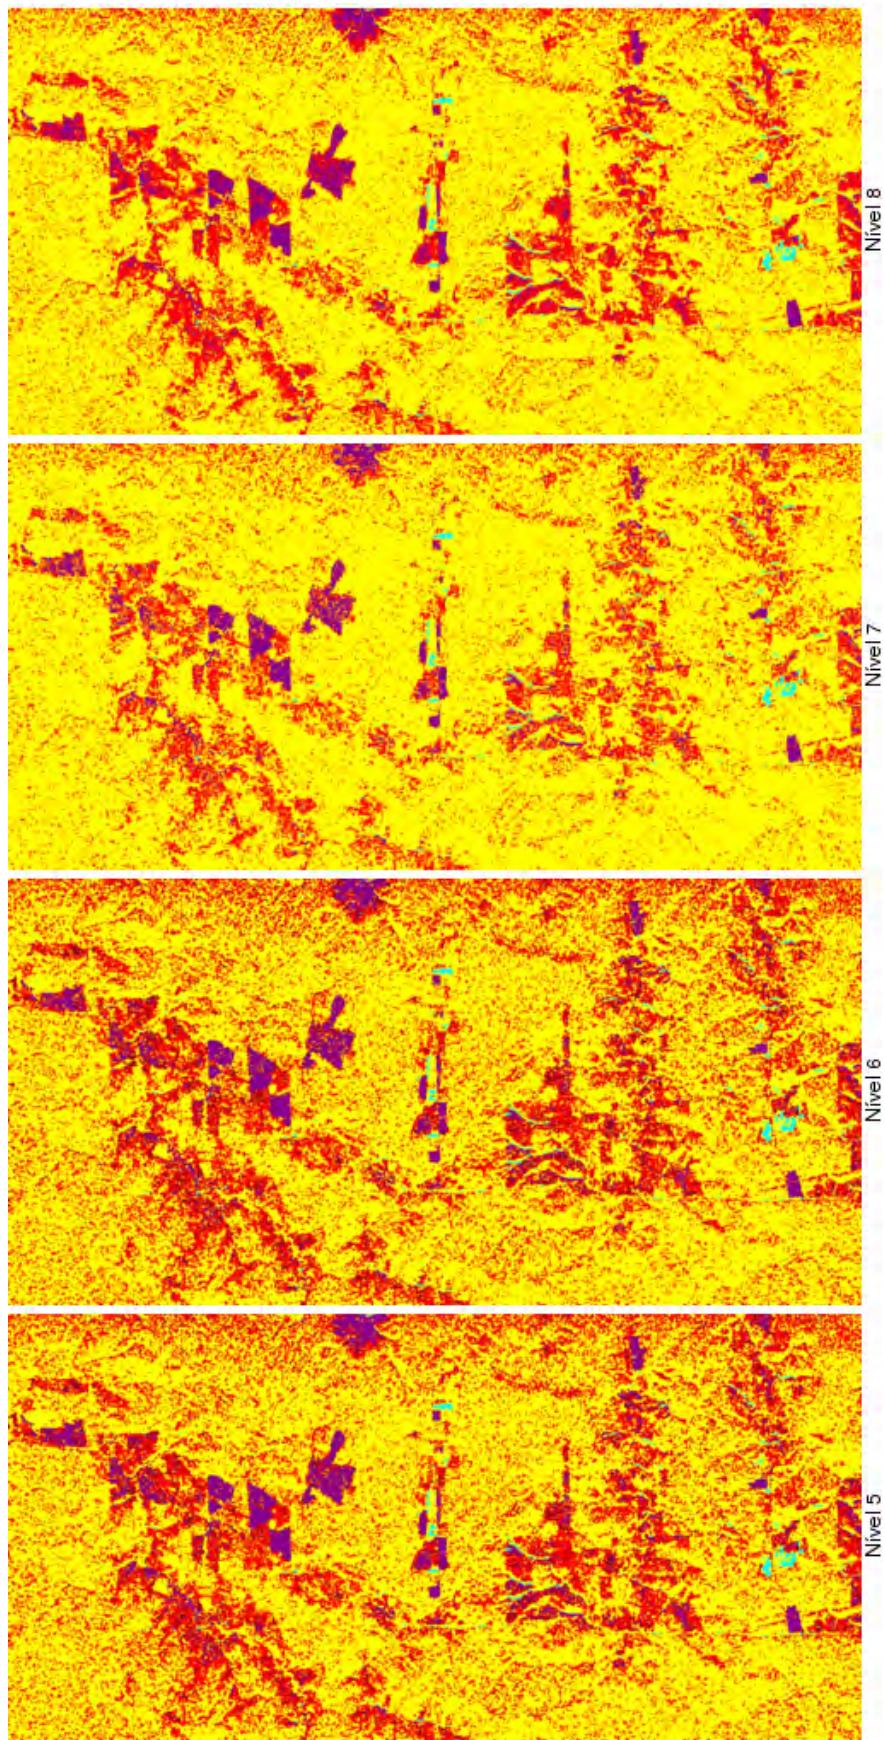


Figura F.6 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Univariados VV para os níveis de discriminação 5 a 8.

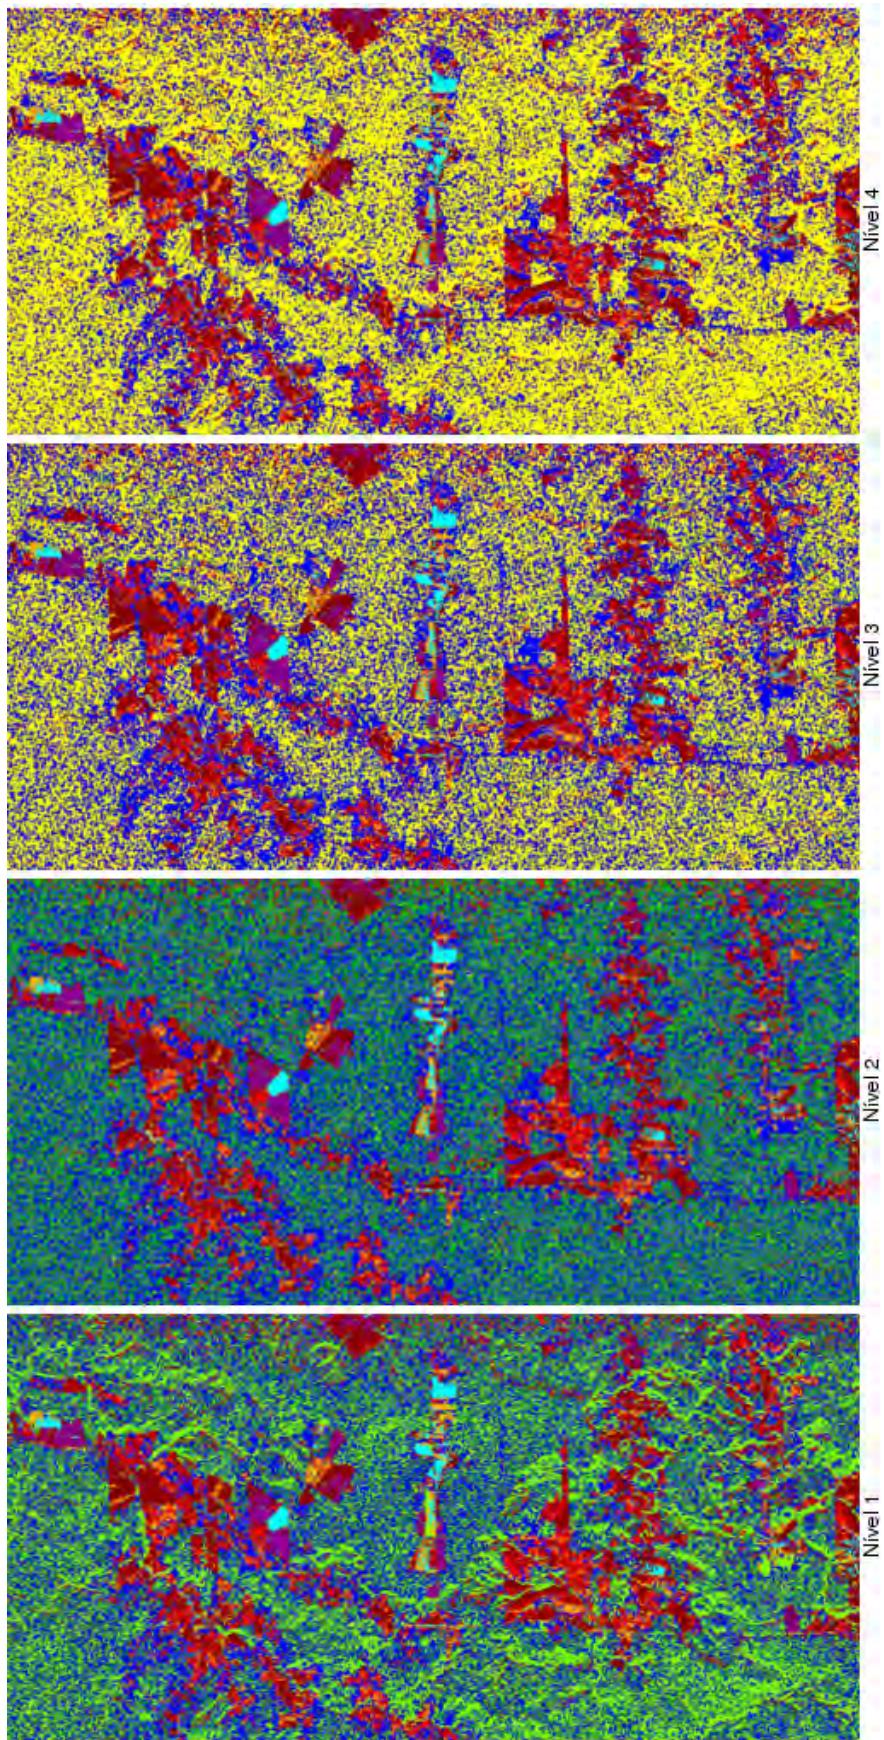


Figura F.7 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Bivariados HH+HV para os níveis de discriminação 1
a. 4.

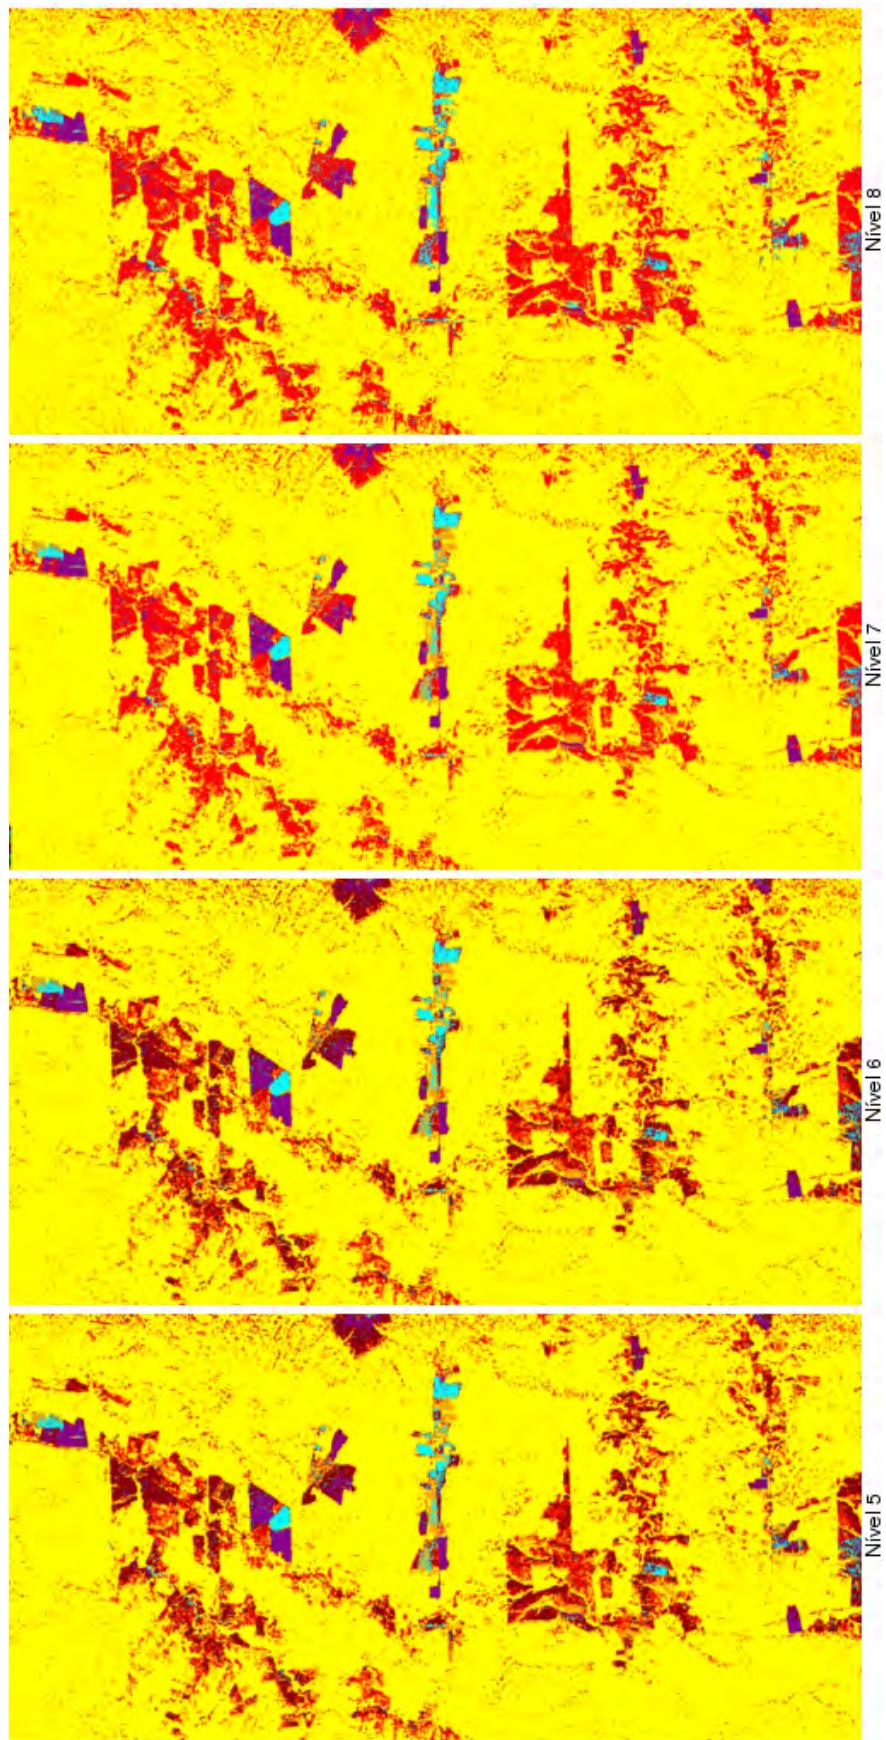


Figura F.8 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Bivariados HH+HV para os níveis de discriminação 5 a 8.

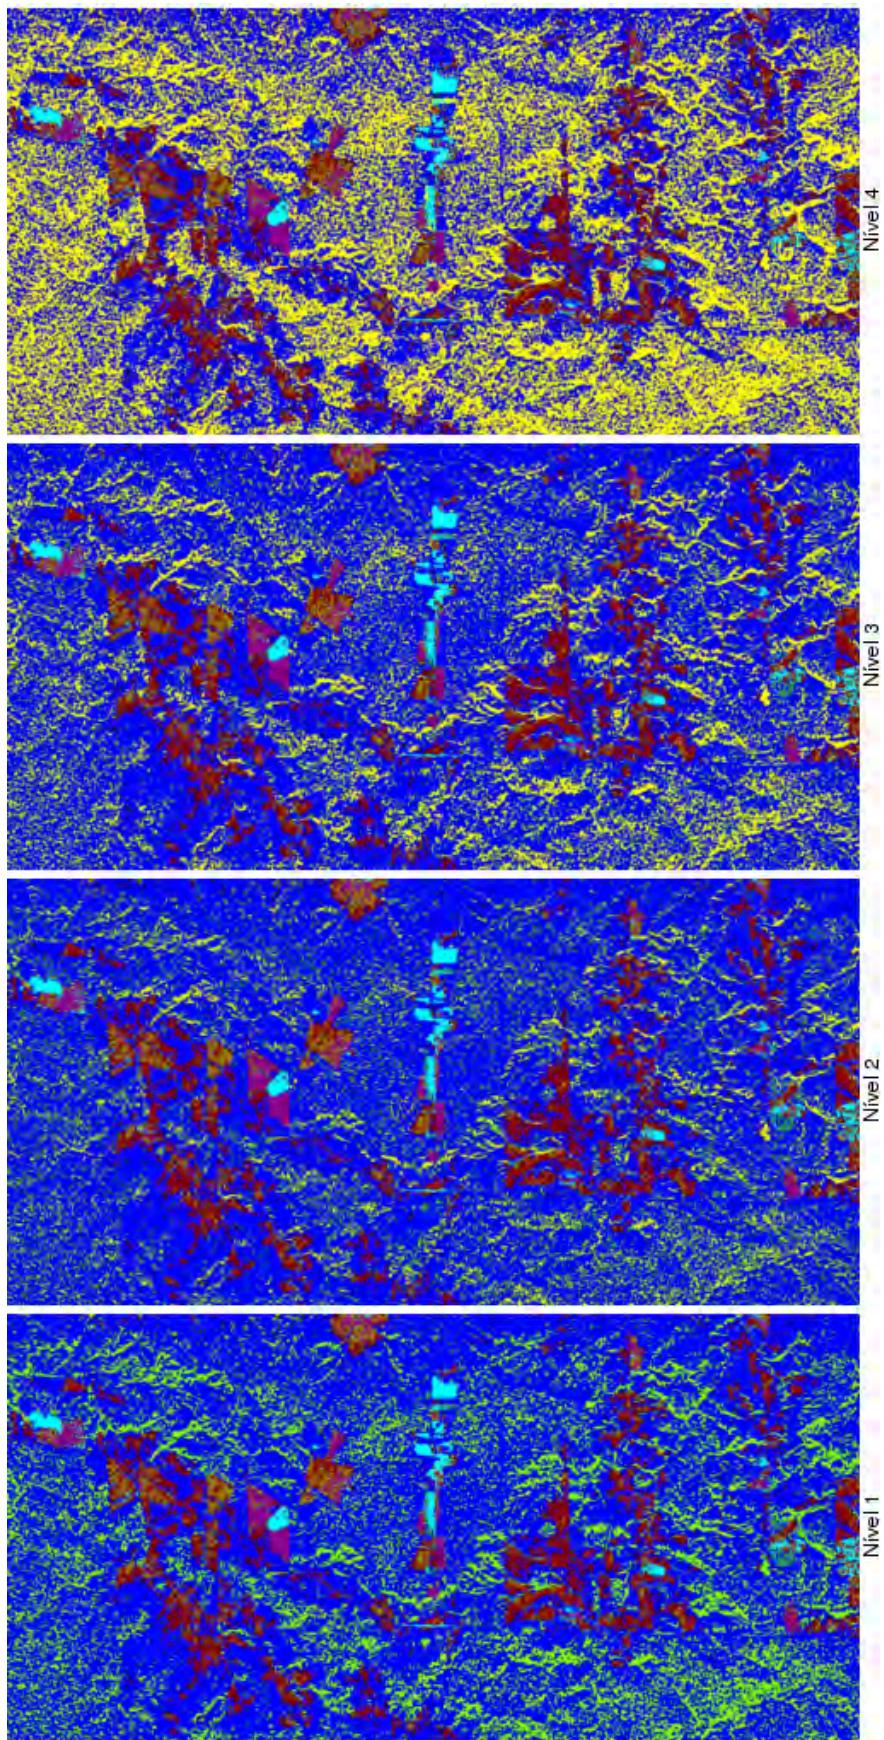


Figura F.9 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Bivariados HV+VV para os níveis de discriminação 1 a 4.

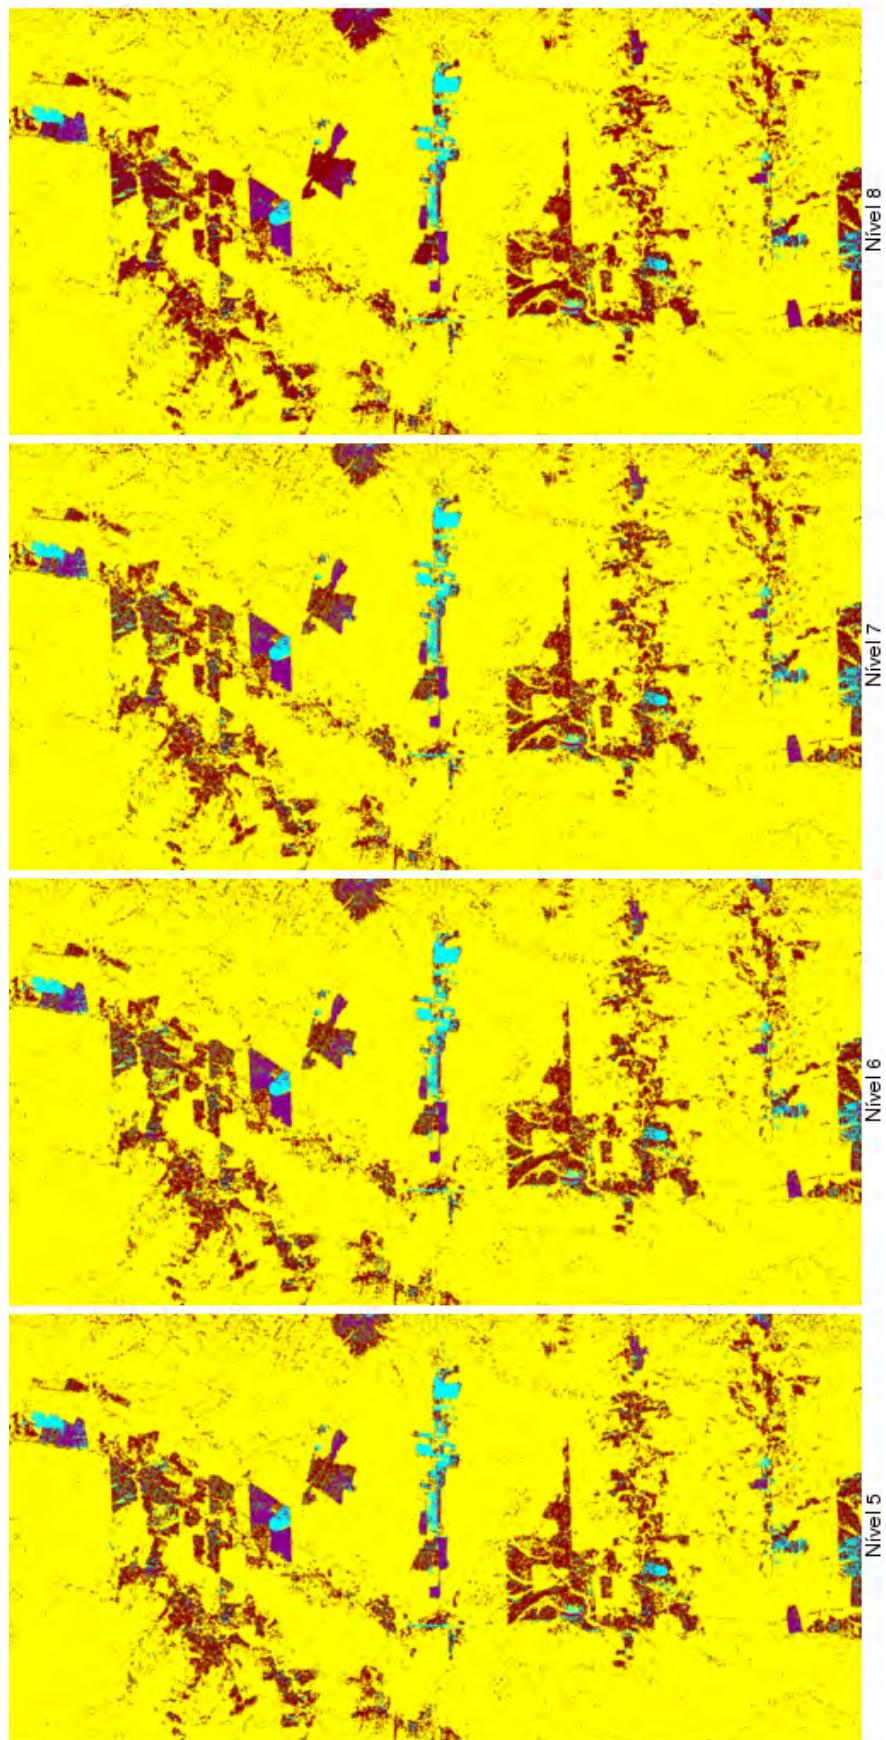


Figura F.10 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Bivariados HV+VV para os níveis de discriminação 5 a 8.

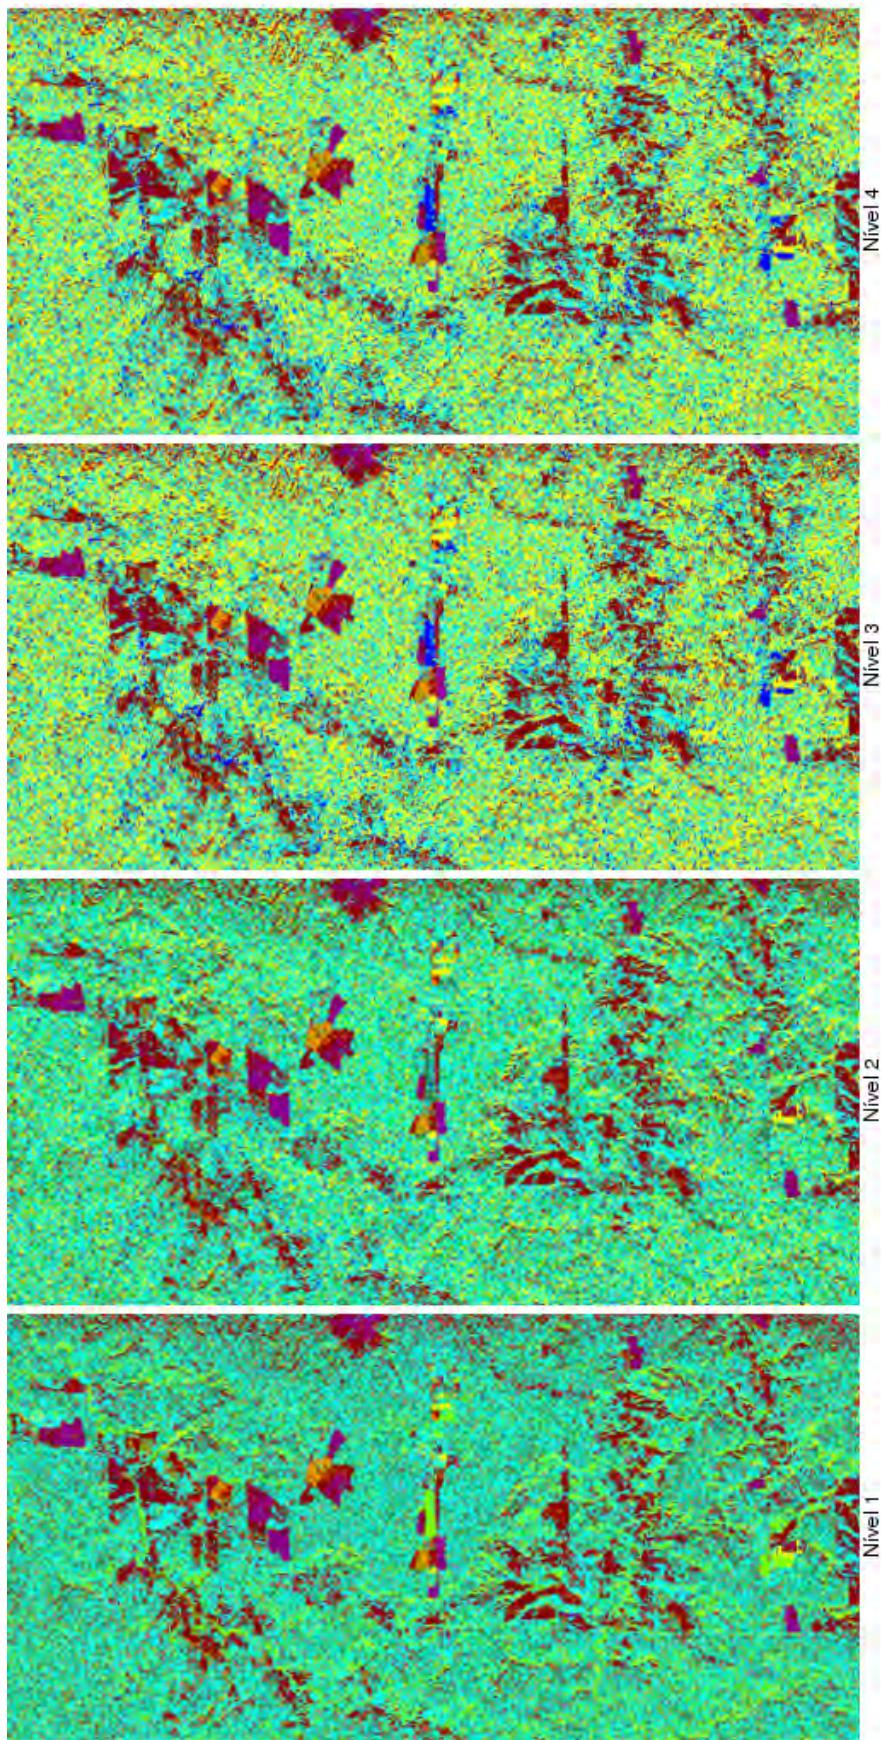


Figura F.11 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Bivariados HH+VV para os níveis de discriminação 1 a 4.

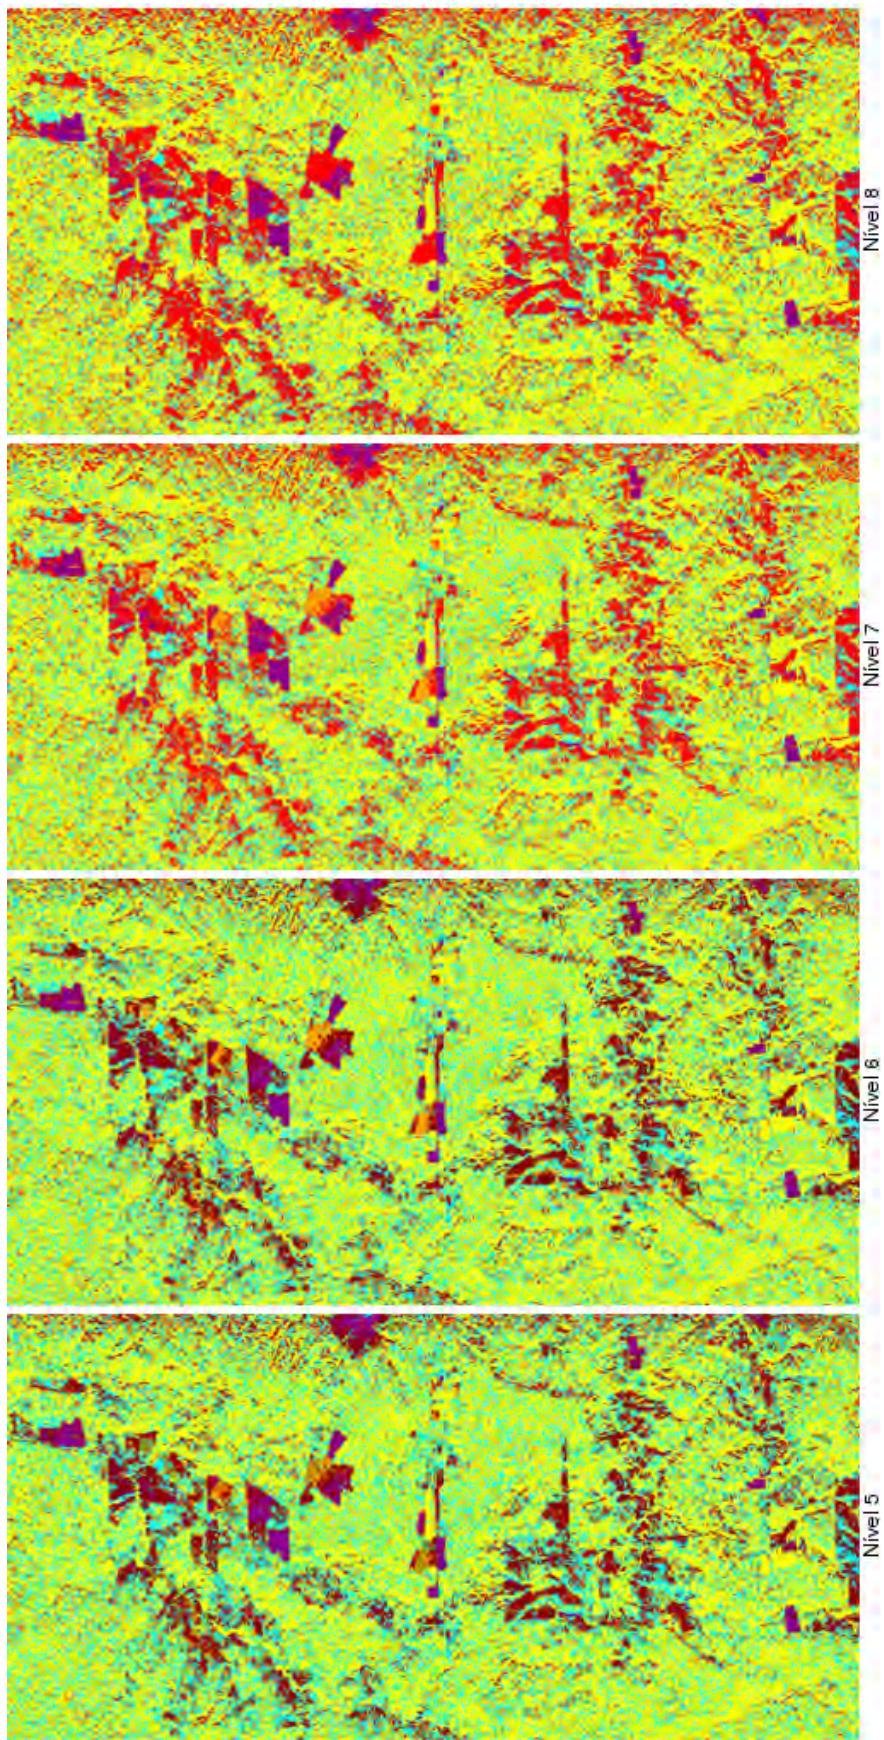


Figura F.12 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Bivariados HH+VV para os níveis de discriminação 5 a 8.

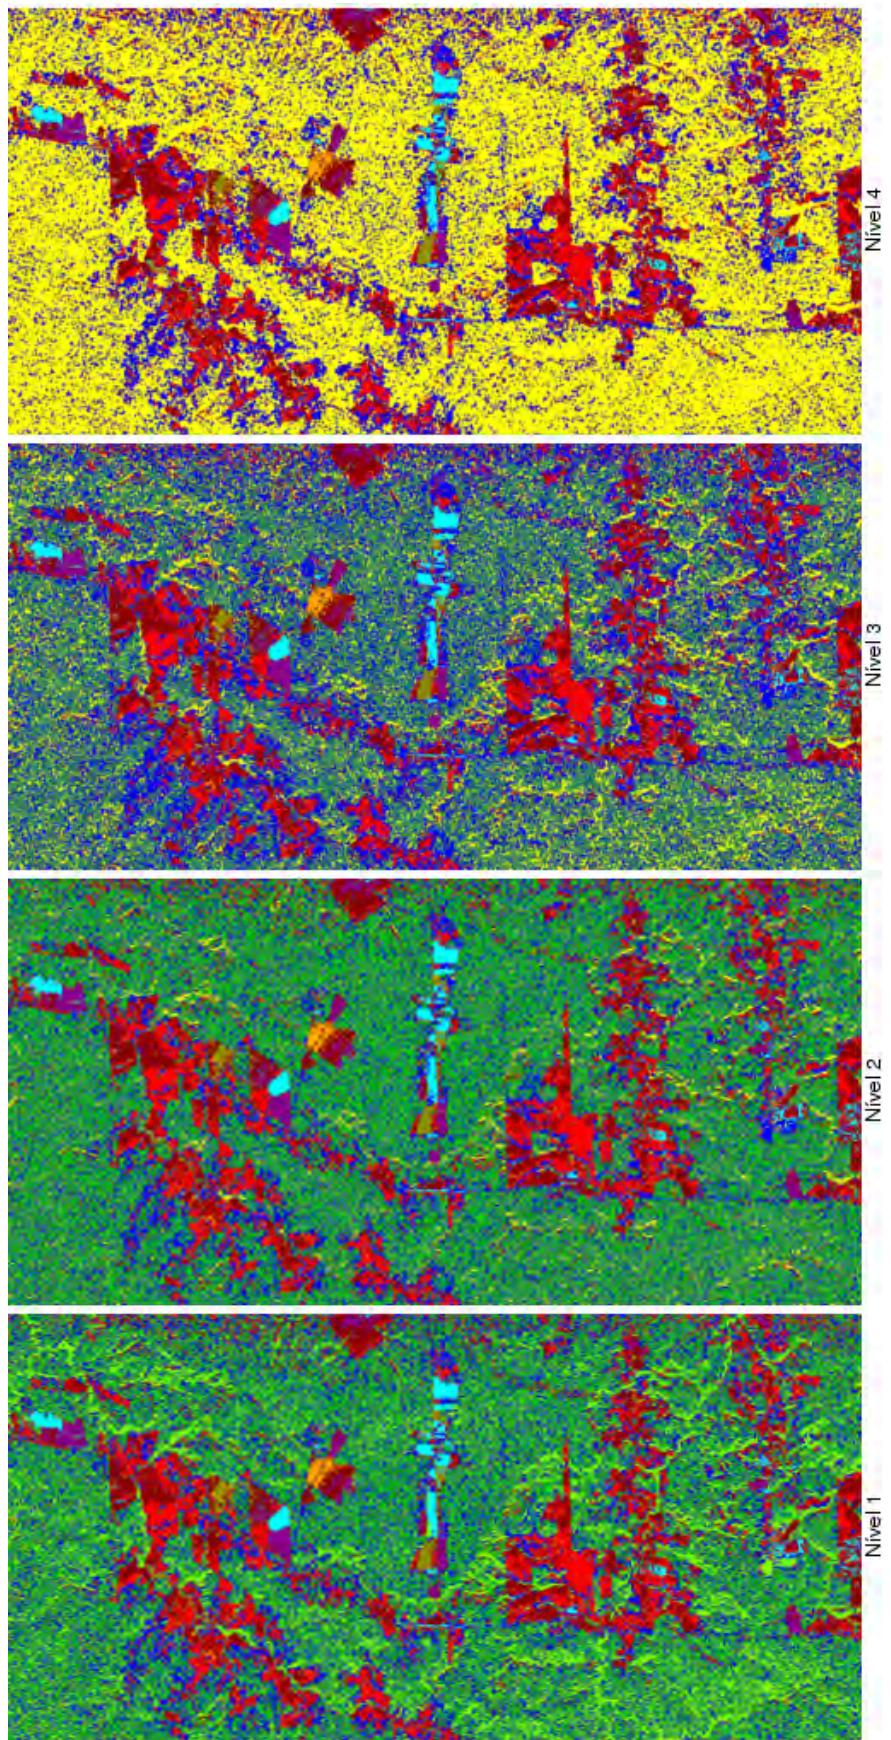


Figura F.13 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Multivariados para os níveis de discriminação 1 a 4.

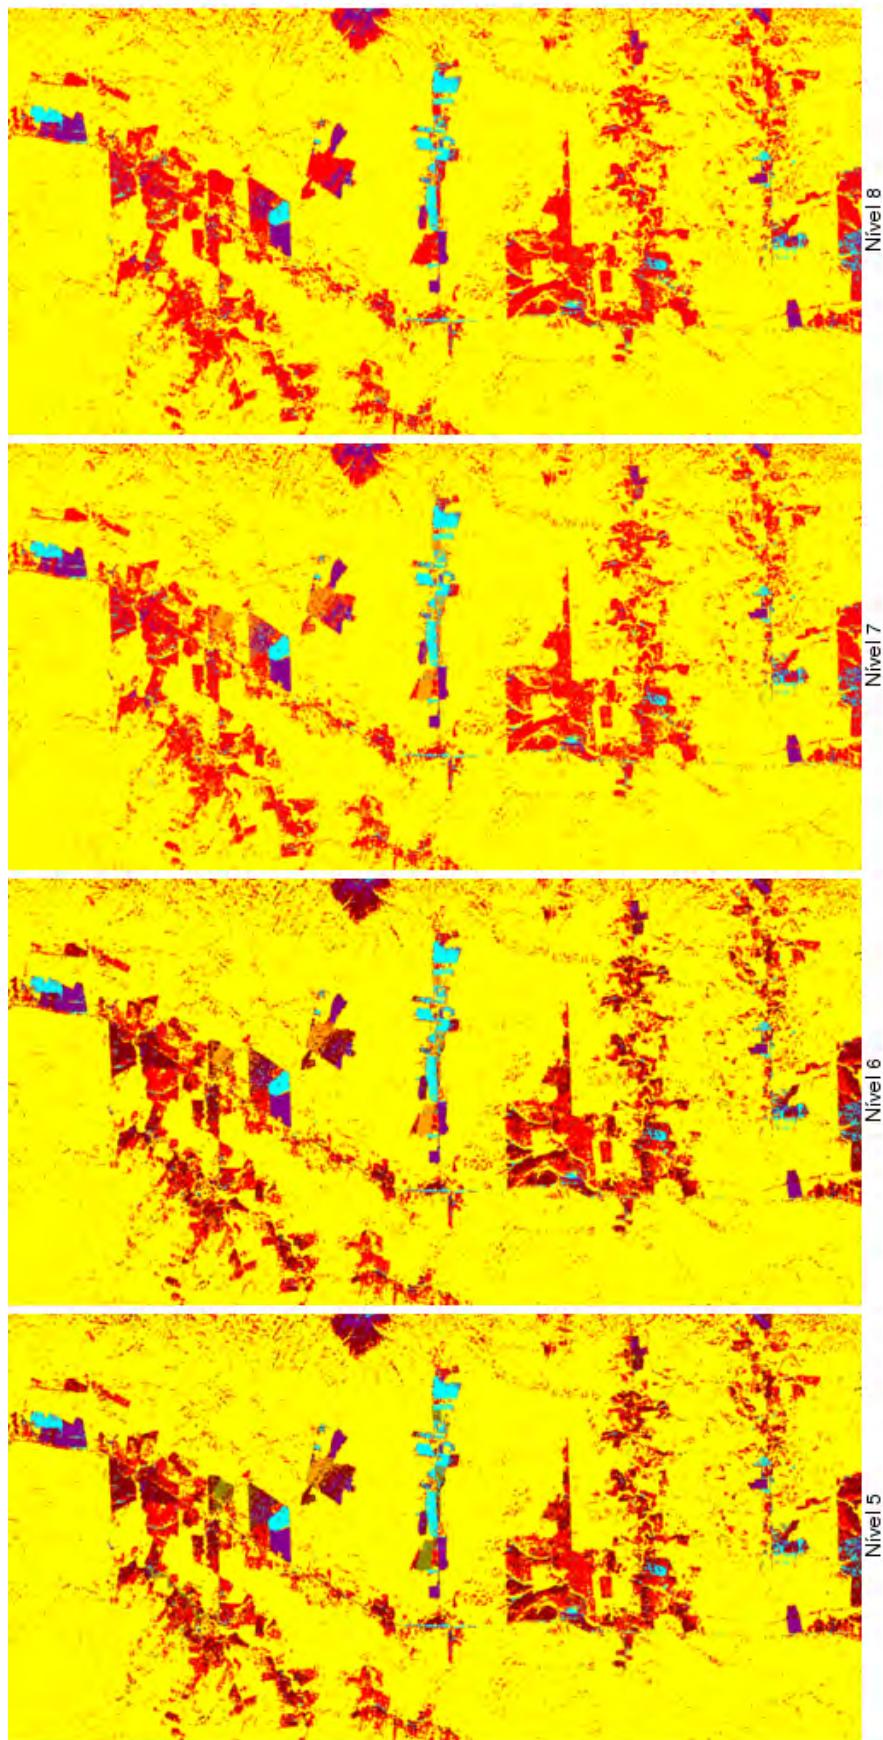


Figura F.14 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Multivariados para os níveis de discriminação 5 a 8.

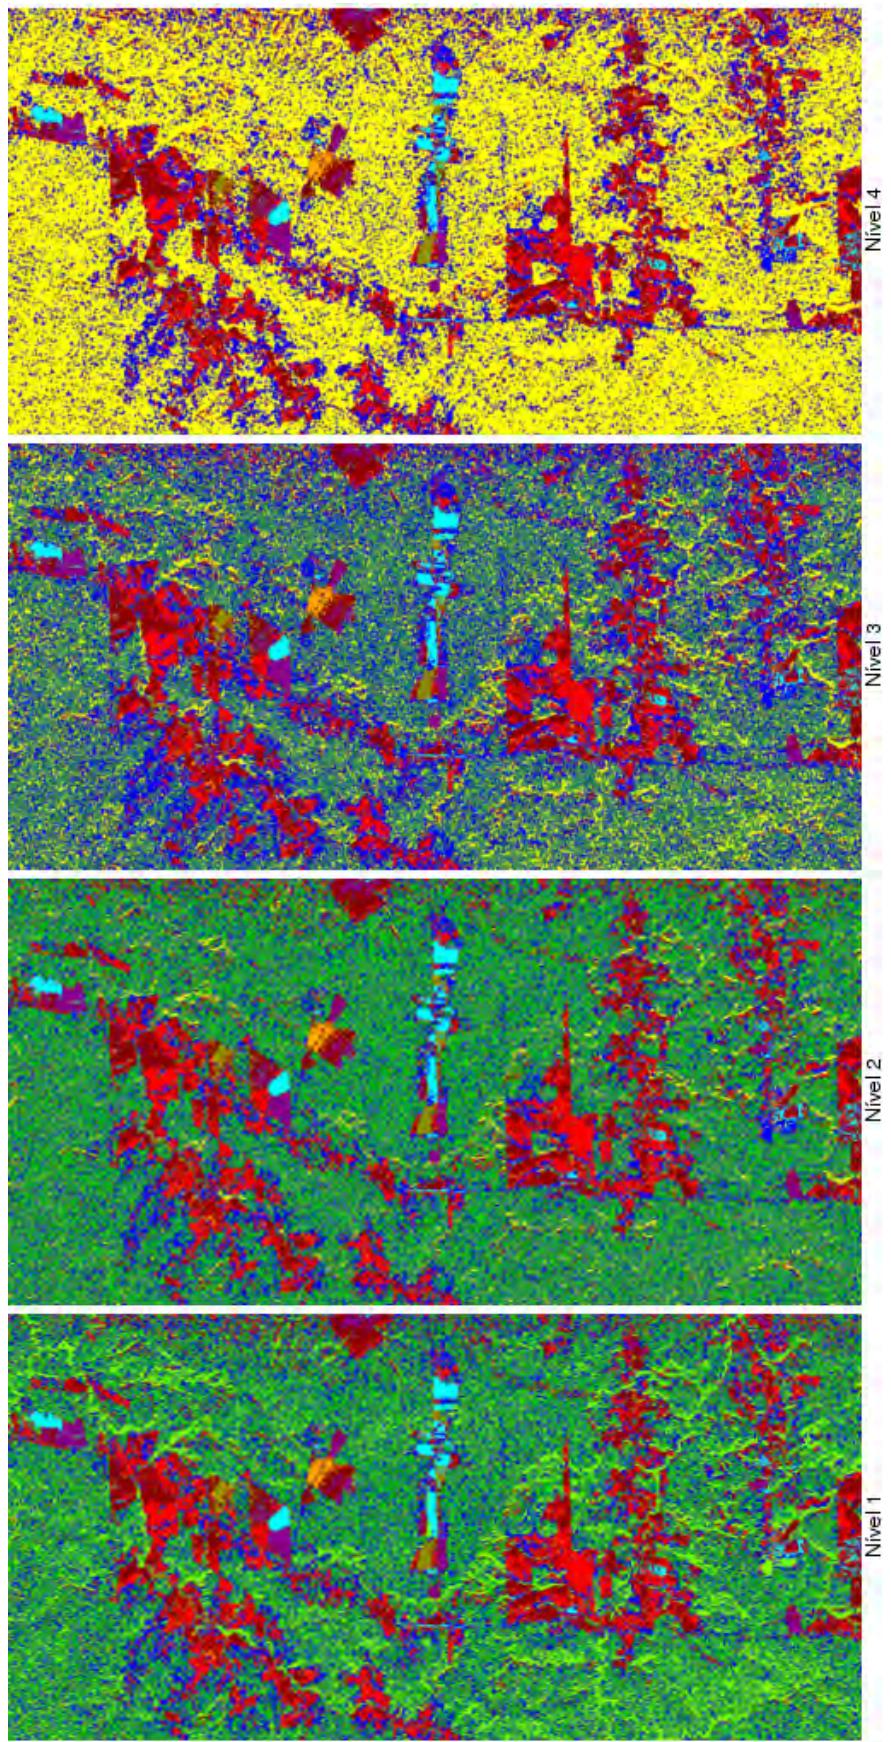


Figura F.15 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Polarimétricos para os níveis de discriminação 1 a 4.

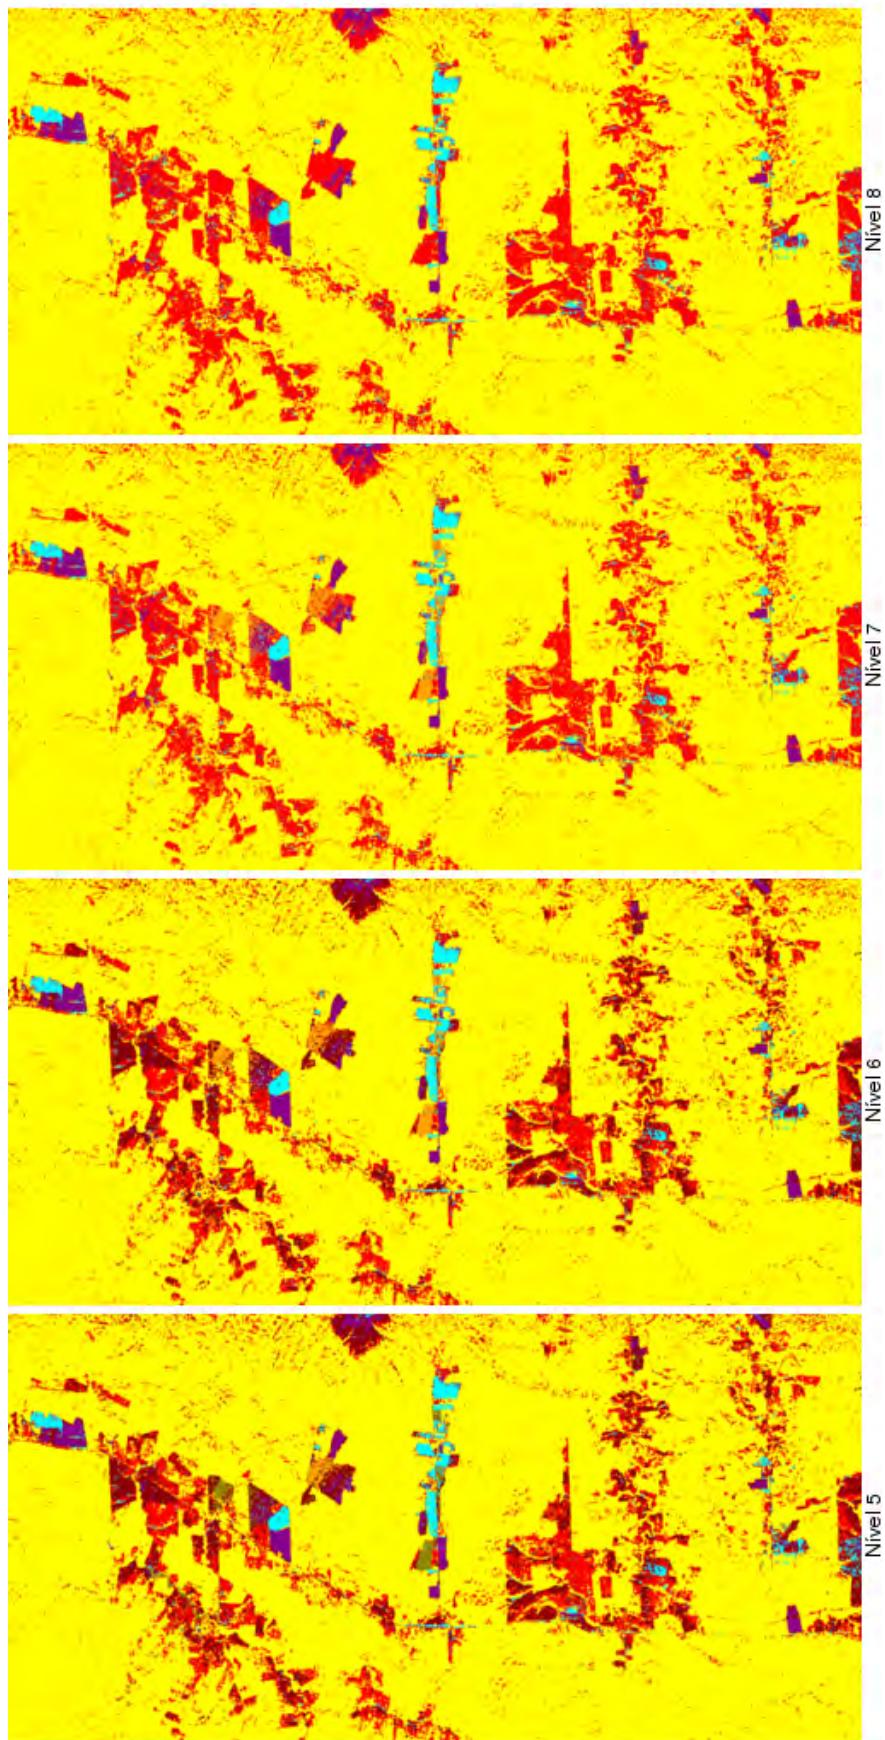


Figura F.16 - Classificações obtidas pelo método MaxVer/ICM a partir de dados Polarimétricos para os níveis de discriminação 5 a 8.