MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21b/2014/02.17.19.38-TDI

# MAPEAMENTO E MODELAGEM DA ESTRUTURA DA VEGETAÇÃO NA VÁRZEA AMAZÔNICA UTILIZANDO DADOS POLARIMÉTRICOS DE BANDA C

Luiz Felipe de Almeida Furtado

Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Thiago Sanna Freire Silva, e Evlyn Márcia Leão de Moraes Novo, aprovada em 10 de março de 2014.

URL do documento original:
<http://urlib.net/8JMKD3MGP5W34M/3FPHTSP>

INPE
São José dos Campos
2014

**PUBLICADO POR:**

Instituto Nacional de Pesquisas Espaciais - INPE
Gabinete do Diretor (GB)
Serviço de Informação e Documentação (SID)
Caixa Postal 515 - CEP 12.245-970
São José dos Campos - SP - Brasil
Tel.:(012) 3208-6923/6921
Fax: (012) 3208-6919
E-mail: pubtc@sid.inpe.br

**CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELECTUAL DO INPE (RE/DIR-204):**
**Presidente:**
Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)
**Membros:**
Dr. Antonio Fernando Bertachini de Almeida Prado - Coordenação Engenharia e Tecnologia Espacial (ETE)
Drª Inez Staciarini Batista - Coordenação Ciências Espaciais e Atmosféricas (CEA)
Dr. Gerald Jean Francis Banon - Coordenação Observação da Terra (OBT)
Dr. Germano de Souza Kienbaum - Centro de Tecnologias Especiais (CTE)
Dr. Manoel Alonso Gan - Centro de Previsão de Tempo e Estudos Climáticos (CPT)
Drª Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação
Dr. Plínio Carlos Alvalá - Centro de Ciência do Sistema Terrestre (CST)
**BIBLIOTECA DIGITAL:**
Dr. Gerald Jean Francis Banon - Coordenação de Observação da Terra (OBT)
**REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**
Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)
Yolanda Ribeiro da Silva Souza - Serviço de Informação e Documentação (SID)
**EDITORAÇÃO ELETRÔNICA:**
Maria Tereza Smith de Brito - Serviço de Informação e Documentação (SID)
André Luis Dias Fernandes - Serviço de Informação e Documentação (SID)

MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21b/2014/02.17.19.38-TDI

# MAPEAMENTO E MODELAGEM DA ESTRUTURA DA VEGETAÇÃO NA VÁRZEA AMAZÔNICA UTILIZANDO DADOS POLARIMÉTRICOS DE BANDA C

Luiz Felipe de Almeida Furtado

Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Thiago Sanna Freire Silva, e Evlyn Márcia Leão de Moraes Novo, aprovada em 10 de março de 2014.

URL do documento original:
<http://urlib.net/8JMKD3MGP5W34M/3FPHTSP>

INPE
São José dos Campos
2014

Dados Internacionais de Catalogação na Publicação (CIP)

Furtado, Luiz Felipe de Almeida.

F984m Mapeamento e modelagem da estrutura da vegetação na várzea Amazônica utilizando dados polarimétricos de banda C / Luiz Felipe de Almeida Furtado. – São José dos Campos : INPE, 2014.

xxxiv + 150 p. ; (sid.inpe.br/mtc-m21b/2014/02.17.19.38-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2014.

Orientadores : Drs. Thiago Sanna Freire Silva, e Evlyn Márcia Leão de Moraes Novo.

1. polarimetria. 2. áreas úmidas. 3. radar de abertura sintética (SAR). 4. mineração de dados. I.Título.

CDU 528.8:551.435.2(811)

Esta obra foi licenciada sob uma Licença Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada.

This work is licensed under a Creative Commons Attribution-NonCommercial 3.0 Unported License.

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

***Sensoriamento Remoto***

Dr. João Roberto dos Santos

***Presidente / INPE / SJCampos - SP***

Dra. Evlyn Márcia Leão de Moraes Novo

***Orientador(a) / INPE / SJCampos - SP***

Dr. Thiago Sanna Freire Silva

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

Dr. José Claudio Mura

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

Dr. Pedro Walfir Martins e Souza Filho

***Convidado(a) / UFPA / Belém - PA***

***Este trabalho foi aprovado por:***

***( ) maioria simples***

***( ) unanimidade***

Aluno (a): ***Luiz Felipe de Almeida Furtado***

***São José dos Campos, 10 de Março de 2014***

*“O caminho do bem é um só caminho / O caminho do bem é para todos / O caminho do bem é racional.”*

*Tim Maia*

*A Deus, aos familiares, aos amigos e pessoas importantes. Ao meu Brasil!*

## AGRADECIMENTOS

A Deus, pois sem Ele nenhuma dessas conquistas seria possíveis. Pela força, determinação, disciplina e coragem para enfrentar todos os desafios.

Aos familiares, principalmente meus pais Maria de Lourdes de Almeida e Genis Vieira Furtado Filho, que me apoiaram incondicionalmente, de todas as maneiras possíveis. Não deve ser nada fácil aturar um filho que está prestes a dar a luz a uma dissertação! Ao meu irmão Leonardo de Almeida Furtado, por toda descontração via LAN!

Aos meus orientadores, Dr. Thiago Silva e Drª Evlyn Novo, que me apoiaram, ensinaram, ajudaram, puxaram minhas orelhas e ao mesmo tempo me deram grandiosa liberdade para trabalhar. Por terem se levantado ao meu favor, quando foi preciso, e por todo apoio frente a tudo que ocorreu durante esses dois anos de mestrado.

A todos os amigos de UFF e INPE, a dizer Andressa, Pedro José, Carlos Leandro, Leandro, Rafaela, Mariane, Taíssa, Sílvia, Zé, Ricardo, Carina, Bonecão, Gordo, Clayton, Renato, Elias e a todos de quem eu não lembrei do nome, mas que estarão sempre presentes no coração. E um alô especial para a Annia, que enfrentou a lama, os mosquitos e os cipós da Amazônia comigo.

A minha namorada, Mayne Assunção, que esteve sempre ao meu lado nas minhas dificuldades, com palavras de carinho e conforto. Quando precisou, puxou minha orelha com as mesmas mãos que afagam o rosto de maneira tão especial. Tenha certeza que você é muito especial!

Aos membros da banca, doutores Pedro Walfir, João Roberto e José Mura, pela disponibilidade, pelas críticas ao trabalho e por terem topado essa missão de ler todo esse texto em apenas 20 dias!

A todos que direta ou indiretamente auxiliaram na execução desse trabalho; mestre Pedro José e doutores Guilherme Fernandes e Raul Vincens, pela

disponibilidade das instalações do LAGEF e aos funcionários da DSR e da Biblioteca do INPE, principalmente a Vera, Yollanda e André, pela extrema agilidade e seriedade de seu trabalho.

Agradecimentos a Capes, ao INPE e a FAPESP pelo financiamento da pesquisa, tanto em termos de bolsa, como no auxílio dos custos do trabalho de campo.

E a todos os outros que não entraram nessa lista, não se sintam excluídos, pois sabem como eu sou extremamente esquecido!

## RESUMO

Áreas úmidas são regiões de extrema importância pela sua biodiversidade e serviços ecológicos, por serem também uma das principais fontes naturais de gases estufa. Estima-se que entre 12% e 29% da bacia Amazônica seja constituída por áreas úmidas. Devido a sua grande extensão e ao caráter dinâmico da sua vegetação, dados de radares de abertura sintética (SAR) são fundamentais, pois permitem a aquisição de informações de maneira sinóptica e multitemporal, mesmo em regiões de frequente cobertura de nuvens. Dados SAR polarimétricos (PolSAR) obtém maior quantidade de informação sobre cobertura vegetal, podendo melhorar a discriminação de diferentes tipos de vegetação e melhor caracterizar sua estrutura, quando comparado a dados multipolarizados e multitemporais. Este estudo teve como objetivo avaliar a eficiência do uso de dados polarimétricos do sensor Radarsat-2 (banda C) para a classificação da vegetação e caracterização de sua distribuição e estrutura na várzea Amazônica, na região da várzea do Lago Grande de Curuai, no Pará Para isso, seis imagens PolSAR Radarsat-2 multitemporais foram classificadas utilizando-se análise de imagem baseada em objetos (OBIA) e algoritmo de mineração de dados. Os resultados da classificação permitiram comparar o desempenho do mapeamento dos tipos de vegetação da várzea usando (a) imagens polarizadas com diferentes ângulos de incidência, (b) diagonais principais das matrizes C e T, (c) diferentes combinações de decomposições polarimétricas e (d) imagens multitemporais. Os resultados dessa comparação permitiram constatar que combinações entre imagens polarizadas e decomposições polarimétricas maximizam a separabilidade de classes tomadas individualmente, mas quando essas classes são analisadas em conjunto, as imagens multitemporais são as que apresentam o melhor desempenho. Por outro lado, as decomposições polarimétricas sobressaíram-se na modelagem da estrutura da várzea do Lago Grande de Curuai e de atributos correlatos, gerando os melhores modelos para estimar DAP, IAF, Densidade de indivíduos e Altura de Inundação. Todos os modelos apresentaram alta correlação com atributos extraídos das cenas SAR, porém todos eles apresentaram heterocedasticidade, havendo necessidade de pesquisas posteriores para identificar e sanar a causa desse problema. Dessa maneira, os resultados desse estudo permitem concluir que os dados polarimétricos foram mais indicados para análises quantitativas da estrutura da vegetação e que as cenas multitemporais foram as mais indicadas para o mapeamento de diversos tipos de vegetação da várzea amazônica.

**MAPPING AND STRUCTURAL MODELING OF AMAZON VÁRZEA VEGETATION USING POLARIMETRIC C BANDA DATA.**

## ABSTRACT

Wetlands are important regions due its biodiversity and ecological services, and also are considered one of the main sources of greenhouse gases. It is estimated that 12% up to 29% of Amazon River basin area consist of floodplains. Due to its great area extent and the dynamics of the vegetation communities, synthetic aperture radar (SAR) data are important because of it's synoptical and multitemporal image acquisition, even under intense cloud-covered regions. Polarimetric SAR data (PolSAR) register an increased amount of vegetation information, increasing vegetation type's discrimination and a better structural characterization, when compared to polarized or multitemporal SAR data. This paper have as objective assess the performance of using C band PolSAR data on mapping Lago Grande de Curuai várzea vegetation types and characterizing its structural properties. To achieve this objective, six full polarimetric Radarsat-2 images were classified using object based image analysis (OBIA) and a data-mining algorithm. The classification results allowed assessing the performance of várzea vegetation mapping using PolSAR images with (a) different incidence angles and polarizations, (b) C and T matrixes main diagonals, (c) polarimetric decompositions and (d) multitemporal imagery. The results demonstrate that the combination of polarimetric decompositions and polarized images maximizes individual class's discrimination, but when those classes are analyzed together, the multitemporal images achieved the best validation indexes. On the other side, polarimetric decompositions highlights structural and correlated attributes modeling, adjusting the best models to estimate DBH, LAI, individual density and flood height. All models have high correlation with SAR imagery, but all of them are heterocedastical, and there is need of further research to understand why. This study concludes that PolSAR data are best suited to quantitative studies of várzea vegetation, and multitemporal scenes are indicated to map different vegetation types of Amazon várzea.

## LISTA DE FIGURAS


| | | Pág. |
|---|---|---|
| Figura 2.1 | Variação anual do nível da água, em centímetros, na estação fluviométrica de Óbidos, na região do baixo Amazonas. A linha azul indica a média diária para o período de 1970 a 2011, e a área sombreada em azul indica o intervalo de confiança de 95% para a média. Em destaque, os anos de 2007 (hidrologia regular), 2005 (seca extrema) e 2009 (cheia extrema) Figura adaptada de SILVA et al. 2013..... | 6 |
| Figura 2.2 | Esquema gráfico com as diferenças entre radares convencionais e polarimétricos. Fonte: adaptado de van der Sanden (1997)..... | 12 |
| Figura 3.1 | Em destaque, a área de estudo no Lago Grande de Curuai - PA. Ao fundo, composição TM/Landsat 5 RGB321 do período da seca. Composição colorida SAR multitemporal (R: cena SQ7 da época da cheia; G: cena SQ7 da época da seca; B: razão entre imagens da seca e cheia). © MacDonald, Dettwiler e Associados, Ltd..... | 30 |
| Figura 3.2 | Composição colorida RGB321 de cena Landsat-5/TM, da estação seca do ano de 2005. O polígono amarelo indica a área de estudo dessa pesquisa..... | 32 |
| Figura 3.3 | Fluxograma geral do processamento dos dados do trabalho..... | 34 |
| Figura 3.4 | Fluxograma das etapas da fase de pré-processamento dos dados..... | 35 |
| Figura 3.5 | Fluxograma das etapas da fase de análise dos dados e classificação..... | 39 |
| Figura 3.6 | Fluxograma das etapas do subitem de classificação dos dados e validação. ..... | 42 |
| Figura 3.7 | Fluxograma das etapas da fase de modelagem dos atributos biofísicos da vegetação..... | 48 |
| Figura 4.1 | Distribuição das amostras das classes gerais na área de estudo (destaque em vermelho). Dados Radarsat-2 © MacDonald, Dettwiler e Associados, Ltd..... | 52 |

Figura 4.2 Distribuição das amostras das classes de várzea na área de estudo (destaque em vermelho). A máscara da região de terra firme encontra-se na região hachurada, em vermelho. Dados Radarsat-2 © MacDonald, Dettwiler e Associados, Ltd..... 53

Figura 4.3 Ângulos alpha da decomposição de Cloude – Pottier (cp_alpha) e ângulo alpha médio da decomposição de Touzi (touzi_alpha_s), para todas as classes de uso e cobertura da várzea do Lago Grande de Curuai, PA..... 54

Figura 4.4 Ângulo alpha médio da decomposição de Touzi para cada um dos autovetores da matriz C (touzi_alpha_s, _s1, _s2 e _s3 respectivamente), para todas as classes de uso e cobertura da várzea do Lago Grande de Curuai, PA..... 54

Figura 4.5 Ângulo φ (phi) médio da decomposição de Touzi e para cada um dos autovetores da matriz C (touzi_phi_s, _s1, _s2 e _s3 respectivamente) para todas as classes de uso e cobertura da várzea do Lago Grande de Curuai, PA..... 55

Figura 4.6 Ângulo ψ (psi) médio da decomposição de Touzi e para cada um dos autovetores da matriz C (touzi_psi_s, _s1, _s2 e _s3 respectivamente) para todas as classes de uso e cobertura da várzea do Lago Grande de Curuai, PA..... 56

Figura 4.7 Ângulo τ (tau) médio da decomposição de Touzi e para cada um dos autovetores da matriz C (touzi_tau_s, _s1, _s2 e _s3 respectivamente) para todas as classes de uso e cobertura da várzea do Lago Grande de Curuai, PA..... 56

Figura 4.8 Resposta, em dB, da camada de espalhamento double bounce das decomposições de Freeman – Durden (fd_double), van Zyl (vz_double) e Yamaguchi (yama_double) para todas as classes de uso e cobertura da várzea do Lago Grande de Curuai, PA..... 57

Figura 4.9 Resposta, em dB, da camada de espalhamento superficial (odd scattering) das decomposições de Freeman – Durden (fd_odd), van Zyl (vz_odd) e Yamaguchi (yama_odd) para todas as classes de uso e cobertura da várzea do Lago Grande de Curuai, PA..... 58

Figura 4.10 Resposta, em dB, da camada de espalhamento volumétrico das decomposições de Freeman – Durden (fd_vol), van Zyl (vz_vol) e Yamaguchi (yama_vol) para todas as classes de uso e cobertura da várzea do Lago Grande de Curuai, PA..... 58

Figura 4.11 Valores de retroespalhamento (dB) para as polarizações da diagonal principal da matriz C (HH, HV e VV) do ângulo de incidência SQ7, das classes de cobertura do solo propostas para o Lago Grande de Curuai - PA, para os três ângulos de incidência. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 60

Figura 4.12 Valores de retroespalhamento (dB) para as polarizações da diagonal principal da matriz C (HH, HV e VV) do ângulo de incidência SQ14, das classes de cobertura do solo propostas para o Lago Grande de Curuai - PA, para os três ângulos de incidência. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 61

Figura 4.13 Valores de retroespalhamento (dB) para as polarizações da diagonal principal da matriz C (HH, HV e VV) do ângulo de incidência SQ27, das classes de cobertura do solo propostas para o Lago Grande de Curuai - PA, para os três ângulos de incidência. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto ..... 62

Figura 4.14 Valores do atributo de textura Dissimilaridade (GLCM Dissimilarity), para as classes de cobertura do solo propostas para o Lago Grande de Curuai - PA. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto. 63

Figura 4.15 Valores do atributo de textura Entropia (GLCM Entropy), para as classes de cobertura do solo propostas para o Lago Grande de Curuai - PA. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 64

Figura 4.16 Valores do atributo de textura Homogeneidade (GLCM Homogeneity), para as classes de cobertura do solo propostas para o Lago Grande de Curuai - PA. A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto ..... 65

Figura 4.17 Valores do atributo de textura Correlação (GLCM Correlation), para as classes de cobertura do solo propostas para o Lago Grande de Curuai - PA. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto. 66

Figura 4.18 Resposta para as classes de cobertura do solo do Lago Grande de Curuai - PA para as imagens da decomposição de Cloude – Pottier: ângulo α (alpha - graus), anisotropia (anisotropy - adimensional) e entropia (entropy - adimensional). As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 70

Figura 4.19 Resposta para as classes de cobertura do solo do Lago Grande de Curuai - PA para as imagens da decomposição de van Zyl: componente Double-bounce (dB), superficial (odd) e volumétrica (vol). As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 71

Figura 4.20 Resposta para as classes de cobertura do solo do Lago Grande de Curuai - PA para as polarizações da diagonal da matriz C para os pulsos da cheia e da seca. As classes são: A – Água Permanente, A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 74

Figura 4.21 Erro de alocação, de todas as classificações, da classe Vegetação Arbustiva..... 77

Figura 4.22 Erro de alocação, de todas as classificações, da classe Floresta Inundável..... 78

Figura 4.23 Erro de alocação, de todas as classificações, da classe Macrófitas Emersas..... 78

Figura 4.24 Erro de alocação, de todas as classificações, da classe Água..... 79

Figura 4.25 Erro de alocação, de todas as classificações, da classe Macrófitas Flutuantes..... 79

Figura 4.26 Erro de alocação, de todas as classificações, da classe Floresta de Terra Firme..... 80

Figura 4.27 Erro de alocação, de todas as classificações, da classe Solo Exposto..... 80

Figura 4.28 Erro de quantidade, de todas as classificações, da classe Vegetação Arbustiva..... 82

Figura 4.29 Erro de quantidade, de todas as classificações, da classe Floresta Inundável..... 82

Figura 4.30 Erro de quantidade, de todas as classificações, da classe Macrófitas Emersas..... 83

Figura 4.31 Erro de quantidade, de todas as classificações, da classe Água..... 83

Figura 4.32 Erro de quantidade, de todas as classificações, da classe Macrófitas Flutuantes..... 84

Figura 4.33 Erro de quantidade, de todas as classificações, da classe Floresta de Terra Firme..... 84

Figura 4.34 Erro de quantidade, de todas as classificações, da classe Solo Exposto..... 85

Figura 4.35 Modelo SQ14 van Zyl *double-bounce,* em escala linear, para a estimativa do DAP (cm). Dados Radarsat-2 © MacDonald, Dettwiler e Associados, Ltd..... 90

Figura 4.36 Modelo SQ27 van Zyl volumétrico, em dB, para a estimativa do log10 da densidade de indivíduos (ind./ha). Dados Radarsat-2 © MacDonald, Dettwiler e Associados, Ltd..... 91

Figura 4.37 Modelo empírico SQ14 van Zyl volumétrico, em dB, para a estimativa do IAF. Dados Radarsat-2 © MacDonald, Dettwiler e Associados, Ltd..... 92

Figura 4.38 Modelo empírico SQ7 Cloude - Pottier anisotropia, em escala linear, para a estimativa da altura de inundação (m). Dados Radarsat-2 © MacDonald, Dettwiler e Associados, Ltd..... 93

Figura 4.39 Tendência crescente para os valores de anisotropia do ângulo de incidência SQ7 (linhas em vermelho) e decrescentes para o ângulo SQ27 (linhas em azul) em função do aumento da altura de inundação (barras cinza). 95

Figura A.1 Análise do decréscimo do coeficiente de variação (CV) para diferentes janelas para o filtro polarimétrico *Refined Lee*, para a cena SQ7 da época da cheia, na polarização HH, em *slant range*, em regiões de Floresta de Terra Firme..... 113

Figura A.2 Efeito da aplicação do filtro *Refined Lee* para diferentes tamanhos de janelas de operação. Imagem: polarização HH, ângulo de incidência SQ7, *slant range*, na época da cheia. Cenas Radarsat-2 © MacDonald, Dettwiler e Associados, Ltd..... 114

Figura A.3 Presença de artefatos em regiões de água (destaque, em vermelho) e ao longo das bordas entre vegetação e água. Cenas Radarsat-2 © MacDonald, Dettwiler e Associados, Ltd..... 115

Figura B.1 Análise do decréscimo do coeficiente de variação (CV) para diferentes janelas de média espacial para a decomposição de Freeman – Durden, cena SQ7 da época da cheia, em *slant range*, em regiões de Floresta de Terra Firme..... 117

Figura B.2 Análise visual das janelas de média espacial das decomposições polarimétricas. Imagem: componente volumétrica da decomposição de Freeman – Durden, em *slant range*, ângulo de incidência SQ7 para a época da cheia..... 118

Figura C.1 Variação da exatidão global (%) das árvores de decisão geradas em função de diferentes valores de Fator de Confiança, para todos os alvos de uso e cobertura da terra da várzea do Lago Grande de Curuai, PA..... 119

Figura C.2 Variação da exatidão global (%) (A), do erro médio absoluto (B) e do número de nós (C) das árvores de decisão geradas em função de diferentes valores de número mínimo de objetos, para todos os alvos de uso e cobertura da terra da várzea do Lago Grande de Curuai, PA..... 120

Figura D.1 Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ7_C_33, em dB, para a variável dependente DAP..... 123

Figura D.2 Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ14_VZ_double, em amplitude linear, para a variável dependente DAP..... 124

Figura D.3 Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ27_C_33, em dB, para a variável dependente DAP..... 125

Figura D.4 Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ7_CP_ani, para a variável dependente Altura de Inundação..... 126

Figura D.5 Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ27_CP_ani, transformada por Log10, para a variável dependente Altura de Inundação..... 127

Figura D.6 Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ14_C_33, em amplitude linear, para a variável dependente Log10 (Densidade de Indivíduos)..... 128

Figura D.7 Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ27_VZ_vol, em dB, para a variável dependente Log10 (Densidade de Indivíduos)..... 129

Figura D.8 Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ7_VZ_vol, em dB, para a variável dependente Log10 (IAF)..... 130

Figura D.9 Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ14_VZ_vol, em dB, para a variável dependente IAF..... 131

Figura D.10 Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ27_VZ_odd, em dB, para a variável dependente Log10 (IAF)..... 132

Figura D.11 Modelos para estimativa do DAP (cm). Em (a), modelo SQ7 VV x DAP (dB x linear); em (b), modelo SQ14 VZ *double-bounce* x DAP (Linear x Linear); em (c) modelo SQ27 VV x DAP (dB x linear)..... 133

Figura D.12 Modelos para estimativa da Densidade de Indivíduos (indivíduos / ha). Em (a), modelo SQ14 VV x Densidade de Indivíduos (linear x log10) e em (b), modelo SQ27 van Zyl volumétrico x Densidade de Indivíduos (dB x log10)..... 134

Figura D.13 Modelos para estimativa do IAF. Em (a), modelo SQ7 van Zyl volumétrico x IAF (dB x log10); em (b), modelo SQ14 van Zyl volumétrico x IAF (dB x linear) e em (c), modelo SQ27 van Zyl superficial x IAF (dB x log10)..... 135

Figura D.14 Modelos para estimativa da Altura de Inundação (metros). Em (a), modelo SQ7 CP anisotropia x altura de inundação (linear x linear) e em (b), modelo SQ27 CP anisotropia x altura de inundação (log10 x linear)..... 136

## LISTA DE TABELAS


| | | Pág. |
|---|---|---|
| Tabela 3.1 | Parâmetros das cenas PolSAR Radarsat – 2 utilizadas... | 30 |
| Tabela 3.2 | Atributos polarimétricos derivados do retroespalhamento e de decomposição de alvos..... | 37 |
| Tabela 3.3 | Classes de cobertura e de vegetação da várzea do Lago Grande de Curuai – PA. Em fotointerpretação, polarização HH do ângulo de incidência SQ7 - © MacDonald, Dettwiler e Associados, Ltd..... | 43 |
| Tabela 3.4 | Limitares para a conversão da radiometria das cenas SAR de 16 para 8 bits. VZ: decomposição de van Zyl; CP: decomposição de Cloude Pottier..... | 46 |
| Tabela 4.1 | Número de amostras por classe de uso e cobertura do solo..... | 51 |
| Tabela 4.2 | Índices de validação da classificação para todas as classes de cobertura da classificação relativa aos ângulos de incidência SQ7, SQ14 e SQ27 e atributos de amplitude e textura. O valor do parâmetro Escala, do segmentador, foi 25 para todas as classificações..... | 67 |
| Tabela 4.3 | Índices de validação da classificação das imagens das decomposições polarimétricas de van Zyl (VZ), Cloude – Pottier (CP) e suas combinações entre si e da diagonal da matriz C. A coluna Escala é referente ao parâmetro utilizado na segmentação das imagens..... | 72 |
| Tabela 4.4 | Índices de validação da classificação das imagens multitemporais, com ou sem razões multitemporais. O valor do parâmetro Escala utilizado para todas as classificações foi de 20..... | 75 |
| Tabela 4.5 | ENL para amostra de água das imagens do ângulo SQ7..... | 86 |
| Tabela 4.6 | ENL para amostra de água das imagens do ângulo SQ14..... | 86 |
| Tabela 4.7 | ENL para amostra de água das imagens do ângulo SQ27..... | 87 |

Tabela 4.8 Variáveis independentes descorrelacionadas (correlações, entre si, menores que 0,3) apresentaram as maiores correlações com os atributos de campo. Células azuis correspondem ao ângulo SQ7, rosas ao ângulo SQ14 e laranjas, SQ27..... 88

Tabela 4.9 Coeficiente de determinação R², RMSE e coeficientes a e b da reta de regressão para cada modelo linear ajustado. Células azuis correspondem ao ângulo SQ7, rosas ao ângulo SQ14 e laranjas, SQ27. Células azuis correspondem ao ângulo SQ7, rosas ao ângulo SQ14 e laranjas, SQ27..... 89

Tabela 4.10 Comparação entre os valores de entropia e anisotropia para os ângulos de incidência SQ7 e SQ27..... 94

Tabela 4.11 Matriz de correlação de Pearson entre as anisotropias dos ângulos de incidência SQ7 e SQ27..... 95

Tabela E.1 Matriz de confusão da classificação do ângulo de incidência SQ7, para as classes gerais, utilizando os descritores de amplitude + textura. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 137

Tabela E.2 Matriz de confusão da classificação do ângulo de incidência SQ14, para as classes gerais, utilizando os descritores de amplitude + textura. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 137

Tabela E.3 Matriz de confusão da classificação do ângulo de incidência SQ27, para as classes gerais, utilizando os descritores de amplitude + textura. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 138

Tabela E.4 Matriz de confusão da classificação do ângulo de incidência SQ7, para as classes gerais, utilizando o descritor amplitude. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 138

Tabela E.5 Matriz de confusão da classificação do ângulo de incidência SQ14, para as classes gerais, utilizando o descritor amplitude. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 139

Tabela E.6 Matriz de confusão da classificação do ângulo de incidência SQ27, para as classes gerais, utilizando o descritor amplitude. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 139

Tabela E.7 Matriz de confusão da classificação do ângulo de incidência SQ7, para as classes gerais, utilizando o descritor textura. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 140

Tabela E.8 Matriz de confusão da classificação do ângulo de incidência SQ14, para as classes gerais, utilizando o descritor textura. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 140

Tabela E.9 Matriz de confusão da classificação do ângulo de incidência SQ27, para as classes gerais, utilizando o descritor textura. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 141

Tabela E.10 Matriz de confusão da classificação do ângulo de incidência SQ7, para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes..... 141

Tabela E.11 Matriz de confusão da classificação do ângulo de incidência SQ14, para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes..... 142

Tabela E.12 Matriz de confusão da classificação do ângulo de incidência SQ27, para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes..... 142

Tabela E.13 Matriz de confusão da classificação da decomposição de Cloude - Pottier, para as classes gerais. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 143

Tabela E.14 Matriz de confusão da classificação da decomposição de Cloude – Pottier + Matriz C, para as classes gerais. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 143

Tabela E.15 Matriz de confusão da classificação da decomposição de Cloude – Pottier + decomposição de van Zyl, para as classes gerais. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 144

Tabela E.16 Matriz de confusão da classificação da decomposição de Cloude – Pottier + decomposição de van Zyl + Matriz C, para as classes gerais. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 144

Tabela E.17 Matriz de confusão da classificação da decomposição de van Zyl, para as classes gerais. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 145

Tabela E.18 Matriz de confusão da classificação da decomposição de van Zyl + Matriz C, para as classes gerais. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 145

Tabela E.19 Matriz de confusão da classificação da decomposição de Cloude - Pottier, para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes..... 146

Tabela E.20 Matriz de confusão da classificação da decomposição de Cloude – Pottier + Matriz C, para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes..... 146

Tabela E.21 Matriz de confusão da classificação da decomposição de Cloude – Pottier + decomposição de van Zyl, para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes..... 147

Tabela E.22 Matriz de confusão da classificação da decomposição de Cloude – Pottier + decomposição de van Zyl + Matriz C, para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes..... 147

Tabela E.23 Matriz de confusão da classificação da decomposição de van Zyl, para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes..... 148

Tabela E.24 Matriz de confusão da classificação da decomposição de van Zyl + Matriz C, para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes..... 148

Tabela E.25 Matriz de confusão da classificação multitemporal para as classes gerais. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 149

Tabela E.26 Matriz de confusão da classificação multitemporal com razões de bandas para as classes gerais. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto..... 149

Tabela E.27 Matriz de confusão da classificação multitemporal para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes..... 150

Tabela E.28 Matriz de confusão da classificação multitemporal com razões de bandas para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes..... 150

## LISTA DE SIGLAS E ABREVIATURAS

| | |
|---|---|
| AD | Erro de alocação / *Alocation Disagreement* |
| alpha | Componente ângulo α da decomposição de Cloude-Pottier |
| *Anisotropy* | Componente Anisotropia, da decomposição de Cloude - Pottier |
| C | Matriz de Covariância |
| CP | Decomposição de Cloude-Pottier |
| cp_alpha | Componente ângulo α da decomposição de Cloude – Pottier |
| CSV | Valores separados por vírgulas / *Comma separated values* |
| CV | Coeficiente de variação |
| DAP | Diâmetro na altura do peito |
| DEM | Modelo digital de elevação / *Digital elevation model* |
| double | Componente de espalhamento *double-bounce* |
| ENL | Número estimado de *looks* / *Estimated number of looks* |
| *Entropy* | Componente Entropia da decomposição de Cloude – Pottier |
| ETM+ | *Enhanced Thematic Mapper Plus* |
| FD | Decomposição de Freeman – Durden |
| GLCM | Matriz de coocorrência de níveis de cinza / *Gray Level Coocurrence Matrix* |
| IAF | Índice de área foliar |
| OBIA | Análise de Imagem Baseada em Objetos / *Object Based Image Analysis* |
| *odd* | Componente de espalhamento superficial |
| PolSAR | SAR polarimétrico |
| QD | Erro de quantidade / *Quantity Disagreement* |
| REM | Radiação eletromagnética |
| RMSE | Erro médio quadrático / *Root mean squared error* |
| S | Matriz de Sinclar |
| SAR | Radar de abertura sintética / *Synthetic Aperture Radar* |
| SRTM | *Shuttle Radar Topographic Mission* |
| T | Matriz de Coerência |
| TM | *Thematic Mapper* |

| | |
|---|---|
| touzi_alpha_s | Componente ângulo α médio da decomposição de Touzi |
| touzi_alpha_s1 | Componente ângulo α do primeiro autovetor da matriz C, da decomposição de Touzi |
| touzi_alpha_s2 | Componente ângulo α do segundo autovetor da matriz C, da decomposição de Touzi |
| touzi_alpha_s3 | Componente ângulo α do terceiro autovetor da matriz C, da decomposição de Touzi |
| touzi_phi_s | Componente ângulo φ médio da decomposição de Touzi |
| touzi_phi_s1 | Componente ângulo φ do primeiro autovetor da matriz C, da decomposição de Touzi |
| touzi_phi_s2 | Componente ângulo φ do segundo autovetor da matriz C, da decomposição de Touzi |
| touzi_phi_s3 | Componente ângulo φ do terceiro autovetor da matriz C, da decomposição de Touzi |
| touzi_psi_s | Componente ângulo ψ médio da decomposição de Touzi |
| touzi_psi_s1 | Componente ângulo ψ do primeiro autovetor da matriz C, da decomposição de Touzi |
| touzi_psi_s2 | Componente ângulo ψ do segundo autovetor da matriz C, da decomposição de Touzi |
| touzi_psi_s3 | Componente ângulo ψ do terceiro autovetor da matriz C, da decomposição de Touzi |
| touzi_tau_m | Componente ângulo τ médio da decomposição de Touzi |
| touzi_tau_m1 | Componente ângulo τ do primeiro autovetor da matriz C, da decomposição de Touzi |
| touzi_tau_m2 | Componente ângulo τ do segundo autovetor da matriz C, da decomposição de Touzi |
| touzi_tau_m3 | Componente ângulo τ do terceiro autovetor da matriz C, da decomposição de Touzi |
| vol | Componente de espalhamento volumétrico |
| VZ | Decomposição de van Zyl |
| yama | Decomposição de Yamaguchi |
| κ | Índice Kappa |

**SUMÁRIO**

**Pág.**

**1 INTRODUÇÃO..... 1**

1.1 Hipótese e objetivos..... 3

**2 FUNDAMENTAÇÃO TEÓRICA..... 5**

2.1. Ecossistemas da várzea amazônica..... 5

2.2. A vegetação da várzea amazônica..... 6

2.3. Sensoriamento Remoto por Radar..... 8

2.3.1. Tipos de interação com alvos de várzea..... 10

2.4. Radares Polarimétricos..... 11

2.4.1. Decomposição de alvos..... 13

2.5. SAR e áreas úmidas..... 20

2.6. Análise de imagem baseada em objetos..... 24

2.7. Mineração de dados e árvores de decisão..... 25

**3 MATERIAIS E MÉTODOS..... 29**

3.1. Área de estudo..... 29

3.2. Dados de sensoriamento remoto..... 29

3.3. Metodologia de campo..... 31

3.4. Processamento dos dados..... 33

3.5. Análise dos dados e classificação..... 38

3.5.1. Seleção das amostras de treinamento e geração dos gráficos boxplot..... 38

3.5.2.Teste dos parâmetros do minerador de dados..... 40

3.5.3. Classificação e validação..... 41

3.5.4. Modelagem dos atributos biofísicos da vegetação de várzea..... 48

**4 RESULTADOS E DISCUSSÕES..... 51**

4.1. Seleção das amostras de treinamento e geração dos gráficos *boxplot*..... 51

4.2. Pré-seleções dos dados polarimétricos..... 53

4.3. Classificação dos dados..... 59

4.3.1. Classificação dos ângulos de incidência..... 59

4.3.2. Classificação das decomposições polarimétricas..... 69

4.3.3. Classificação da diagonal da matriz C multitemporal..... 73

4.3.4. Análise dos resultados das classificações por classe individual..... 76

4.3.4.1. Erros de alocação..... 76

4.3.4.2. Erros de quantidade..... 81

4.4. Modelagem e estimativa dos parâmetros biofísicos da Floresta Inundável da várzea do Lago Grande de Curuai – PA..... 85

**5 CONCLUSÕES GERAIS..... 99**

**REFERÊNCIAS BIBLIOGRÁFICAS..... 101**

**APÊNDICE A – TESTE DA JANELA DO FILTRO *SPECKLE*..... 113**

**APÊNDICE B – TESTE DO TAMANHO DA JANELA DE MÉDIA ESPACIAL DAS DECOMPOSIÇÕES POLARIMÉTRICAS..... 117**

**APÊNDICE C – PARAMETRIZAÇÃO DO MINERADOR DE DADOS..... 119**

**APÊNDICE D – ANÁLISES DOS ERROS E ESPACIALIZAÇÃO DOS MODELOS DOS ATRIBUTOS BIOFÍSICOS DA FLORESTA DA VÁRZEA DO LAGO GRANDE DE CURUAI – PA..... 123**

**APÊNDICE E – MATRIZES DE CONFUSÃO DAS CLASSIFICAÇÕES. 137**

# 1. INTRODUÇÃO

*Wetlands* ou áreas úmidas[1] são "ecossistemas na interface entre ambientes terrestres e aquáticos, continentais ou costeiros, naturais ou artificiais, permanentemente ou periodicamente inundados por águas rasas ou com solos encharcados, doces, salobras ou salgadas, com comunidades de plantas e animais adaptadas à sua dinâmica hídrica" (JUNK et al., 2014). As áreas úmidas são ecossistemas ricos em biodiversidade, e possuem importante papel nos ciclos biogeoquímicos do planeta atuando como armazenadores, transformadores e emissores de gases estufa, podendo emitir anualmente de 115 a 227 Tg-$CH_4$ (MITSCH et al., 2012). Elas são importantes para a manutenção da qualidade da água (HENDERSON; LEWIS, 2008) e para os ciclos hidrológicos, regularizando naturalmente a vazão dos rios com os quais se conectam (MITSCH; GOSSELINK, 2007; HENDERSON; LEWIS, 2008; CASTELLO et al., 2012).

Cerca de 5% a 8% da superfície do planeta é coberta por áreas úmidas (MITSCH; GOSSELINK, 2007), mas estima-se que cerca de 50% dela tenha sido destruída por atividades de agricultura, desmatamento e impactos de origem antrópica (MITSCH; GOSSELINK, 2007; HENDERSON; LEWIS, 2008). Na bacia Amazônica, a planície de inundação do rio Amazonas, também chamada de várzea, é uma das maiores áreas úmidas do planeta. Dos 12% a 29% da bacia Amazônica que são constituídas por áreas úmidas, cerca de 300 mil km² são estimados como regiões de planícies de inundação (MITSCH; GOSSELINK, 2007; MELACK; HESS, 2010; CASTELLO et al., 2012).

O rio Amazonas é um rio de água branca, e apresenta grandes concentrações de sedimento em suspensão, que sustentam grande biodiversidade vegetal, incluindo muitas espécies endêmicas (JUNK, 1997). Essa riqueza torna as várzeas atraentes à ocupação humana, servindo como fonte de alimento, água

[1] Também conhecidas por áreas inundáveis ou áreas alagáveis.

e meio de transporte, durante a cheia, para a população ribeirinha, que sobrevive da pesca, extração de madeira e fibras, agricultura e pecuária (JUNK, 1997; WITTMAN et al., 2004). Essas características explicam a tanto a histórica ocupação humana ao longo das margens do rio Amazonas e Solimões, como também sua elevada densidade populacional (JUNK, 1997).

Devido ao aspecto dinâmico de seus processos ecológicos, estudos que envolvem várzeas necessitam de observações espaço temporais sistemáticas (ARNESEN, 2013). Trabalhos de campo são onerosos e de logística complexa, sendo um método caro para o estudo sistemático da várzea. Neste contexto, o uso de dados de sensoriamento remoto permite a observação sistemática de grandes extensões e também de diferentes épocas do ano (HESS et al., 1995) aumentando a quantidade de informação sobre a cobertura de vegetação de sua área de estudo.

O uso de dados de sensoriamento remoto óptico em regiões tropicais úmidas pode ser prejudicado pela sua intensa cobertura de nuvens. Além disso, dosséis de comunidades de plantas suficientemente fechados podem prejudicar a aquisição de informação sobre a estrutura da vegetação e sobre os alvos que ocupam seu substrato, seja o sub-bosque ou a extensão da inundação da várzea (HENDERSON; LEWIS, 2008).

Os dados de radares de abertura sintética (*Synthetic Aperture Radar* – SAR) oferecem uma alternativa aos dados de sensores ópticos, pois podem penetrar a cobertura de nuvens, e são mais sensíveis à estrutura da vegetação (HENDERSON; LEWIS, 1998; HENDERSON; LEWIS, 2008, KLEMAS, 2013). Para manter uma boa relação sinal/ruído e imagear grandes extensões da superfície da terra, sensores SAR convencionais possuem, em geral, uma ou duas polarizações e um comprimento de onda, possuindo capacidade limitada para diferenciar tipos de vegetação (HESS et al., 1995; SILVA et al., 2010).

A nova geração de radares polarimétricos orbitais (PolSAR) permite o registro da amplitude e a fase da onda retroespalhada, em todas as combinações de

polarizações, aumentando a quantidade de informação sobre a vegetação. (VAN DER SANDEN, 1997; BRISCO et al., 2013). Por conta disso, supõe-se que essas imagens podem melhor quantificar os atributos biofísicos desses alvos e mapeá-los com maior precisão utilizando menor número de cenas, quando comparado com as imagens dos SAR convencionais e com estudos multitemporais.

## 1.1. Hipótese e objetivos

Assim, a hipótese deste trabalho é de que o uso das decomposições polarimétricas derivadas de dados PolSAR de banda C melhoram (a) o reconhecimento e classificação das tipologias vegetais em ambientes de várzea amazônicos e (b) a modelagem preditiva de seus atributos biofísicos, quando comparados com imagens multipolarizadas (HH, HV e VV) e com imagens multitemporais.

Para testar tal hipótese, o presente trabalho possuiu os seguintes objetivos específicos:

- Avaliar a influência de diferentes (a) ângulos de incidência, (b) decomposições polarimétricas e (c) épocas do ano, a partir de uma série de imagens polarimétricas Radarsat-2, na acurácia da classificação da vegetação de várzea do Lago Grande de Curuai, PA.

- Avaliar a correlação entre as respostas das imagens multipolarizadas, decomposições polarimétricas e atributos estruturais da floresta obtidos em campo; e

- Estabelecer modelos preditivos empíricos para o mapeamento dos atributos estruturais da floresta de várzea.

# 2. FUNDAMENTAÇÃO TEÓRICA

## 2.1. Ecossistemas da várzea amazônica

O rio Amazonas é um rio de “águas brancas”, caracterizado pela alta concentração de sedimentos em suspensão (variando em torno de 31 a 247 $mgL^{-1}$ em profundidades entre 0 – 1 metros), média riqueza em minerais dissolvidos na água (como cálcio e outros minerais que são recursos nutritivos para a vegetação) e pH próximo ao neutro (JUNK, 1997). Estas características físico-químicas afetam de maneira positiva a biodiversidade da vegetação das planícies de inundação banhadas por águas brancas, conhecidas como várzeas.

O ecossistema de várzea é caracterizado pelo chamado “pulso de inundação” (JUNK et al., 1989), onde os fluxos originados da precipitação sazonal à montante dos principais rios da bacia Amazônica convergem para criar um pulso anual de influxo de água que percorre toda a extensão do Rio Amazonas (Figura 2.1).

Os processos de sucessão autogênica e alogênica da várzea amazônica são ligados diretamente ao zoneamento dos tipos de vegetação. Quando há deposição de sedimentos, aumenta-se o nível de base local, diminuindo a duração do período de inundação, e permitindo assim o estabelecimento de espécies menos tolerantes à inundação e a ocorrência de sucessão ecológica secundária ou clímax. Quando há remoção do substrato, há redução do nível de base local e aumento do período de inundação, causando estresse e mortandade na vegetação menos tolerante, forçando o retorno aos estágios sucessionais anteriores (JUNK; PIEDADE, 1997; WORBES, 1997).

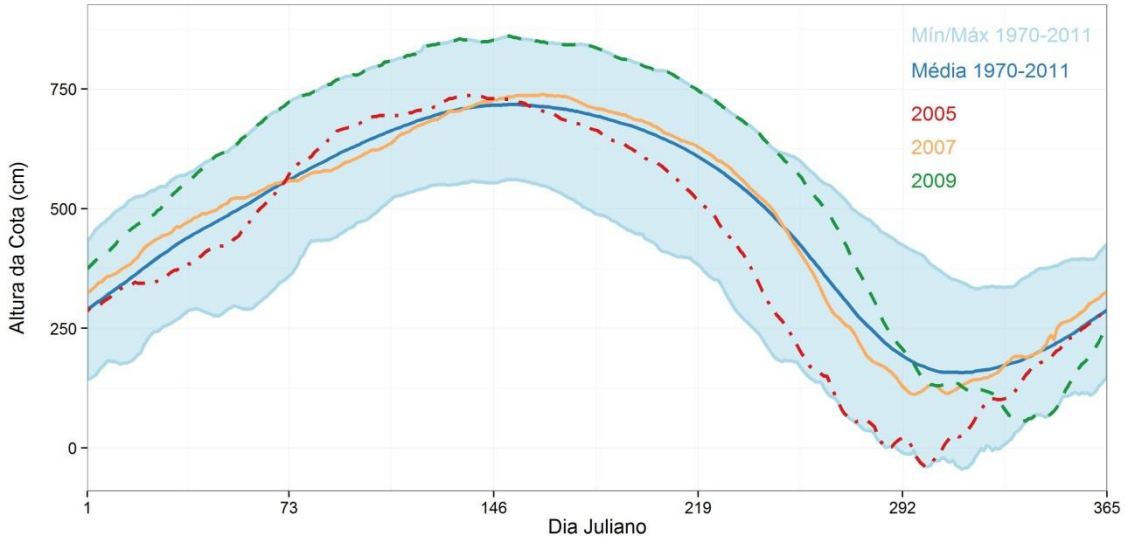


Figura 2.1 - Variação anual do nível da água, em centímetros, para a estação fluviométrica de Óbidos, na região do baixo Amazonas. A linha azul indica a média diária para o período de 1970 a 2011, e a área sombreada em azul indica o intervalo de confiança de 95% para a média. Em destaque, os anos de 2007 (vazão normal), 2005 (seca extrema) e 2009 (cheia extrema).
Fonte: Figura adaptada de SILVA et al. (2013).

Regiões com menor elevação possuem cerca de 300 dias de inundação anuais e são marcadas pela presença de plantas herbáceas anuais. Regiões com cerca de 270 dias de alagamento anuais possuem elevações médias e são marcadas por plantas arbustivas tolerantes a inundação. As regiões mais altas possuem menos de 230 dias de inundação anuais e são ocupadas por florestas inundáveis bem desenvolvidas. Este zoneamento é diretamente ligado ao grau de adaptação à inundação exibido por diferentes espécies (JUNK; PIEDADE, 1997; WORBES, 1997).

## 2.2. A vegetação da várzea amazônica

Em geral, podem-se distinguir cinco principais formações vegetais nas regiões de várzea (WITTMANN et al., 2004; WITTMANN et al., 2010): (1) plantas herbáceas flutuantes livres; (2) herbáceas enraizadas ou não enraizadas; (3)

ervas sublenhosas tolerantes à inundação, em pausa metabólica; (4) plantas lenhosas arbustivas perenes e tolerantes à inundação, em fase de pausa metabólica durante a inundação e (5) plantas lenhosas arbóreo-arbustivas perenes adaptadas à inundação, em fase produtiva na cheia.

Junk et al. (2012) classifica a vegetação da várzea amazônica em dois grupos principais: (6) regiões dominadas por plantas herbáceas e (7) regiões dominadas por florestas e arbustos. Em (6), podem ser discriminados três subgrupos de plantas herbáceas, subdivididos em função de sua fenologia, composição específica e elevação – (6.a) gramíneas anuais em terrenos baixos, (6.b) gramíneas perenes em terrenos baixos (*Paspalum fasciculatum, P. repens, Echinochloa polystachya*) e (6.c) áreas elevadas perturbadas antrópicamente, com a presença de gramíneas anuais. Com relação a (7), existe três grupos principais, divididos em função da duração do período de inundação: (7.a) florestas de várzea baixa (> três meses de inundação anuais); (7.b) florestas de várzea alta (<três meses de inundação anuais) e (7.c) florestas pantanosas, que apresenta períodos de inundação anuais maiores que os outros dois grupos. Cada um desses grupos é subdividido outros mais específicos segundo sua composição de espécies e estágios sucessionais.

Em mapeamentos prévios utilizando dados de sensoriamento remoto, (1), (2), (3), (6.a), (6.b) e (6.c) são comumente agregados sob a classe “macrófitas” (*macrophytes*), (4) e (7.c) sob “vegetação arbustiva” (*shrubs*), e (5) e (7.a) e (7.b) sob “vegetação arbustivo-arbórea” (*woodland*) ou “arbórea” (*forest*), de acordo com a composição específica e densidade/biomassa de indivíduos (HESS et al., 2003, SILVA et al., 2010, ARNESEN et al., 2013;; RENÓ et al., 2011;).

A diversidade das florestas de várzea da planície de inundação Amazônica é limitada pela adaptação à inundação periódica (PAROLIN et al., 2010). As florestas de várzea possuem menor número de espécies do que as florestas de terra firme Amazônicas, porém estudos indicam que sua diversidade de

espécies está entre as maiores do mundo, considerando-se as florestas de áreas úmidas (MITSCH; GOSSELINK, 2007; WITTMANN et al., 2010). A dinâmica fenológica da floresta é também diretamente controlada pelo pulso de inundação, resultando em elevada caducifólia durante o início da inundação (WORBES, 1997; SCHÖNGART et al., 2002). Muitas dessas espécies possuem frutos que flutuam sobre a lâmina d'água e são dispersados por espécies de peixes ou que são resistentes à inundação e sobrevivem por longos períodos no fundo dos lagos, onde germinam na época seca. (JUNK; PIEDADE, 1997; WORBES, 1997).

A vegetação herbácea também possui papel importante na várzea amazônica, ocupando vastas áreas e realizando funções chave em vários processos ecológicos (SILVA et al., 2009; PIEDADE et al., 2010). Além da sedimentação e consolidação do substrato, as macrófitas são importantes para a fauna, servindo como habitat para uma grande variedade de invertebrados, peixes e répteis (JUNK; PIEDADE, 1997). Diversas formas de vida e modos de crescimento podem ser observados para uma mesma espécie de macrófita, de acordo com os diferentes períodos do ciclo hidrológico. Muitas destas plantas exibem um ciclo de crescimento anual, com mortalidade ao final do ciclo e rápidas taxas de decomposição, implicando em um pulso de liberação de nutrientes. Este pulso pode ser fator determinante na sucessão de espécies vegetais durante a fase de seca. Considerando-se que as áreas habitadas por macrófitas podem se estender por vários quilômetros, torna-se claro que o efeito destas plantas sobre a disponibilidade de nutrientes minerais no ambiente aquático é de considerável magnitude(JUNK; PIEDADE, 1997).

## 2.3. Sensoriamento Remoto por Radar

Radares de abertura sintética (SAR) são sistemas de SR ativos que operam na região espectral das microondas, coerentes e de geometria de imageamento de visada lateral. Devido ao tamanho e a natureza de suas ondas, sensores SAR são pouco perturbados por fenômenos atmosféricos como nuvens e

aerossóis, e são sensíveis à constante dielétrica (relacionada principalmente com a composição química e a quantidade de umidade dos materiais), geometria e estrutura dos alvos. As bandas espectrais mais utilizadas em SAR são X (~3 cm), C (~5.6 cm), L (~23 cm) e P (~72 cm) (HENDERSON; LEWIS, 1998).

Sistemas radares operam através do registro do retroespalhamento da onda emitida. As ondas de um SAR são sempre emitidas e registradas em polarizações lineares, sejam horizontais (H), verticais (V) e suas combinações: as polarizações paralelas (H emitido e H recebido - HH; V emitido e V recebido - VV) ou cruzadas (H emitido e V recebido - HV; V emitido e H recebido - VH). As polarizações têm efeito significativo sobre a interação entre a REM e os alvos (HENDERSON; LEWIS, 1998; LEE; POTTIER, 2009).

Quando a onda do radar atinge a superfície da Terra, ela interage com inúmeros refletores da superfície. A soma coerente da intensidade e fase de cada uma desses retroespalhamentos causa oscilação no sinal de retorno daquele elemento de resolução, o que provoca a flutuação dos níveis de cinza dos pixels da cena ou o efeito de granulação (JENSEN, 2007). A esse efeito dá-se o nome de *speckle.*

A interpretação visual e a classificação digital de cenas SAR são prejudicadas pelo *speckle*, e a aplicação de filtros adaptativos para a atenuação desse efeito é comum. Porém, tal filtragem deve ser realizada com parcimônia, uma vez que causa perda de resolução espacial e informações texturais (SANT'ANNA; MASCARENHAS, 1996; HENDERSON; LEWIS, 1998).

O SAR é disposto em uma plataforma móvel e a direção em que a nave se desloca é chamada de azimute. A direção de *range* é a direção perpendicular ao azimute. A direção de *range* é dividida em (a) *near range* e (b) *far range*, sendo respectivamente a distância entre a antena e o primeiro ou último pulso de REM emitido e registrado pelo sensor. Outro parâmetro importante na geometria de aquisição das imagens SAR é o ângulo de incidência, que afeta o

retroespalhamento dos alvos, o grau de penetração da onda em seu meio e a ocorrência de distorções de terreno, como *layovers, foreshortenings* e sombras. (OLIVER; QUEGAN; 2004; LEE; POTTIER, 2009).

### 2.3.1. Tipos de interação com alvos de várzea

A várzea apresenta espalhamento superficial para solos úmidos e para regiões cobertas de água, para os menores comprimentos de onda (bandas C e X). Para os maiores comprimentos de onda (bandas L e P), também há ocorrência desse tipo de espalhamento para regiões de vegetação herbácea pouco densa, onde o sinal ultrapassa seus dosséis. Esse tipo de espalhamento é registrado pelas polarizações HH e VV e é diretamente proporcional à rugosidade da superfície – são mais intensos para alvos mais rugosos como solos expostos e menos intensos para águas paradas e sem ondas (HENDERSON; LEWIS, 1998).

O espalhamento volumétrico ocorre principalmente nos dosséis de alvos de vegetação, onde há uma inversão ou rotação da polarização emitida devido aos múltiplos espalhamentos sofridos pela onda no interior desses dosséis. Dessa maneira, são registrados nas polarizações HV e VH. O sinal emitido nas bandas C e X penetra em alvos com menor biomassa, como plantas herbáceas, formações arbustivas e florestas menos densas, ficando restrito às camadas superiores dos dosséis das florestas mais densas. As bandas L e P, por sua vez, possuem maior penetração em florestas mais densas, mas em alguns casos podem ultrapassar quase completamente coberturas vegetais pouco densas (HENDERSON; LEWIS, 1998).

O espalhamento *double-bounce* ocorre principalmente em alvos de vegetação que apresentam água ou algumas vezes solos expostos lisos em seu substrato. São caracterizados por um forte sinal de retorno, sendo registrados nas imagens como pixels bastante claros nas polarizações HH e VV. As bandas C e X apresentam maior *double-bounce* em regiões de gramíneas, formações arbustivas e sob florestas inundáveis menos densas, ao passo que

nas bandas L e P os *double-bounces* são mais intensos em florestas inundáveis e mesmo em florestas de terra firme. (HESS et al., 1990; HENDERSON; LEWIS, 1998)

## 2.4. Radares Polarimétricos

Radares polarimétricos são aqueles que possuem a capacidade de sintetizar a intensidade da REM retroespalhada e sua fase, em todas as combinações de polarizações lineares (figura 2.3). Dessa maneira, pode-se obter a matriz de espalhamento S, chamada de matriz de Sinclair, que contém as informações completas sobre o retroespalhamento dos alvos imageados (VAN DER SANDEN, 1997; LEE; POTTIER, 2009; CLOUDE, 2009).

A representação dos dados PolSAR se dá na forma de vetor ou de matriz. A forma vetorial de representação mais utilizada para os dados polarimétricos é a de Jones, cujo objetivo é descrever a polarização de uma onda eletromagnética com o mínimo de parâmetros necessários (LEE; POTTIER, 2009). É possível utilizar outras representações vetoriais, como o vetor de Stokes, mas pelo maior número de parâmetros associadas a ele, sua complexidade é maior e o vetor de Jones em geral é preferido.

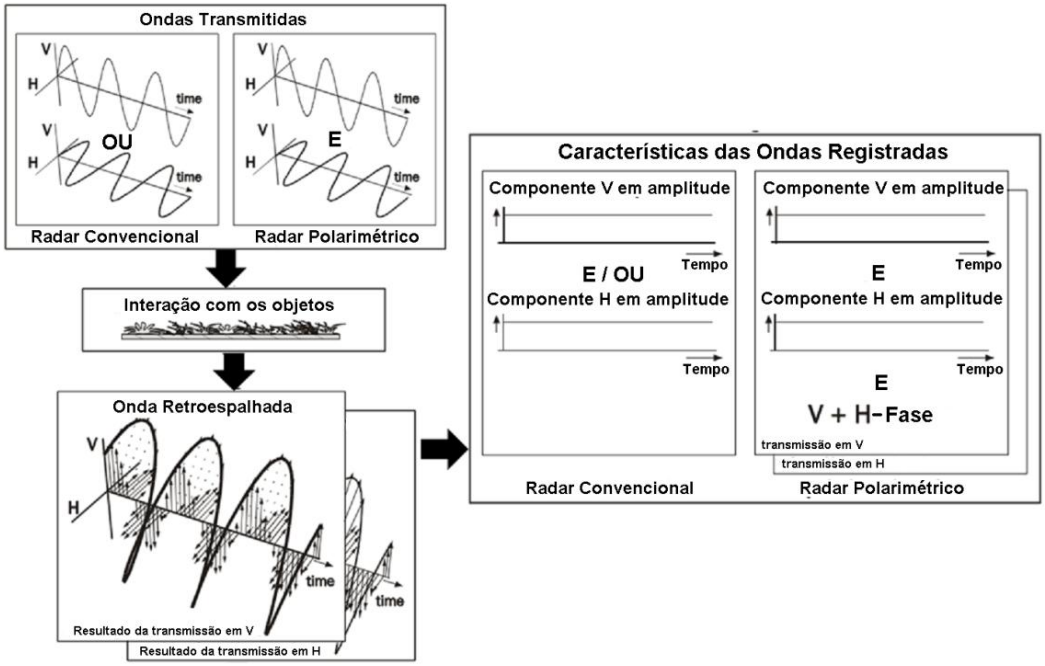


Figura 2.2 – Esquema gráfico com as diferenças entre radares convencionais e polarimétricos.

Fonte: adaptado de van der Sanden (1997).

As matrizes T (coerência) e C (covariância) são utilizadas para descrever o retroespalhamento de alvos aleatórios ou não determinísticos e são obtidas a partir de médias espaciais da matriz de espalhamento S (CLOUDE, 2009; LEE; POTTIER, 2009). A matriz T origina-se pelo produto vetorial da matriz S (equação 2.1) na forma de vetor na base de Pauli (equação 2.2 – suponto que $S_{HV} = S_{VH}$) pelo seu complexo transposto conjugado (equações 2.3). A base de Pauli associa cada componente da matriz coerência a um tipo de mecanismo de espalhamento – superficial ($S_{HH} + S_{VV}$), *double-bounce* ($S_{HH} - S_{VV}$) e volumétrico ($S_{HV} + S_{VH}$):

$$S = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix} \tag{2.1}$$

$$\overrightarrow{K_p} = \frac{1}{\sqrt{2}}[(S_{HH} + S_{VV})(S_{HH} - S_{VV})(S_{HV} + S_{VH})]^T \tag{2.2}$$

$$T_{3x3} = \langle \vec{K}_p \vec{K}_p^{*T} \rangle \quad (2.3)$$

Sendo S = Matriz S ou de Sinclair; $K_P$ = Matriz S na base vetorial de Pauli; $K_P^{*T}$ = vetor de Pauli conjugado transposto.

A matriz C é obtida pelo produto vetorial da matriz S (equação 2.4) em forma de vetor lexicográfico (equação 2.5 – supondo $S_{HV} = S_{VH}$) pelo seu complexo transposto conjugado (2.6). A base lexicográfica associada cada elemento da matriz C a uma combinação de polarizações (HH, HV e VV).

$$S = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix} \quad (2.4)$$

$$\overrightarrow{K_B} = [S_{HH} S_{HV}\ S_{VV}]^T \quad (2.5)$$

$$C_{3x3} = \langle \vec{K}_B \vec{K}_B^{*T} \rangle \quad (2.6)$$

Sendo S = Matriz S ou de Sinclair; $K_B$ = Matriz S na base vetorial lexicográfica; $K_B^{*T}$ = vetor lexicográfico conjugado transposto. Dessa forma, percebe-se que a matriz T está ligada a uma estimativa dos mecanismos de espalhamento dos alvos, enquanto a matriz C está relacionada às medições do sistema sensor (LEE; POTTIER, 2009).

### 2.4.1. Decomposição de alvos

Os teoremas de decomposição de alvos baseiam-se na simulação de mecanismos de espalhamento de diferentes naturezas pela associação destes com matrizes elementares originadas a partir das matrizes S e/ou T (HENDERSON; LEWIS, 1998; TOUZI et al., 2007). Nesse universo, existem diferentes paradigmas de decomposição: (a) decomposições coerentes da matriz de espalhamento S (como Pauli); (b) decomposições baseadas em modelos de espalhamento (como Freeman – Durden e Yamaguchi) e (c) decomposição dos autovalores e autovetores da matriz T (Cloude – Pottier e van Zyl) e (LEE; POTTIER, 2009).

O primeiro grupo de decomposição de alvos é aquele das decomposições coerentes da matriz de Sinclair (S). Essas decomposições têm como objetivo decompor tal matriz em outras *n* matrizes elementares, que correspondem a um tipo de mecanismo de espalhamento determinístico ou canônico. Apesar de serem decomposições que simulam alvos determinísticos, são muito utilizadas em trabalhos envolvendo alvos naturais (CLOUDE, 2009; LEE; POTTIER, 2009).

A decomposição coerente de Pauli, um exemplo desse tipo de decomposição polarimétrica, expressa a matriz S como uma soma complexa de matrizes, tal que cada componente estima um tipo de espalhamento elementar: (a) a primeira componente HH+VV estima o espalhamento de superfícies lisas ou espalhamento superficial; (b) HH – VV o espalhamento de um diedro, ou espalhamento *double-bounce* e (c) HV o espalhamento de um diedro orientado à 45° com o eixo horizontal do vetor da REM, que representa o espalhamento volumétrico. A quarta componente, que estima todos os mecanismos não simétricos de espalhamento, só é calculada quando o princípio de simetria do sensor não é válido (ou seja, HV é diferente de VH, o que não ocorre para o Radarsat - 2). A base de Pauli consiste em (equação 2.7):

$$S = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix} \therefore a = \frac{S_{HH} + S_{VV}}{\sqrt{2}} \quad b = \frac{S_{HH} - S_{VV}}{\sqrt{2}} \quad c = \frac{S_{HV} + S_{VH}}{\sqrt{2}} \tag{2.7}$$

O segundo grupo de decomposições são aquelas que estimam os mecanismos de espalhamento dos alvos através de modelos de espalhamento, cujo objetivo é simular estes mecanismos sem utilizar informações obtidas em campo. A decomposição de Freeman – Durden (FREEMAN; DURDEN, 1998) possui três componentes: (a) espalhamento superficial (*odd scattering*) a partir de um modelo de espalhamento de Bragg, (b) espalhamento volumétrico (*volumetric scattering*) estimado através de uma nuvem de dipolos aleatoriamente posicionados e (c) espalhamento de *double-bounce,* estimado entre duas superfícies não metálicas, ortogonais e com propriedades dielétricas diferentes.

Em relação à componente superficial, o espalhamento de Bragg de uma matriz S é dado por (equação 2.8):

$$S = \begin{bmatrix} S_{HH} & 0 \\ 0 & S_{VV} \end{bmatrix} \tag{2.8}$$

Quando o produto vetorial de S e $S^{*T}$ é realizado, a matriz C resultante é (equação 2.9):

$$C_{3S} = \begin{bmatrix} |S_{HH}|^2 & 0 & S_{HH}S_{VV}^* \\ 0 & 0 & 0 \\ S_{VV}S_{HH}^* & 0 & |S_{VV}|^2 \end{bmatrix} = f_s \begin{bmatrix} |\beta|^2 & 0 & \beta \\ 0 & 0 & 0 \\ \beta^* & 0 & 1 \end{bmatrix} \tag{2.9}$$

Sendo que $f_s$corresponde à contribuição da componente de espalhamento superficial para a componente $|S_{VV}|^2$ (equação 2.10):

$$f_s = |S_{VV}|^2 \;\; e \;\; \beta = \frac{S_{HH}}{S_{VV}} \tag{2.10}$$

Em relação à componente *double-bounce*, a matriz S de um diedro não-metálico, ortogonal, se dá por (equação 2.11):

$$S = \begin{bmatrix} e^{2j\gamma_H} R_{TH}R_{GH} & 0 \\ 0 & e^{2j\gamma_V} R_{TV}R_{GV} \end{bmatrix} \tag{2.11}$$

Os termos $R_{TH}$ e $R_{TV}$ são os coeficientes de reflexão de uma superfície vertical para as polarizações H e V, respectivamente. Os termos $e^{2j\gamma h}$e$e^{2j\gamma v}$ são fatores de propagação e representam atenuações e efeitos de mudança de fase causados pela interação entre a REM e as superfícies. Os termos $R_{GH}$ e $R_{GV}$ são os coeficientes de reflexão de Fresnel – ou seja, a reflexão da onda não é a de um diedro perfeito, e sim de algo que se aproximaria de um diedro natural.

A matriz C originada pelo o produto vetorial de S e $S^{*T}$ é (equação 2.12):

$$C_{3D} = \begin{bmatrix} |R_{TH}R_{GH}|^2 & 0 & e^{2j(\gamma_H - \gamma_V)}R_{TH}R_{GH}R^*{}_{TV}R^*{}_{GV} \\ 0 & 0 & 0 \\ e^{2j(\gamma_V - \gamma_H)}R_{TV}R_{GV}R^*{}_{TH}R^*{}_{GH} & 0 & |R_{TV}R_{GV}|^2 \end{bmatrix} = f_D \begin{bmatrix} |\alpha|^2 & 0 & \alpha \\ 0 & 0 & 0 \\ \alpha^* & 0 & 1 \end{bmatrix} \quad (2.12)$$

Sendo $f_D$ corresponde à contribuição do espalhamento *double-bounce* na componente $|S_{VV}|^2$, onde (equação 2.13):

$$f_D = |R_{TV}R_{GV}|^2 \text{e} \;\; \alpha = e^{2j(\gamma_H - \gamma_V)}\frac{R_{TH}R_{GH}}{R_{TV}R_{GV}} \quad (2.13)$$

Em relação à componente volumétrica, o modelo pressupõe que há um arranjo de inúmeros dipolos horizontais muito finos orientados de maneira aleatória, com o ângulo θ variando de –π a π com relação ao eixo horizontal da REM. A matriz S de um dipolo horizontal muito estreito é (equação 2.14):

$$S = \begin{bmatrix} a & 0 \\ 0 & b \end{bmatrix} \rightarrow a \sim 1 \; e \; b \sim 0 \quad (2.14)$$

A matriz C resultante da operação vetorial de S e $S^{*T}$, após a distribuição aleatória ter sido aplicada, é (equação 2.15):

$$< C_{3V} > \theta = \frac{f_V}{8}\begin{bmatrix} 3 & 0 & 1 \\ 0 & 2 & 0 \\ 1 & 0 & 3 \end{bmatrix} \quad (2.15)$$

Sendo $f_V$ a contribuição de espalhamento volumétrico na componente $|Svv^2|$. Finalmente, a proporção de cada tipo de espalhamento, em relação ao total (*Span*) é simulado como (equação 2.16):

$$Span = |S_{HH}|^2 + 2|S_{HV}|^2 + |S_{VV}|^2 = P_S + P_D + P_V \quad (2.16)$$

Onde $P_S$, $P_D$ e $P_V$ são as componentes finais superficial, double-bounce e volumétrica – as imagens de saída.

A decomposição de Yamaguchi (LEE; POTTIER, 2009) diferencia-se da de Freeman - Durden por supor que não há simetria de espalhamento da matriz S ($S_{HH}S^*_{HV} \neq S_{VV}S^*_{VH}$). Dessa maneira, a modelagem da componente volumétrica é feita de maneira diferente e o espalhamento dos alvos é descrito por quatro componentes: volumétrico, *double-bounce*, superficial e helicoidal, que estima o espalhamento assimétrico. As matrizes S de um espalhador em forma de hélice são (equação 2.17):

$$S_{LH} = \begin{bmatrix} 1 & j \\ j & -1 \end{bmatrix} \quad e \quad S_{RH} = \begin{bmatrix} 1 & -j \\ -j & -1 \end{bmatrix} \tag{2.17}$$

Sendo $S_{LH}$ a hélice girando para a esquerda e $S_{RH}$ para direita. As matrizes C oriundas das matrizes S acima são (equação 2.18):

$$C_{3LH} = \frac{f_c}{4}\begin{bmatrix} 1 & -j\sqrt{2} & -1 \\ j\sqrt{2} & 2 & -j\sqrt{2} \\ -1 & j\sqrt{2} & 1 \end{bmatrix} \text{ e } C_{3RH} = \frac{f_c}{4}\begin{bmatrix} 1 & j\sqrt{2} & -1 \\ -j\sqrt{2} & 2 & j\sqrt{2} \\ -1 & -j\sqrt{2} & 1 \end{bmatrix} \tag{2.18}$$

Sendo assim $f_c$ é a contribuição do espalhamento helicoidal na componente $|S_{VV}|^2$. O Span e as imagens finais passam a ser (equação 2.19):

$$Span = |S_{HH}|^2 + 2|S_{HV}|^2 + |S_{VV}|^2 = P_S + P_D + P_V + P_C \tag{2.19}$$

Sendo$P_C$ a proporção de espalhamento de hélice no retroespalhamento total.

O terceiro e último grupo de decomposições a ser considerado nesse estudo é aquele baseado em decomposição dos autovalores (*eigenvalues*) e autovetores (*eigenvectors*) da matriz T. Os autovetores possuem informações sobre o tipo de espalhamento que os alvos possuem – volumétrico, *double bounce*, etc; e os autovalores, sobre a contribuição que cada tipo de espalhamento possui em relação ao espalhamento total – a proporção do

espalhamento em relação a todos os outros (CLOUDE, 2009; LEE; POTTIER, 2009).

De uma maneira geral, pode-se escrever a matriz T da seguinte forma (equação 2.20):

$$T_3 = U_3 \Sigma_3 U_3^{-1} \tag{2.20}$$

Onde (equações 2.21 e 2.22):

$$\Sigma_3 = \begin{bmatrix} \lambda_1 & 0 & 0 \\ 0 & \lambda_2 & 0 \\ 0 & 0 & \lambda_3 \end{bmatrix} \tag{2.21}$$

$$\mathrm{U}_3 = [\underline{u}_1 \quad \underline{u}_2 \quad \underline{u}_3] \tag{2.22}$$

$\Sigma_3$ contém os autovalores da matriz $T_3$. Os autovalores são números reais, não negativos, onde $\lambda_1 > \lambda_2 > \lambda_3 > 0$. $U_3$ contém os autovetores da mesma matriz, que são definidos como (equação 2.23):

$$u_i = [cos\alpha e^{j\phi} \quad sen\alpha cos\beta e^{j(\delta+\phi)} \quad sen\alpha sen\beta e^{j(\gamma+\phi)} \tag{2.23}$$

Onde α é o ângulo que define o tipo de espalhamento; *β* é o ângulo de orientação do alvo e *Φ*, *δ* e *γ* são ângulos relativos à fase da onda. Finalmente, a matriz $T_3$ pode ser escrita da seguinte maneira (equação 2.24):

$$\langle T_3 \rangle = \sum_{j=1}^{3} \lambda_i \underline{u}_i \underline{u}_i^{*T} \tag{2.24}$$

Ou seja, a matriz $T_3$ é decomposta pelo somatório do produto de um autovalor *i*, seu autovetor *i* correspondente e o complexo conjugado desse mesmo autovetor *i*. Esse somatório é feito para os três autovalores e três autovetores. A decomposição de autovalores e autovetores, por si só, é uma decomposição de alvos; mas a transformação de Cloude – Pottier usa três parâmetros

derivados dessa decomposição para melhor explicar os mecanismos de espalhamento dos alvos: Entropia, Anisotropia e Ângulo *α* (CLOUDE, 2009; LEE; POTTIER, 2009).

A entropia (*H*) é definida como o grau de desordem do espalhamento de um alvo (equação 2.25 e 2.26), e é associada ao tipo de espalhamento principal que esse alvo possui.

$$\langle T_3 \rangle = \sum_{j=1}^{3} p_i \log_3(p_i) \tag{2.25}$$

$$p_i = \frac{\lambda_i}{\sum_{k=1}^{3} \lambda_k} \tag{2.26}$$

Como visto, a entropia descreve a probabilidade de ocorrência de um autovalor em relação aos outros três. Quando os três autovalores possuem iguais probabilidades de ocorrência, a entropia é máxima (*H* = 1) e não há um tipo de espalhamento dominante. Ao contrário, se *H* = 0, ocorre apenas um tipo de espalhamento.

A Anisotropia (*A*), por sua vez, relaciona-se com a importância relativa do segundo e terceiro tipos de espalhamento que o alvo apresenta. A anisotropia define-se como (equação 2.27):

$$A = \frac{\lambda_2 - \lambda_3}{\lambda_2 + \lambda_3} \tag{2.27}$$

Em termos práticos, *A* só pode ser empregada quando *H* > 7. Em qualquer outro caso, ela é muito afetada por ruídos e não possui informações relevantes. (LEE; POTTIER, 2009).

O ângulo alfa (*α*) refere-se ao tipo de espalhamento principal do alvo. Quando 0° < *α* < 45°, a onda incidente e a onda retroespalhada possuem diferenças em amplitude, mas as fases das ondas são iguais Quando o ângulo *α* é de 45° graus, há espalhamento anisotrópico perfeito. Quando 45° < *α* < 90°, as ondas

possuem amplitudes e fases diferentes, o que pode significar espalhamentos em forma de diedro ou de hélice. No caso extremo (90°) as duas ondas possuem mesma amplitude, mas com 180° de diferença de fase. Logo, resumidamente o ângulo α divide-se em: (a) superficial (valores próximos de 0°); (b) espalhamento volumétrico (para valores próximos de 45°) e (c) espalhamento *double-bounce* (para valores próximos de 90°) (CLOUDE, 2009; LEE; POTTIER, 2009).

A decomposição de alvos de Touzi (TOUZI, 2007) oferece informações complementares à decomposição de Cloude – Pottier. Parâmetros como a diferença de fase dos alvos ($\Phi_i$ - $\Phi_j$) e ângulo de orientação do alvo ($\beta$) complementam as informações fornecidas pelo ângulo $\alpha$, que podem ser redundantes principalmente na região que compreende os espalhamentos double-bounce (TOUZI, 2007).

Finalmente, a decomposição de van Zyl (CLOUDE, 2009; LEE; POTTIER, 2009) é uma decomposição intermediária entre as baseadas em modelo de retroespalhamento e em decomposição de autovalores/autovetores. Van Zyl expressa a matriz $T_3$ da seguinte maneira (equação 2.28):

$$\langle C_3 \rangle = \sum_{j=1}^{3} \lambda_i \underline{u}_i \underline{u}_i^{*T} = \Lambda_1 \begin{bmatrix} |\alpha|^2 & 0 & \alpha \\ 0 & 0 & 0 \\ \alpha^* & 0 & 1 \end{bmatrix} + \Lambda_2 \begin{bmatrix} |\beta|^2 & 0 & \beta \\ 0 & 0 & 0 \\ \beta^* & 0 & 1 \end{bmatrix} + \Lambda_3 \begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad (2.28)$$

Onde $\Lambda_1$,$\Lambda_2$ e $\Lambda_3$ são termos baseados nas relações entre os autovetores $u_1$, $u_2$ e $u_3$ e autovalores $\lambda_1$, $\lambda_2$ e $\lambda_3$ respectivamente. Van Zyl relaciona os dois primeiros autovetores aos espalhamentos superficial e volumétrico. O autovalor $\lambda_3$ por sua vez é relacionado aos *double-bounces*.

## 2.5. SAR e áreas úmidas

Para esse trabalho, a análise de trabalhos da literatura será dividida em três partes: (1) aqueles relacionados com o mapeamento de tipos de vegetação de áreas úmidas e similares; (2) aqueles sobre estimativa e modelagem de

atributos biofísicos de tipos de vegetação de várzea e semelhantes e (3) trabalhos utilizando dados polarimétricos.

Com relação ao item (1), Hess et al. (1990), Kasischke et al. (1997) e Henderson and Lewis (2008) são artigos de revisão que abordam o tema do uso de imagens SAR para a classificação de alvos de vegetação e mapeamento da dinâmica e extensão de inundação, em áreas úmidas de todo o mundo, para todas as frequências SAR mais comuns (X, C, L e P). Os autores relatam que a (a) banda C pode ser usada para estudar áreas úmidas dominadas por florestas, sendo inapropriada somente para aquelas com elevadas quantidades de biomassa; (b) dão grande importância à informação polarizada, afirmando que muitas vezes maior número de polarizações é mais adequado do que maior número de cenas multitemporais de uma mesma polarização; (c) não há uma ligação direta entre o uso de ângulos de incidência e maiores índices de precisão e acerto da classificação – essa relação depende diretamente da área de estudo e dos alvos imageados; afirmam também que a combinação de mais de um ângulo de incidência nem sempre aumenta a precisão da classificação; (d) o uso de imagens multitemporais, em geral, aumenta a precisão da classificação apenas até certo ponto, e muitas vezes incorre em um aumento do erro geral da classificação e (e) a área de estudo e suas classes são fundamentais para o mapeamento – como pode ser observado nesse trabalho, dado que alguns resultados obtidos para a várzea amazônica diferem sensivelmente de resultados obtidos em outras áreas úmidas.

Outros autores reforçam muitos dos resultados vistos anteriormente, como Costa; Telmer (2006), Martinez; Le Toan (2006), Li et al. (2007), Lang et al. (2008), Lucas et al. (2008) e Marti-Cardona et al. (2010). Estes autores investigaram os efeitos do uso de diferentes polarizações, ângulos de incidência e uso de cenas multitemporais na classificação dos alvos de vegetação em áreas úmidas em diferentes regiões do mundo, tanto para banda C como para banda L. Entre suas conclusões, pode-se afirmar que (f) cenas de

diversas polarizações possuem melhor resultado que cenas multitemporais com apenas uma polarização e seriam capazes de suprimir parte da confusão entre as classes que os múltiplos ângulos não resolverem – apesar de que esse resultado está ligado diretamente aos tipos de vegetação presente nessas áreas úmidas, dado que nessa pesquisa foi observado um resultado diferente; (g) a banda C é mais adequada para o uso em regiões de vegetação de áreas úmidas dominadas por gramíneas e vegetação arbórea de menor porte, devido a sua menor capacidade de penetração que a banda L; (h) o uso cenas multitemporais melhora a análise das classes somente até certo ponto e (i) não necessariamente o menor ângulo de incidência é o mais adequado para diferenciar os tipos de vegetação imageados; muitas vezes ângulos médios e maiores possuem maior poder de discriminar esses tipos.

Também é observado na literatura trabalhos envolvendo o uso de imagens SAR, na banda C ou L, e sua sinergia com dados de outros sensores ópticos e/ou modelos digitais de elevação. Bwangoy et al. (2010) utilizaram dados multisensor (TM/Landsat-5, SAR – banda L e SRTM) no mapeamento de alvos de áreas úmidas no Congo. De todos os 28 *layers* usados na classificação, os dados SAR representaram sozinhos 9% de toda a informação utilizada na classificação, e a imagem da época cheia apresentou mais de 8% da participação, superando muitos dos comprimentos de onda normalmente utilizados no sensoriamento remoto de dados ópticos. Silva et al. (2010) utilizaram dados multisensores (MODIS, SRTM e Radarsat-1 – banda C) para o estudo das dinâmicas temporal e espacial de macrófitas e para a estimativa de sua produtividade, na várzea do lago de Monte Alegre, no Pará. Através da análise de imagens baseada em objetos (*Object-Based Image Analysis* – OBIA) foi possível detectar não só a cobertura e a dinâmica dessas plantas, mas também modelar sua produtividade.

Com relação aos trabalhos do item (2), sobre o ajuste de modelos preditivos de atributos biofísicos da vegetação de áreas úmidas a partir de dados SAR, Townsend (2002), Costa et al. (2002), Moreau; Le Toan (2003), Novo et al.

(2002) e Sartori et al. (2012) mostraram que ambas as bandas C e L, além de possuírem correlação com os parâmetros biofísicos de gramíneas, como biomassa, altura e porcentagem de cobertura, também são complementares e podem ser utilizadas em conjunto, melhorando o ajuste e o desempenho dos modelos. Os autores também mostram que, mesmo somente com a banda C, pode-se estabelecer correlações significativas para plantas herbáceas e arbustos de menor densidade, como $r^2 = 0.78$, para o log da biomassa seca de macrófitas, como visto em Costa et al. (2002) e Novo et al. (2002). Porém, poucos são os trabalhos que discutem o erro médio quadrático (*Root Mean Squared Error* – RMSE) e os resíduos dos modelos. Tal discussão, que é importante para trabalhos que envolvem modelagem preditivas, foi observada apenas em Sartori et al. (2012) e Moreau; Le Toan (2003).

Com relação ao item (3), há poucos trabalhos abordando dados polarimétricos e seu potencial em mapear a distribuição e a estrutura de alvos de vegetação em áreas úmidas. Touzi et al. (2009) investigaram a decomposição de alvos de Touzi para discriminar tipos de vegetação em áreas úmidas no Canadá, e concluíram que sua decomposição obteve melhores resultados que outra decomposição similar: Cloude – Pottier para a vegetação úmida de Mer de Bleue. Brisco et al. (2013) compararam o desempenho de dados polarimétricos e polarimétricos compactos (onde o sensor emite em apenas uma polarização, mas recebe nas duas, e ainda contém a informação de fase) no mapeamento de alvos comuns de regiões de áreas úmidas e também de regiões de rizicultura. Os autores observaram que, devido à maior quantidade de informação por parte dos dados polarimétricos, esses destacaram-se sobre os polarimétricos compactos e obtiveram melhor resultado. Koch et al. (2012) utilizaram dados ópticos e polarimétricos de banda C e L para mapeamento das condições ambientais de áreas úmidas na Espanha. Os autores utilizaram a decomposição de Cloude – Pottier e de Yamaguchi, e relatam o bom resultado dos dados polarimétricos na classificação de sua área de estudo. Os autores também mostram que os dados ópticos e SAR se complementam,

dado que o sensoriamento remoto óptico foi mais sensível ao nível de degradação da área úmida, ao passo que dados SAR são mais sensíveis a estrutura e às condições de inundação ou de umidade dos alvos. Sartori et al. (2011) utilizaram dados polarimétricos de banda L para a classificação de espécies de grupos de macrófitas no lago de Monte Alegre, no Pará. A informação derivada de dados polarimétricos (como decomposição de Freeman – Durden e Cloude – Pottier) obteve diferentes taxas de sucesso, separando grupos de vegetação como floresta inundável, vegetação arbustiva e macrófitas, e a decomposição de Touzi permitiu a melhor caracterização à nível de espécie.

## 2.6. Análise de imagem baseada em objetos

No mapeamento por processamento digital, algoritmos computacionais são utilizados na identificação automática dos alvos e são baseados em classificadores *pixel a pixel* ou por regiões. A diferença entre as duas metodologias de classificação consiste no tratamento dado ao pixel. Enquanto na *pixel a pixel*, estes são avaliados isoladamente, a classificação por regiões avalia os segmentos, ou seja, pixels agrupados em regiões contíguas durante segmentação a partir algoritmos que examinam a textura e a resposta espectral dos pixels adjacentes e, alguns destes, a forma do objeto.

Diferentemente dos classificadores tradicionais, que apenas utilizam a resposta espectral, a análise de imagens baseada em objeto (*Object-based Image Analisys – OBIA*) possibilita utilizar outros descritores. Como as imagens estão estruturadas em objetos, que possuem identidade própria, é possível utilizar descritores como textura, forma, relações topológicas com os objetos vizinhos, relação hierárquica entre os níveis de segmentação, entre outros, simulando os processos cognitivos humanos de interpretação de imagens (BLASCHKE, 2010). Torna-se também exeqüível a utilização de árvores de decisão, que são estruturas de classes baseadas em decisões binárias, organizadas em níveis hierárquicos. Diversos trabalhos demonstram o melhor desempenho da

classificação por OBIA quando comparara à pixel a pixel no mapeamento de diferentes tipos de vegetação, quando as metodologias são comparadas por meio de índices de acurácia (AMARAL *et al.*, 2009; YU *et al.*, 2006; GERGEL *et al.,* 2007; DORREN *et al.,* 2003, JOHANSEN *et al.,* 2007; SOUSA *et al.,* 2011).

## 2.7. Mineração de dados e árvores de decisão

A mineração de dados consiste em um conjunto de técnicas, programas e algoritmos computacionais que permite a detecção, extração de padrões e construção de conhecimento em grandes volumes de dados (WITTEN; FRANK, 2005).

Os mineradores de dados possuem três características principais associados a ele (WITTEN; FRANK, 2005): (a) o seu conceito, (b) suas instâncias e (c) seus atributos. O conceito é a maneira que o computador se utiliza para detectar os padrões dos dados de entrada (ou seja, "aprender" sobre os dados), e são em número de quatro: "*classification learning*", "*association learning*", "*clustering*" e "*numeric predition*". O algoritmo J4.8 (como visto em WITTEN; FRANK, 2005), pertence ao conceito de *classification learning*, pois apreende os padrões dos dados a partir de amostras pré-classificadas.

A *instância* é o dado propriamente dito, fornecido para o algoritmo. Como exemplo, os atributos de média de uma classe são uma instância, assim como o nome dessa classe e os tipos de relação topológica com as demais classes. Os *atributos* são os valores das instâncias. Podem ser numéricos, categóricos ou nominais. Como, por exemplo, 0.0134 para a média de um objeto e "Solo Exposto" para uma classe.

O algoritmo J4.8. "aprende" sobre os dados de entrada e apresenta como resultado uma árvore de decisão, que é um modelo de classificação para esses dados. Esse algoritmo, fundamentado no algoritmo C4.5, é um algoritmo não-paramétrico baseado em ganho de informação / entropia.

A descrição do algoritmo, a seguir, é como em Witten; Frank (2005). Primeiramente, o algoritmo J4.8. é alimentado com os dados de entrada (as instâncias e atributos) que descrevem as classes de cobertura do solo. Uma dessas instâncias deve ser obrigatoriamente nominal (normalmente é a instância que contém o nome das classes de cobertura) e o restante, numérico. Um nó inicial é criado contendo todos os objetos de todas as classes e o seu valor de informação é calculado. Em seguida são gerados nós-filhos, um para cada atributo numérico, e o valor de informação de cada um desses nós é calculado. A diferença entre o valor de informação do nó inicial e do nó filho é chamada de ganho de informação.

O ganho de informação é relacionado à pureza do nó; quando uma instância e um atributo são capazes de separar uma classe inteira em apenas um nó, ele possui menor valor de informação, consequentemente possuindo maior ganho de informação. Assim, o atributo com maior valor de ganho de informação é aquele mais eficiente em separar ao máximo as classes em diferentes nós.

A instância e o atributo que apresentam maior ganho de informação são selecionados pelo algoritmo e o segundo nó da árvore é formado. Assim, todo o processo continua até que todas as classes de entrada estejam completamente separadas (ou seja, que classe esteja contida totalmente em um nó separado dos demais) ou até que não haja mais ganho de informação (mesmo que todas as classes não tenham sido separadas).

Ganho de informação, ou entropia, é calculado como na equação (2.29):

$$entropy(p_1, p_2 \dots p_n) = -p_1 log p_1 - p_2 log p_2 \dots - p_n log p_n \qquad (2.29)$$

Os logaritmos da equação (2.29) são de base 2, portanto a unidade da entropia é bits. Os argumentos $p_1$, $p_{2...}$ $p_n$ são frações, calculadas como na equação (2.30):

$$entropy(p_1, p_2 \dots p_n) = entropy(q, r \dots s) = entropy(\frac{q}{q+r+s}, \frac{r}{q+r+s}, \frac{s}{q+r+s}) \quad (2.30)$$

Onde *q*, *r* e *s* é o número de elementos das classes dentro de um nó. Quando um nó possui elementos de apenas uma classe seu valor de informação é zero. Quando um nó possui elementos das classes igualmente distribuídos ele possui o máximo de informação ou entropia.

# 3. MATERIAIS E MÉTODOS

## 3.1. Área de estudo

A região de estudo (Figura 3.1) compreende a várzea do Lago Grande de Curuai, localizado entre as latitudes 1°51'12'' S e 02°21'06'' S e longitudes 55°56'32'' W e 55°03'14'' W, ao sul do município de Óbidos, no Estado do Pará. Tal área de estudo é representativa da planície de inundação do Baixo Amazonas, caracterizada por vegetação lenhosa e herbácea em variadas proporções (BARBOSA, 2005). A planície de inundação do Lago Grande de Curuai possui regime de inundação monomodal, anual, previsível, regular e de grande amplitude. A sua principal fonte de inundação é fluvial, onde o Rio Amazonas contribui com aproximadamente 77% de toda a água do sistema (BONNET et al., 2008). Entre maio e junho ocorre o máximo de inundação (época da cheia), e entre outubro e dezembro o menor nível (época da seca). A diferença na altura de inundação entre as duas épocas é de 5 a 7 metros, podendo variar anualmente até 2 m (BARBOSA, 2005).

## 3.2. Dados de sensoriamento remoto

Foram utilizadas seis cenas polarimétricas adquiridas pelo sensor a bordo do satélite Radarsat-2, que opera na banda C (5.6 cm), sob três diferentes ângulos de incidência (Tabela 3.1). As cenas foram obtidas entre 19 e 22 de junho e 20 de outubro e 10 de novembro de 2011, coincidindo com as épocas de cheia e seca da várzea, respectivamente. As imagens polarimétricas possuem 9 x 7.6 m (range x azimute) de resolução,com ângulos de incidência de 25° (SQ7), 33° (SQ14) e 45° (SQ27). As cenas Radarsat-2 foram fornecidas através do programa Science and Operational Applications Research (SOAR), coordenado pela Canadian Space Agency (CSA), projeto número 5052. Os dados e produtos Radarsat-2 são licenciados para uso pela MacDonald, Dettwiler e Associados, Ltd.

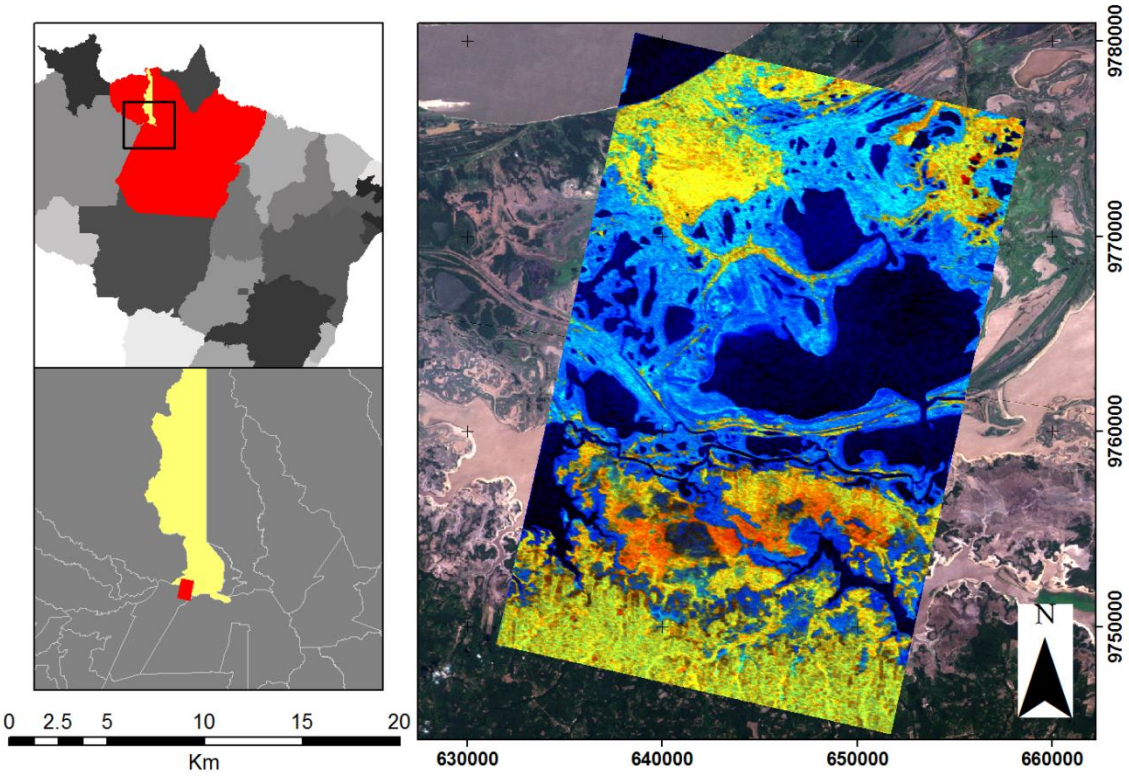


Figura 3.1 – Em destaque, a área de estudo no Lago Grande de Curuai - PA. Ao fundo, composição TM/Landsat 5 RGB321 do período da seca. Composição colorida SAR multitemporal (R: cena SQ7 da época da cheia; G: cena SQ7 da época da seca; B: razão entre imagens da seca e cheia). © MacDonald, Dettwiler e Associados, Ltd.

Tabela 3.1. – Parâmetros das cenas PolSAR Radarsat – 2 utilizadas.

| Cena | Data | Modo de Imageamento | Ângulo de Incidência (Graus) | Tamanho do pixel (Rng x Az - m) | Resolução do sistema (Rng x Az - m) | Swath (Km) |
|---|---|---|---|---|---|---|
| SQ7 | 19/jun/2011 | Standard Quad-Pol | 25 - 27 | 8 x 5.1 | 9 x 7.6 | 25 |
| SQ14 | 22/jun/2011 | | 33 - 35 | | | |
| SQ27 | 29/jun/2011 | | 45 - 47 | | | |
| SQ7 | 20/out/2011 | | 25 - 27 | | | |
| SQ14 | 27/out/2011 | | 33 - 35 | | | |
| SQ27 | 10/nov/2011 | | 45 - 47 | | | |

Um modelo de elevação digital gerado pela *Shuttle Topography Radar Mission* (SRTM) foi usado para a correção do efeito do terreno na geometria *range-*

*doppler* e na ortorretificação. O MDE SRTM possui 90 m de resolução espacial e aproximadamente 16 metros de precisão vertical e foi obtido no *website* do *Consortium for Spatial Information* (CGIAR - CSI), no endereço http://srtm.csi.cgiar.org/, em sua versão 4. Cenas Landsat5/TM e Landsat7/ETM$^{+}$do mesmo período de aquisição das imagens Radarsat-2 foram utilizadas para auxiliar na interpretação da cobertura da terra e na coleta de amostras de treinamento. As cenas Landsat5/TM foram obtidas no website do Instituto Nacional de Pesquisas Espaciais, no endereço http://www.dgi.inpe.br, nas coordenadas WRS-2 órbita 228 e pontos 061 e 062. As cenas Landsat7/ETM+ ortorretificadas foram obtidas através da *Global Land Cover Facility* (GLCF), em http://glcf.umd.edu/data/landsat/.

### 3.3. Metodologia de campo

Foram realizadas amostragens na floresta de várzea da área de interesse em destaque na Figura 3.2 que corresponde à cena PolSAR. O trabalho de campo ocorreu entre 18/10 e 29/10 de 2013, no período de seca da várzea.

Durante o trabalho de campo foram amostradas 17 parcelas de 25 x 25 m, cuja localização geral foi determinada em função da homogeneidade e tipo de vegetação, facilidade de acesso e distância entre as parcela se os barcos utilizados para locomoção e instalação em campo.

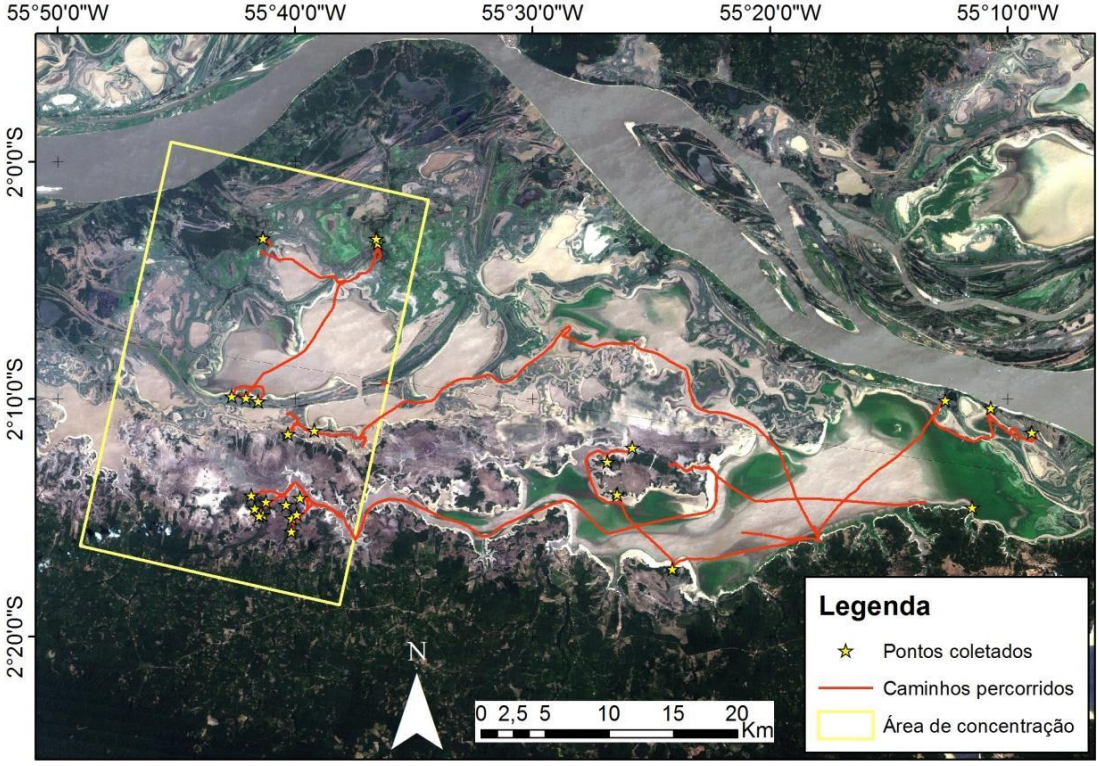


Figura 3.2 – Composição colorida RGB321 de cena Landsat-5/TM, da estação seca do ano de 2005. O polígono amarelo indica a área de estudo dessa pesquisa.

Foram amostrados os seguintes atributos da vegetação em campo:

- Diâmetro à altura do peito (DAP) (cm);
- Número de indivíduos;
- Altura total (metros);
- Altura de fuste (metros);
- Índice de área foliar (IAF);
- Altura da marca de máxima inundação nos troncos;
- Identificação taxonômica.

O DAP foi medido com o auxílio de fita diamétrica, a uma altura de 1,3 metros em relação ao nível do solo. Indivíduos com DAP entre 5 e 10 cm foram contabilizados mas não medidos, e indivíduos com DAP < 5 cm foram

ignorados. As alturas total e de fuste foram obtidas com um clinômetro. Em cada canto da parcela foi também medida a altura da marca d'água deixada pela última inundação, totalizando 4 medidas tomadas nos quatro cantos de cada parcela. O IAF foi mensurado com o uso do equipamento LAI-2200 (Li-Cor Inc.), através de oito medidas ao longo da parcela, em duas fileiras de 4 amostras orientadas a favor da direção do sol.

Após a aquisição dos dados, as seguintes variáveis derivadas foram calculadas:

- Área basal (m²/ha);
- Densidade de indivíduos (n° indivíduos/ha);
- Espessura da copa (diferença entre a altura total e a de fuste - metros);
- Altura de Lorey.

A altura de Lorey pode ser calculada pela razão entre o somatório do produto da altura de cada indivíduo pela sua área basal, dividido pela altura basal média de cada parcela (equação 3.1):

$$H_{lorey} = \frac{\sum Área\ basal * Altura}{Área\ Basal\ da\ parcela} \tag{3.1}$$

Para cada parcela, foi calculada a média de cada um dos atributos medidos em campo (com exceção da área basal e densidade de indivíduos) e derivados. Esses valores foram utilizados para a quantificação da relação entre as imagens PolSAR e os atributos de campo.

### 3.4. Processamento dos dados

Uma série de etapas de pré-processamento, análise dos dados, classificação e validação, modelagem empírica dos atributos biofísicos da vegetação e validação dos modelos foram realizadas no decorrer da pesquisa (Figura 3.3).

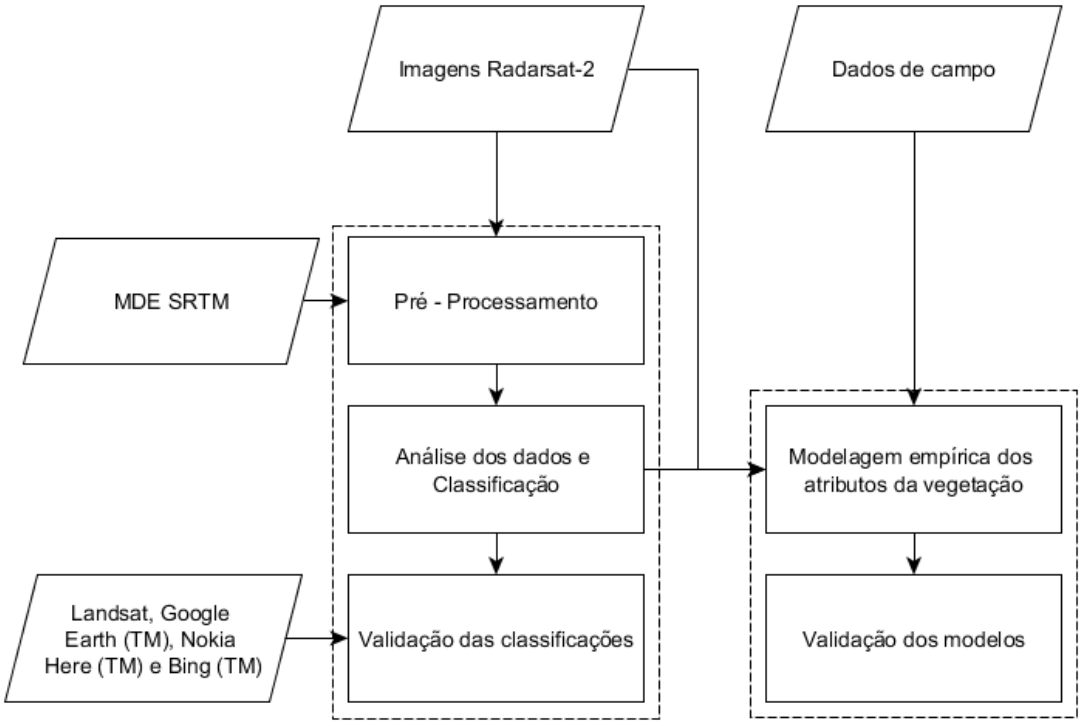


Figura 3.3 – Fluxograma geral do processamento dos dados da pesquisa.

Nessa etapa foi realizada a preparação dos dados PolSAR: (a) *multilooking* e cálculo da matriz C, (b) filtragem do efeito *speckle*, (c) cálculo das decomposições polarimétricas e pré-seleção das decomposições com maior potencial para classificação da vegetação, (d) transformação do nível digital para σ° (valores de retroespalhamento) e (e) correção de terreno Range-Doppler (Figura 3.4). A matriz T, necessária para o cálculo das decomposições polarimétricas, é calculada automaticamente a partir da matriz C pelo software *Polarimetric SAR Data Processing and Educational Tool* (PolSARPRO) v.4.2.0

A matriz C foi calculada usando o dado complexo original, através do software PolSARPRO v.4.2.0. O processamento *multilook* é passo obrigatório no cálculo da matriz C (LEE, POTTIER, 2009). Para tal foram utilizados 2x3 looks, para que os elementos de resolução da cena, de 8 x 5.1 m (range x azimute) resultassem em pixels de aproximadamente 15 x 15 m.

A matriz C foi filtrada usando o filtro polarimétrico *Refined Lee*, o qual preserva as bordas entre os objetos e ao mesmo tempo suaviza o efeito *speckle* em regiões homogêneas (LEE; POTTIER, 2009). Para escolher o tamanho da janela do filtro *Refined Lee*, foi realizado um teste onde o tamanho da janela varia de 3x3 até 11x11 com o objetivo de escolher o tamanho que apresenta o melhor custo-benefício entre (a) redução do efeito *speckle,* avaliado através do coeficiente de variação (CV) e (b) a preservação das bordas entre os objetos e sua textura, que foi escolhido através de análise visual de toda a imagem. Amostras da classe Floresta de Terra Firme, na cena SQ7 da época da cheia, na polarização HH, em s*lant range*, foram usadas para calcular o CV. Alvos de Floresta de Terra Firme foram escolhidos por serem considerados alvos homogêneos para a banda C (HENDERSON; LEWIS, 1998).

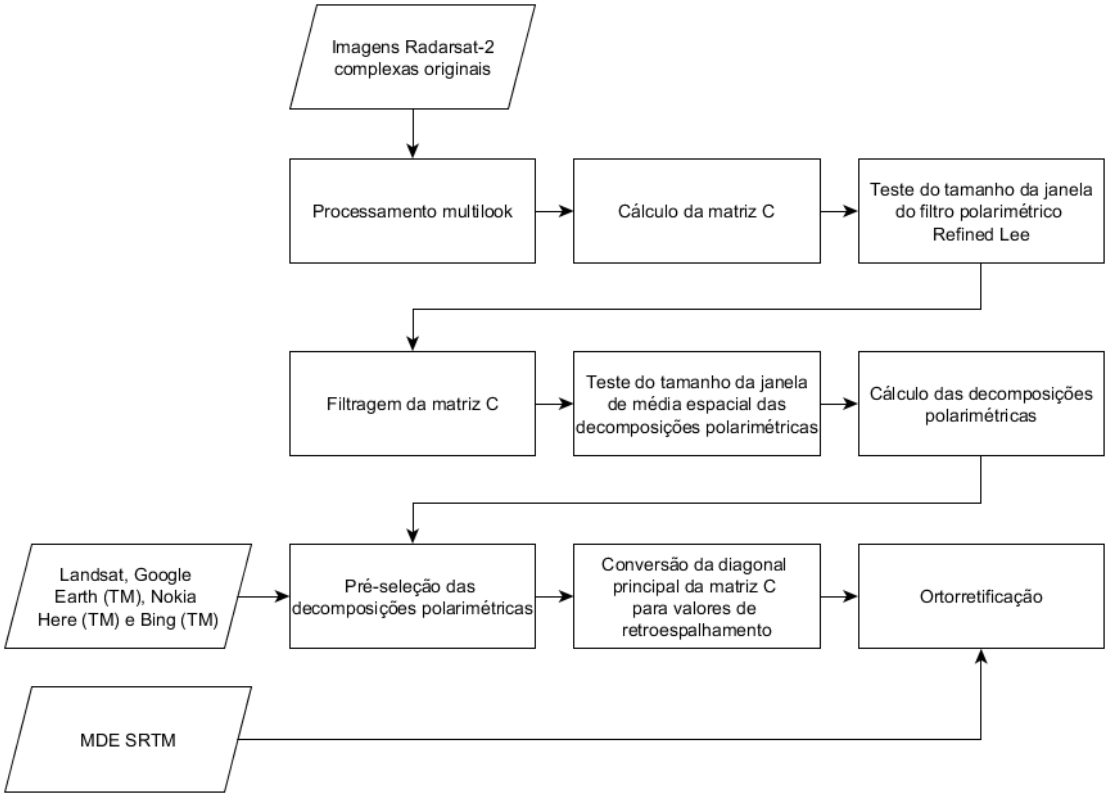


Figura 3.4 – Fluxograma das etapas da fase de pré-processamento dos dados.

Após essa etapa, calcularam-se as decomposições polarimétricas. Esse procedimento se deu através de uma janela de média espacial, e também foi realizado no software PolSARPRO v.4.2.0. De maneira semelhante à etapa anterior, o tamanho da janela da média espacial foi escolhido em função de (a) redução do CV e (b) preservação da textura e borda dos alvos da imagem. Foram usadas as mesmas amostras e ângulo de incidência do teste anterior, mas no teste foram utilizadas apenas as imagens geradas pela decomposição de Freeman – Durden, dado que essa decomposição é semelhante às decomposições de van Zyl e Yamaguchi, e também porque a decomposição de Freeman – Durden é uma das mais tradicionalmente usadas em trabalhos da literatura, permitindo a comparação dos resultados obtidos nessa pesquisa com outros trabalhos apropriados. Após a escolha do tamanho da janela das decomposições polarimétricas, foram calculadas as decomposições polarimétricas (tabela 3.2).

Como as decomposições polarimétricas geram produtos muito similares, estas foram submetidas a um processo de pré-seleção para uso na classificação da cobertura vegetal. O critério de pré-seleção foi escolher, dentre todas apresentadas anteriormente, aquelas com o maior potencial para *discriminar e mapear* as classes de cobertura de vegetação da várzea. Esse potencial foi avaliado por meio da análise visual de gráficos *boxplot*, gerados utilizando-se estatística descritiva não paramétrica (mediana e percentis) de amostras coletadas, para todas as classes, nas decomposições referentes ao ângulo de incidência SQ7, da época da cheia. A época da cheia foi escolhida por ser quando todos os tipos de vegetação encontram-se em máximo vigor vegetativo (dado que na época da seca, grande parte das macrófitas, tanto flutuantes quanto enraizadas, morrem ou não apresentam-se em máximo desenvolvimento). Como as imagens de todos os ângulos de incidência possuem alta correlação entre si (como pode ser observado na seção sobre a modelagem empírica dos dados PolSAR e também pelo desempenho similar com relação às classificações dos ângulos de incidência) optou-se por fazer a

pré-seleção das decomposições apenas para a imagem de menor ângulo, assumindo que o maior grau de penetração da REM nos alvos de vegetação aumentaria a diferenciação entre eles (HENDERSON; LEWIS, 1998).

Tabela 3.2: Atributos polarimétricos derivados do retroespalhamento e de decomposição de alvos.

| Decomposição de Alvos | Símbolo | Descrição |
|---|---|---|
| *Cloude-Pottier (LEE; POTTIER, 2009)* | | |
| Ângulo Alpha | $\alpha$ | Mecanismo de espalhamento dominante. |
| Entropia | $H$ | Número de mecanismos de espalhamento dominantes. |
| Anisotropia | $A$ | Mede a importância relativa do segundo e terceiro tipos de espalhadores. |
| *Freeman - Durden (FREEMAN; DURDEN, 1998)* | | |
| Volumétrico | $FD_V$ | Nuvem de dipolos cilíndricos, muito finos, aleatoriamente posicionados. |
| Double - Bounce | $FD_D$ | Par de superfícies ortogonais, não metálicas e com constantes dielétricas diferentes. |
| Superficial | $FD_S$ | Modelado como o espalhamento de Bragg. |
| *Touzi (Touzi, 2007)* | | |
| Magnitude do tipo de espalhamento | $\alpha_{S1;}$ $\alpha_{S2;}$ $\alpha_{S3;}$ $\alpha_{Sm;}$ | Ângulo da direção do vetor de espalhamento simétrico, em base triedral-diedral. |
| Fase do tipo de espalhamento | $\Phi_{\alpha S1}$, $\Phi_{\alpha S2}$, $\Phi_{\alpha S3}$, $\Phi_{\alpha Sm}$ | Diferença de fase entre espalhamentos em forma de triedro e diedro. |
| Helicidade | $\tau 1$; $\tau 2$; $\tau 3$; $\tau m$ | Natureza simétrica do espalhamento do alvo. Se $\tau = 0$, o alvo é completamente isotrópico. |
| Ângulo de Orientação | $\psi 1$; $\psi 2$; $\psi 3$; $\psi m$ | Ângulo de orientação do alvo. |
| *Yamaguchi (LEE; POTTIER, 2009)* | | |
| Volumétrico | $Y_V$ | Nuvem de dipolos cilíndricos, muito finos, aleatoriamente posicionados. |
| Double - Bounce | $Y_D$ | Par de superfícies ortogonais, não metálicas e com constantes dielétricas diferentes. |
| Superficial | YS | Modelado como o espalhamento de Bragg. |
| Helicidade | YH | Modelo de espalhamento em forma de hélice. |
| *Van Zyl (LEE; POTTIER, 2009)* | | |
| Volumétrico | $VZ_V$ | Proporção de espalhamento volumétrico simulado à partir de decomposição de autovalores/vetores; |
| Double – Bounce | $VZ_D$ | Espalhamento double-bounce simulado à partir de decomposição de autovalores/vetores; |
| Superficial | $VZ_S$ | Proporção de espalhamento superficial; |

Fonte: Adaptado de Sartori et al. (2011).

No final do teste, foi selecionada apenas uma das decomposições entre (a) van Zyl, Freeman-Durden e Yamaguchi e (b) Cloude-Pottier e Touzi, que foram separadas em dois grupos distintos pela similaridade de seus produtos.

Após a pré-seleção das decomposições polarimétricas foi realizada a etapa de conversão da diagonal principal da matriz C para valores de retroespalhamento. Foram utilizados os parâmetros dos metadados das cenas, com erro radiométrico esperado de até 1 dB através do software PolSARPRO v.4.2.0.

Ao término do pré-processamento, foi realizada a correção de terreno Range-Doppler com o objetivo de (a) transformar as imagens de *slant* para *ground range* e (b) geocodificá-las (ortorretificação e georreferenciamento). O MDE SRTM foi utilizado nessa etapa, realizada no software Next ESA SAR Toolbox (NEST), v. 5.0.16. Esse procedimento foi aplicado a todas as imagens das diagonais da matriz C e T e a todas as decomposições pré-selecionadas.

## 3.5. Análise dos dados e classificação

As etapas da análise dos dados e das classificações estão resumidas no fluxograma da figura 3.5.

### 3.5.1. Seleção das amostras de treinamento e geração dos gráficos boxplot

As amostras de treinamento coletadas serviram para duas finalidades: (a) caracterização das respostas dos alvos, e (b) classificação das imagens utilizando o algoritmo de árvore de decisão J.48. Para ambas as etapas foram utilizadas os mesmos polígonos, que foram desenhados no software ArcGIS 10.0. Uma média de 25 polígonos de treinamento foi obtida para cada classe, cada um deles contendo de 250 a 300 pixels.

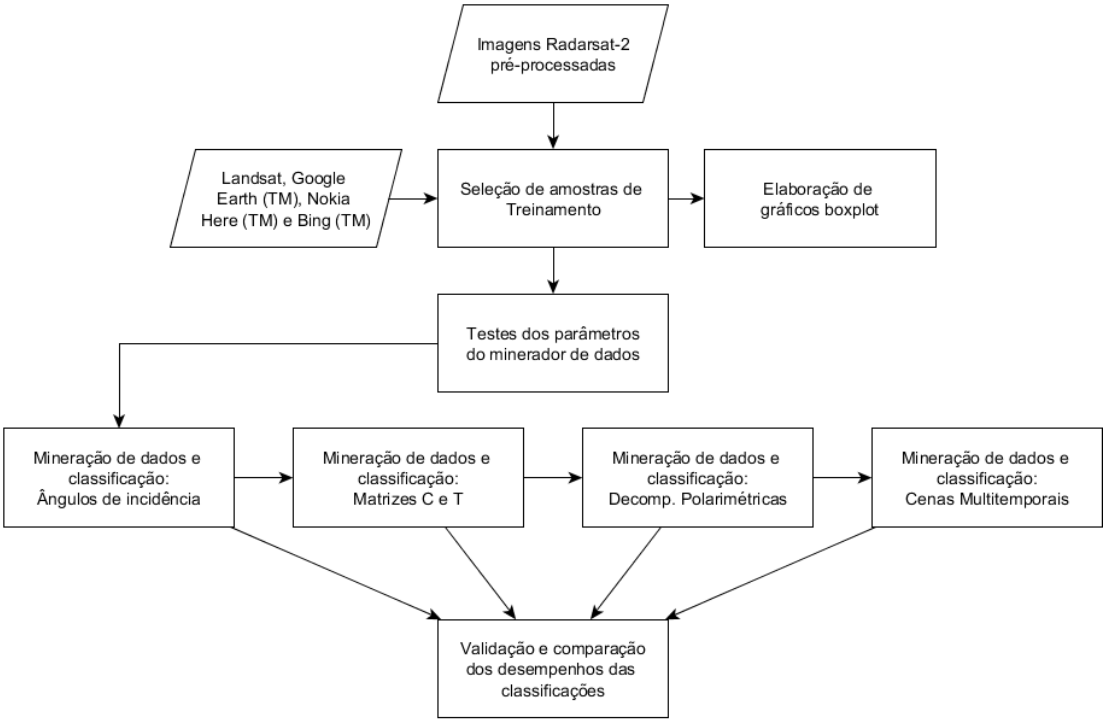


Figura 3.5 – Fluxograma das etapas da fase de análise dos dados e classificação.

Para a caracterização das respostas dos alvos de vegetação foram utilizados os valores dos pixels contidos dentro de cada polígono, extraídos através do software ENVI 4.5, e posteriormente foram calculadas suas estatísticas descritivas não paramétricas no software R.

A construção dos gráficos propostos, como em Silva et al. (2010) e Furtado et al. (2013), tem como objetivo visualizar a variação das respostas de cada classe em função: (a) dos ângulos de incidência, (b) do tipo de matriz utilizada (C ou T), (c) das decomposições polarimétricas e (d) da época do ano (seca ou cheia).

Para a classificação das imagens, os polígonos foram incorporados como objetos no eCognition 8.0.Os atributos de classes foram calculados (medianas e atributos texturais) e exportados, em formato CSV, para a geração da árvore de decisão através do software Weka 3.6.10.

### 3.5.2. Teste dos parâmetros do minerador de dados

Com o objetivo de gerar árvores de decisão com o máximo de parcimônia, nessa etapa foram configurados os parâmetros ótimos de poda (*pruning*) das árvores de decisão geradas.

No software Weka 3.6.10, são dois os principais parâmetros que configuram o tamanho das árvores de decisão: (a) número mínimo de objetos (*minimum number of objects*) e (b) fator de confiança (*confidence factor*). O parâmetro número mínimo de objetos une nós da mesma classe que possuam um número menor de objetos do que o indicado por esse parâmetro. Se a união de um nó, influenciado por esse parâmetro, aumentar o erro da classificação final, esse nó continua sendo unido e a árvore fica mais inexata.

O parâmetro fator de confiança, por sua vez, estabelece um valor mínimo de diferença estatística entre os nós; ele une os nós que não atenderem ao critério de diferença pré-estabelecido. Se a união de um nó devido ao fator de confiança aumentar o erro da classificação final, esse nó não é unido e o erro da árvore de decisão continua o mesmo.

Os testes foram realizados de duas formas: (a) alterando o valor do número mínimo de objetos, de 2 (*default* do programa) até 30, em intervalos de 5 em 5, mantendo o fator de confiança inicial (0.25) e (b) alterando o valor do fator de confiança de 0.1 até 1, em intervalos de 0.1, mantendo o número mínimo inicial de objetos (2). Para esse teste, foram utilizadas as imagens da diagonal principal da matriz C (HH, HV e VV) do menor ângulo de incidência, em amplitude linear, para todas as classes de uso e cobertura do solo, na época da cheia. Julgou-se representativo, de todas as imagens, a diagonal da matriz C do menor ângulo por critérios similares aos da pré-seleção das decomposições polarimétricas – grande correlação e similaridade entre todas as cenas. Assim, foi feita a suposição que as imagens do menor ângulo de incidência causariam o máximo de diferenciação nas classes de uso e

cobertura do solo devido à maior penetração da REM nos dosséis dos tipos de vegetação.

A variação do erro geral da árvore de decisão foi obtida através dos logs de cada mineração executada. Foram então selecionados os parâmetros que apresentaram a menor árvore de decisão (em termos de números de nós) sem prejuízo da exatidão da classificação.

### 3.5.3. Classificação e validação

Nessa etapa foram realizadas as classificações e as suas respectivas validações utilizando o software eCognition 8.7, o algoritmo de classificação por árvores de decisão J4.8, implementado no software Weka 3.6.10, e o software ArcGIS 10 (Figura 3.6). A validação das classificações e a avaliação de seus desempenhos foram realizadas através dos índices Kappa (CONGALTON, 1991) e *Quantity Disagreement (*QD*)* e *Allocation Disagreement (*AD*)* (PONTIUS; MILLONES, 2011).

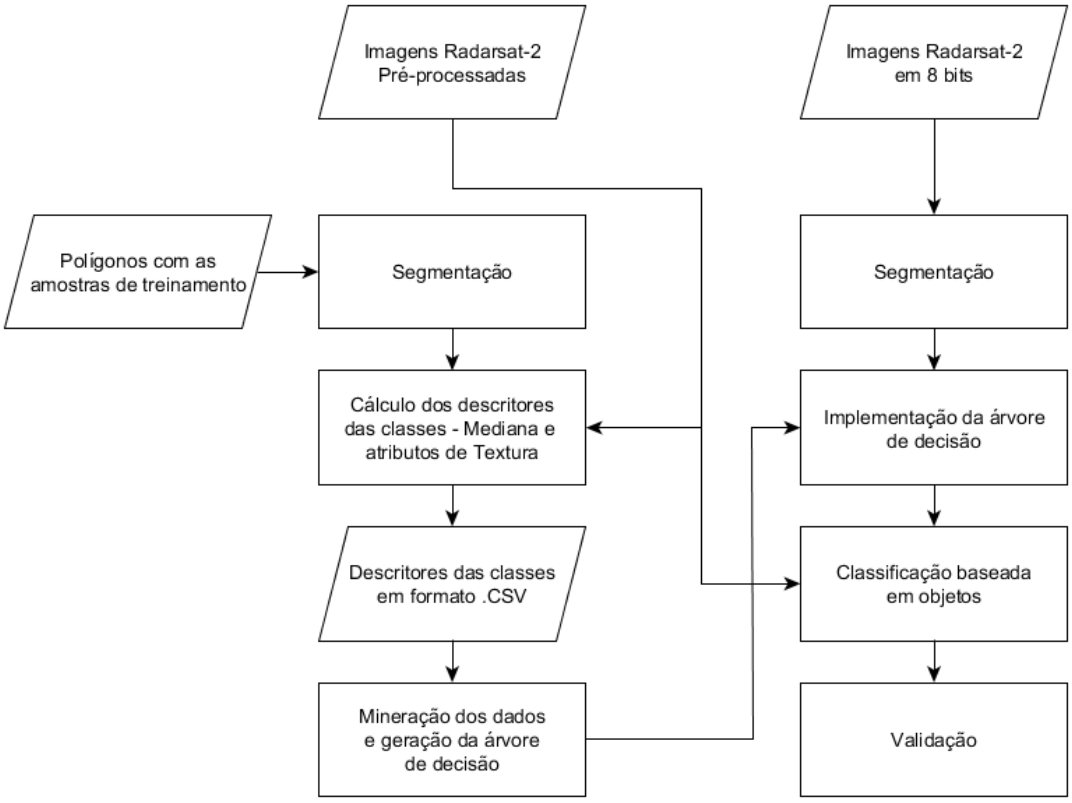


Figura 3.6 – Fluxograma das etapas do subitem de classificação dos dados e validação.

As classes de uso e cobertura do solo propostas (Tabela 3.3) foram divididas em dois grupos distintos. As cinco primeiras classes (Água, Vegetação Arbustiva, Floresta Inundável, Macrófitas Emersas e Macrófitas Flutuantes) foram agrupadas como “classes de várzea”. Quando há a inclusão de Floresta de Terra Firme e Solo Exposto na classificação, o grupo passa a se chamar “classes gerais”. Essas duas últimas classes foram incluídas com o propósito de comparar o resultado de suas classificações com as classes de várzea e, quando possível, com a literatura.

Tabela 3.3 – Classes de cobertura e de vegetação da várzea do Lago Grande de Curuai – PA. Em fotointerpretação, polarização HH do ângulo de incidência SQ7 - © MacDonald, Dettwiler e Associados, Ltd.

| Nome | Descrição | Fotointerpretação | Fotografia |
|---|---|---|---|
| Água | Lâmina d'água sem cobertura vegetal | 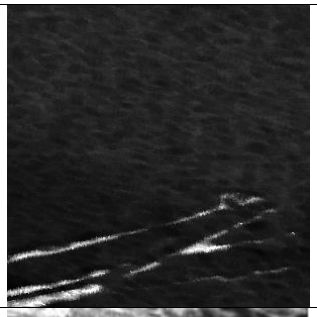 | |
| Vegetação Arbustiva | Indivíduos lenhosos com altura reduzida, organizados em formações fechadas alternando-se com áreas abertas cobertas por gramíneas, sujeitos a inundável sazonal. | 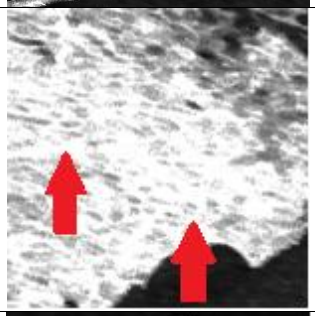 | |
| Floresta Inundável | Floresta sujeita a inundação, com variados graus de densidade de indivíduos, localizada ao longo de diques e nas regiões com maiores elevações da várzea. | 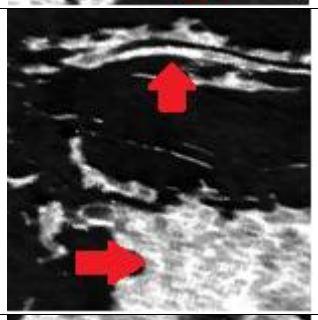 | 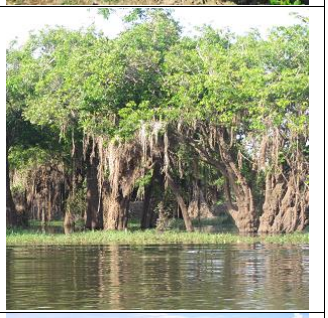 |
| Macrófitas Emersas | Herbáceas anuais ou perenes, enraizadas, sujeitas aos maiores períodos de inundação da várzea; | 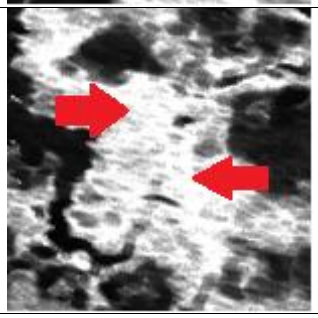 | 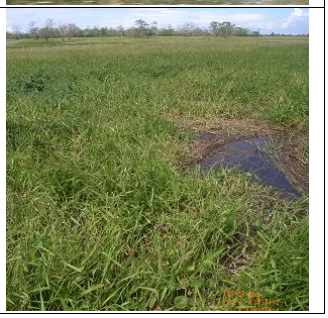 |

Tabela 3.3 (cont.) – Classes de cobertura e de vegetação da várzea do Lago Grande de Curuai – PA. Em fotointerpretação, polarização HH do ângulo de incidência SQ7 - © MacDonald, Dettwiler e Associados, Ltd.

| | | | |
|---|---|---|---|
| Macrófitas Flutuantes | Herbáceas não enraizadas, agrupadas em banco de espécies flutuantes em corpos d'água, com menor densidade de indivíduos quando comparada com as Macrófitas Emersas. | 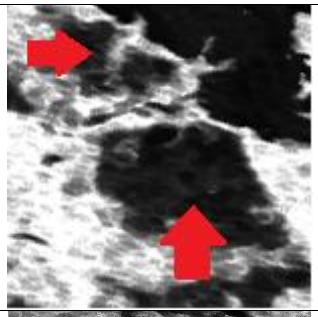 | |
| Floresta de Terra Firme | Vegetação lenhosa bem desenvolvida, localizadas em regiões de terra firme, não sujeitas a inundação. | 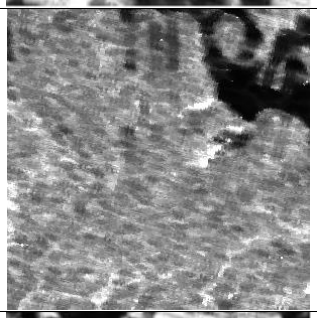 | |
| Solo Exposto | Solo exposto ou com herbáceas pouco densas, localizados em regiões de terra firme não sujeitas a inundação. | 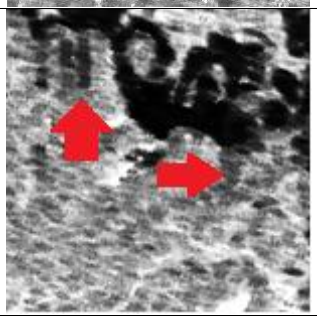 | |

Primeiramente, os polígonos com as amostras de treinamento foram segmentados no software eCognition 8.7, e usados para calcular as medianas e os atributos de textura das imagens a serem classificadas. Esses atributos foram exportados em formato CSV e, usando algoritmo J.48, foram calculadas as árvores de decisão podadas com os parâmetros testados na etapa anterior. A mediana foi selecionada pelo seu caráter não paramétrico, tendo em vista o caráter não paramétrico do algoritmo de mineração de dados J.4.8. Os atributos de textura utilizados, (descritos em Haralick et al., 1973) e implementados no eCognition 8.7foram:

- *GLCM Homogeneity* – um objeto é considerado homogêneo quando as combinações dos níveis de cinza dentro dele concentram-se ao longo da diagonal principal da matriz de co-ocorrência de níveis de cinza (Gray Level Co-ocurrence Matrix, GLCM). O atributo de textura decresce exponencialmente na medida em que as combinações dos objetos afastam-se da diagonal principal;
- *GLCM Dissimilarity* – um objeto possui textura dissimilar quando as suas combinações de níveis de cinza concentram-se fora da diagonal principal da matriz de co-ocorrência. Essa textura é contrária à GLCM Homogeneity, mas ao invés de decrescer exponencialmente, esse descritor é linear;
- *GLCM Entropy* – uma textura que apresenta alta entropia possui combinações de níveis de cinza distribuídas de maneira uniforme ao longo de toda a matriz de co-ocorrência. Sempre que há concentração ao longo ou afastada da diagonal principal, há baixa entropia. Esse descritor é calculado utilizando-se de uma escala logarítmica;
- *GLCM Correlation* – esse descritor mede a correlação linear entre um pixel e seus vizinhos.

Após a geração da árvore de decisão, realizou-se a classificação propriamente dita. Para cada classificação, uma ou mais imagens foram segmentadas utilizando o algoritmo de segmentação *Multiresolution Segmentation*, do eCognition 8.0 (BENZ et al., 2004). Para um melhor controle dos parâmetros de segmentação (escala - *scale*, forma – *shape,* e compacidade - *compactness*) a resolução radiométrica das cenas PolSAR foi convertida de 16 bits para 8 bits utilizando o SPRING 5.2.5. Os limiares mínimos e máximos do histograma dos níveis digitais foram selecionados de maneira que (a) causassem o mínimo de saturação do nível digital dos pixels em relação à imagem original e (b) resultassem em contraste linear satisfatório (tabela 3.4). A conversão para 8 bits foi feita multiplicando os limiares mínimo e máximo por 255, reamostrando assim todos os outros valores. Os parâmetros de escala, forma e compacidade foram escolhidos heuristicamente.

Tabela 3.4 – Limitares para a conversão da radiometria das cenas SAR de 16 para 8 bits. VZ: decomposição de van Zyl; CP: decomposição de Cloude Pottier.

| Cena (ângulo – período - imagem) | Mínimo | Máximo |
|---|---|---|
| SQ7 Cheia HH | 0 | 0.491 |
| SQ7 Cheia HV | 0 | 0.100 |
| SQ7 Cheia VV | 0 | 0.379 |
| SQ14 Cheia HH | 0 | 0.316 |
| SQ14 Cheia HV | 0 | 0.086 |
| SQ14 Cheia VV | 0 | 0.301 |
| SQ27 Cheia HH | 0 | 0.275 |
| SQ27 Cheia HV | 0 | 0.065 |
| SQ27 Cheia VV | 0 | 0.281 |
| SQ27 Seca HH | 0 | 0.231 |
| SQ27 Seca HV | 0 | 0.058 |
| SQ27 Seca VV | 0 | 0.228 |
| SQ27 Cheia CP - Alpha | 25.133 | 51.646 |
| SQ27 Cheia CP - Anisotropia | 0.172 | 0.707 |
| SQ27 Cheia CP - Entropia | 0.462 | 0.904 |
| SQ27 VZ Double - Bounce | 0 | 0.149 |
| SQ27 VZ - Superficial | 0 | 0.238 |
| SQ27 VZ - Volumétrico | 0 | 0.098 |

Terminada a etapa de segmentação, a árvore de decisão foi implementada manualmente no software eCognition 8.7 e a classificação foi realizada segundo os parâmetros dessa árvore de decisão. As imagens 8 bits não foram utilizadas nessa etapa, apenas as imagens originais. Cada classificação foi então exportada como formato vetorial (*shapefile*) para sua validação utilizando o software ArcGIS 10.

Para validar cada classificação, foram utilizados 320 pontos (para as classes de várzea) e 388 pontos (para as classes gerais). Esses pontos foram gerados através de (a) dados de GPS e fotográficos de campos anteriores (ARNESEN, 2013) e (b) através de fotointerpretação de imagens Google Earth ™, Bing ™ e

Nokia HERE ™ de alta resolução e cenas Landsat 5/TM e 7/ETM+, da mesma época do ano das cenas Radarsat-2.

Os desempenhos das classificações foram comparados entre si utilizando-se os três índices calculados anteriormente. A primeira classificação utilizou apenas as imagens da diagonal principal da matriz C (HH, HV e VV), para os três ângulos de incidência (SQ7, SQ14 e SQ27), utilizando-se atributos de textura e de amplitude. Essa classificação teve o objetivo de determinar o ângulo de incidência de maior potencial para o mapeamento das classes de vegetação de várzea e o tipo de atributo (mediana da amplitude, em escala linear e/ou textura dos objetos). O ângulo com o melhor desempenho na classificação, medido pelos índices indicados anteriormente, foi então utilizado em todas as etapas de classificação subsequentes.

Em seguida, foi comparado o desempenho das imagens da diagonal da matriz C com as decomposições polarimétricas escolhidas na etapa de pré-seleção das decomposições, para determinar se houve ganho precisão do mapeamento com a utilização de decomposições polarimétricas.

Por último, o desempenho das classificações prévias, monotemporais, foi comparado com o desempenho de uma classificação multitemporal, com o objetivo de verificar o ganho de precisão na classificação com o uso de mais de uma cena de épocas diferentes.

Todas essas classificações, mapeamentos e comparações foram realizados tanto para as classes da várzea como também para as classes gerais. Apenas quando devidamente especificado o contrário, as cenas foram classificadas em valores de amplitude linear.

No escopo da presente pesquisa, não foi testado se diferentes decomposições polarimétricas, calculadas para diferentes ângulos de incidência, possuem diferenças de desempenho na classificação. Da mesma forma, para a classificação multitemporal, não foi avaliada se diferentes ângulos de incidência e/ou decomposições polarimétricas de variadas épocas do ano possuem

diferentes desempenhos na classificação. Tais testes serão realizados em pesquisas futuras.

### 3.5.4. Modelagem dos atributos biofísicos da vegetação de várzea

Para cada parcela amostrada em campo foram gerados e editados manualmente polígonos ao seu redor, de maneira que apresentem uma média de 50 pixels. As imagens PolSAR passam a ser as variáveis independentes e os atributos de campo as variáveis dependentes. O fluxograma da figura 3.7 resume os passos da modelagem.

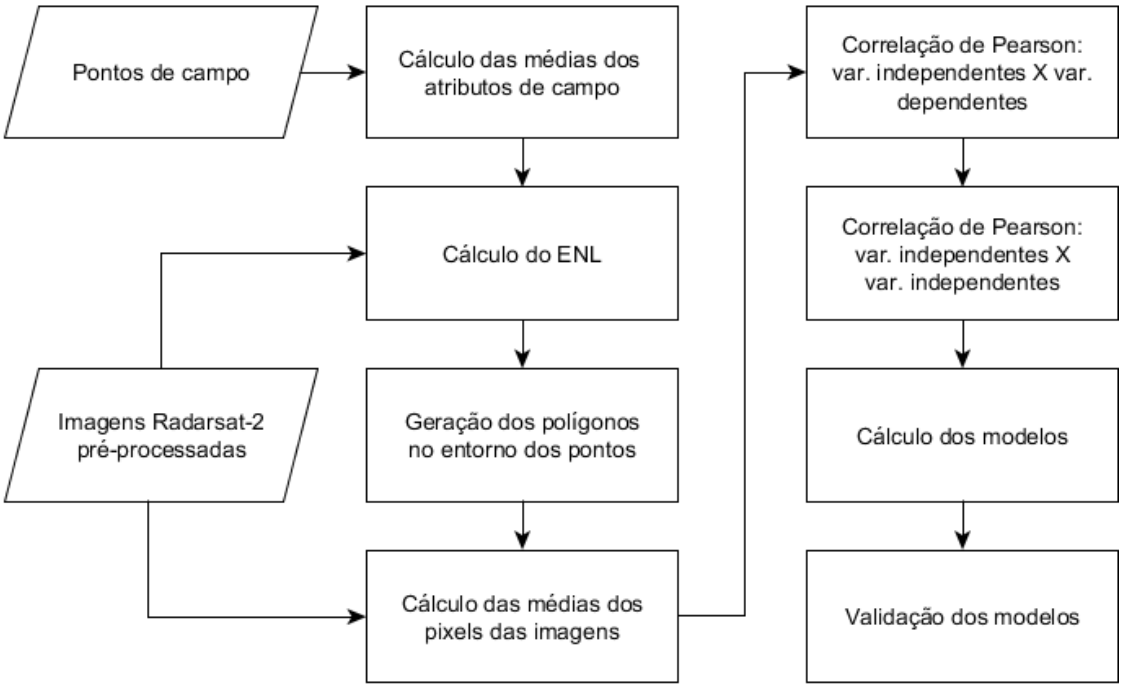


Figura 3.7 – Fluxograma das etapas da fase de modelagem dos atributos biofísicos da vegetação

Como visto em Costa et al. (2002), Moreau ; Le Toan (2003) e Carreiras et al. (2012), o *speckle* presente nas cenas de radar é um problema para a estimativa da correlação do retroespalhamento do radar com os parâmetros biofísicos medidos em campo. Os polígonos editados manualmente devem conter um número mínimo de pixels com base no número efetivo de *looks*

(*Effective Number of Louis* – ENL), para que o valor de retroespalhamento seja representativo.

Por isso, estimou-se o ENL com base em Laur et al. (1996), através de polígonos traçados em regiões homogêneas conforme a relação (equação 3.2):

$$ENL = \frac{1}{CV^2} \tag{3.2}$$

Onde CV é o coeficiente de variação, definido como (equação 3.3):

$$CV = \frac{\sigma}{\mu} \tag{3.3}$$

Onde σ é o desvio padrão dos valores medidos no polígono e μ é sua média.

O número mínimo de pixels amostrais foi calculado segundo Laur et al. (1996), para que o intervalo de confiança das amostras seja, com 95% de confiança, de +/- 2 dB. Para calcular o ENL foram utilizando cerca de 1500 pixels de regiões de água (região homogênea).

Posteriormente, foi calculada a média dos pixels das imagens utilizando os polígonos desenhados ao redor dos pontos das parcelas de campo. As imagens utilizadas foram as mesmas da etapa da classificação. Cada ponto, no final dessa etapa, possui atrelado a ele um valor de média de retroespalhamento/atributo polarimétrico para cada imagem e um valor de média para cada atributo biofísico da vegetação.

Em seguida foi calculada a correlação de Pearson entre as médias das variáveis independentes e a média das variáveis dependentes, para todos os 17 pontos. Para identificar o melhor ajuste linear entre as variáveis, calculou-se a correlação de Pearson (a) com ambas as médias em escalas lineares (linear – linear), (b) com a variável independente em dB (ou log10, para as imagens que não expressam retroespalhamento, como aquelas da decomposição de Cloude - Pottier) e as dependentes em escala linear (dB – linear), (c) com a

variável independente em escala linear e a variável dependentes em log10 (linear – log) e (d) com ambas as variáveis em dB e/ou Log10 (dB – log) (COSTA et al., 2002; NOVO et al., 2002). A transformação em log na base 10 foi escolhida para que ela tivesse a mesma base da transformação da amplitude em dB. Nessa etapa, foram descartadas todas as relações entre variáveis que apresentassem correlação de Pearson menor que 0,5. De modo a eliminar variáveis independentes correlacionadas entre si, calculou-se, em seguir, a correlação de Pearson entre as variáveis independentes selecionadas na etapa anterior. Foram então eliminadas as variáveis independentes com correlação superior a 0,3.

Em seguida foram ajustados os modelos para todas as variáveis independentes selecionadas segundo os critérios descritos no parágrafo anterior. Foram ajustados modelos lineares com apenas uma variável, um para cada variável independente. A validação dos modelos foi feita através de validação cruzada (*jackknife*), como em Hebron e Gongo (1983): o modelo foi ajustado utilizando n-1 pontos e para o ponto restante foi calculado o erro; esse procedimento foi repetido até que o erro para todos os pontos fossem calculados. Os modelos foram comparados entre si através dos seguintes parâmetros: (a) $R^2$, (b) erro quadrático médio (RMSE), (c) distribuição dos pontos ao longo da curva calculada, (d) aleatoriedade dos resíduos e (e) normalidade dos resíduos.

No escopo da presente pesquisa, foram utilizados modelos lineares com apenas uma variável independente. Para pesquisas futuras, o desempenho de modelos não-lineares e multivariados serão avaliados.

# 4. Resultados e discussões

Nessa seção serão apresentados os resultados da amostragem e geração dos gráficos boxplot, a pré-seleção dos dados polarimétricos, as classificações das imagens polarimétricas e a modelagem empírica dos atributos biofísicos da vegetação. Os resultados das etapas (a) teste do tamanho do filtro *speckle;* (b) teste da janela de média espacial das decomposições polarimétricas, (c) parametrização do minerador de dados e (d) validação dos modelos empíricos encontram-se respectivamente nos apêndices A, B, C e D. As matrizes de confusão das classificações serão dispostas no apêndice E.

## 4.1. Seleção das amostras de treinamento e geração de gráficos boxplot

As classes com menor área nas cenas, como Solo Exposto e Macrófitas Flutuantes tiveram o menor número de amostras – 16 e 20 objetos respectivamente (Tabela 4.1). Todas as outras classes apresentam número semelhante de amostras (de 24 a 32 objetos). A distribuição das amostras na imagem pode ser observada nas Figuras 4.1 e 4.2. Para a coleta de amostras das classes de várzea, foi utilizada uma máscara excluindo a região de terra firme, delimitada através de fotointerpretação.

Tabela 4.1 – Número de amostras por classe de uso e cobertura do solo.

| Classe | Número de amostras |
|---|---|
| Água | 32 |
| Arbustos | 27 |
| Campos de Várzea | 29 |
| Floresta Inundável | 28 |
| Floresta de Terra Firme | 30 |
| Macrófitas Emersas | 24 |
| Macrófitas Flutuantes | 20 |
| Solo Exposto | 16 |

Campos de Várzea é uma classe transitória criada para a classificação multitemporal. Essa classe é composta pelo mesmo tipo de vegetação herbácea que a classe Macrófitas Emersas, mas a sua assinatura espectral multitemporal é diferente. A classe Macrófita Emersa, em geral, apresenta alto retroespalhamento na cheia, devido ao mecanismo de espalhamento *double-bounce* entre a planta e a lâmina d'água, e baixo na época da seca, pela dinâmica fenológica dessas plantas, que apresentam elevada mortandade na seca. Por sua vez, a classe Campos de Várzea possui um padrão de resposta invertido: na cheia, apresentam-se totalmente cobertos por água, possuindo assim baixo retroespalhamento; mas, na seca, com a redução do nível da água, há o afloramento dessas regiões, nas quais podem crescer algumas espécies de plantas herbáceas, aumentando o seu retroespalhamento.

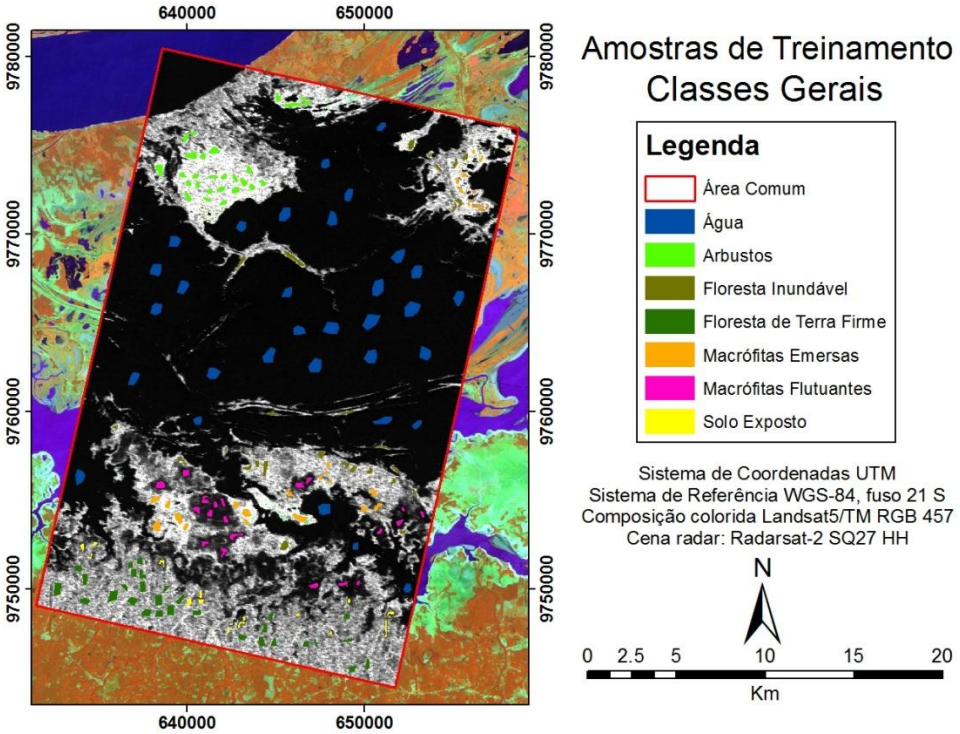


Figura 4.1 – Distribuição das amostras das classes gerais na área de estudo (destaque em vermelho). Dados Radarsat-2 © MacDonald, Dettwiler e Associados, Ltd.

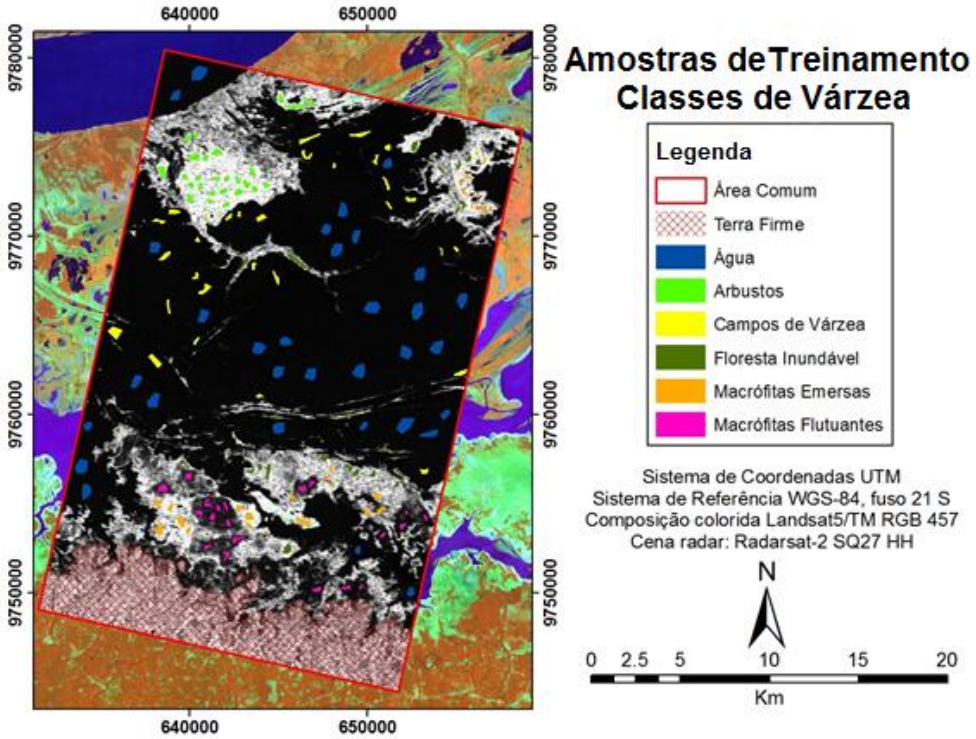


Figura 4.2 – Distribuição das amostras das classes de várzea na área de estudo (destaque em vermelho). A máscara da região de terra firme encontra-se na região hachurada, em vermelho. Dados Radarsat-2 © MacDonald, Dettwiler e Associados, Ltd.

## 4.2. Pré-seleções dos dados polarimétricos

O primeiro grupo de imagens analisadas é o grupo das decomposições de Cloude – Pottier (CP) e Touzi. O ângulo α (alpha) das duas decomposições é semelhante (Figura 4.3), mas a decomposição de Touzi o detalha ainda mais em outras três componentes, como se pode perceber na figura 4.4.

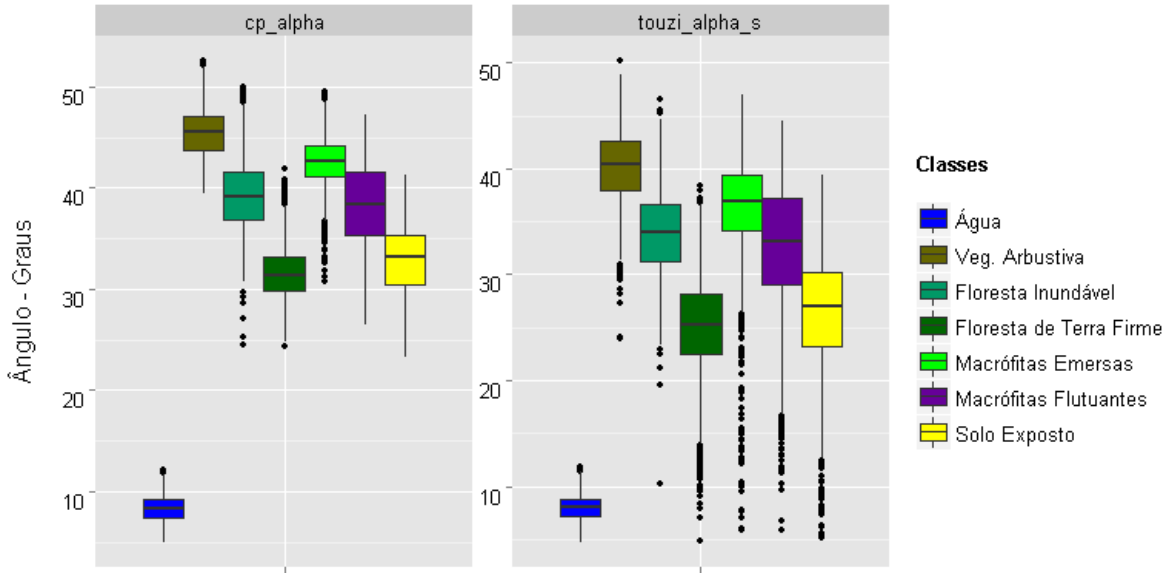


Figura 4.3 – Ângulos alpha da decomposição de Cloude – Pottier (cp_alpha) e ângulo alpha médio da decomposição de Touzi (touzi_alpha_s), para todas as classes de uso e cobertura da várzea do Lago Grande de Curuai, PA.

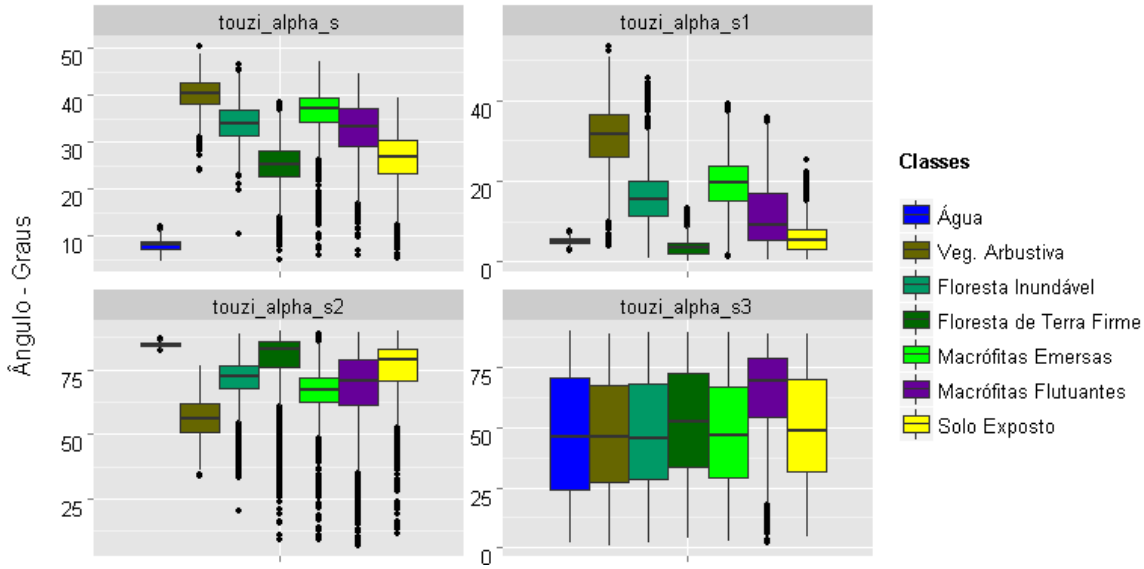


Figura 4.4 – Ângulo alpha médio da decomposição de Touzi para cada um dos autovetores da matriz C (touzi_alpha_s, _s1, _s2 e _s3 respectivamente), para todas as classes de uso e cobertura da várzea do Lago Grande de Curuai, PA.

Apesar do ângulo *α* da decomposição de Touzi apresentar potencial para gerar uma boa classificação da vegetação da várzea do Lago Grande de Curuai, todos os seus outros produtos apresentaram desempenhos questionáveis (figura 4.5 a 4.7), apresentando grande sobreposição entre as respostas de todas as classes e um grande número de outliers. Dessa forma, a decomposição de Cloude – Pottier foi preferida sobre a decomposição de Touzi.

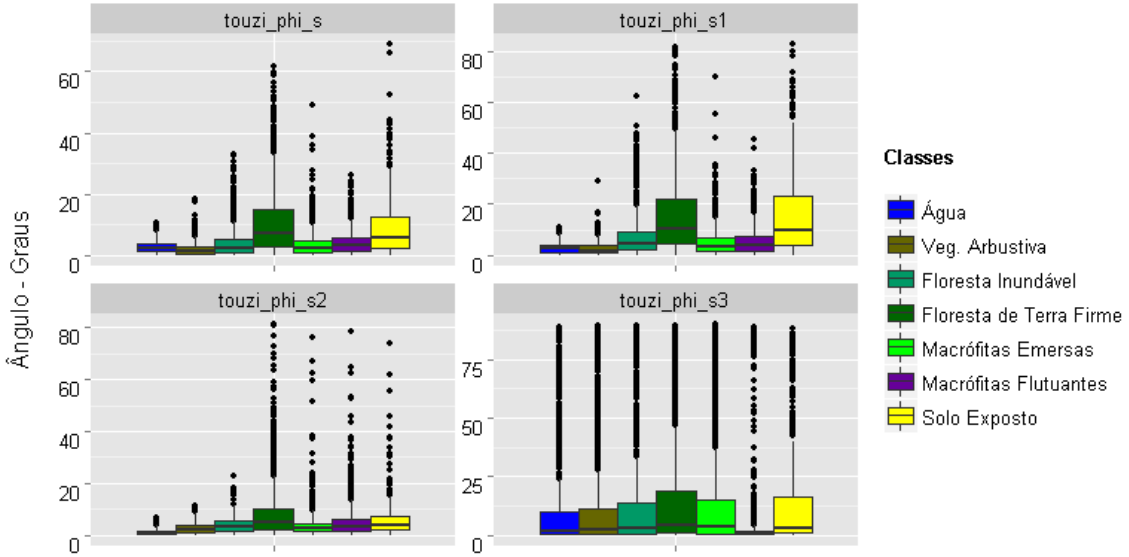


Figura 4.5 – Ângulo φ (phi) médio da decomposição de Touzi e para cada um dos autovetores da matriz C (touzi_phi_s, _s1, _s2 e _s3 respectivamente) para todas as classes de uso e cobertura da várzea do Lago Grande de Curuai, PA.

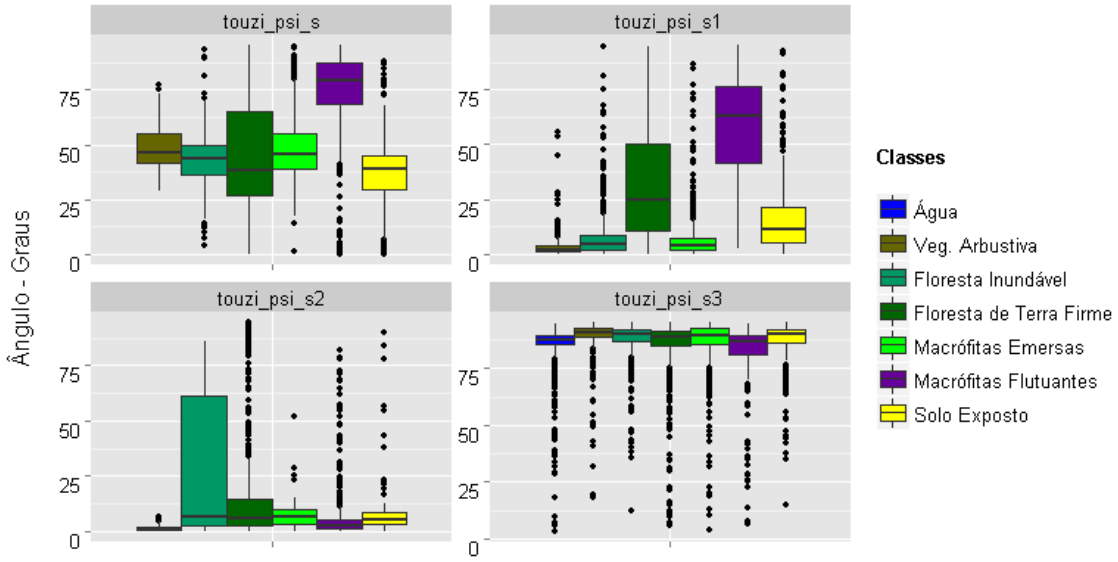


Figura 4.6 – Ângulo ψ (psi) médio da decomposição de Touzi e para cada um dos autovetores da matriz C (touzi_psi_s, _s1, _s2 e _s3 respectivamente) para todas as classes de uso e cobertura da várzea do Lago Grande de Curuai, PA.

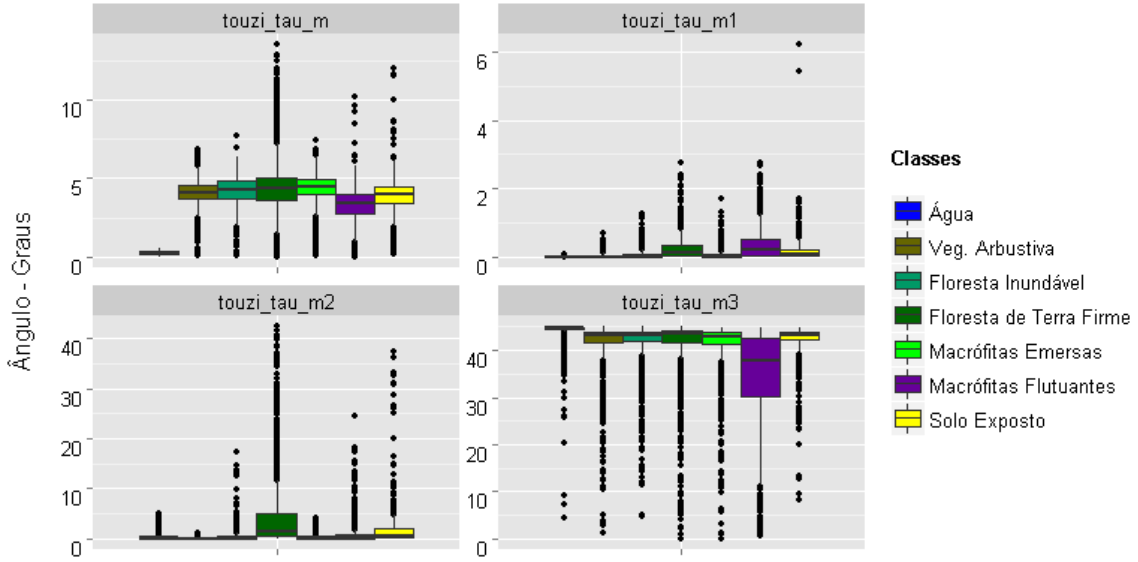


Figura 4.7 – Ângulo τ (tau) médio da decomposição de Touzi e para cada um dos autovetores da matriz C (touzi_tau_s, _s1, _s2 e _s3 respectivamente) para todas as classes de uso e cobertura da várzea do Lago Grande de Curuai, PA.

O segundo grupo de imagens análisadas é aquele referente às decomposições de Freeman – Durden (FD), van Zyl (VZ) e Yamaguchi (Yama). Percebe-se que todas as suas componentes apresentaram desempenhos bastante similares (figura 4.8 a 4.10).

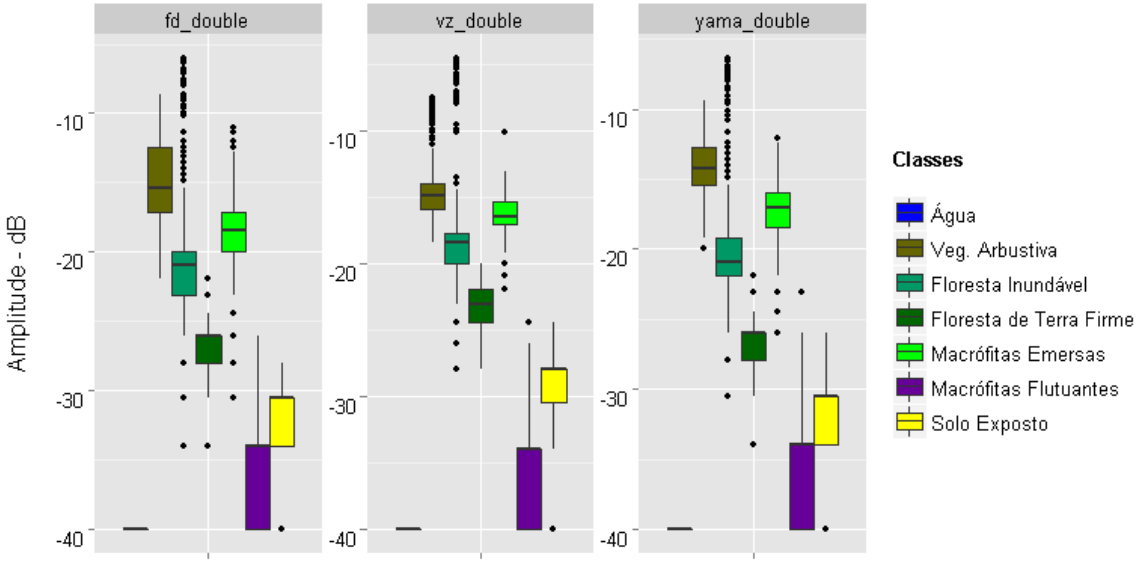


Figura 4.8 – Resposta, em dB, da camada de espalhamento double bounce das decomposições de Freeman – Durden (fd_double), van Zyl (vz_double) e Yamaguchi (yama_double) para todas as classes de uso e cobertura da várzea do Lago Grande de Curuai, PA.

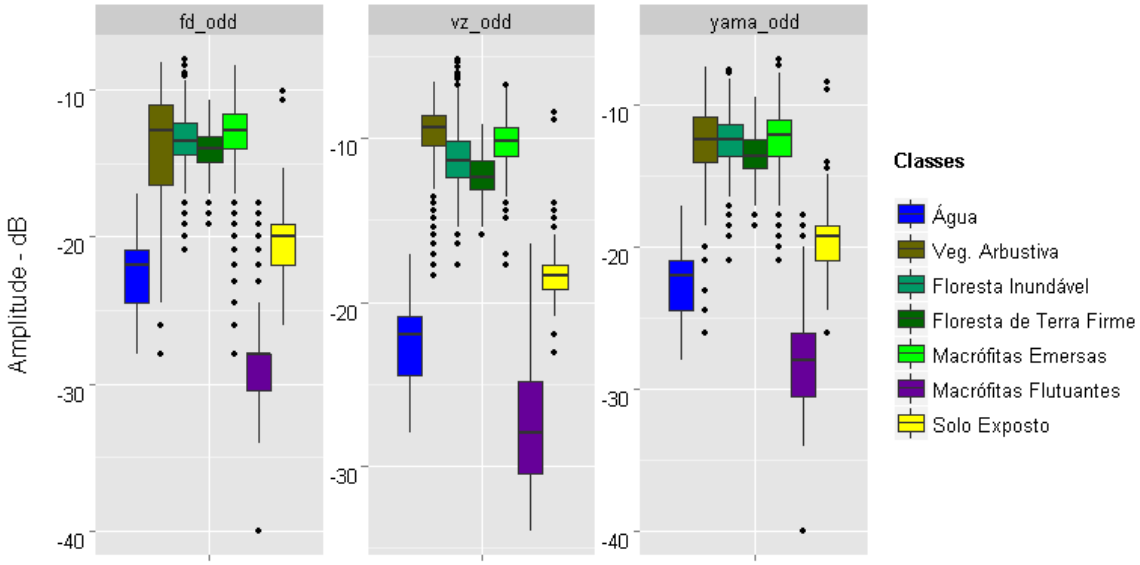


Figura 4.9 – Resposta, em dB, da camada de espalhamento superficial (odd scattering) das decomposições de Freeman – Durden (fd_odd), van Zyl (vz_odd) e Yamaguchi (yama_odd) para todas as classes de uso e cobertura da várzea do Lago Grande de Curuai, PA.

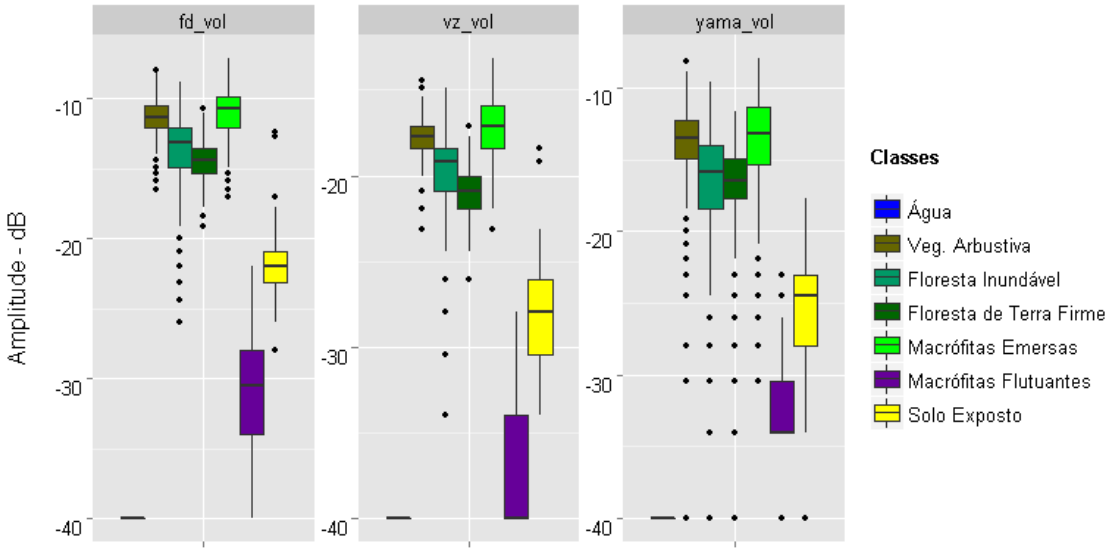


Figura 4.10 – Resposta, em dB, da camada de espalhamento volumétrico das decomposições de Freeman – Durden (fd_vol), van Zyl (vz_vol) e Yamaguchi (yama_vol) para todas as classes de uso e cobertura da várzea do Lago Grande de Curuai, PA.

Analisando os gráficos percebe-se que a decomposição de van Zyl apresentou o melhor potencial para separar os alvos nas camadas volumétricas (_vol) e superficial (_odd), mas não para a camada de espalhamento *double-bounce* (_db), a qual a decomposição de Yamaguchi se destaca. Porém, por possuir duas das três melhores componentes, a decomposição de van Zyl foi preferida sobre a de Freeman – Durden e Yamaguchi.

Dessa maneira, foram pré-selecionadas a decomposição de Cloude – Pottier (CP) e a de van Zyl (VZ), e, além da matriz C, somente as imagens dessas duas decomposições foram convertidas de *slant* para *ground range* e ortorretificadas.

## 4.3. Classificação dos dados

Os resultados das classificações dos dados serão primeiramente apresentados para toda a classificação e depois para as classes analisadas individualmente. As matrizes de confusão referentes a cada classificação podem ser observadas no apêndice. Os índices de validação utilizados para comparar os resultados são o índice Kappa (κ), o erro de alocação (AD) e o erro de quantidade (QD).

O parâmetro *Escala*, do segmentador presente no eCognition 8.7, foi definido para cada classificação, com o intuito de gerar a melhor segmentação possível para aquele grupo de imagens. Dessa maneira, diminui-se a introdução de erros na classificação oriundos de uma segmentação na qual não houvesse a melhor separação das classes de cobertura em objetos distintos. Os parâmetros *Forma* e *Compacidade* utilizados foram os valores padrão do algoritmo de segmentação, a dizer 0,1 e 0,5, para todas as classificações.

### 4.3.1. Classificação dos ângulos de incidência

A primeira comparação, entre os ângulos de incidência, foi realizada para as classes gerais, utilizando atributos de amplitude e textura referentes às imagens dos três ângulos de incidência (SQ7, SQ14 e SQ27). Essa análise teve como objetivo verificar qual a combinação de (a) atributos das imagens

(retroespalhamento e/ou textura) e (b) ângulo de incidência que promove a melhor classificação das classes gerais.

Percebe-se pela análise qualitativa dos gráficos boxplot (Figuras 4.11 a 4.17) que (a) a amplitude possui o maior potencial para discriminar as classes propostas e que (b) os atributos de textura apresentam elevada confusão entre todas as classes, com exceção do atributo *GLCM Entropy*.

Entre os ângulos de incidência, com relação ao descritor amplitude, aqueles que apresentam a melhor separabilidade entre as classes foram o SQ7, para as classes de terra firme (Floresta de Terra Firme e Solo Exposto) e o SQ27 para as classes de vegetação da várzea (Macrófitas Emersas, Vegetação Arbustiva e Floresta Inundável).

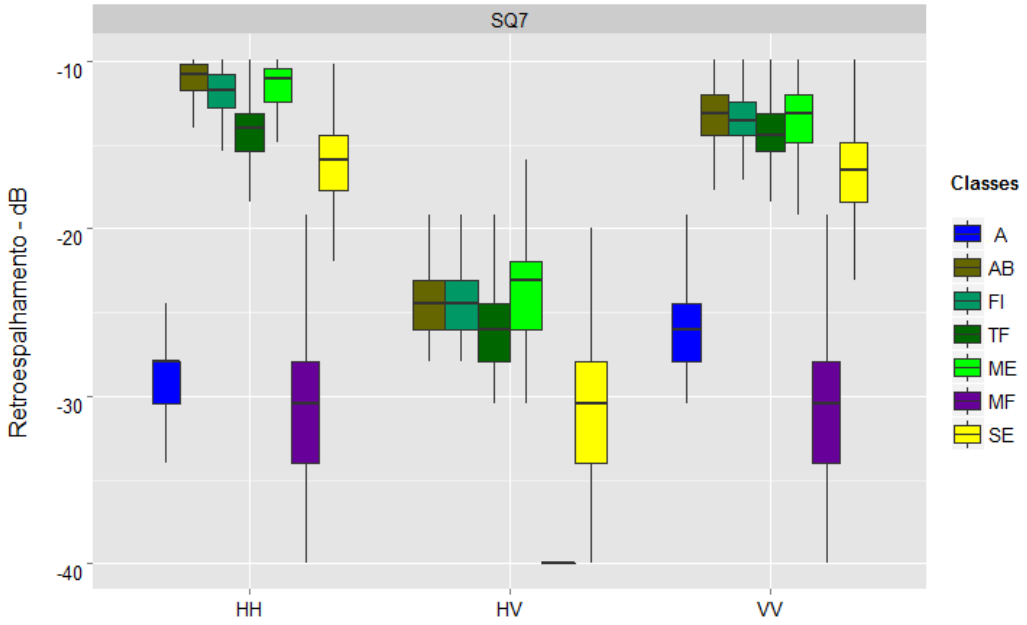


Figura 4.11 – Valores de retroespalhamento (dB) para as polarizações da diagonal principal da matriz C (HH, HV e VV) do ângulo de incidência SQ7, das classes de cobertura do solo propostas para o Lago Grande de Curuai - PA, para os três ângulos de incidência. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

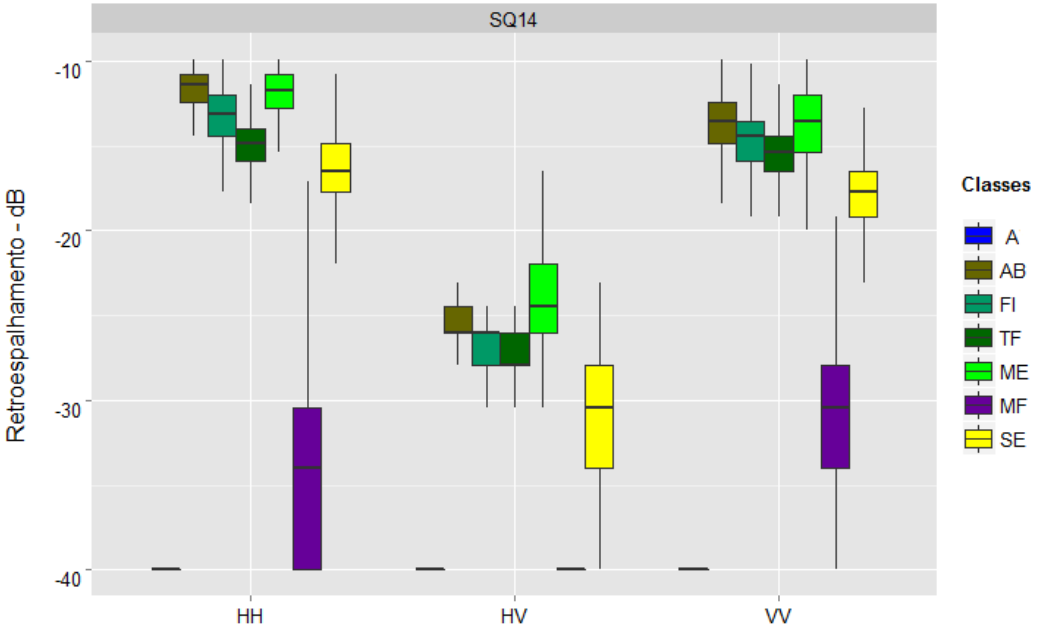


Figura 4.12 – Valores de retroespalhamento (dB) para as polarizações da diagonal principal da matriz C (HH, HV e VV) do ângulo de incidência SQ14, das classes de cobertura do solo propostas para o Lago Grande de Curuai - PA, para os três ângulos de incidência. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

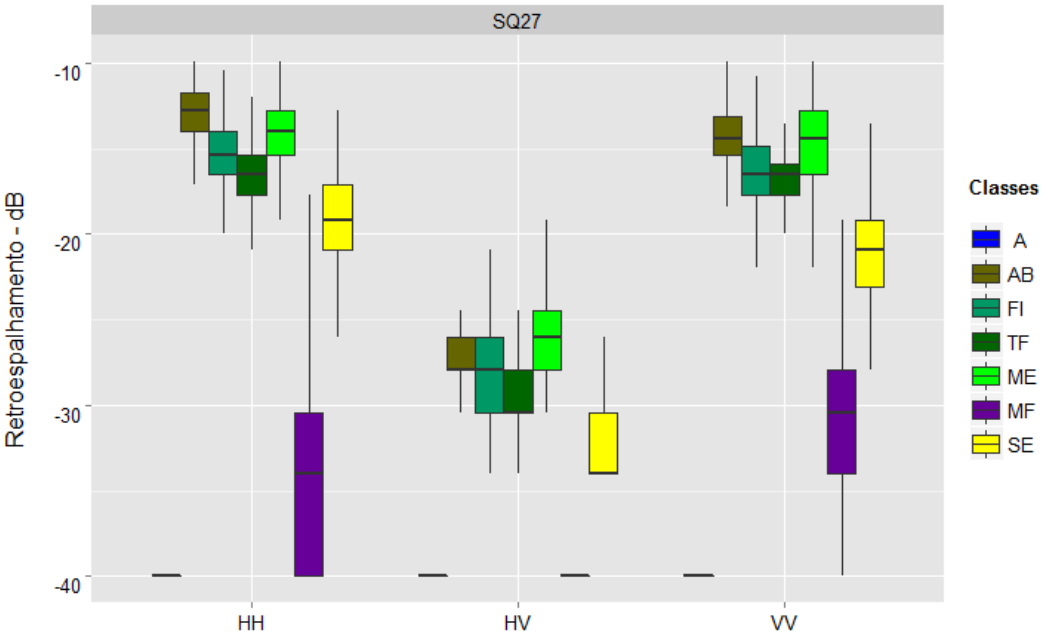


Figura 4.13 – Valores de retroespalhamento (dB) para as polarizações da diagonal principal da matriz C (HH, HV e VV) do ângulo de incidência SQ27, das classes de cobertura do solo propostas para o Lago Grande de Curuai - PA, para os três ângulos de incidência. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

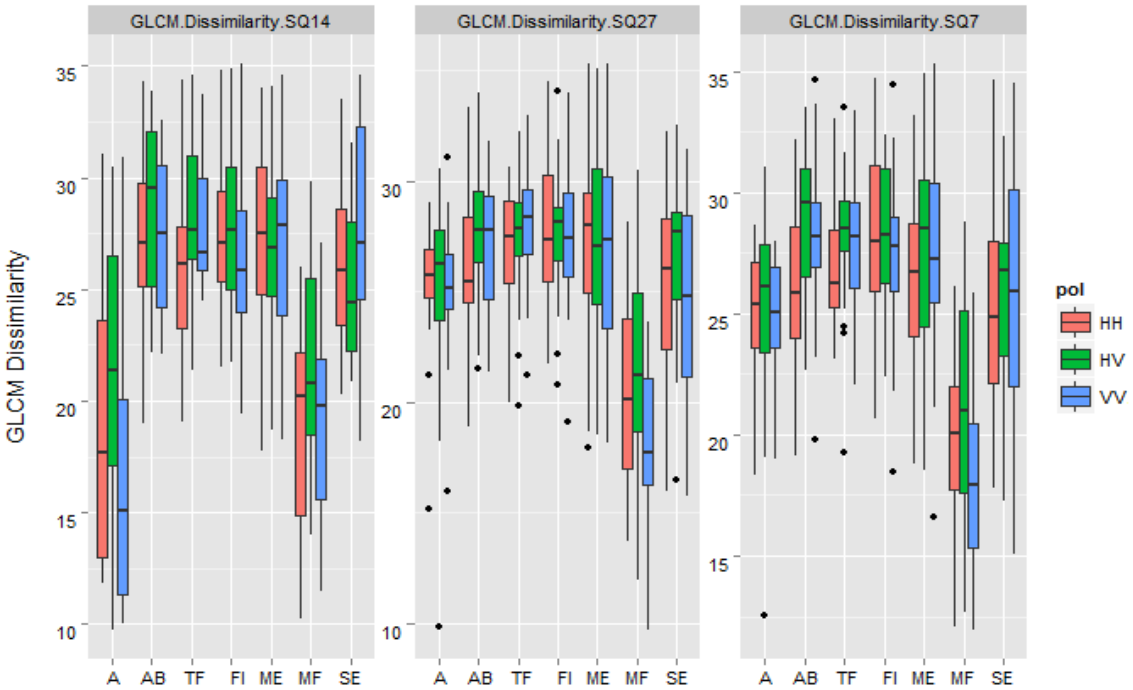


Figura 4.14 – Valores do atributo de textura Dissimilaridade (GLCM Dissimilarity), para as classes de cobertura do solo propostas para o Lago Grande de Curuai - PA. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

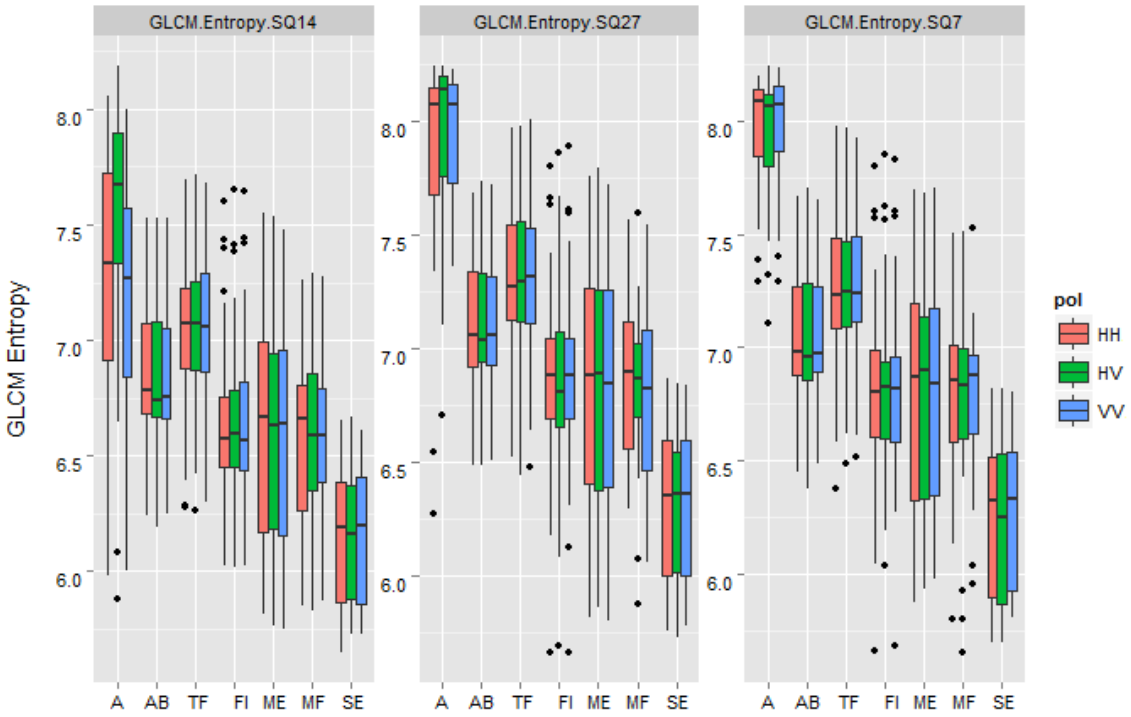


Figura 4.15 – Valores do atributo de textura Entropia (GLCM Entropy), para as classes de cobertura do solo propostas para o Lago Grande de Curuai - PA. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

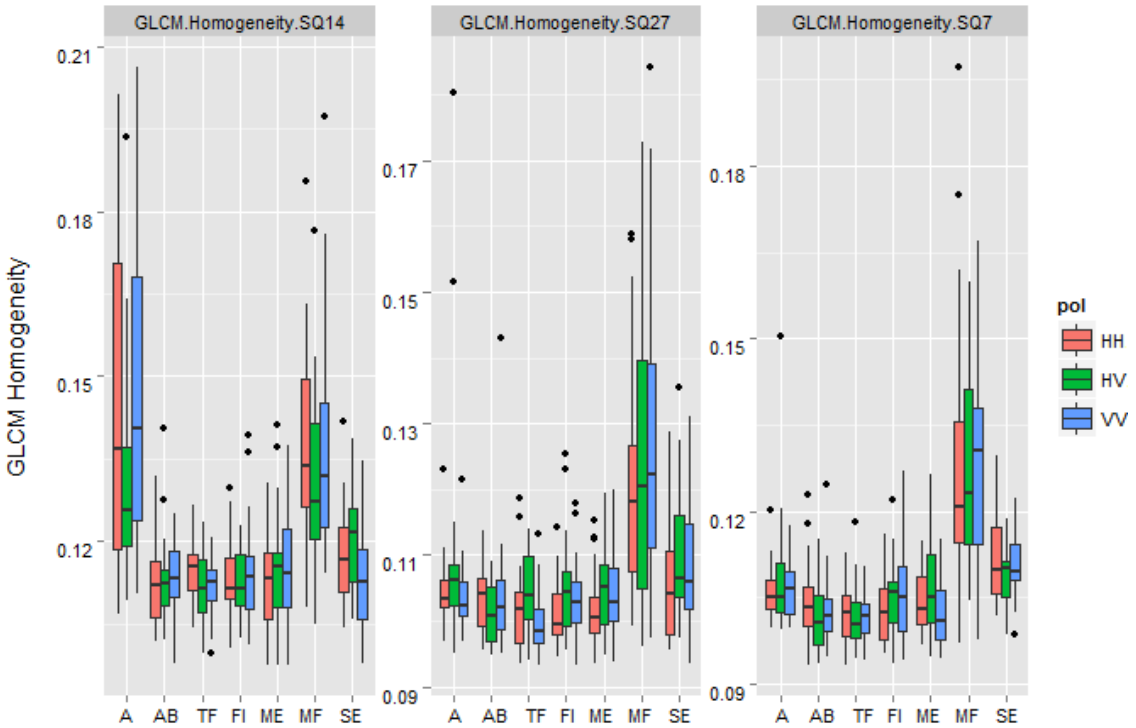


Figura 4.16 – Valores do atributo de textura Homogeneidade (GLCM Homogeneity), para as classes de cobertura do solo propostas para o Lago Grande de Curuai - PA. A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

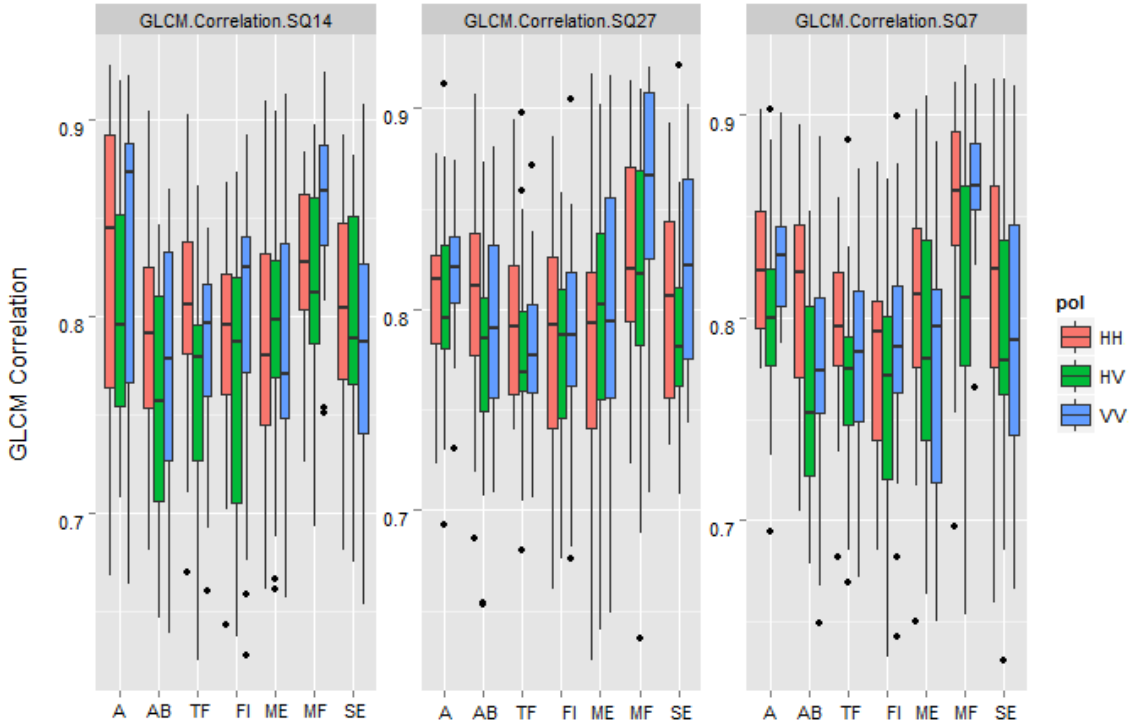


Figura 4.17 – Valores do atributo de textura Correlação (GLCM Correlation), para as classes de cobertura do solo propostas para o Lago Grande de Curuai - PA. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

A Tabela 4.2 resume os resultados da classificação por atributo e ângulo de incidência utilizado. Percebe-se que a tendência observada nos gráficos é mantida – o melhor desempenho para as classes gerais é alcançado com o uso das imagens do ângulo de incidência SQ7 em amplitude (κ = 0,68; QD = 13,73% e AD = 10,14%). Porém, o melhor QD foi obtido no ângulo de incidência SQ14 (QD = 11%).

A melhor classificação utilizando apenas atributos de textura foi aquela referente ao ângulo de incidência SQ27 (κ = 0,38; QD = 11,52% e AD = 33,80%). O ângulo SQ27 também obteve o melhor desempenho no índice Kappa e no QD quando a amplitude e textura foram combinadas (κ = 0,67 e

QD = 5,79%), mas o melhor valor de AD foi observado para o ângulo SQ14 (AD = 14,96%). Devido ao baixo desempenho dos atributos de textura, eles não foram utilizados na classificação dos alvos de várzea.

O melhor resultado as classes de várzea foi obtidos pelo ângulo de incidência SQ27 (κ = 0,74; QD = 8,64% e AD = 4,77%).

Tabela 4.2 – Índices de validação da classificação para todas as classes de cobertura da classificação relativa aos ângulos de incidência SQ7, SQ14 e SQ27 e atributos de amplitude e textura. O valor do parâmetro Escala, do segmentador, foi 25 para todas as classificações.

| Ângulo de incidência | Classes | Atributo utilizado | Imagens utilizadas | Nº de nós na árvore | Kappa | Erro de Quantidade | Erro de Alocação |
|---|---|---|---|---|---|---|---|
| SQ7 | Classes Gerais | Amplitude | HH, HV e VV | 13 | 0,68 | 13.73 | 10,14 |
| SQ14 | | | | 13 | 0,65 | 11.00 | 14,96 |
| SQ27 | | | | 13 | 0,63 | 14.47 | 12,98 |
| SQ7 | | Textura | | 23 | 0,32 | 14.30 | 37,46 |
| SQ14 | | | | 19 | 0,18 | 20.07 | 50,21 |
| SQ27 | | | | 17 | 0,38 | 11.52 | 33,80 |
| SQ7 | | Amplitude + Textura | | 15 | 0,60 | 12.96 | 17,26 |
| SQ14 | | | | 13 | 0,64 | 11.31 | 14,96 |
| SQ27 | | | | 15 | 0,67 | 5.79 | 16,98 |
| SQ7 | Classes de várzea | Amplitude | HH, HV e VV | 9 | 0,71 | 12.61 | 6.82 |
| SQ14 | | | | 9 | 0,65 | 13.07 | 10.85 |
| SQ27 | | | | 9 | 0,74 | 12.86 | 4.77 |

As árvores de decisão geradas com atributos de textura foram maiores que aquelas que se utilizam apenas da amplitude - 23, 19 e 17 nós para os ângulos SQ7, SQ14 e SQ27 respectivamente, para as classificações de textura, e 13 nós para os mesmos ângulos na classificação utilizando apenas a amplitude. A combinação da amplitude e textura também aumentou ligeiramente as árvores (15, 13 e 15 respectivamente para os ângulos SQ7, SQ14 e SQ27, utilizando atributos de textura e amplitude, e 13 nós para os mesmos ângulos utilizando apenas amplitude). Isso demonstra que a textura possui menor capacidade de discriminar os alvos quando comparada com o atributo de amplitude, dado que

o algoritmo J.4.8 precisou utilizar um maior número de nós para diferenciar as mesmas classes que foram separadas, pelo atributo amplitude, utilizando um menor número de nós.

Em geral, o desempenho dos ângulos de incidência foi similar, principalmente em relação aos ângulos SQ7 e SQ27, com pequenas diferenças quanto à discriminação de uma ou outra classe particular, o que é corroborado pela literatura (HESS et al., 1990; LI et al., 2007; HENDERSON; LEWIS, 2008; MARTI-CARDONA et al., 2010). A análise dos boxplots das respostas das classes de cobertura do solo e vegetação mostra que o menor ângulo destacou-se na discriminação das classes gerais, obtendo os melhores índices tanto na classificação geral como nas classes individualmente. Já o maior ângulo destacou-se na discriminação dos alvos de várzea.

Resultado semelhante foi observado em Lang et al. (2008), onde os autores relatam que os ângulos de incidência medianos e grandes são os mais indicados para o estudo do substrato florestal. Como o ângulo SQ7 apresenta o maior grau de penetração no dossel da vegetação da várzea, pode-se associar a isso a maior ocorrência de espalhamento double-bounce e volumétrico para as classes de vegetação (COSTA; TELMER, 2006). Por conseguinte, o ângulo SQ27 apresenta a menor penetração e a maior atenuação da REM dentro do dossel, apresentando assim menos ocorrência de double-bounces e diferentes taxas de atenuação da REM e de espalhamento volumétrico, em função de diferentes arquiteturas do dossel e quantidade de folhas, ramos e galhos.

As imagens obtidas segundo o ângulo de incidência SQ27 são sensíveis às diferenças de espalhamento volumétrico dos diferentes tipos de vegetação da várzea, enquanto que nas imagens SQ7, essas diferenças são menos explícitas pela saturação do espalhamento volumétrico e pela elevada ocorrência de *double-bounce*. Dessa maneira, para todas as polarizações, as há maior poder de discriminação das classes de vegetação da várzea com o aumento do ângulo de incidência.

Devido aos maiores valores de índices Kappa e AD, quando comparado com os outros ângulos de incidência, o ângulo SQ27 foi escolhido como aquele que apresentou o maior desempenho para a classificação dos alvos da várzea. Assim, todas as classificações seguintes utilizarão imagens com esse ângulo de incidência.

### 4.3.2. Classificação das decomposições polarimétricas

Percebe-se pela análise dos gráficos boxplot (Figura 4.18) que, para a decomposição de Cloude – Pottier (CP) há maior diferenção das classes nas imagens do ângulo α e da Anisotropia, em comparação com a imagem Entropia, que apresenta respostas semelhantes para a maioria dos alvos de vegetação, com exceção de Floresta de Terra Firme. Os objetos de água, para todas as imagens da decomposição de CP, apresentaram valores ruidosos, o que pode ter sido causado pelo baixíssimo sinal de retorno presente nessas regiões para um ângulo de incidência grande como o SQ27 (cerca de 45°). Além disso, as imagens dessa decomposição apresentam poucas bordas entre os alvos, dificultando sua delimitação. Devido a essas características, quando as imagens da decomposição de CP foram utilizadas combinadas à outras imagens, elas não foram utilizadas na etapa de segmentação.

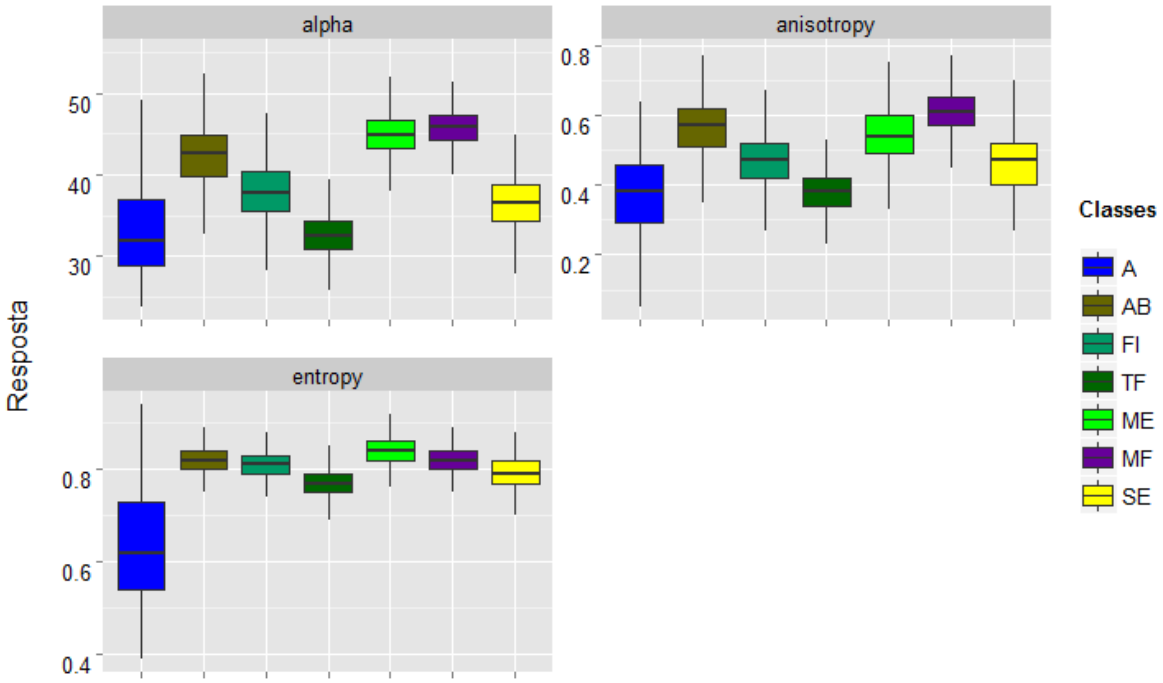


Figura 4.18 – Resposta para as classes de cobertura do solo do Lago Grande de Curuai - PA para as imagens da decomposição de Cloude – Pottier: ângulo α (alpha - graus), anisotropia (anisotropy - adimensional) e entropia (entropy - adimensional). As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

As componentes de espalhamento volumétrica e *double-bounce* da decomposição de van Zyl (VZ) proporcionou boa separabilidade para todas as classes de cobertura (Figura 4.19), enquanto que a componente de espalhamento superficial apresentou pouca variação nas respostas. Dado que a cena é composta por uma maioria de alvos de vegetação de diferentes tipos, prevalecem diferentes respostas para os mecanismos de espalhamento *double-bounce* e volumétricos. O espalhamento superficial, por sua vez, é menos expressivo para a separação das classes de cobertura, possuindo respostas muito semelhantes para todas as classes.

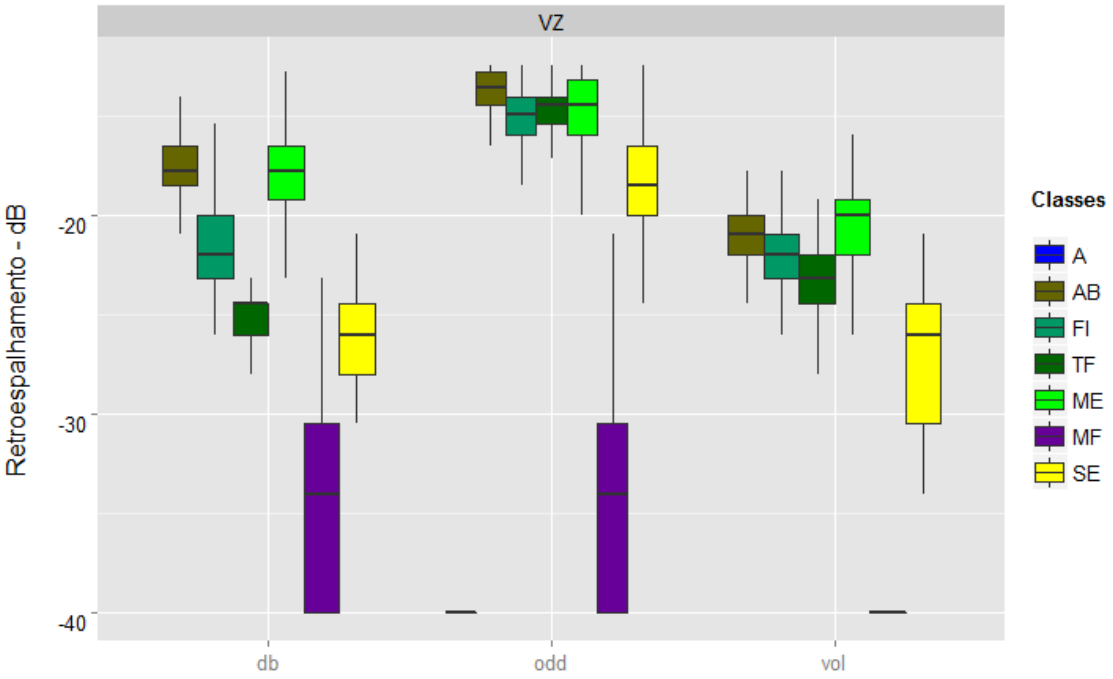


Figura 4.19 – Resposta para as classes de cobertura do solo do Lago Grande de Curuai - PA para as imagens da decomposição de van Zyl: componente Double-bounce (dB), superficial (odd) e volumétrica (vol). As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

Observando a classificação como um todo, a decomposição de Cloude – Pottier apresentou o pior desempenho (κ = 0,37 e 0,39; QD = 12,62% e 16,64% e AD de 39,83% e 31,65%, para classes gerais e de várzea respectivamente). Esse desempenho pode ser associado (a) à pobre definição das bordas entre os diferentes alvos, levando a formação de objetos incoerentes e incapazes de separar as classes de cobertura, (b) pela similaridade das respostas da imagem do ângulo α e Anisotropia e (c) e pela pouca separabilidade das classes na imagem Entropia (tabela 4.3).

Os melhores desempenhos das classificações das decomposições foram CP + VZ (κ = 0,73 e 0,75; QD = 12,44% e 11,27% e AD = 8,22% e 5,95%) e VZ (κ = 0,73 e 0,75; QD = 10,93% e 11,26% e AD = 10,09% e 5,63%; para as classes

gerais e de várzea respectivamente). Porém, quando comparados com os índices alcançado apenas com a classificação da diagonal da matriz C, não houve melhora significativa no emprego de decomposições polarimétricas, quando a classificação é analisada como um todo – os índices kappa foi apenas 0.01 maior e ambos os índices QD e AD foram ligeiramente piores que os da diagonal da matriz C. Deve-se, desta maneira, observar o desempenho das classes individuais para melhor analisar os benefícios trazidos pelo uso de decomposições polarimétricas.

Tabela 4.3 – Índices de validação da classificação das imagens das decomposições polarimétricas de van Zyl (VZ), Cloude – Pottier (CP) e suas combinações entre si e da diagonal da matriz C. A coluna Escala é referente ao parâmetro utilizado na segmentação das imagens.

| Decomposição | Classes | Imagens utilizadas | Escala | Número de nós na árvore | Kappa | Erro de Quantidade | Erro de Alocação |
|---|---|---|---|---|---|---|---|
| **CP** | Classes Gerais | **CP -** anisotropia, entropia e ângulo alpha; **VZ -** superficial, volumétrico e double-bounce e **C -** HH, HV e VV | 15 | 21 | 0,37 | 12,62 | 39,83 |
| **CP + C** | | | 25 | 15 | 0,71 | 13,97 | 7,33 |
| **CP + VZ** | | | | 15 | 0,73 | 12,44 | 8,22 |
| **CP + VZ + C** | | | | 15 | 0,72 | 12,49 | 8,65 |
| **VZ** | | | | 15 | 0,73 | 10,43 | 10,09 |
| **VZ + C** | | | | 13 | 0,71 | 12,25 | 9,79 |
| **CP** | Classes de Várzea | | 15 | 11 | 0,39 | 16,64 | 31,65 |
| **CP + C** | | | 25 | 11 | 0,69 | 14,73 | 6,52 |
| **CP + VZ** | | | | 11 | 0,75 | 11,27 | 5,95 |
| **CP + VZ + C** | | | | 9 | 0,74 | 11,42 | 6,22 |
| **VZ** | | | | 11 | 0,75 | 11,26 | 5,63 |
| **VZ + C** | | | | 9 | 0,74 | 11,42 | 6,22 |

As árvores de decisão geradas com as decomposições polarimétricas apresentaram um número de nós ligeiramente maior que aquelas geradas apenas com as imagens da diagonal da matriz C. De maneira similar aos resultados observados com o uso de atributos de textura, esse aumento no

número de nós da árvore de decisão indica uma menor separabilidade dos alvos, principalmente para a decomposição de Cloude – Pottier.

Os reais benefícios das decomposições de alvos foram nas classificações observados apenas para as classes analisadas individualmente. O uso de OBIA permite a construção de uma árvore de decisão utilizando apenas as imagens com os melhores índices para cada classe de cobertura, integrando diferentes cenas, polarizações, razões, índices e épocas do ano em uma classificação capaz de combinar todas as potencialidades desses dados, ao mesmo tempo em que minimiza o erro associado a cada um deles. Nesse sentido, OBIA pode permitir que se utilize apenas as composições com os melhores resultados para cada classe combinadas em uma só árvore, melhorando o desempenho da classificação como um todo.

Na literatura observa-se o uso de OBIA e árvores de decisão para fins semelhantes, integrando imagens de diferentes sensores, sensores SAR de diferentes comprimentos de onda, polarizações, decomposições polarimétricas e épocas do ano (SILVA et al., 2010, SARTORI et al., 2011, SANTIAGO et al., 2013; SIMARD et al., 2002).

Como não houve aumento significativo do desempenho geral das classificações com o uso de decomposições polarimétricas, procedeu-se para a classificação multitemporal utilizando apenas a diagonal da matriz C.

### 4.3.3. Classificação da diagonal da matriz C multitemporal

Para esta classificação, foram utilizadas as imagens da diagonal da matriz C, para ambos os pulsos de inundação da cheia e da seca, para o ângulo de incidência SQ27. Como plano de informação adicional às imagens da seca, foram geradas para essa classificação razões de polarizações multitemporais – HH seca / HH cheia; HV seca / HV cheia e VV seca / VV cheia.

A dinâmica hidrológica da várzea entre os pulsos da cheia e da seca muda significativamente os valores do retroespalhamento das classes devido,

principalmente, às dinâmicas fenológicas (perda de folhas) das classes de vegetação, como pode ser observado na Figura 4.20.

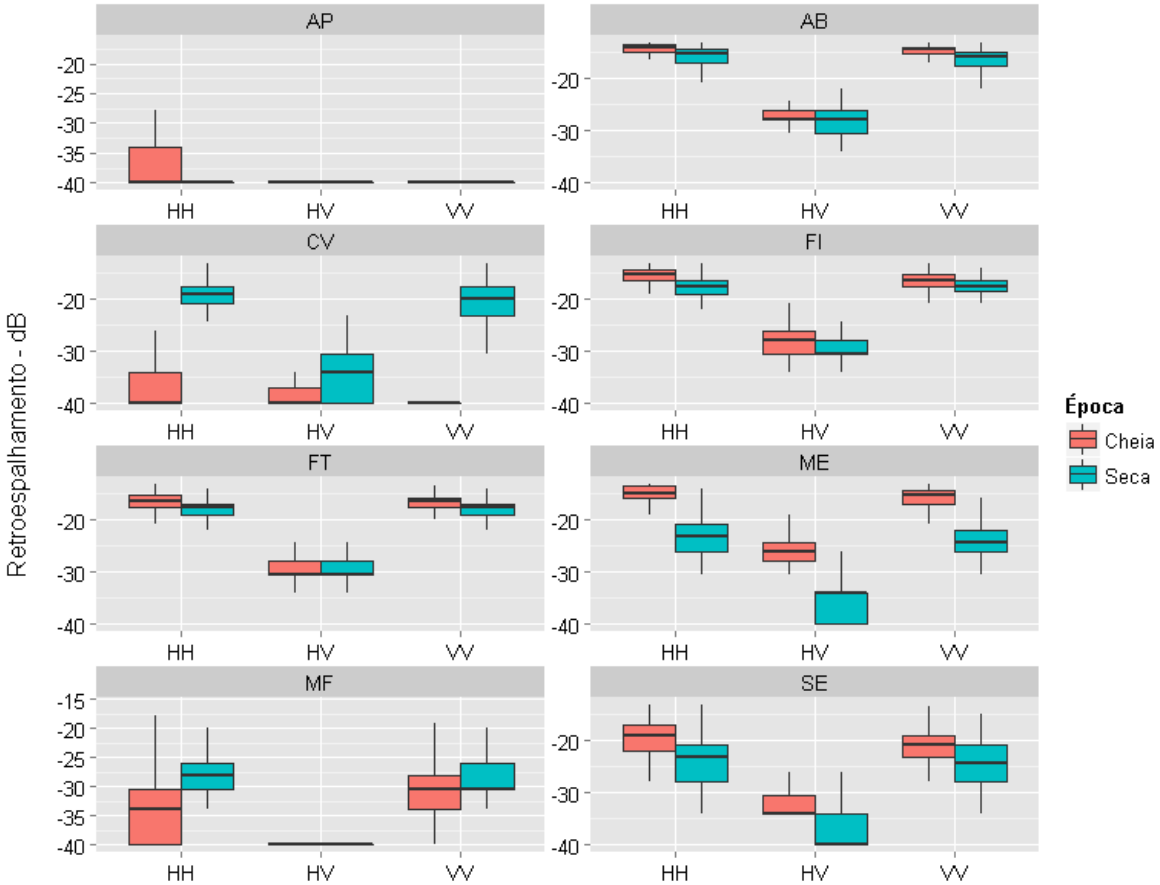


Figura 4.20 – Resposta para as classes de cobertura do solo do Lago Grande de Curuai - PA para as polarizações da diagonal da matriz C para os pulsos da cheia e da seca. As classes são: A – Água Permanente, A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

Observando a classificação como um todo, o uso de cenas multitemporais aumentou o desempenho das classificações, principalmente quando as razões entre as polarizações foram utilizadas (Tabela 4.4). O melhor desempenho foi alcançado para a classificação utilizando as razões multitemporais (κ = 0,79 e 0,87; QD = 4,52% e 2,75% e AD = 11,81% e 7,02%; respectivamente para as classes gerais e classes de várzea).

Tabela 4.4 - Índices de validação da classificação das imagens multitemporais, com ou sem razões multitemporais. O valor do parâmetro Escala utilizado para todas as classificações foi de 20.

| Multitemporal | Classes | Imagens utilizadas | Número de nós na árvore | Kappa | Erro de Quantidade (%) | Erro de Alocação (%) |
|---|---|---|---|---|---|---|
| **Sem razões multitemporais** | Classes Gerais | HH, HV e VV - cheia e seca; | 17 | 0,74 | 6,78 | 13,99 |
| **Com razões multitemporais** | | HH, HV e VV - cheia e seca; razões multitemporais | 17 | 0,79 | 4,52 | 11,81 |
| **Sem razões multitemporais** | Classes de Várzea | HH, HV e VV - cheia e seca; | 13 | 0,78 | 5,69 | 9,45 |
| **Com razões multitemporais** | | HH, HV e VV - cheia e seca; razões multitemporais | 11 | 0,87 | 2,75 | 7,02 |

Contudo percebe-se que usando ou não as razões multitemporais, houve ligeiro aumento do AD, quando comparado com a classificação das imagens da diagonal da matriz C monotemporal. O erro foi menor quando houve uso de razão de bandas multitemporais, aproximando-se do erro observado para a classificação monotemporal (AD de 7,02% para a classificação multitemporal com razões multitemporais e 4,77% para a classificação monotemporal).

Os reais benefícios da classificação multitemporal foram relativos à melhora do índice QD e a estimativa das áreas das classes – enquanto a classificação da matriz C obteve QD de 5,79% e 8,64% para as classes gerais e de várzea respectivamente, a classificação multitemporal obteve QD de 4,52% e 2,75% para as mesmas classificações.

Apesar de ser afirmado na literatura que o uso de cenas multitemporais nem sempre aumenta a precisão da classificação (HENDERSON; LEWIS, 2008) foi observado nesse trabalho um aumento significativo de QD e apenas uma ligeira queda de AD, aumentando o kappa das classificações multitemporais consideravelmente.

A razão de bandas multitemporal realça os alvos que apresentam mudanças no retroespalhamento ao longo do tempo e foi usada com o objetivo de maximizar a diferença das respostas das classes em diferentes épocas (SILVA et al., 2010). Ela cumpriu parte do objetivo – pois melhorou o QD em detrimento do AD; e o kappa refletiu esse aumento. Dessa maneira, assume-se que a classificação multitemporal melhorou a estimativa da área das classes com relação a classificação monotemporal, ao custo de uma pequena parte da precisão do posicionamento das mesmas.

### 4.3.4. Análise dos resultados das classificações por classe individual

#### 4.3.4.1. Erro de alocação

Ao analisar o AD das classes individualmente (Figuras 4.21 a 4.27), percebe-se que a maioria delas foi mais bem classificada por decomposições polarimétricas ou pelo uso de decomposições combinadas à matriz C: (a) Vegetação Arbustiva, pela decomposição de van Zyl (AD de 0,81% e 0,88% para as classes gerais e de várzea, respectivamente), (b) Floresta Inundável, pela combinação entre Cloude – Pottier e matriz C (3,38% e 2,5%), (c) Macrófitas Emersas, pela combinação entre imagens das decomposições de Cloude – Pottier e van Zyl (0,52% e 0,37%), (d) Floresta de Terra Firme e Solo Exposto, pela combinação entre Cloude – Pottier e a matriz C (0,68% e 0,8% respectivamente).

O melhor desempenho das classificações da diagonal principal da matriz C e das cenas multitemporais, quando analisadas para o conjunto das classes, só ocorreu porque todas as classes apresentaram erros médios e baixos, e ao serem analisadas como um todo, o kappa manteve-se alto e o erro de alocação manteve-se baixo. Por sua vez, as decomposições polarimétricas apresentaram classes com índices de validação muito díspares: algumas das classes apresentaram valores excelentes ao mesmo tempo em que outras classes obtiveram desempenhos ruins. Quando esse desempenho é tomado para o conjunto das classes, as disparidades dos índices de validação se

compensam e a classificação como um todo é comparável com as da matriz C e multitemporal.

A escolha das classes também afeta o desempenho da classificação geral. A classe de Floresta Inundável foi uma das que apresentou a maior diferença entre os índices allocation disagreement calculado para as classes gerais e as classes de várzea. A melhora nesse índice para as classes de várzea se deu pela eliminação da classe Floresta de Terra Firme, a qual apresentou sensível confusão com Floresta Inundável.

As classes de Água e Macrófitas Flutuantes apresentaram AD de 0% na maioria de suas classificações, e naquelas onde houve erro foi devido à confusão entre objetos dessas duas classes. Dessa maneira, pode-se afirmar que são classes facilmente discrimináveis, quando comparadas com classes de vegetação.

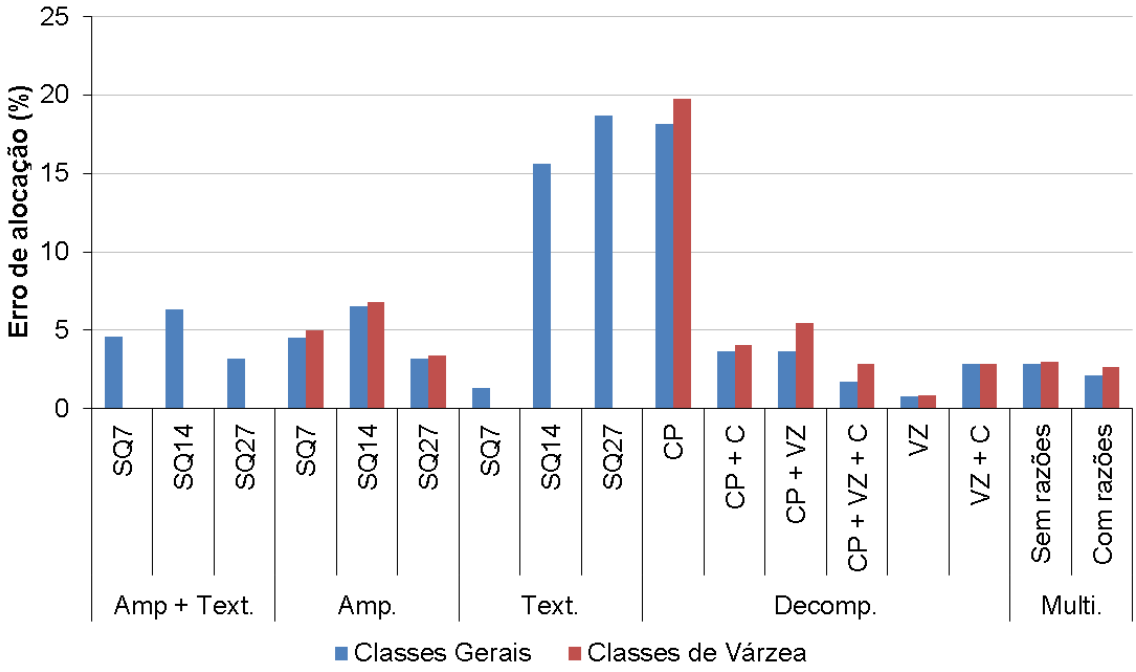


Figura 4.21 – Erro de alocação, de todas as classificações, da classe Vegetação Arbustiva.

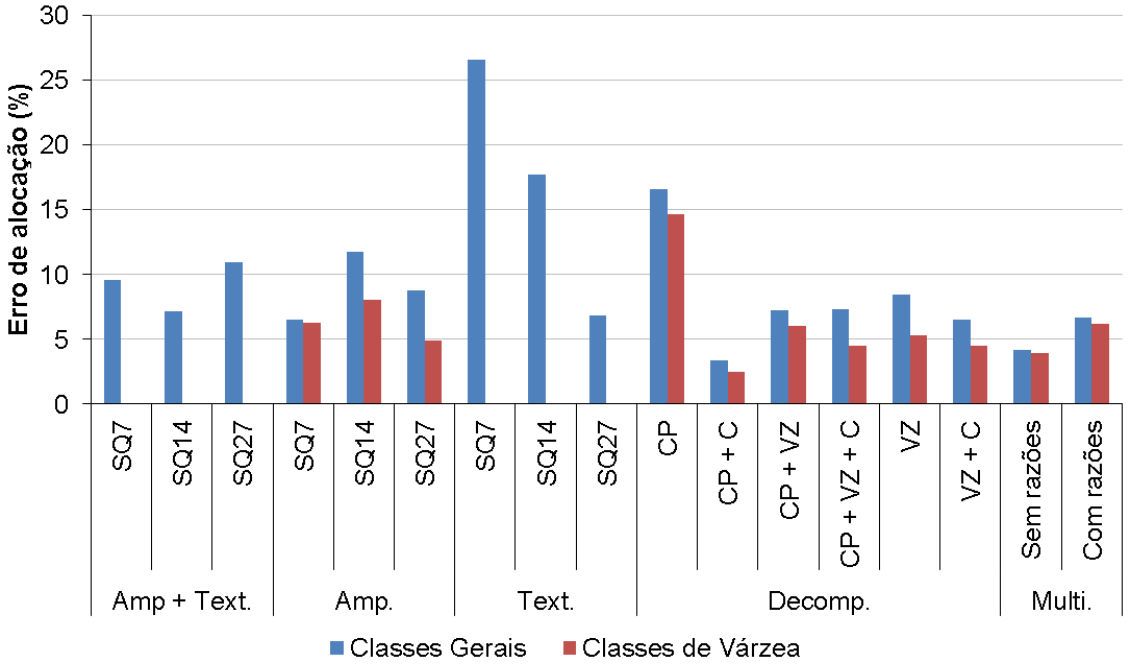


Figura 4.22 – Erro de alocação, de todas as classificações, da classe Floresta Inundável.

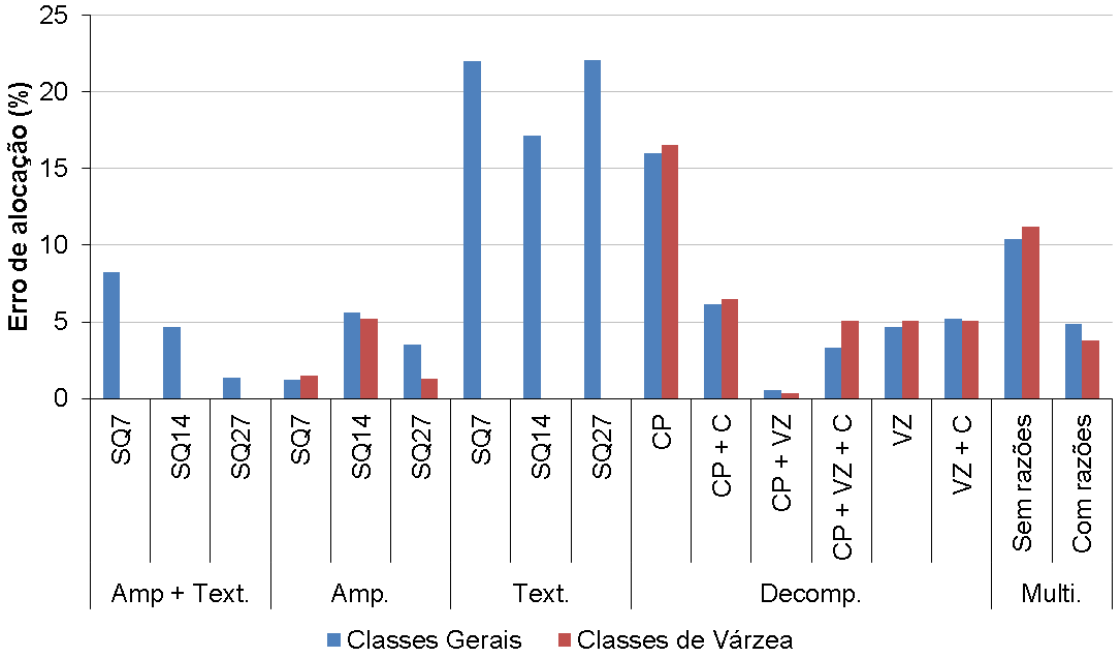


Figura 4.23 – Erro de alocação, de todas as classificações, da classe Macrófitas Emersas.

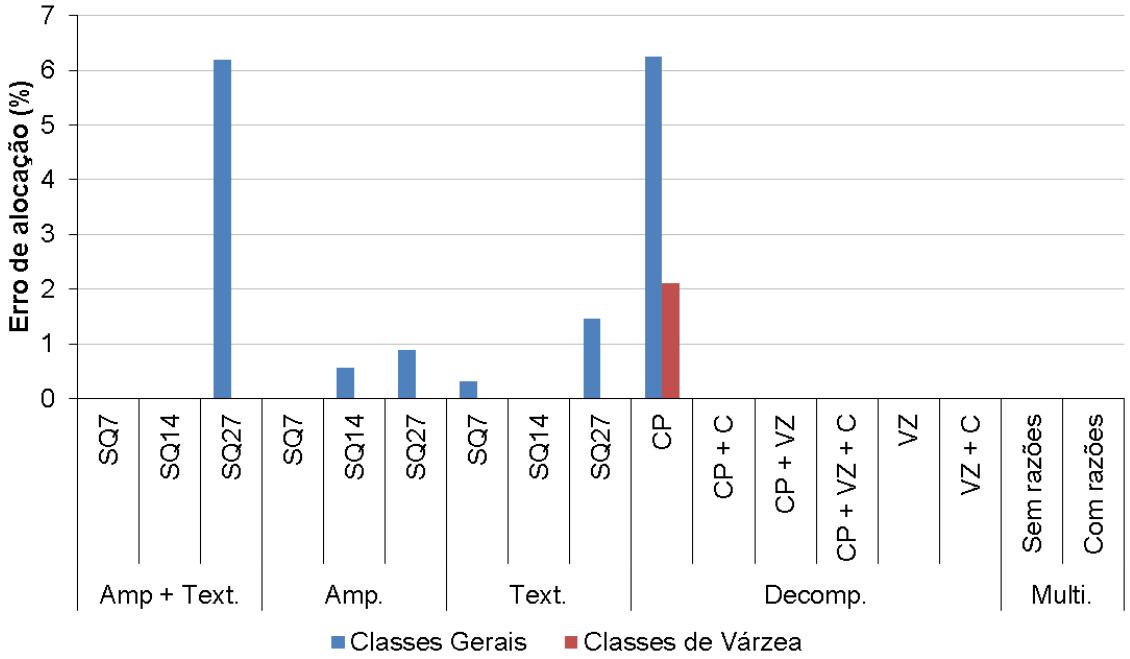


Figura 4.24 – Erro de alocação, de todas as classificações, da classe Água.

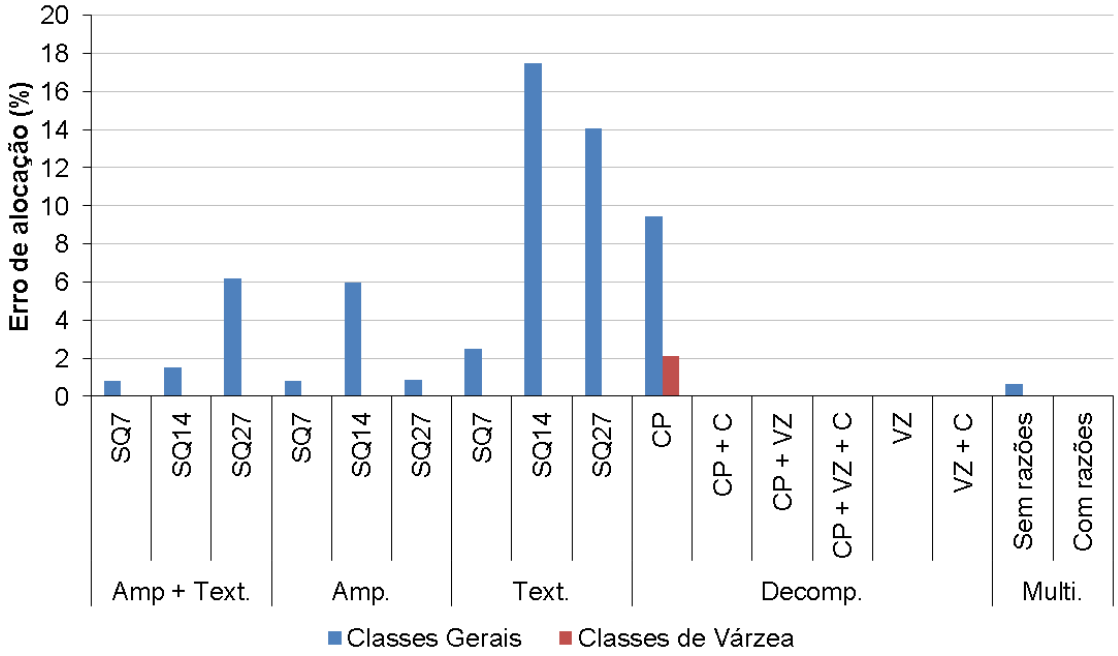


Figura 4.25 – Erro de alocação, de todas as classificações, da classe Macrófitas Flutuantes.

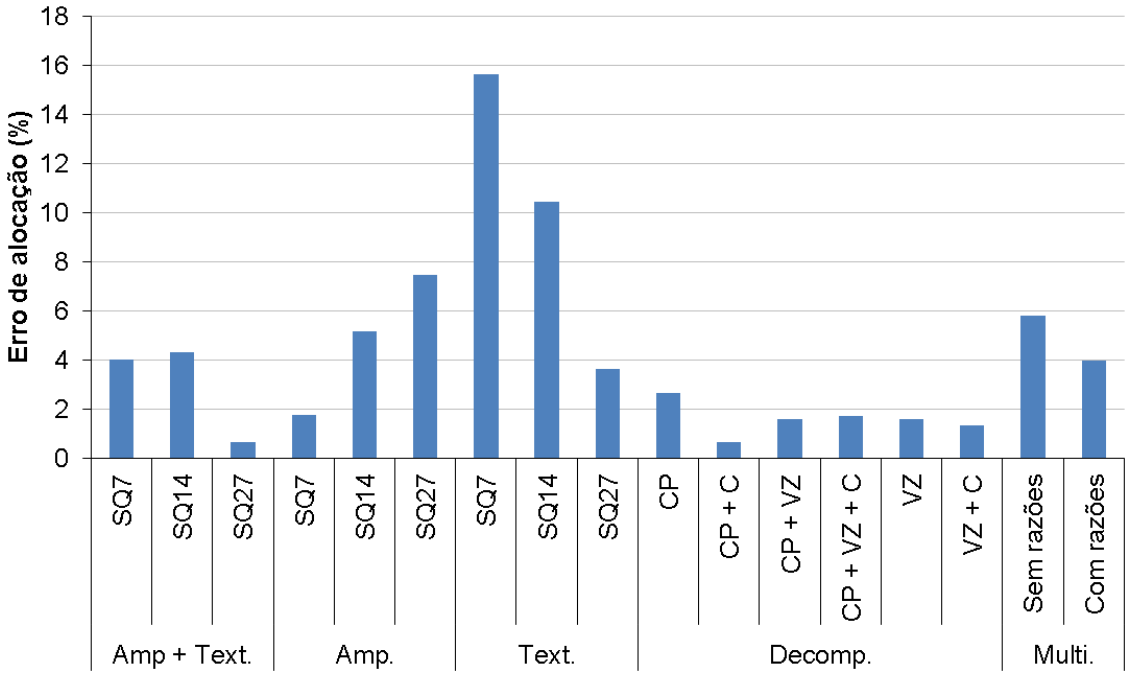


Figura 4.26 – Erro de alocação, de todas as classificações, da classe Floresta de Terra Firme.

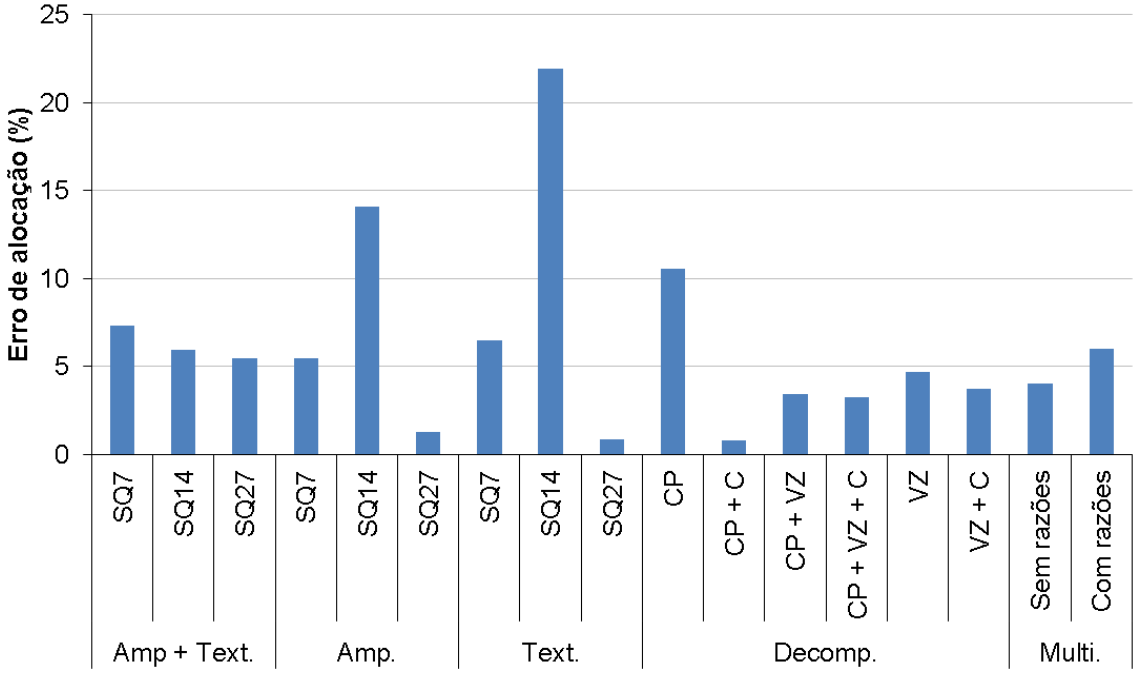


Figura 4.27 – Erro de alocação, de todas as classificações, da classe Solo Exposto.

#### 4.3.4.2. Erro de quantidade

Não foi possível perceber um padrão para as melhores imagens, em termos de QD, quando foram analisadas as classes individualmente (Figuras 4.28 a 4.34). A classe Vegetação Arbustiva apresentou o melhor QD para a combinação CP + VZ + C (0,28% e 0,13%, para as classes gerais e de várzea, respectivamente). A classe Floresta Inundável, na classificação dos dados da decomposição de VZ para as classes gerais (0,1%) e para a combinação entre CP + VZ para as classes de várzea (0,08%). As Macrófitas Emersas obtiveram o melhor desempenho com os dados do ângulo de incidência SQ14 nas classes gerais (0,01%) e com os dados multitemporais com razções de bandas (0,18%) para as classes de várzea; Floresta de Terra Firme obteve o melhor resultado através da combinação entre amplitude e textura do ângulo de incidência SQ27 (0,14%) e Solo Exposto com a classificação multitemporal com razões de bandas (0,24%).

Percebe-se que, para a maioria das classes analisadas individualmente, o uso de cenas multitemporais diminuiu o QD, principalmente para as classificações com razões de imagens, quando comparado com o desempenho da classificação das imagens da diagonal da matriz C monotemporais – de maneira semelhante às classificações analisadas como um todo. Com exceção de Vegetação Arbustiva, todas as classes apresentaram significativa melhora no QD e isso foi responsável pelo aumento do índice kappa, dado que o AD para essas mesmas classes piorou.

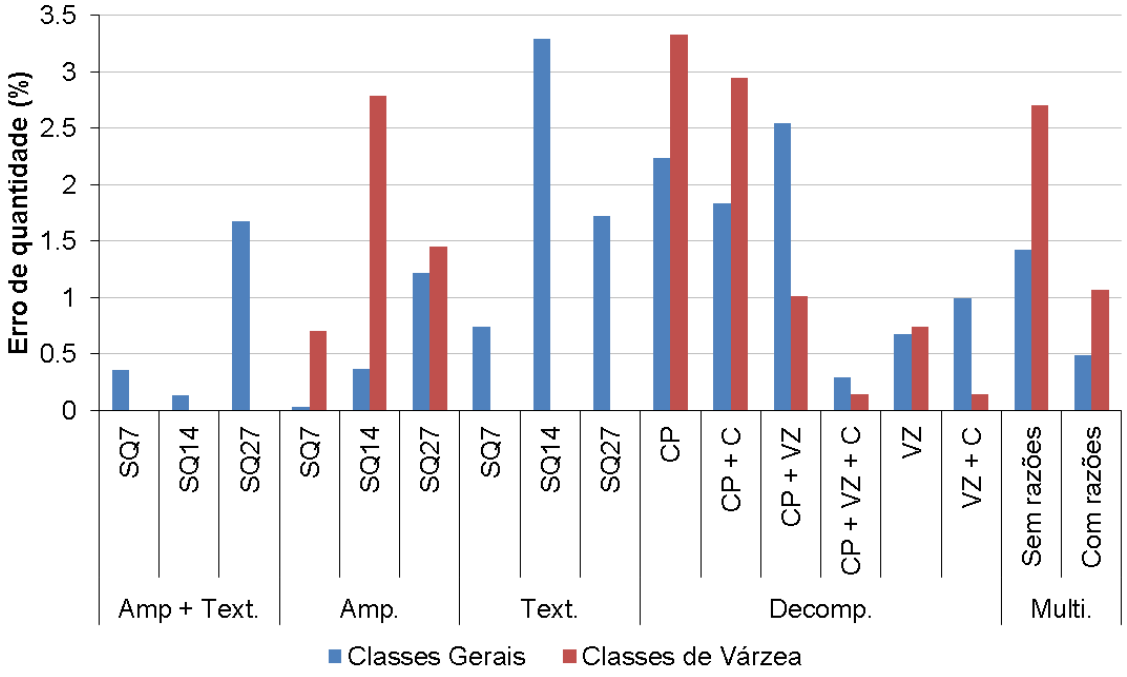


Figura 4.28 – Erro de quantidade, de todas as classificações, da classe Vegetação Arbustiva.

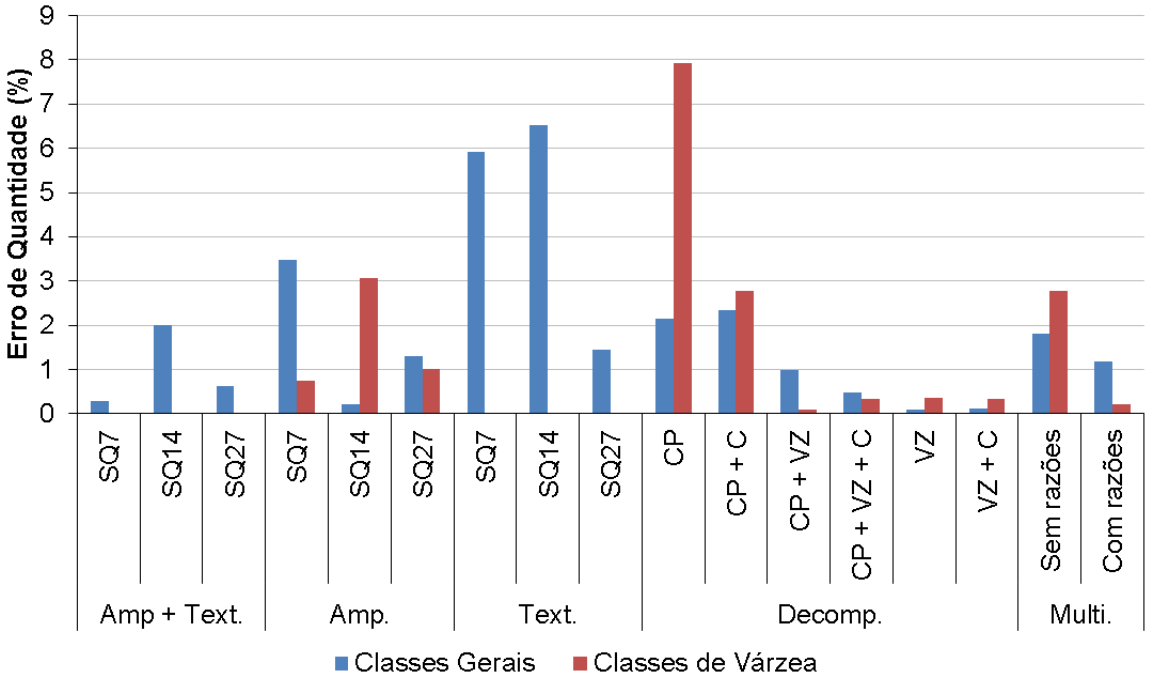


Figura 4.29 – Erro de quantidade, de todas as classificações, da classe Floresta Inundável.

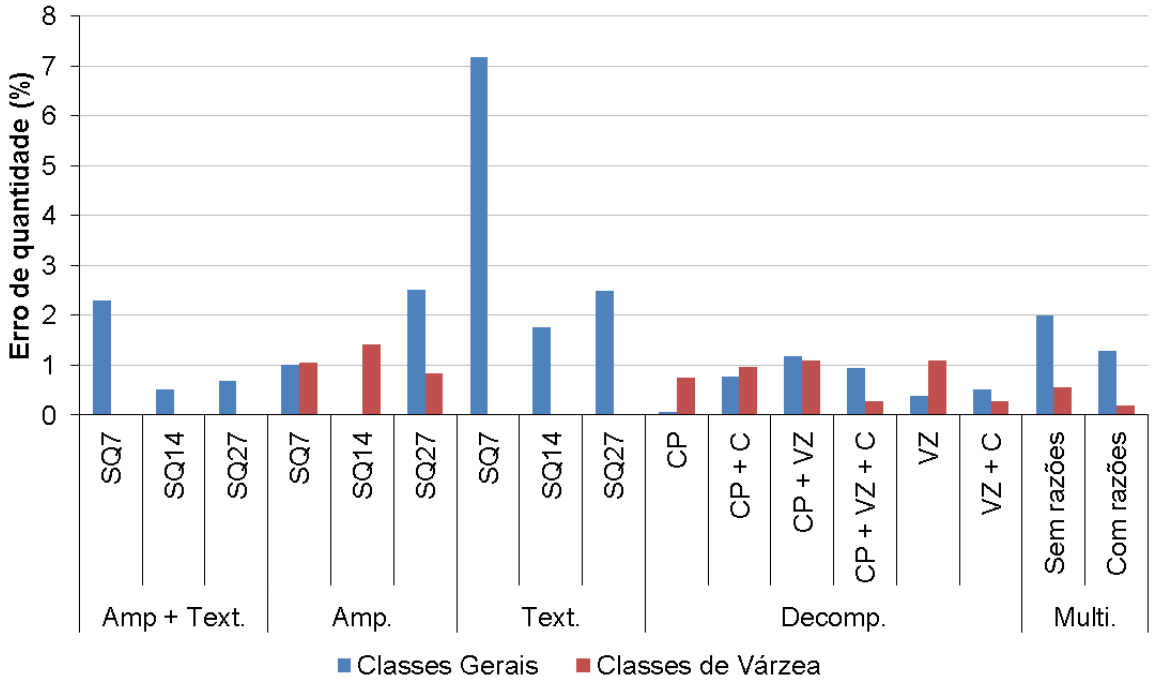


Figura 4.30 – Erro de quantidade, de todas as classificações, da classe Macrófitas Emersas.

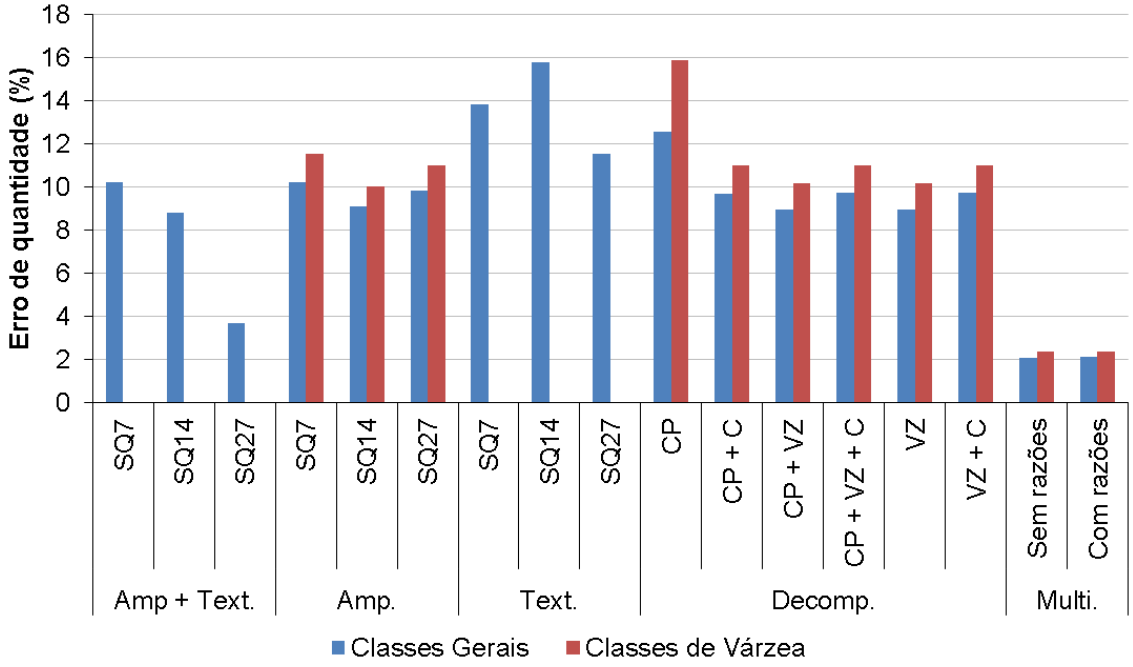


Figura 4.31 – Erro de quantidade, de todas as classificações, da classe Água.

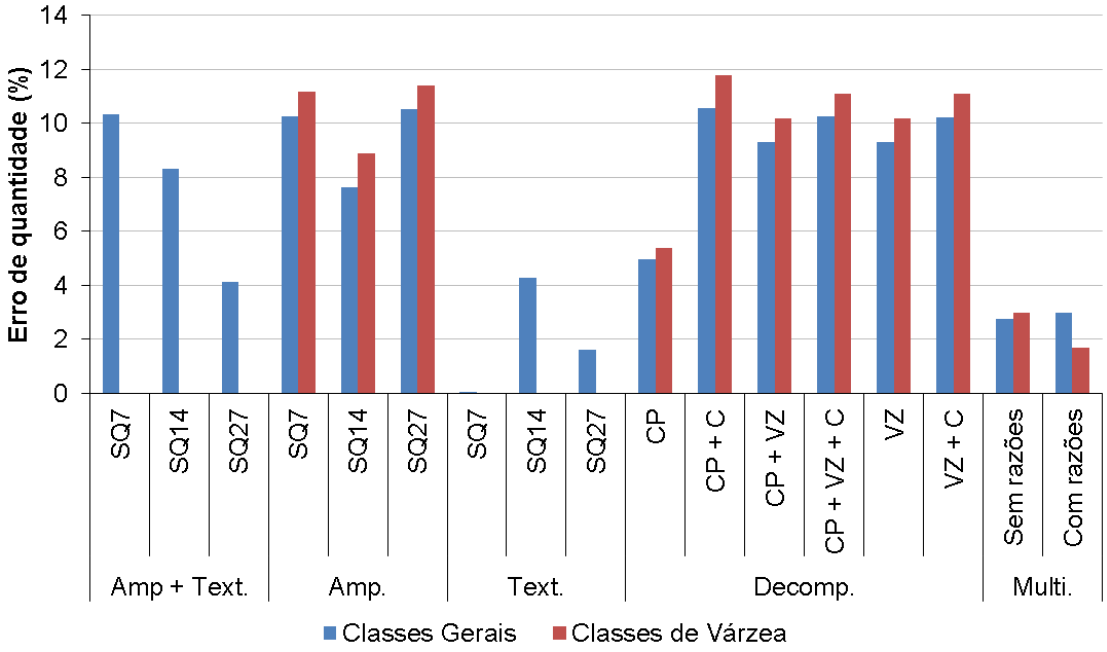


Figura 4.32 – Erro de quantidade, de todas as classificações, da classe Macrófitas Flutuantes.

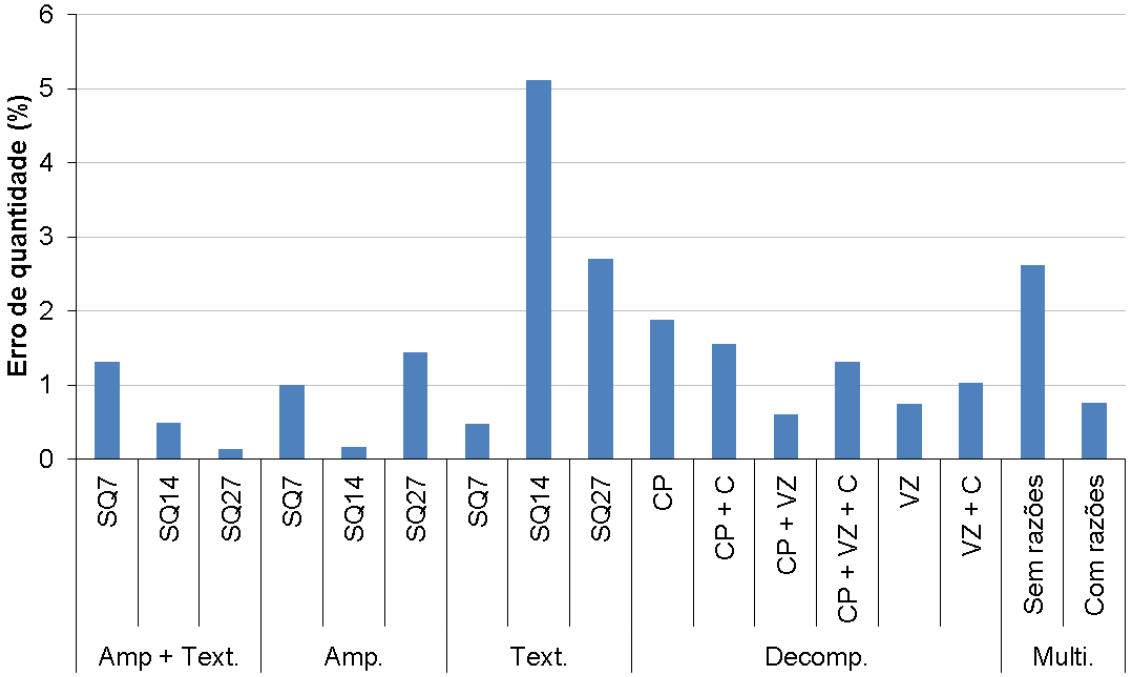


Figura 4.33 – Erro de quantidade, de todas as classificações, da classe Floresta de Terra Firme.

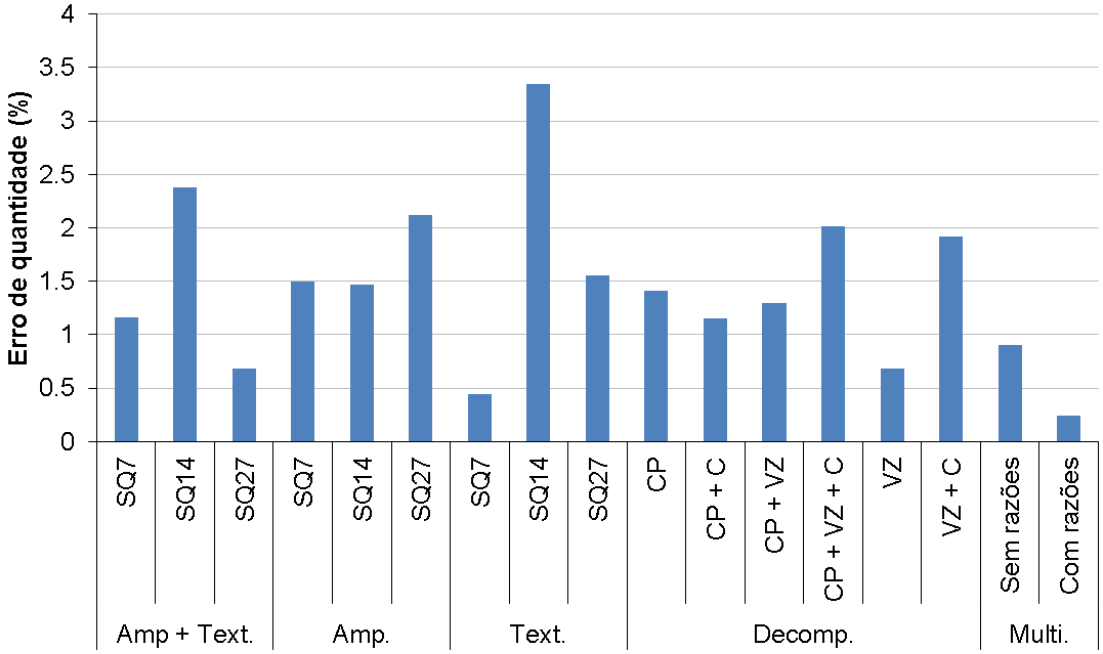


Figura 4.34 – Erro de quantidade, de todas as classificações, da classe Solo Exposto.

## 4.4. Modelagem e estimativa dos parâmetros biofísicos da Floresta Inundável da várzea do Lago Grande de Curuai.

O ENL foi calculado para todas as imagens utilizadas nessa etapa (Tabela 4.5 a 4.7). Como o ENL variou, em média, de 5 a 10, segundo Laur et al. (1996), os 50 pixels amostrados, em média, possuem erro estimado de ±1 a 1.5 dB, com 95% de confiança.

O ângulo que apresentou o maior número de correlações com os atributos biofísicos da vegetação foi o SQ27, seguido pelo SQ14 e SQ7, para quatro dos nove atributos biofísicos da várzea (DAP, altura de inundação, densidade de indivíduos e IAF). O atributo que apresentou a correlação mais forte com as imagens PolSAR foi o IAF, seguido pelo DAP, densidade de indivíduos e por último a altura de inundação.

Tabela 4.5 – ENL para amostra de água das imagens do ângulo SQ7.

| | Imagem | Mínimo | Máximo | Média | Desvio - Padrão | CV | ENL |
|---|---|---|---|---|---|---|---|
| SQ7 | HH | 0.010 | 0.041 | 0.021 | 0.004 | 0.192 | 5.198 |
| | HV | 0.001 | 0.001 | 0.001 | 0.001 | 0.13 | 7.591 |
| | VV | 0.017 | 0.064 | 0.032 | 0.006 | 0.203 | 4.923 |
| | HH+VV | 0.024 | 0.098 | 0.049 | 0.01 | 0.202 | 4.927 |
| | HH-VV | 0.002 | 0.007 | 0.004 | 0.001 | 0.159 | 6.26 |
| | CP - Ang. Alpha | 9.747 | 19.40 | 13.58 | 1.286 | 0.094 | 10.56 |
| | CP - Anisotropia | 0.444 | 0.716 | 0.597 | 0.039 | 0.065 | 15.24 |
| | CP - Entropia | 0.198 | 0.412 | 0.289 | 0.032 | 0.110 | 9.045 |
| | VZ - Double bounce | 0.003 | 0.004 | 0.003 | 0.0001 | 0.042 | 23.33 |
| | VZ - Superficial | 0.028 | 0.078 | 0.049 | 0.007 | 0.150 | 6.643 |
| | VZ - Volumétrico | 0.003 | 0.003 | 0.003 | NaN | NaN | NaN |

Tabela 4.6 – ENL para amostra de água das imagens do ângulo SQ14.

| | Imagem | Mínimo | Máximo | Média | Desvio - Padrão | CV | ENL |
|---|---|---|---|---|---|---|---|
| SQ14 | HH | 0.00 | 0.01 | 0.00 | 0.00 | 0.40 | 2.52 |
| | HV | 0.00 | 0.00 | 0.00 | 0.00 | 0.15 | 6.86 |
| | VV | 0.00 | 0.02 | 0.00 | 0.00 | 0.87 | 1.15 |
| | HH+VV | 0.00 | 0.02 | 0.00 | 0.00 | 0.99 | 1.01 |
| | HH-VV | 0.00 | 0.00 | 0.00 | 0.00 | 0.19 | 5.33 |
| | CP - Ang. Alpha | 20.39 | 57.22 | 45.74 | 6.58 | 0.14 | 6.95 |
| | CP - Anisotropia | 0.39 | 0.69 | 0.56 | 0.04 | 0.08 | 12.57 |
| | CP - Entropia | 0.37 | 0.93 | 0.84 | 0.10 | 0.12 | 8.05 |
| | VZ - Double bounce | 0.00 | 0.00 | 0.00 | 0.00 | 0.15 | 6.58 |
| | VZ - Superficial | 0.00 | 0.02 | 0.00 | 0.00 | 1.16 | 0.86 |
| | VZ - Volumétrico | 0.00 | 0.00 | 0.00 | 0.00 | 0.02 | 54.35 |

Tabela 4.7 – ENL para amostra de água das imagens do ângulo SQ27.

| | Imagem | Mínimo | Máximo | Média | Desvio - Padrão | CV | ENL |
|---|---|---|---|---|---|---|---|
| SQ27 | HH | 0.001 | 0.003 | 0.002 | 0.000 | 0.174 | 5.756 |
| | HV | 0.000 | 0.001 | 0.001 | 0.000 | 0.152 | 6.591 |
| | VV | 0.001 | 0.005 | 0.003 | 0.001 | 0.243 | 4.120 |
| | HH+VV | 0.001 | 0.005 | 0.003 | 0.001 | 0.234 | 4.267 |
| | HH-VV | 0.001 | 0.003 | 0.002 | 0.000 | 0.157 | 6.355 |
| | CP - Ang. Alpha | 33.974 | 53.855 | 43.067 | 3.183 | 0.074 | 13.528 |
| | CP - Anisotropia | 0.288 | 0.591 | 0.447 | 0.054 | 0.121 | 8.261 |
| | CP - Entropia | 0.721 | 0.929 | 0.831 | 0.046 | 0.055 | 18.034 |
| | VZ - Double bounce | 0.002 | 0.002 | 0.002 | 0.000 | 0.026 | 37.818 |
| | VZ - Superficial | 0.002 | 0.004 | 0.003 | 0.001 | 0.236 | 4.237 |
| | VZ - Volumétrico | 0.002 | 0.002 | 0.002 | -NaN | -NaN | -NaN |

Um teste de correlação entre as variáveis independentes foi realizado e percebeu-se que todas as variáveis independentes são altamente correlacionadas entre si, consideradas dentro de um mesmo ângulo de incidência. Esse resultado mostra que a classe Floresta Inundável possui resposta muito semelhante independentemente do tipo de imagem (diferentes polarizações e decomposições polarimétricas) na banda C.

Dessa maneira, buscando ajustar modelos que possuam de fato informações descorrelacionadas, para cada ângulo, apenas as imagens com a maior correlação com o atributo de campo analisado foram escolhidas para o ajuste dos modelos preditivos (Tabela 4.8).

Tabela 4.8 – Variáveis independentes descorrelacionadas (correlações, entre si, menores que 0,3) apresentaram as maiores correlações com os atributos de campo. Células azuis correspondem ao ângulo SQ7, rosas ao ângulo SQ14 e laranjas, SQ27.

| Var. Dependentes | Var. Independentes | Correlação | Ajuste |
|---|---|---|---|
| DAP | SQ7_C_33 | -0.701 | Db x Linear |
| | SQ14_T_22 | -0.649 | Linear x Log10 |
| | SQ14_VZ_double | -0.712 | Linear x Linear |
| | SQ27_C_33 | -0.640 | Db x Linear |
| Altura de Inundação | SQ7_CP_ani | 0.639 | Linear x Linear |
| | SQ27_CP_ani | -0.629 | Db x Linear |
| Densidade de Indivíduos | SQ14_C_33 | 0.548 | Linear x Log10 |
| | SQ27_VZ_vol | 0.740 | dB x Log10 |
| IAF | SQ7_VZ_vol | 0.689 | dB x Log10 |
| | SQ14_VZ_vol | 0.823 | Db x Linear |
| | SQ27_VZ_odd | 0.783 | dB x Log10 |

Percebe-se que os modelos ajustados utilizando decomposições polarimétricas apresentaram desempenhos melhores que aqueles da diagonal da matriz C (HH, HV e VV) (tabela 4.9). Todos os modelos que, por sua vez, utilizaram imagens da diagonal da matriz C foram ajustados com a polarização VV, mostrando que essa polarização possui melhor desempenho que as outras para estimar atributos estruturais da floresta de várzea.

Os gráficos de dispersão, histograma dos erros, análise da aleatoriedade dos resíduos e teste da normalidade dos ruídos podem ser encontrados no Apêndice D, nas figuras D.1 à D.11.

Tabela 4.9 – Coeficiente de determinação R², RMSE e coeficientes a e b da reta de regressão para cada modelo linear ajustado. Células azuis correspondem ao ângulo SQ7, rosas ao ângulo SQ14 e laranjas, SQ27. Células azuis correspondem ao ângulo SQ7, rosas ao ângulo SQ14 e laranjas, SQ27.

| Var. Dependente | Var. Independente | Ajuste (imagem x atributo) | R² | RMSE | RMSE (%) | b | a |
|---|---|---|---|---|---|---|---|
| DAP | SQ7_C_33 | dB x Linear | 0.49 | 3.05 | 15.51 | -13.585 | -2.344 |
| | SQ14_VZ_double | Linear x Linear | 0.51 | 2.91 | 14.78 | 35.116 | -279.935 |
| | SQ27_C_33 | dB x Linear | 0.47 | 3.10 | 15.72 | -18.416 | -1.505 |
| Altura de Inundação | SQ7_CP_ani | Linear x Linear | 0.41 | 0.86 | 21.67 | 0.637 | 9.707 |
| | SQ27_CP_ani | dB x Linear | 0.38 | 0.90 | 22.61 | 7.565 | 7.618 |
| Densidade de Indivíduos | SQ14_C_33 | Linear x Log10 | 0.30 | 228.75 | 31.36 | 2.356 | 3.022 |
| | SQ27_VZ_vol | dB x Log10 | 0.55 | 219.27 | 30.06 | 4.989 | 0.085 |
| IAF | SQ7_VZ_vol | dB x Log10 | 0.47 | 0.83 | 17.99 | 1.857 | 0.060 |
| | SQ14_VZ_vol | dB x Linear | 0.68 | 0.61 | 13.22 | 14.473 | 0.414 |
| | SQ27_VZ_odd | dB x Log10 | 0.61 | 0.72 | 15.52 | 1.595 | 0.058 |

Para a variável dependente DAP, o melhor modelo foi ajustado utilizando-se a imagem do espalhamento *double-bounce* da decomposição de van Zyl, no ângulo de incidência SQ14 ($R^2$ = 0,51 e RMSE = 2,91 ou 14,78%) (Figura 4.35). Para a densidade de indivíduos, a decomposição de van Zyl, componente volumétrica, para o maior ângulo de incidência, apresentou melhor desempenho ($R^2$ = 0,55 e RMSE = 219,27 ou 30,06%) (Figura 4.36). Para o IAF, o melhor modelo foi gerado através da imagem da decomposição de van Zyl, componente volumétrica, para o ângulo SQ14 ($R^2$ = 0,68 e RMSE = 0,61/13,22%) (Figura 4.37).

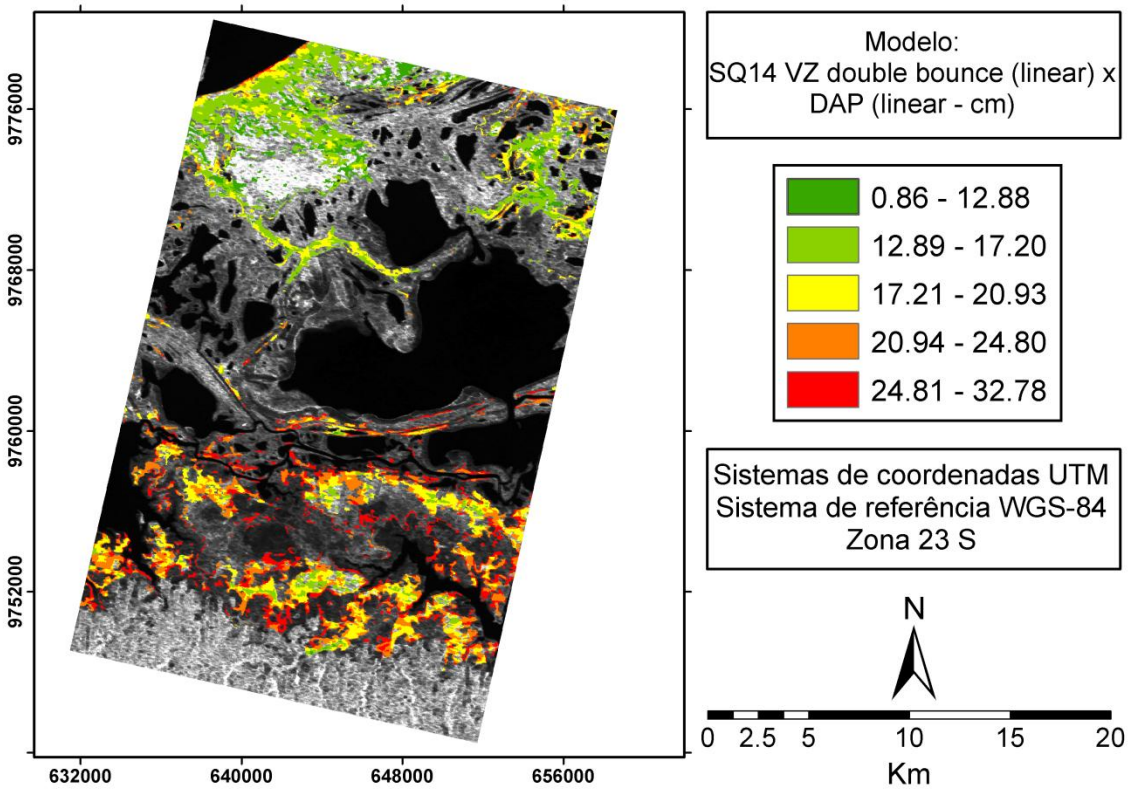


Figura 4.35 – Modelo SQ14 van Zyl *double-bounce,* em escala linear, para a estimativa do DAP (cm). Dados Radarsat-2 © MacDonald, Dettwiler e Associados, Ltd.

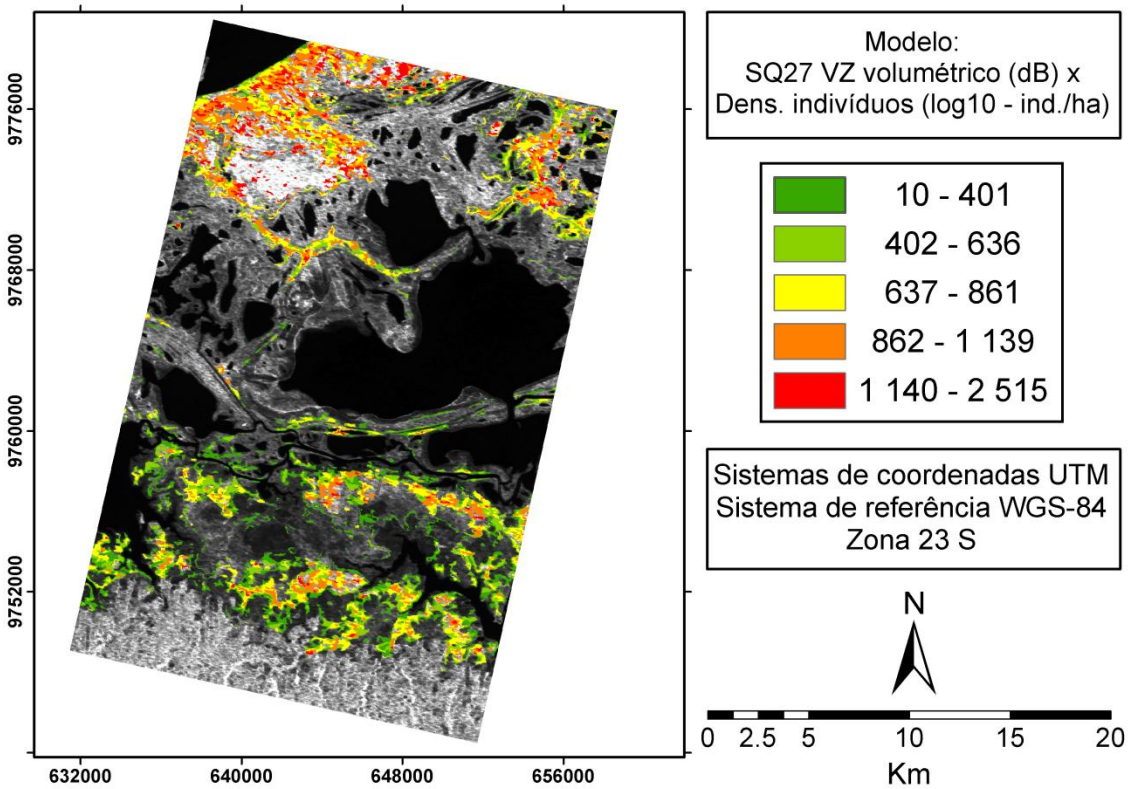


Figura 4.36 – Modelo SQ27 van Zyl volumétrico, em dB, para a estimativa do log10 da densidade de indivíduos (ind./ha). Dados Radarsat-2 © MacDonald, Dettwiler e Associados, Ltd.

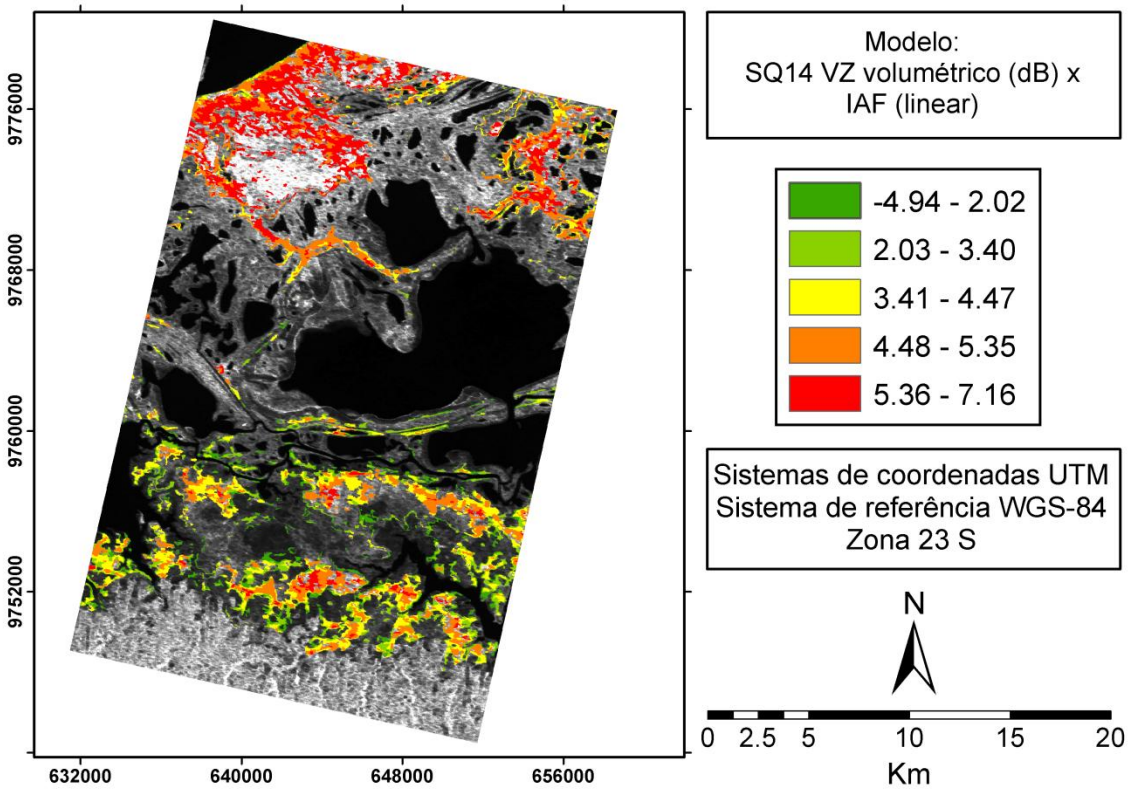


Figura 4.37 – Modelo empírico SQ14 van Zyl volumétrico, em dB, para a estimativa do IAF. Dados Radarsat-2 © MacDonald, Dettwiler e Associados, Ltd.

A variável altura de inundação apresentou os melhores resultados para a imagem anisotropia, da decomposição de Cloude – Pottier e tiveram como entrada imagens dos ângulos SQ7 e SQ27, sendo que o SQ7 obteve o melhor desempenho (figura 4.38).

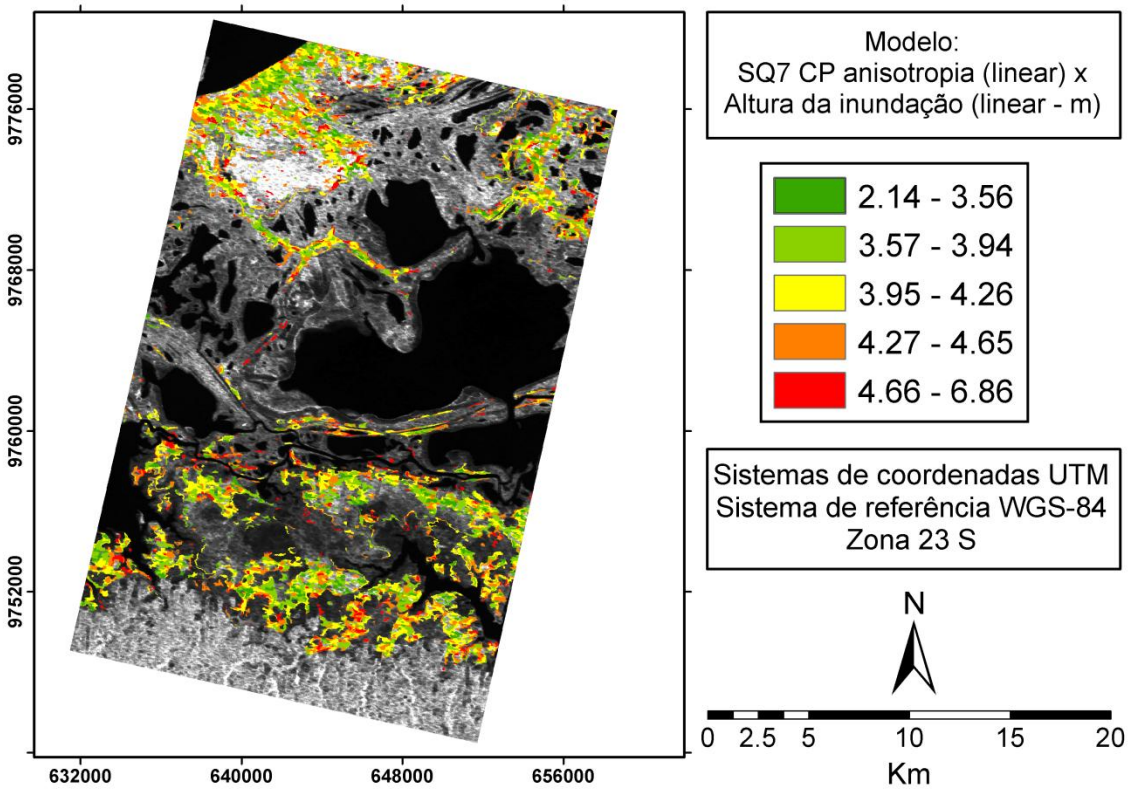


Figura 4.38 – Modelo empírico SQ7 Cloude - Pottier anisotropia, em escala linear, para a estimativa da altura de inundação (m). Dados Radarsat-2 © MacDonald, Dettwiler e Associados, Ltd.

Os modelos que estimam a altura de inundação, embora apresentem desempenhos similares, apresentaram correlação inversa com a variável dependente. ($R^2$ = 0,41 e 0,38; RMSE = 0,86/21,67% e 0,9/22,61%; correlação de Pearson: 0,639 e -0,629, respectivamente para os ângulos SQ7 e SQ27).

Para avaliar em que medida o tamanho da amostra ou a presença de ruídos estaria afetando esses resultados, foram feitas as seguintes análises: (a) verificou-se os valores de entropia associados a cada observação, (b) observou-se a distribuição dos valores de anisotropia em função do aumento da altura de inundação e (c) calculou-se a correlação de Pearson entre a imagem anisotropia do ângulo SQ7 e SQ27.

Os resultados mostram que os valores de entropia associados as observação foram sempre superiores a 0,7 (Tabela 4.10), o que permite descartar que o comportamento dos modelos se deva a ruídos na anisotropia decorrentes dos baixos valores de entropia (LEE; POTTIER, 2009).

Tabela 4.10 – Comparação entre os valores de entropia e anisotropia para os ângulos de incidência SQ7 e SQ27.

| Anisotropia - SQ7 | Entropia - SQ7 | Anisotropia - SQ27 | Entropia - SQ27 |
|---|---|---|---|
| 0.389 | 0.784 | 0.481 | 0.777 |
| 0.329 | 0.785 | 0.380 | 0.773 |
| 0.322 | 0.766 | 0.452 | 0.757 |
| 0.492 | 0.779 | 0.338 | 0.732 |
| 0.230 | 0.775 | 0.398 | 0.709 |
| 0.277 | 0.762 | 0.463 | 0.770 |
| 0.373 | 0.766 | 0.478 | 0.746 |
| 0.296 | 0.774 | 0.356 | 0.722 |
| 0.376 | 0.794 | 0.374 | 0.791 |
| 0.408 | 0.815 | 0.317 | 0.770 |
| 0.338 | 0.726 | 0.374 | 0.752 |
| 0.332 | 0.737 | 0.452 | 0.761 |
| 0.474 | 0.768 | 0.372 | 0.744 |
| 0.303 | 0.801 | 0.412 | 0.770 |
| 0.316 | 0.777 | 0.455 | 0.721 |
| 0.287 | 0.786 | 0.419 | 0.728 |
| 0.315 | 0.799 | 0.357 | 0.763 |

Em relação ao comportamento da anisotropia em função da altura de inundação para os ângulos SQ7 e SQ27 (figura 4.59) observou-se a tendência crescente para o menor ângulo e decrescente para o maior ângulo, o que explica as correlações positivas e negativas, respectivamente.

A matriz de correlação entre as imagens anisotropia dos ângulos de incidência SQ7 e SQ27 (Tabela 4.11) aponta que há pouca correlação entre as duas cenas (aproximadamente -0,32), mostrando que de fato as duas cenas são relativamente diferentes entre si e também opostas.

Esses resultados mostram que, como é afirmado por Touzi et al. (2009), os parâmetros calculados pela decomposição de Cloude – Pottier (ângulo alpha, anisotropia e entropia) variam em função do ângulo de incidência, ou seja, não são estáveis em função da base de polarização. Ao mesmo tempo em que esse acontecimento pode causar ambiguidades nas respostas dos alvos naturais, pode também ressaltar diferentes partes da estrutura da vegetação, por intensificar a interação da REM com determinadas partes da floresta, como o dossel, o tronco e o substrato.

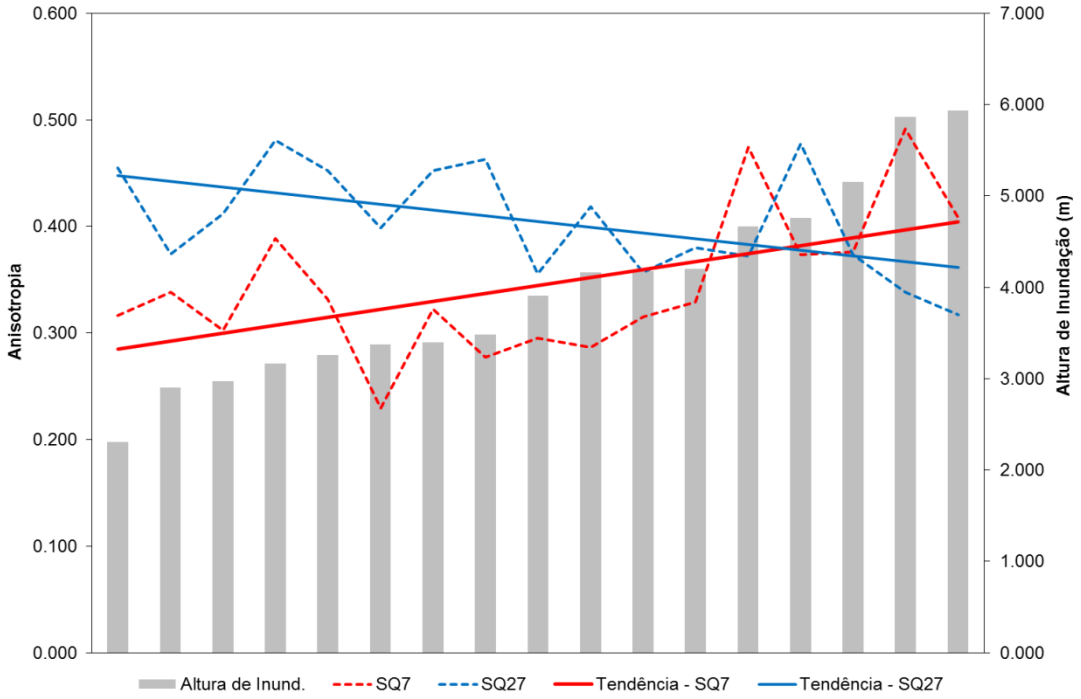


Figura 4.39 – Tendência crescente para os valores de anisotropia do ângulo de incidência SQ7 (linhas em vermelho) e decrescentes para o ângulo SQ27 (linhas em azul) em função do aumento da altura de inundação (barras cinza).

Tabela 4.11 – Matriz de correlação de Pearson entre as anisotropias dos ângulos de incidência SQ7 e SQ27.

| | **Anisotropia - SQ7** | **Anisotropia - SQ27** |
|---|---|---|
| **Anisotropia - SQ7** | 1 | -0.321 |
| **Anisotropia - SQ27** | -0.321 | 1 |

Um problema observado para todos os modelos é que eles não apresentam uma distribuição aleatória dos resíduos, os quais tendem a crescer com o aumento dos valores da variável dependente (o que pode ser observado nas Figuras D.1 a D.11). Esse comportamento dos indica que as variáveis independentes (no caso as imagens PolSAR) não explicam totalmente a variância das variáveis biofísicas selecionadas. Esse fato pode ser explicado pela saturação do retroespalhamento na banda C em dosséis de formações de vegetação lenhosa (HENDERSON; LEWIS, 1998; HENDERSON; LEWIS, 2008) ou pela diferença de dois anos entre as datas da imagem e do campo, tanto em relação às mudanças da vegetação como em condições de umidade.

Apesar da heterocedasticidade dos modelos, eles foram capazes de explicar semi-quantitativamente a estrutura da vegetação da várzea da área de estudo: na região norte das imagens, percebe-se que há uma maior densidade de indivíduos com troncos finos e dosséis bem fechados, ao passo que a região sul da imagem se caracteriza por um número menor de indivíduos com troncos mais grossos e dosséis mais abertos, com menor presença de sub-bosque. A floresta da várzea mais ao sul da imagem possui estágio sucessional mais próximo do clímax, ao passo que a região norte caracteriza-se por uma floresta em desenvolvimento ou por coberturas mais próximas de uma formação arbustiva. E isso pode ser associado à altura de inundação: a região norte da imagem apresenta os maiores valores, ao passo que a região sul da imagem possui menor altura de inundação.

Dessa forma, verificou-se que os dados SAR de banda C mostraram forte correlação com importantes atributos relacionados à vegetação da várzea – DAP, IAF, Altura de Inundação e Densidade de Indivíduos, mesmo utilizando apenas 17 pontos de campo. As imagens PolSAR também se mostraram radiometricamente sensíveis à pouca variação dos valores dos atributos: a vegetação amostrada em campo possui um range de valores pequenos e mesmo assim os modelos lineares ajustados para esses atributos foram

capazes de perceber essa pouca variação, apesar dos ruídos heterocedásticos.

As imagens SAR adquiridas segundo maiores ângulos de incidência foram aquelas cujos produtos apresentaram as correlações mais altas com os atributos biofísicos da vegetação de várzea. Entre as imagens multipolarizadas e as decomposições de alvos, as últimas apresentaram correlações mais fortes que as primeiras, gerando os melhores modelos. Sartori et al. (2012) e Proisy et al. (2000) relatam que a polarimetria e os atributos polarimétricos são bons estimadores de atributos biofísicos tanto para macrófitas como em regiões de mangue, tanto para banda C como para L, X e P. Como as decomposições polarimétricas estimam mecanismos de espalhamento específicos, aumentam a sensibilidade do dado a esse mecanismo, melhorando a distribuição dos valores de retroespalhamento e assim, permitindo um melhor ajuste com os modelos.

Em relação ao DAP, Townsend (2002) relata que a penetração da REM do radar no dossel vegetal é altamente correlacionada com atributos derivados do tronco da vegetação, principalmente para a polarização VV. Esse resultado pode ser observado para esse estudo, onde todos os modelos gerados com as imagens da matriz C, para estimar o DAP, foram utilizando essa polarização. Para esses modelos a correlação entre o sinal do radar e o DAP foi negativa, indicando que árvores mais grossas atenuam o sinal com mais intensidade do que árvores mais finas. Também podem indicar que regiões com DAP menor possuem mais indivíduos finos, aumentando o retroespalhamento da REM, ao passo que regiões com elevados valores de DAP possuem menos indivíduos, com troncos mais grossos.

Os modelos que estimaram o IAF foram aqueles que apresentaram os maiores coeficientes de determinação e os menores erros médios quadráticos, mostrando que o sinal de banda C possui forte correlação com essa variável. Dessa vez, a correlação foi positiva, mostrando que o aumento do IAF causa

maior retroespalhamento no sinal do radar, pelo aumento dos elementos espalhadores (folhas e pequenos galhos, no caso da banda C). Assim como o IAF, a Densidade de Indivíduos apresentou correlação positiva com o sinal do SAR. Quanto maior essa variável, mais indivíduos estão presentes em uma dada área e assim, maior é a disponibilidade de elementos espalhadores em contato com a REM do radar.

Para a Altura de Inundação existe uma tendência de diminuição do IAF e Área Basal quando a Altura de Inundação aumenta. Assim, como o ângulo SQ7 apresenta maior penetração no dossel, na medida em que o IAF e a Área Basal diminuem, diminui o espalhamento volumétrico (relacionado ao IAF) e os double-bounces (relacionados a Área Basal) e aumenta a interação com o substrato (liteira e sub bosque), colaborando para um aumento da anisotropia. O contrário acontece para o ângulo de incidência SQ27: quando o IAF e a Área Basal diminuem, também diminui a atenuação da REM dentro do dossel. Dessa maneira, há maior sinal de retorno do espalhamento volumétrico e double-bounce, aumentando a importância deles em relação ao superficial. Dessa maneira, a anisotropia diminui. Percebe-se dessa maneira que, apesar da altura de inundação ter sido medida indiretamente em campo, ela causa mudanças na estrutura da floresta e, portanto, pode ser estimada indiretamente.

Isso tudo indica que a banda C possui correlação com importantes atributos biofísicos da vegetação e que mais campanhas de campo para coletas de pontos de controle podem melhorar o ajuste desses modelos e seu desempenho.

# 5. CONCLUSÕES GERAIS

A hipótese inicial do trabalho pode ser parcialmente aceita: 1) o uso de decomposições polarimétricas melhora o desempenho tanto da classificação e a modelagem preditiva; 2) a melhora do desempenho da classificação, contudo é limitada ás classes de maneira individual, o que faz com que os erros de classificação para o conjunto apresente índices de validação semelhantes aos da classificação utilizando atributos multitemporais ou multipolarizados; 3) com o uso de OBIA e de árvore de decisão personalizada torna-se possível gerar uma classificação em que para cada classe, sejam utilizadas apenas as imagens que apresentaram o melhor desempenho tanto em relação ao Kappa, quanto ao AD e QD.

A modelagem preditiva mostrou bons resultados, tendo em vista o número limitado de amostras e a pequena amplitude dos valores apresentados pelas variáveis biofísicas. Isso mostra que a banda C é sensível aos parâmetros biofísicos da Floresta Inundável da várzea do Lago Grande de Curuai. As decomposições polarimétricas geraram os melhores modelos, e os ângulos de incidência maiores também foram aqueles que apresentaram as mais altas correlação com as variáveis biofísicas.

Como pesquisas futuras, esse trabalho divide-se em dois ramos principais: (a) relacionado à classificação e mapeamento dos tipos de vegetação de várzea amazônica e (b) à modelagem de seus parâmetros.

Com relação a (a), pesquisas futuras vão investigar outros algoritmos de mineração de dados (como Random Forests e Support Vector Machines – SVM) e seus desempenhos na classificação de dados PolSAR. Método similar a adotada a essa será aplicada a dados multifrequência, usando imagens ALOS-PALSAR, e, quando disponível, ALOS-PALSAR 2 polarimétrico.

Com relação a (b), mais campanhas de campo serão realizadas para aumentar o banco de dados de pontos de controle na várzea do Lago Grande de Curuai,

para um melhor ajuste de modelos preditivos de propriedades estruturais da floresta de várzea. Será investigada a predição das variáveis usando modelos multivariados e não-lineares, e também o uso de dados multifrequência, principalmente no tocante ao uso de razões de imagens multifrequência, buscando superar as limitações de cada uma das bandas espectrais utilizadas. Algoritmos de mineração de dados também serão utilizados para testar a combinação de todas as imagens entre si, buscando o melhor modelo possível para cada atributo da vegetação da várzea.

## REFERÊNCIAS BIBLIOGRÁFICAS


ALSDORF, D. E.; MELACK, J. M.; DUNNE, T.; MERTES, L. A. K.; HESS, L. L.; SMITH, C. L. Interferometric Radar Measurements of Water Level Changes On the Amazon Floodplain. **Nature**, v. 404, p. 174 – 177, 2000.

AMARAL, M.V.F.; SOUZA, A. L.; SOARES, V. P.; SOARES, C. P; LEITE, H. G.; MARTINS, S.V.; FERNANDES FILHO, S.V.; LANA, E.I.J.M. Avaliação e comparação de métodos de classificação de imagens de satélites para o mapeamento de estádios de sucessão florestal. **Revista Árvore**, v. 33, n. 3, p. 575-582, 2009.

AGÊNCIA NACIONAL DE ÁGUAS (ANA). **Séries históricas**. plataforma hidroweb. Retrieved 23 Agos 2012, from http://hidroweb.ana.gov.br/. 2012

ARNESEN, A. S., SILVA, T. S. F., HESS, L. L., NOVO, E. M. L. M., RUDORFF, C. M., CHAPMAN, B. D., & MCDONALD, K. C. Monitoring flood extent in the lower Amazon River floodplain using ALOS/PALSAR ScanSAR images. **Remote Sensing of Environment,** v. 130, pp. 51–61, 2013.

ARNESEN, A. S.; SILVA, T. S. F.; HESS, L. L.; NOVO, E. M. L. M.; RUDORFF, C. M.; CHAPMAN, B. D. MCDONALD, K. C. Monitoring flood extent in the lower Amazon River floodplain using ALOS/PALSAR ScanSAR images. **Remote Sensing of Environment**, v. 130, p. 51 – 61, 2013.

BARBOSA, C. C. F. **Sensoriamento remoto da dinâmica de circulação da água do sistema planície de Curuai/Rio Amazonas**. 2005. 286p. (INPE – 14614 – TDI/1193). Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005. Disponível em: <http://urlib.net/6qtX3pFwXQZGivnJSY/KfjFc>. Acesso em: 14 abr. 2014.

BENNETT, L. T.; JUDD, T. S.; ADAMS, M. A. Close-Range Vertical Photography for Measuring Cover Changes in Perennial Grasslands**. Journal of Range Management,** v. 53, n. 6, p. 634-641, 2000.

BENZ, U. C., HOFMANN, P. WILLHAUCK, G. LINGENFELDER, I. HEYNEN, M. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 58, n. 3 – 4, p. 239 – 258, 2004.

Blaschke, T. Object Based Image Analysis For Remote Sensing. **ISPRS Journal of Photogrammetry and Remote Sensing,** v. 65, n. 1, pp. 2 – 16, 2010.

BONNET, M. P.; BARROUX, G; MARTINEZ, J. M; SEYLER, F.; MOREIRA-TURCQ, P.; COCHONNEAU, G.; MELACK, J. M.; BOAVENTURA, G.; MAURICE-BOURGOIN, L.; LEÓN, J. G.; ROUX, E.; CALMANT, S.; KOSUTH, P.; GUYOT, J. L.; SEYLER, P. Floodplainhydrology in anAmazonfloodplainlake (Lago Grande de Curuai). **Journal of Hydrology**, v. 349, n. 1-2, p. 18-30, 2008.

BOOTH, D. T.; COX, S. E.; MEIKLE, T. W.; FITZGERALD, C.The accuracy of ground-cover measurements. **Rangeland Ecology & Management**, v. 59, n. 2, p. 179-188, 2006.

BRISCO, B.; LI, K.; TEDFORD, B.; CHARBONNEAU, F.; YUN, S.; MURNAGHAN, K. Compact polarimetry assessment for Rice and wetland mapping. **International Journal of Remote Sensing**, v. 34, n. 6, p. 1949 – 1964, 2013.

BWANGOY, J. R. B.; HANSEN, M. C.; ROY; D. P.; GRANDI; G.; JUSTICE; C. O. Wetland mapping in the Congo basin using optical and radar remotely sensed data and derived topographical índices. **Remote Sensing of Environment**, v. 114, n. 1, p. 73 – 86, 2010.

CARREIRAS, J. M. B.; VASCONCELOS, M. J.; LUCAS, R. M. Understanding the relationship between aboveground biomass and ALOS/PALSAR data in the forests of Guinea-Bissau (West Africa).**Remote Sensing of Environment**, v. 121, p. 426 – 442, 2012.

CASTELLO, L.; MCGRATH, D.; HESS, L. L.; COE, M. T.; LEFEBVRE, P. A., PETRY, P.; MACEDO, M. N.; RENÓ, V. F.; ARANTES, C. C. The vulnerability of Amazon freshwater ecosystems.**Conservation Letters** (Advanced Online Publication, DOI 10.1111/conl.12008), 2012.

CLOUDE, S. R. **Polarisation:** applications in remote sensing. New York: Oxford University Press. 2009, 453 p.

CONGALTON, R. G. A Review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, n. 1, pp 35–46, 1991.

COSTA, M. P. F.; NIEMANN, O.; NOVO, E.; AHERN, A. Biophysical properties and mapping of aquatic vegetation during the hydrological cycle of the Amazon floodplain using JERS-1 and Radarsat. **International Journal of Remote Sensing**, v. 23, n. 7, p. 1401 – 1426, 2002.

Costa, M. P. F., Telmer, K. H. Utilizing SAR imagery and aquatic vegetation to map fresh and brackish lakes in the Brazilian Pantanal wetland. **Remote Sensing of Environment**, v. 105, n. 3, pp. 204–213, 2006.

DORREN, L.K.A.; MAIER, B; SEIJMONSBERGEN, A.C. Improved landsat-based forest mapping in steep mountainous terrain using object-based classification.**Forest Ecology and Management**, v. 183, n. 1-3, p. 31-46, 2003.

EFRON, B.; GONG, G. A leisurely look at the bootstrap, the jackknife and cross-validation.**The American Statistician**, v. 37, n. 1, p. 36 – 48. 1983.

FREEMAN, A.; DURDEN, S. L.A three-component scattering model for polarimetric SAR data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 36, n. 3, p. 963 – 973, 1998.

FURTADO, L.F.A.; SILVA, T. S. F.; NOVO, E.M.L.M. Backscattering response of different land cover types in the Lago Grande de Curuai floodplain (Amazon, Brazil) determined from Radarsat-2 and TerraSAR-X data. In: SIMPÓSIO

BRASILEIRO DE SENSORIAMENTO REMOTO, 16. (SBSR), 2013, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2013. p. 8475-8482. DVD, Internet. ISBN 978-85-17-00066-9 (Internet), 978-85-17-00065-2 (DVD). Disponível em: <http://urlib.net/3ERPFQRTRW34M/3E7GJ26>. Acesso em: 14 abr. 2014. GERGEL, S.E.; STANGE, Y.; COOPS, N.C.; JOHANSEN, K.; KIRBY, K.R. What is the value of a good map? An example using high spatial resolution imagery to aid riparian restoration. **Ecosystems**, v. 10, n. 5, p. 688-702, 2007.

GILLISON, A. N. **A field manual for rapid vegetation classification and survey for general purposes**. Bogor, Indonesia: Center for International Forestry Research. 2006, 85 p.

HARALICK, R. M.; SHANMUGAN, K.; ITS'HAK, D. Textural Features for Image Classification. **IEEE Transactions on Systems, Man and Cybernetics**, v. 3, n. 6, p. 610 – 621, 1973.

HENDERSON, F.; LEWIS, A. **Principles and applications of imaging radar -** manual of remote sensing. 3.ed. New York: Wiley, 1998. v. 2. p. xxiv + 866.

HENDERSON, F.; LEWIS, A. Radar detection of wetland ecosystems: a review**.** **International Journal of Remote Sensing**, v. 29, n. 20, p. 5809–5835, 2008.

HESS, L. L.; MELACK, J. M.; SIMONETT, D. S. Radar detection of flooding beneath the forest canopy: a review. **International Journal of Remote Sensing**, v. 11, n. 7, p. 1313 – 1325, 1990.

HESS, L. L.; MELACK, J. M.; FILOSO, S.; WANG, Y. Delineation of inundated area and vegetation along the Amazon floodplain with the SIR-C synthetic aperture radar. **IEEE Transactions on Geoscience and Remote Sensing**, v. 33, n. 4, p. 893 – 904, 1995.

HESS, L. L.; MELACK, J. M.; NOVO, E. M. L. M.; BARBOSA, C. C. F.; GASTIL, M. Dual-season mapping of wetland inundation and vegetation for the central

Amazon basin. **Remote Sensing of Environment**, v. 87, n.4, p. 404–428, 2003.

JENSEN, J. R. **Remote sensing of the environment: an Earth resource perspective**. 2. ed. Englewood Cliffs: Prentice Hall, 2007. 544 p.

JOHANSEN, K.; COOPS, N.C.; GERGEL, S.E.; STANGE, Y. Application of high spatial resolution satellite image for riparian and forest ecosystem classification. **Remote Sensing of Enviroment**, v. 110, n. 1, p. 29-44, 2007.

JUNK, W. J., BAYLEY, P. B., SPARKS, R. E. The flood pulse concept in river-floodplain systems. **Canadian Special Publications in Fisheries and Aquatic Sciences**, 106, 110–127. 1989.

JUNK, W. J.; PIEDADE; M. T. F.Plant life in the floodplain with special reference to herbaceous plants. In: JUNK, W. J. (Ed). **The central Amazon floodplain**: ecology of a pulsing system. Berlin: Springer, 1997. Cap. 8. P. 147 – 186.

JUNK, W. J. General aspects of floodplain ecology with special reference to Amazonian floodplains. In: JUNK, W. J. (Ed). **The central Amazon floodplain**: ecology of a pulsing system. Berlin: Springer, 1997. Cap. 1. P. 3 – 22.

JUNK, W. J., PIEDADE, M. T. F., SCHÖNGART, J., WITTMANN, F.A classification of major natural habitats of Amazonian white-water river floodplains (várzeas).**Wetlands Ecology and Management**, v. 20, n. 6, pp. 461 – 475, 2012.

JUNK, W.J., PIEDADE, M.T.F., LOURIVAL, R., WITTMANN, F., KANDUS, P., LACERDA, L.D., BOZELLI, R.L., ESTEVES, F.A., NUNES DA CUNHA, C., MALTCHIK, L., SCHÖNGART, J., SCHAEFFER-NOVELLI, Y., AGOSTINHO, A.A., NÓBREGA, R.L.B. **Definição e Classificação de Áreas Úmidas (AUs) Brasileiras**: base científica para uma nova política de proteção e manejo sustentável. Cuiabá: Instituto Nacional de Ciência e Tecnologia em Áreas Úmidas – INAU. Disponível em http://www.inau.org.br/. Acesso em 13/02/2014.

KASISCHKE. E. S.; MELACK, J. M.; DOBSON, C. The use of imaging radars for ecological applications – a review. **Remote Sensing of Environment**, v. 59, n. 2, p. 141 – 156; 1997.

KLEMAS, V. Remote sensing of coastal wetland biomass: an overview. **Journal of Coastal Research**, v. 29, n. 5, pp. 1016 – 1028. 2013.

KOCH, M.; SCHMID, T.; REYES, M. GUMUZZIO, J. Evaluating full polarimetric C- and L- band data for mapping wetland conditions in a semi-arid environment in central Spain. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 5, n. 3, p. 1033 – 1043, 2012.

LANG, M. W.; TOWNSEND, P. A.; KASISCHKE, E. S. Influence of incidence angle on detecting flooded forests using C-HH synthetic aperture radar data. **Remote Sensing of Environment**, v. 112, n. 10, p. 3898 – 3907, 2008.

LAUR, H.; BALLY, P.; MEADOWS, P.; SANCHEZ, J.; SCHAETTLER, B.; LOPINTO, E. **Derivation of the backscattering coefficient $\sigma^0$ in ERS.SAR.PRI products**. ESA/ESRIN, n. 2, Rev. 2. 1996.

LEE, J. S.; POTTIER, E. **Polarimetric radar imaging:** from basics to applications. New York: CRC Press. 2009. 398 p.

LI, J.; CHEN, W.; TOUZI, R. Optimum RADARSAT-1 configurations for wetlands discrimination: a case study of the MerBleue peat bog. **Canadian Journal of Remote Sensing**, v. 33, n. 1, p. 46-55, 2007.

LUCAS, R.M.; CARREIRAS, J.; PROISY, C; BUNTING, P. ALOS PALSAR applications in the Tropics and Subtropics: characterization, mapping and detecting change in forests and coastal wetlands. **ALOS PI symposium**, Rhodes, Greece, 2008. Disponível em http://amapmed.free.fr. Acessadoem 26/02/2013.

MARTI-CARDONA, B.; LOPEZ-MARTINES, C.; DOLZ-RIPOLLES, J.; BLADÈ-CASTELLET, E. ASAR polarimetric, multi-incidence angle and multitemporal

characterization of Doñana wetlands for flood extent monitoring. **Remote Sensing of Environment**, v. 114, n.11, p. 2802-2815, 2010.

MARTINEZ, J. M.; LE TOAN, T. Mapping of flood dynamics and spatial distribution of vegetation in the Amazon floodplain using multitemporal SAR data. **Remote Sensing of Environment**, v. 108, n. 3, p. 209 – 233, 2007.

MELACK, J. M.; HESS, L. L. Remote sensing of the distribution and extent of wetlands in the Amazon basin. In: JUNK, W. J. et al. (Ed). **Amazonian floodplain forests**: ecophysiology, biodiversity and sustainable management. New York: Springer Verlag, 2010. Cap. 3. P. 43-60.

MITSCH, W. J., BERNAL, B., NAHLIK, A. M., MANDER, U., ZHANG, LI., ANDERSON, C. J., JORGENSEN, S. E., BRIX, H. Wetlands, carbon, and climate change. **Landscape Ecology** (Advanced Online Publication, DOI: 10.1007/s10980-012-9758-8), 2012.

MITSCH, W. J., GOSSELINK, J. G. **Wetlands**.4° Ed. New York: John Wiley & Sons, 2007, 582 p.

MOREAU, S.; LE TOAN, T. Biomass quantification of Andean wetland forages using ERS satellite SAR data for optimizing livestock management**. Remote Sensing of Environment,** v. 84, n. 4, p. 477 – 492, 2003.

NARVAES, I. S. **Avaliação de dados SAR polarimétricos para estimativa de biomassa em diferentes fitofisionomias de florestas tropicais**. 2010. 190 p. (sid.inpe.br/mtc-m19@80/2010/08.09.22.43-TDI). Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2010. Disponível em: <http://urlib.net/8JMKD3MGP7W/3837N9S>. Acesso em: 26 fev. 2013.

NOVO , E. M. L. M.; COSTA, M. P. F.; MANTOVANI, J. E.; LIMA, I. B. T. Relationship between macrophyte stand variables and radar backscatter at L and C band, Tucuruí reservoir, Brazil. **International Journal of Remote Sensing**, vol. 23, n. 7, p. 1241 – 1260, 2002.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. 4° ed. São Paulo: Blucher, 1989. 363 p.

OLIVER, C.; QUEGAN, S. **Understanding synthetic aperture radar images**. Raleigh: SciTech Publishing. 2004, 489 p.

PAROLIN et al., 2010

PEET, R. K.; WENTWORTH, T. R.; WHITE, P. S.A flexible multipurpose method for recording vegetation composition and structure.**Castanea**, v. 63, n. 3, p. 262 – 274, 1998.

PIEDADE, M. T. F.; JUNK, W. J.; D'ÂNGELO, S. A.; WITTMANN, F.; SCHÖNGART, J.; BARBOSA, K. M. N.; LOPES, A. Aquatic herbaceous plants of the Amazon floodplains: state of the art and research needed. **Acta Limnologica Brasiliensia**, v. 22, n. 2, p. 165–178, 2010.

PONTIUS, R.G. JR.; MILLONES, M. Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. **International Journal of Remote Sensing,** v. 32, n. 15; p. 4407 – 4429,2011.

PROISY, C., MOUGIN, E., FROMARD, F., & KARAM, M. A. Interpretation of Polarimetric Radar Signatures of Mangrove Forests. **Remote Sensing of Environment**, v. 71, n. 1, pp. 56 – 66. 2000.

RENÓ, V. F.; NOVO, E. M. L. M.; SUEMITSU, C.; RENNÓ, C. D., SILVA, T. S. F. Assessment of deforestation in the Lower Amazon floodplain using historical Landsat MSS/TM imagery. **Remote Sensing of Environment,**v. 115, n. 12, p. 3446–3456, 2011.

SANT'ANNA, S.J.S.; MASCARENHAS, N.D.A. Comparação do desempenho de filtros redutores de "*speckle*". In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8. (SBSR), 1996, Salvador. **Anais...** São José dos Campos: INPE, 1996. p. 871-878. CD-ROM. ISBN 85-17-00014-5. (INPE-

6184-PRE/2273). Disponível em: <http://urlib.net/sid.inpe.br/deise/1999/02.01.15.54>. Acesso em: 14 abr. 2014. .

SARTORI, L. R.; IMAI, N. N.; MURA, J. C.; NOVO, E. M. L. M.; SILVA, T. S. F. Mapping macrophyte species in the Amazon floodplain wetlands using fully polarimetric ALOS/PALSAR data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 49, n. 12, p. 4717 – 4728, 2011.

SARTORI, L. R., IMAI, N. N., MURA, J. C., & TACHIBANA, V. M. Atributos polarimétricos de imagem radar na inferência de parâmetros morfológicos de macrofitas. **Boletim de Ciências Geodésicas**, v. 18, n. 1, pp. 138–153. 2012.

SCHÖNGART, J.; PIEDADE, M. T. F.; LUDWIGSHAUSEN, S.; HORNA, V.; WORBES, M. Phenology and stem-growth periodicity of tree species in Amazonian floodplain forests. **Journal of Tropical Ecology**, v. 18, n. 4, p. 581–597, 2002.

SILVA, T. S. F.; COSTA, M. P. F.; MELACK, J. M. Annual net primary production of macrophytes in the eastern Amazon floodplain.**Wetlands**, v. 29, n. 2, p. 747–758, 2009.

SILVA, T. S. F; COSTA, M. P. F.; MELACK, J. M. Spatial and temporal variability of macrophyte cover and productivity in the eastern Amazon floodplain: A remote sensing approach. **Remote Sensing of Environment**, v. 114, n. 9, p. 1998, 2010, 2010.

SILVA et al. 2013

SOUSA, A.M.O.; MESQUITA, P.; GONÇALVES, A.C.; MARQUES DA SILVA, J.R.; SILVA, L.L. **Detecção de vegetação arbórea através de segmentação e classificação orientada a objecto de imagens multiespectrais de alta resolução (QuickBird)**. Disponível em: http://hdl.handle.net/10174/2807. Acessado em: 11 - dez - 2011.

TOUZI, R. Target Scattering Decomposition in Terms of Roll-Invariant Target Parameters. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, n. 1, pp.73 – 84, 2007.

TOUZI, R., DESCHAMPS, A., ROTHER, G. Phase of Target Scattering for Wetland Characterization Using Polarimetric C-Band SAR. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 9, pp. 3241–3261. 2009.

TOWNSEND, P. A. Estimating forest structure in wetlands using multitemporal SAR**. Remote Sensing of Environment, v. 79, n. 2-3, p. 288 – 304, 2002.**

VAN DER SANDEN, J. J. **Radar remote sensing to support tropical forest management**.Wageningen: Wageningen Agricultural University, Tropenbos-Guyana Series 5.333 p, 1997.

WITTEN, I. H.; FRANK, E. **Data Mining – Practical Machine Learning Tools and Techniques**. 2. ed. San Francisco, CA. USA.: Elsevier, 2005; 525p.

WITTMANN, F.; HOUSEHOLDER, E.; PIEDADE, M. T. F.; ASSIS, R. L.; SCHONGART, J.; PAROLIN, P. JUNK, W. J. Habitat specifity, endemism and the neotropical distribution of Amazonian White-water floodplain trees. Ecography, v. 35, p. 1 – 18, 2012.

WITTMANN, F.; JUNK, W. J.; PIEDADE, M. T. F. The várzea forests in Amazonia: flooding and the highly dynamic geomorphology interact with natural forest sucession. **Forest Ecology and Management**, v. 196, n. 2 – 3, p. 199 – 212, 2004.

WITTMANN, F.; SCHÖNGART, J.;& JUNK, W. J. Phytogeography, species diversity, community structure and dynamics of central Amazonian floodplain forests.**In**JUNK, W. J.;PIEDADE, M. T. F.;WITTMANN, F; SCHÖNGART, J.;PAROLIN, P. (Eds.). **Amazonian floodplain forests**: ecophysiology, biodiversity and sustainable management. New York, NY: Springer Verlag., 2010. Cap. 4, p. 61–102.

WORBES, M. The forest ecosystem of the floodplains. In: JUNK, W. J. (Ed). **The central Amazon floodplain**: ecology of a pulsing system. Berlin: Springer, 1997. Cap. 11. P. 223 – 266.

YU, O.; GONG, P.; CLINTON, N.; BIGING, G.; KELLY, M.; SHIROKAUER, D. Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery. **Photogrammetic Engineering and Remote Sensing**, v. 72, n. 7, p. 799-811, 2006.

## APÊNDICE A – TESTE DA JANELA DO FILTRO *SPECKLE*

Pode-se observar que a partir do tamanho de janela 5x5 (Figura 4.1), há pouca redução do CV quando comparada com o nível anterior – há forte diminuição do CV para a janela 3x3, tornando-se menor na janela 5x5, e decrescendo ainda mais para cada incremento no tamanho da janela, tornando-se quase estável à partir de 9x9.

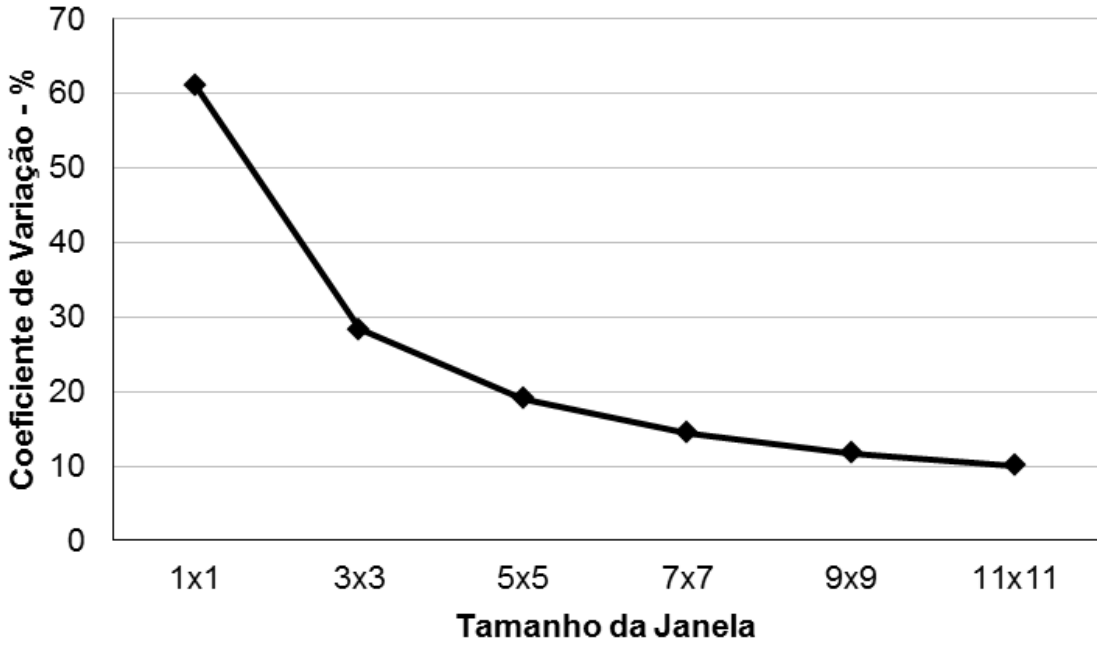


Figura A.1 - Análise do decréscimo do coeficiente de variação (CV) para diferentes janelas para o filtro polarimétrico *Refined Lee*, para a cena SQ7 da época da cheia, na polarização HH, em *slant range*, em regiões de Floresta de Terra Firme.

Analisando os efeitos de cada janela visualmente (Figura A.2) percebe-se excessivo borramento das bordas entre as diferentes classes, além da perda de informações da rugosidade e textura dos alvos, principalmente para janelas maiores que 7x7. Nota-se ainda que, a partir da janela 7x7, há a formação de artefatos em regiões com gradientes de bordas excessivos, como em transições entre regiões cobertas por água e por vegetação (Figura 4.3).

Dessa maneira, o melhor custo-benefício foi obtido com a janela de tamanho 5x5, sendo utilizado para processar todas as imagens nas etapas posteriores.

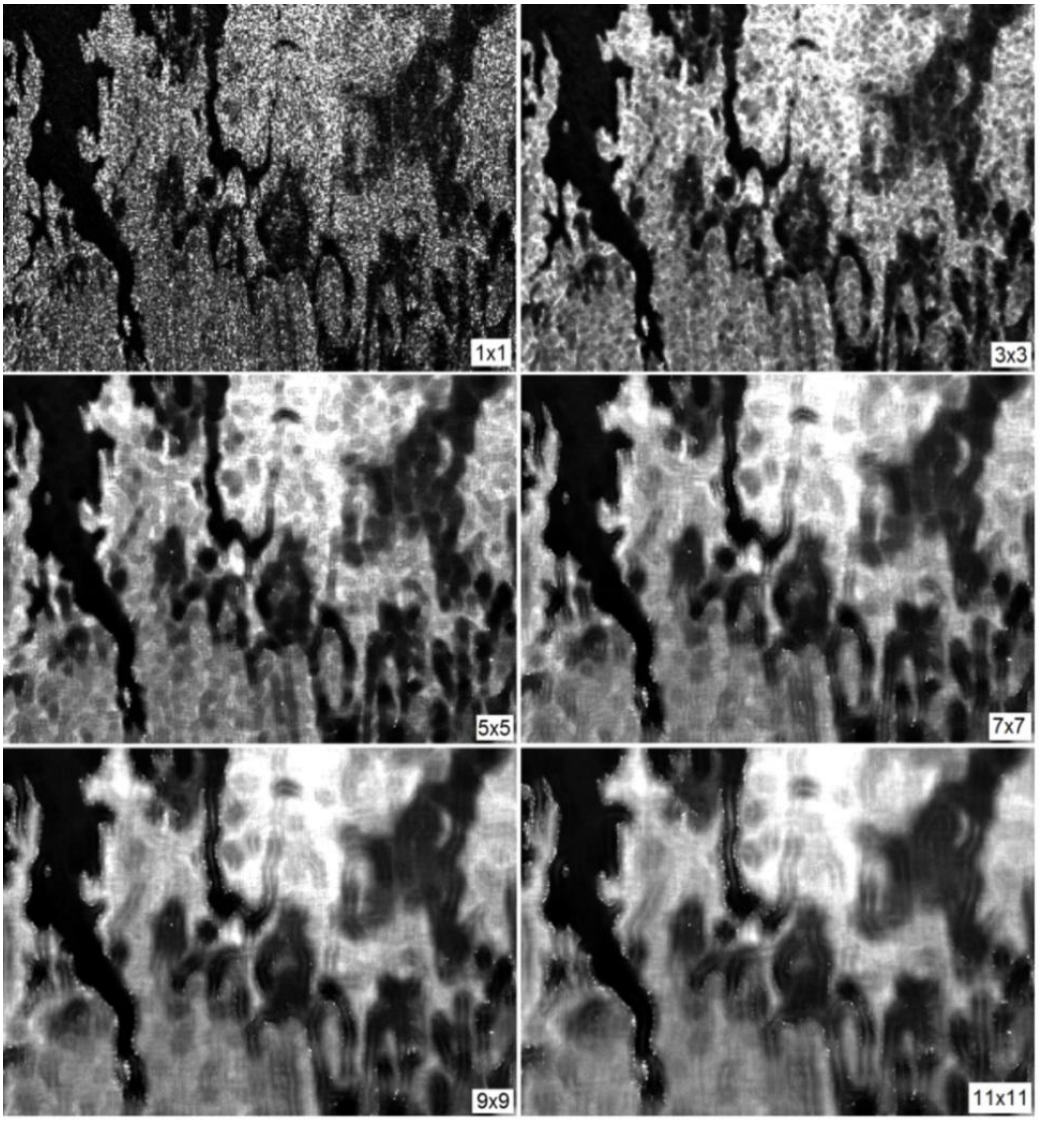


Figura A.2 - Efeito da aplicação do filtro *Refined Lee* para diferentes tamanhos de janelas de operação. Imagem: polarização HH, ângulo de incidência SQ7, *slant range*, na época da cheia. Cenas Radarsat-2 © MacDonald, Dettwiler e Associados, Ltd.

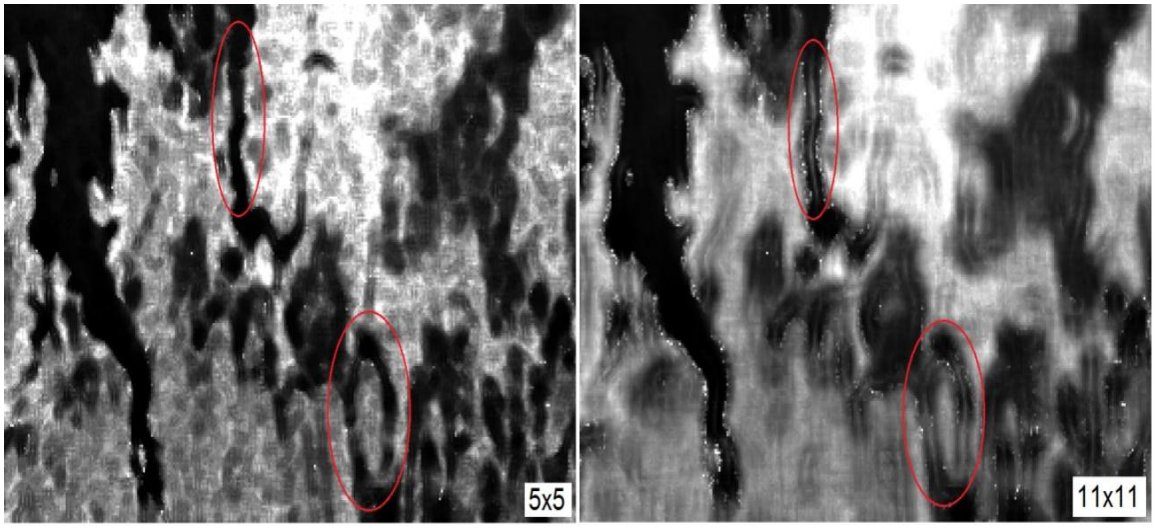


Figura A.3 - Presença de artefatos em regiões de água (destaque, em vermelho) e ao longo das bordas entre vegetação e água. Cenas Radarsat-2 © MacDonald, Dettwiler e Associados, Ltd.

## APÊNDICE B - TESTE DO TAMANHO DA JANELA DE MÉDIA ESPACIAL DAS DECOMPOSIÇÕES POLARIMÉTRICAS

Observa-se que as janelas com tamanhos maiores que 5x5 (Figura B.1), apresentam pouca redução do CV em relação às menores. A redução do CV varia com as componentes da imagem, sendo maior para a componente *double-bounce*, que apresenta valores díspares, enquanto que para as componentes volumétrica e superficial a taxa de decréscimo para o CV é muito similar para todos os tamanhos de janela.

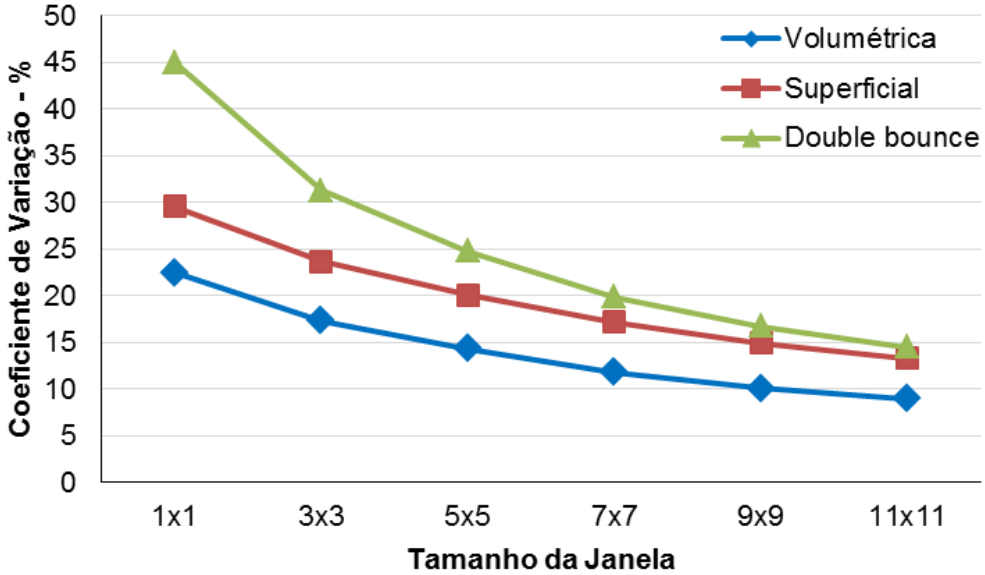


Figura B.1 - Análise do decréscimo do coeficiente de variação (CV) para diferentes janelas de média espacial para a decomposição de Freeman – Durden, cena SQ7 da época da cheia, em *slant range*, em regiões de Floresta de Terra Firme.

Visualmente nota-se que a janela de média espacial possui maior intensidade de borramento dos pixels quando comparado com o filtro *Refined Lee* (Figura B.2), o que é esperado, dado que esse último filtro é adaptativo. Apesar do maior efeito de borramento, a janela de média espacial possui menor ocorrência de artefatos, quando comparado ao *Refined Lee*.

Assim, as decomposições polarimétricas foram processadas com a janela 5x5, de maneira a corroborar com o resultado dos testes supracitados.

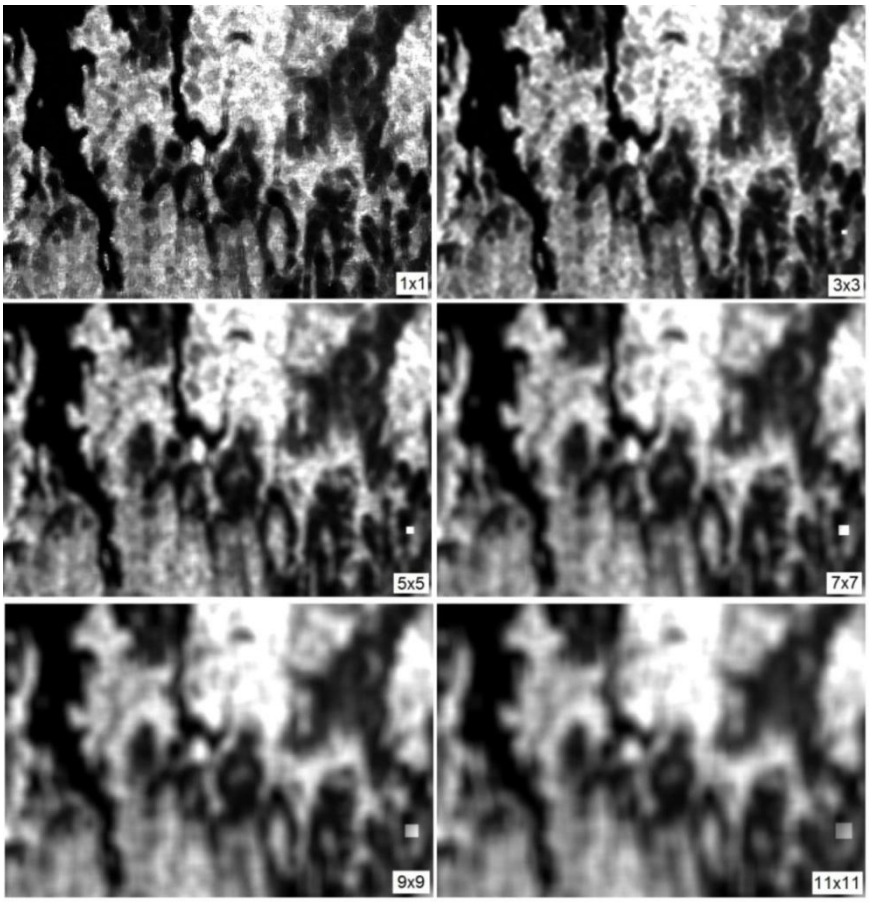


Figura B.2 - Análise visual das janelas de média espacial das decomposições polarimétricas. Imagem: componente volumétrica da decomposição de Freeman – Durden, em *slant range*, ângulo de incidência SQ7 para a época da cheia.

## APÊNDICE C – PARAMETRIZAÇÃO DO MINERADOR DE DADOS

O parâmetro fator de confiança apresentou pouco ou nenhum efeito no tamanho das árvores de decisão geradas e no seu erro médio absoluto (Figura C.1 e Tabela C.1). Dessa maneira, optou-se por utilizar o valor padrão desse parâmetro, de 0,25.

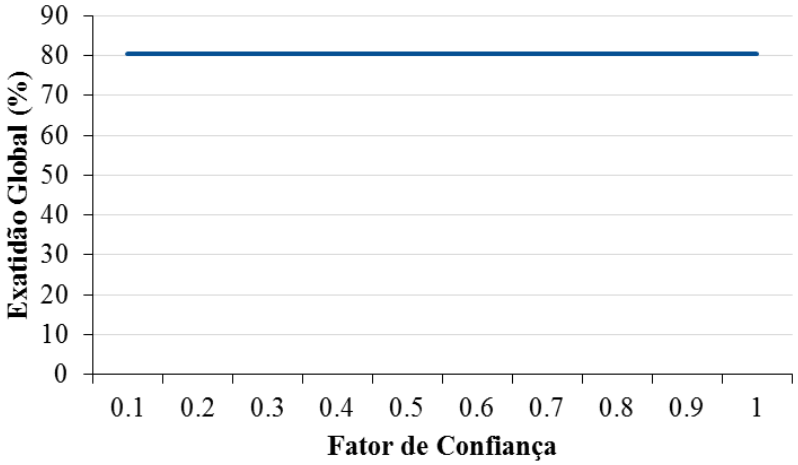


Figura C.1 – Variação da exatidão global (%) das árvores de decisão geradas em função de diferentes valores de Fator de Confiança, para todos os alvos de uso e cobertura da terra da várzea do Lago Grande de Curuai, PA.

Tabela C.1 – Valores de exatidão global (%), erro médio absoluto e número de nós em função da variação do fator de confiança, para todos os alvos de uso e cobertura da terra da várzea do Lago Grande de Curuai, PA

| Fator de Confiança | Exatidão Global (%) | Erro Médio Absoluto | Número de nós |
|---|---|---|---|
| 0.1 | 80.3371 | 0.0588 | 31 |
| 0.2 | 80.3371 | 0.0589 | 31 |
| 0.3 | 80.3371 | 0.0589 | 31 |
| 0.4 | 80.3371 | 0.0589 | 31 |
| 0.5 | 80.3371 | 0.0589 | 31 |
| 0.6 | 80.3371 | 0.0589 | 31 |
| 0.7 | 80.3371 | 0.0589 | 31 |
| 0.8 | 80.3371 | 0.0589 | 31 |
| 0.9 | 80.3371 | 0.0589 | 31 |
| 1 | 80.3371 | 0.0589 | 31 |

Houve maior variação do resultado para o parâmetro número mínimo de objetos (Figura C.2 e Tabela C.2). Percebe-se significativa queda na Exatidão Global e aumento do Erro Médio Absoluto quando o número mínimo de objetos passou de 15 para 20. Isso ocorre pois há apenas 16 amostras de Solo Exposto, e quando o número mínimo de objetos é igual a 20, objetos dessa classe não possuem número suficiente para serem isolados em um nó, sendo assim unidos aos nós de outras classes.

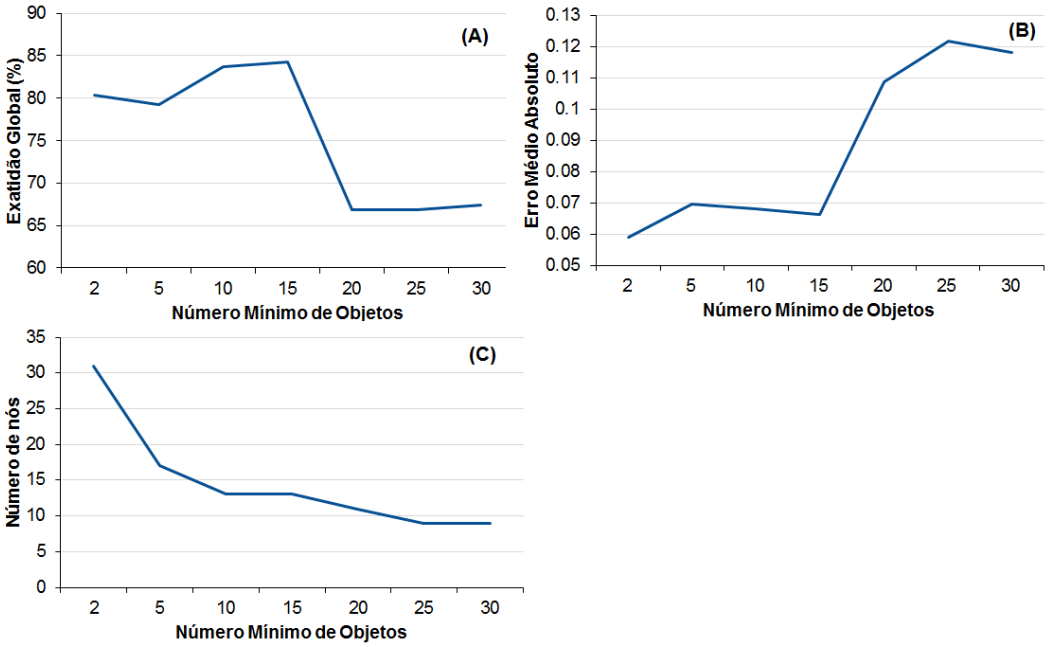


Figura C.2 – Variação da exatidão global (%) (A), do erro médio absoluto (B) e do número de nós (C) das árvores de decisão geradas em função de diferentes valores de número mínimo de objetos, para todos os alvos de uso e cobertura da terra da várzea do Lago Grande de Curuai, PA.

Tabela C.2 – valores de exatidão global (%), erro médio absoluto e número de nós em função da variação do fator de confiança, para todos os alvos de uso e cobertura da terra da várzea do Lago Grande de Curuai, PA.

| Nº min. Objetos | Exatidão Global | Erro Médio Absoluto | Número de nós |
|---|---|---|---|
| 2 | 80.3371 | 0.0589 | 31 |
| 5 | 79.2135 | 0.0695 | 17 |
| 10 | 83.7079 | 0.0681 | 13 |
| 15 | 84.2697 | 0.0663 | 13 |
| 20 | 66.8539 | 0.1086 | 11 |
| 25 | 66.8539 | 0.1216 | 9 |
| 30 | 67.4157 | 0.1182 | 9 |

Apesar de número mínimo de objetos igual a 15 ter apresentado exatidão global maior que o parâmetro 10, esse foi preferido ao invés de aquele. Isso se deu pois um número mínimo de objetos igual a 10 permite que a maioria das classes seja dividida em mais de um nó, quando necessário, pelo algoritmo J.48. Dessa maneira há menor possibilidade de comprometimento da Exatidão Global da árvore de decisão pela união de nós da mesma classe que apresentem padrões de respostas diferentes, e ao mesmo tempo evita a criação de árvores com elevado número de nós.

**APÊNDICE D – ANÁLISES DOS ERROS E ESPACIALIZAÇÃO DOS MODELOS DOS ATRIBUTOS BIOFÍSICOS DA VEGETAÇÃO DA VÁRZEA DO LAGO GRANDE DE CURUAI – PA.**

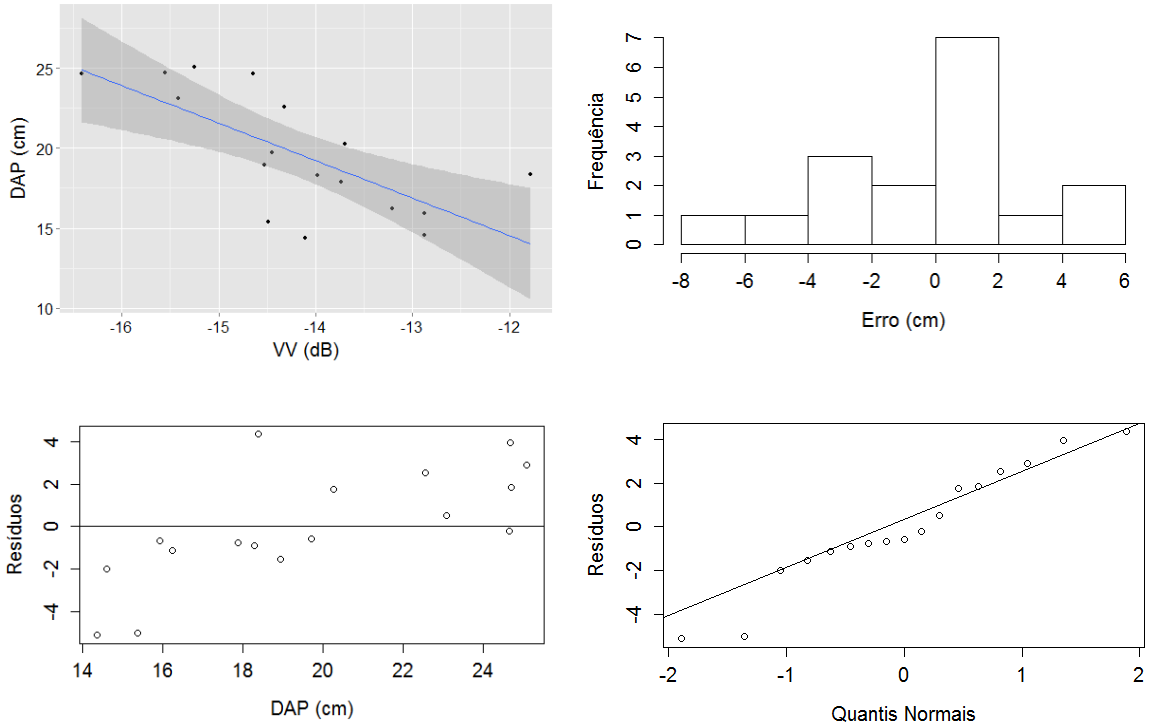


Figura D.1 – Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ7_C_33, em dB, para a variável dependente DAP.

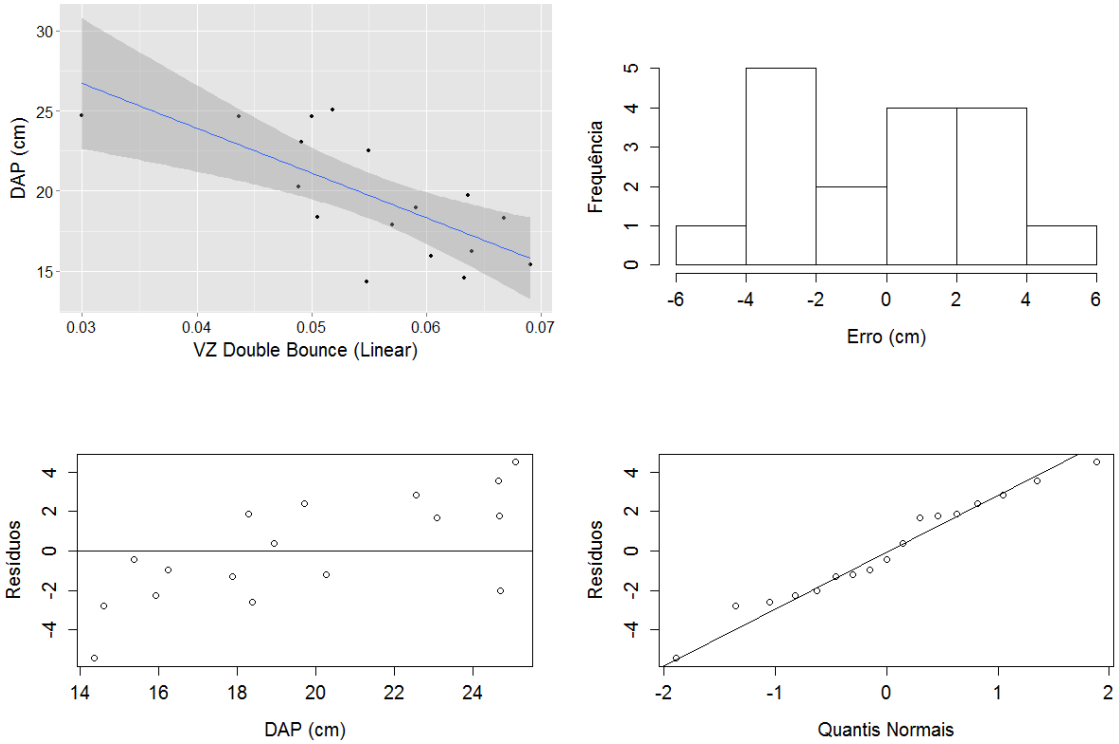


Figura D.2 – Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ14_VZ_double, em amplitude linear, para a variável dependente DAP.

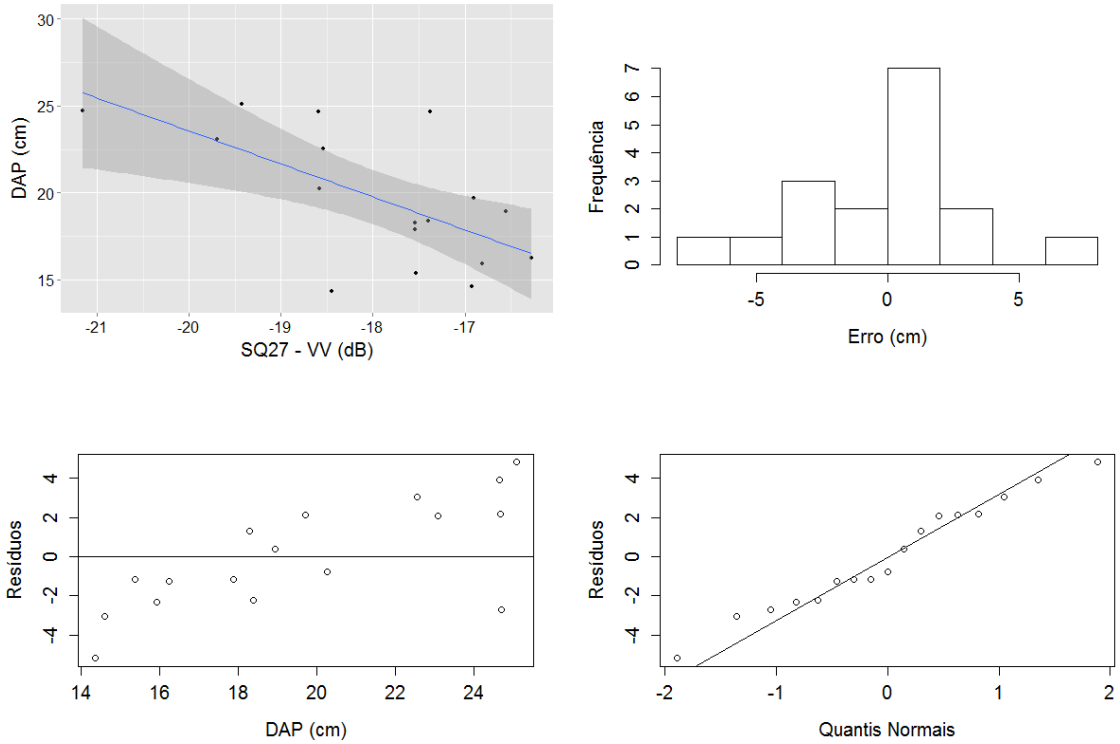


Figura D.3 – Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ27_C_33, em dB, para a variável dependente DAP.

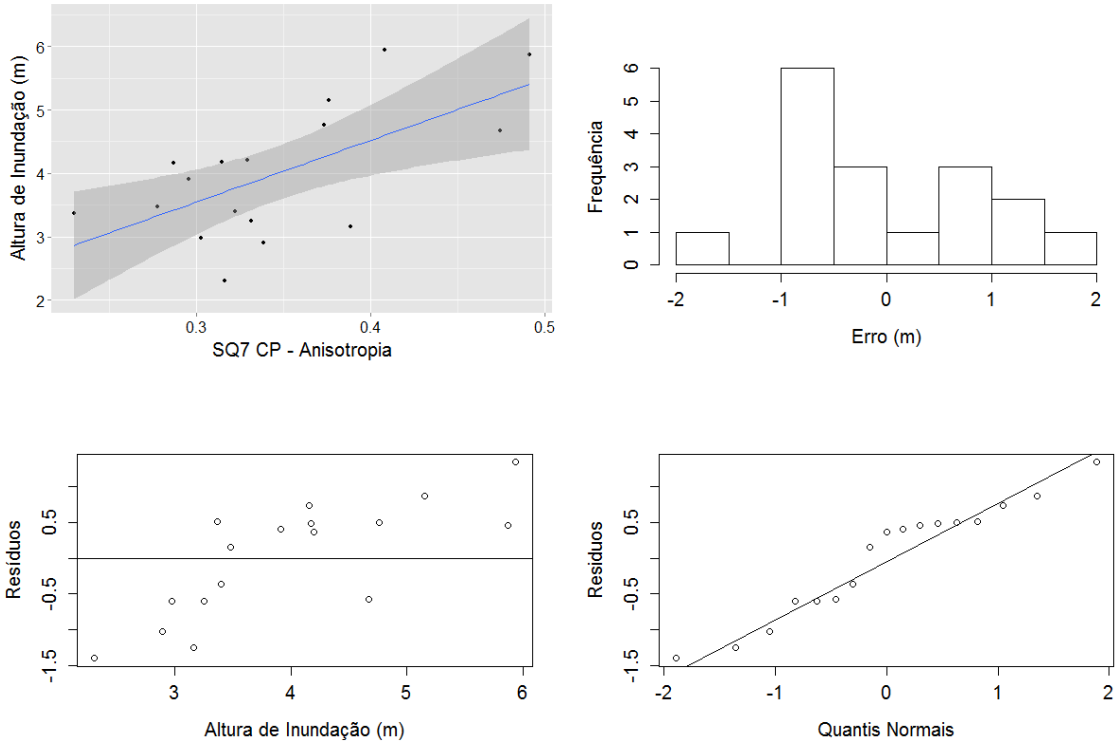


Figura D.4 – Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ7_CP_ani, para a variável dependente Altura de Inundação.

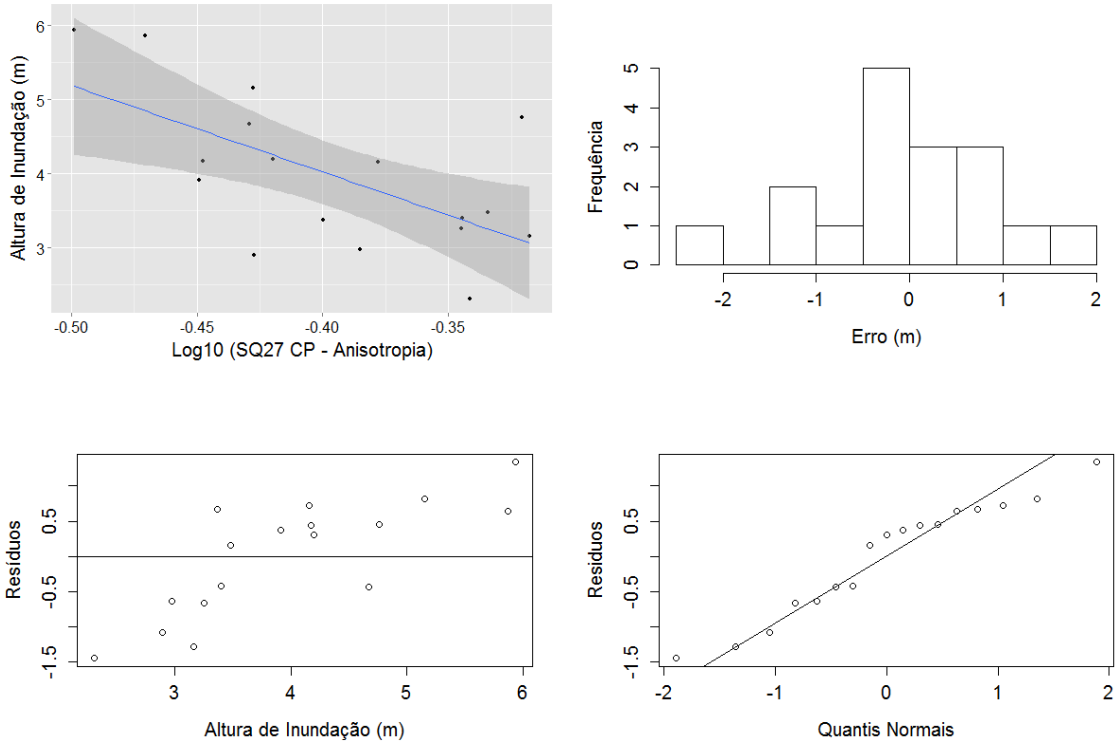


Figura D.5 – Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ27_CP_ani, transformada por Log10, para a variável dependente Altura de Inundação.

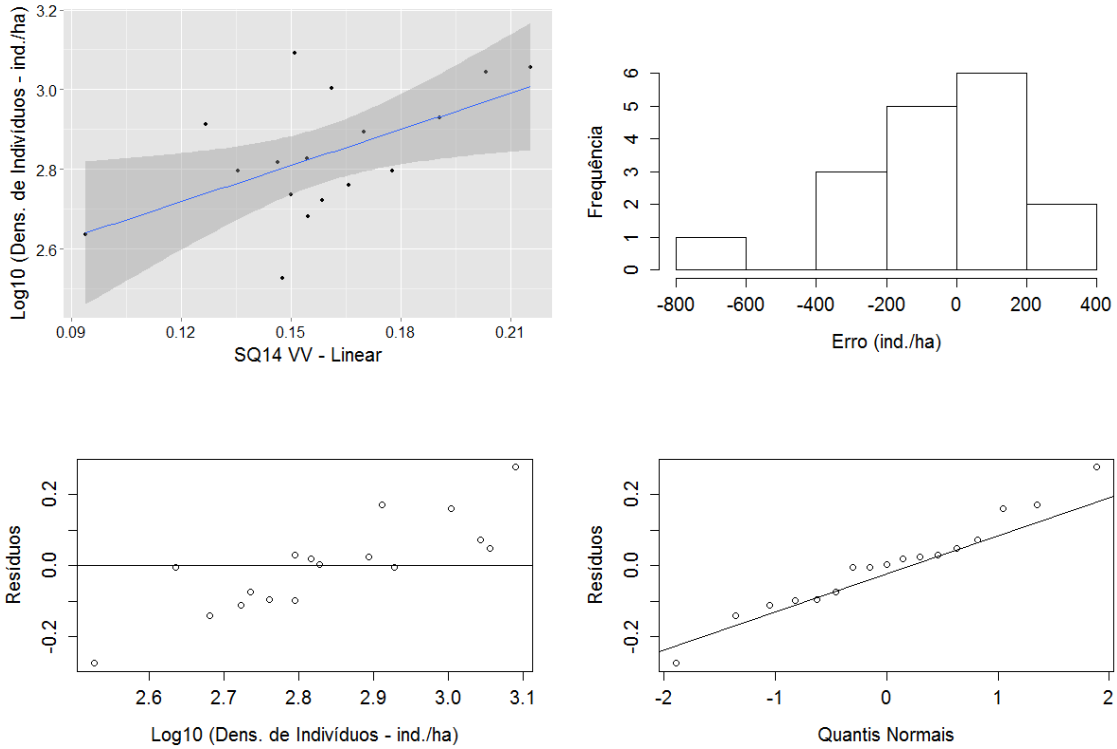


Figura D.6 – Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ14_C_33, em amplitude linear, para a variável dependente Log10 (Densidade de Indivíduos).

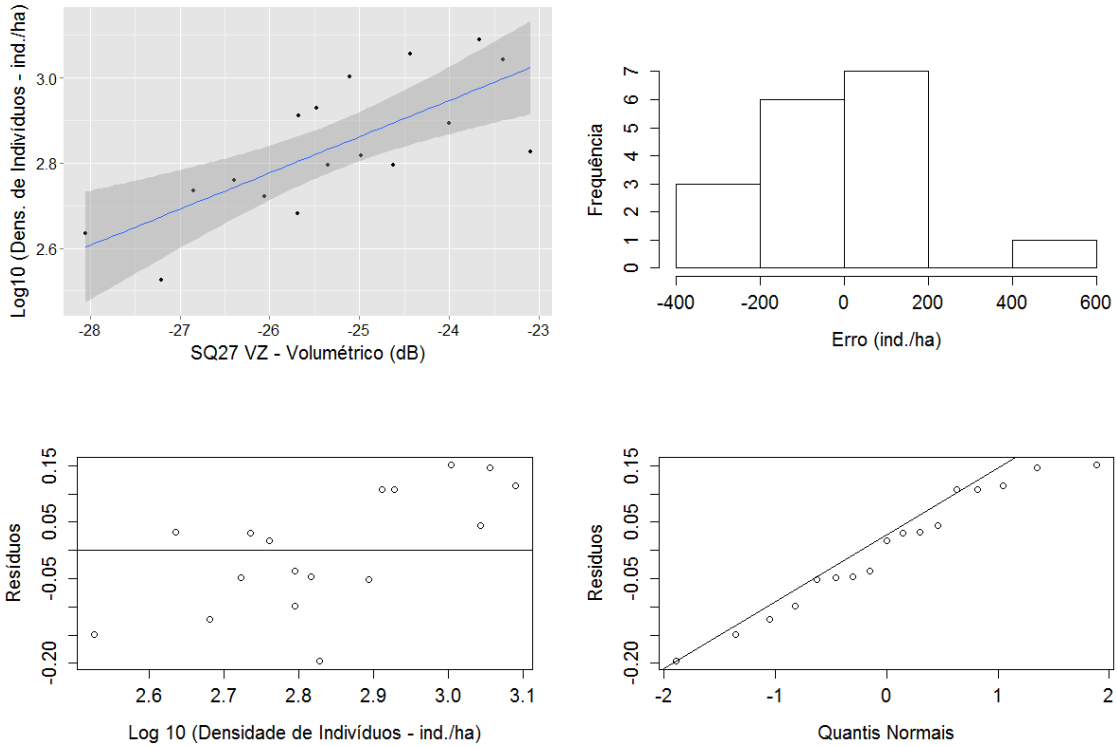


Figura D.7 – Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ27_VZ_vol, em dB, para a variável dependente Log10 (Densidade de Indivíduos).

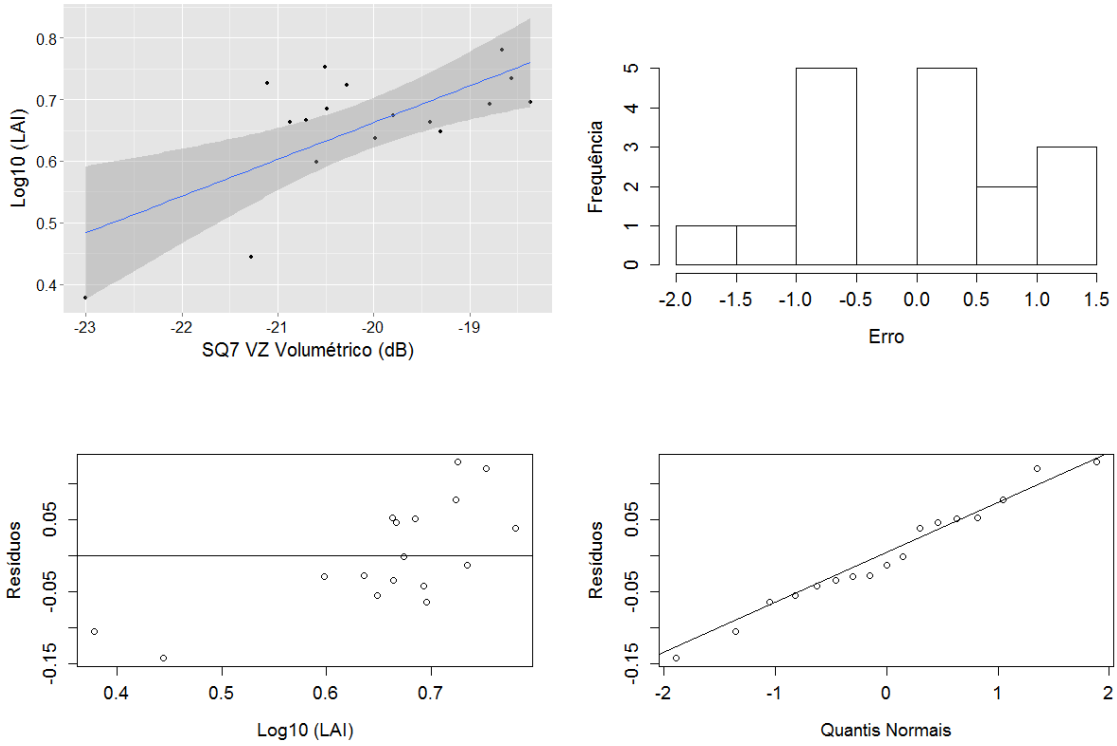


Figura D.8 – Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ7_VZ_vol, em dB, para a variável dependente Log10 (IAF).

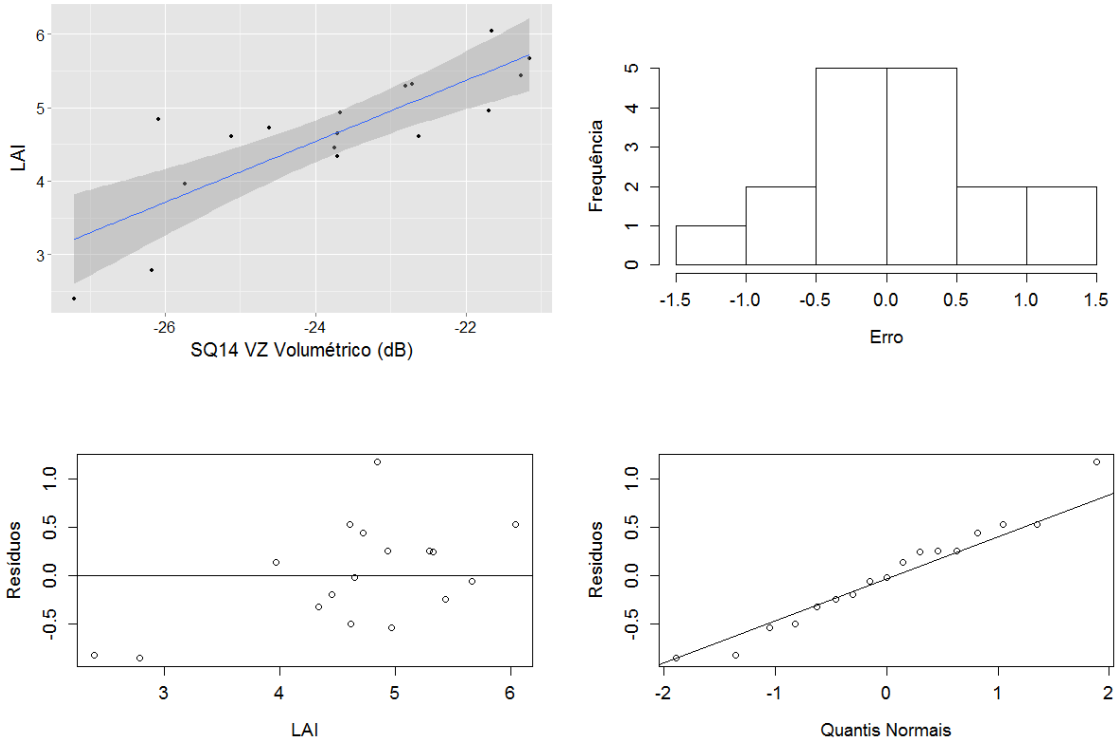


Figura D.9 – Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ14_VZ_vol, em dB, para a variável dependente IAF.

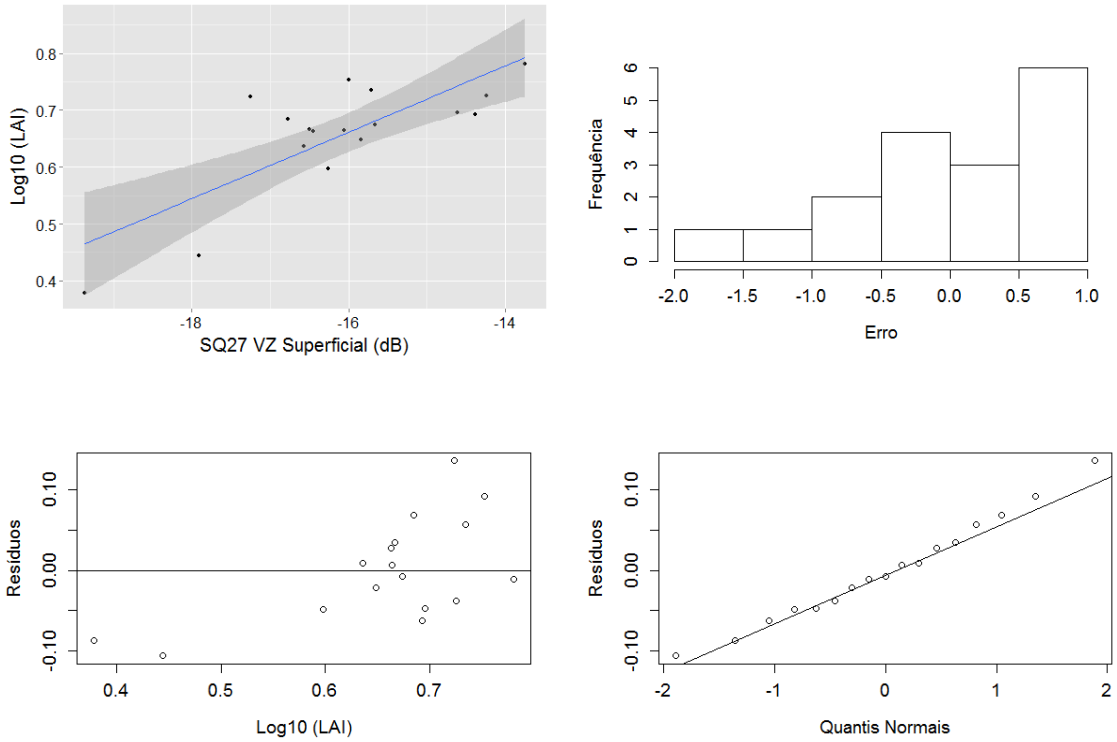


Figura D.10 – Dispersão dos pontos, histograma dos erros, análise dos resíduos e teste de normalidade dos resíduos do modelo da imagem SQ27_VZ_odd, em dB, para a variável dependente Log10 (IAF).

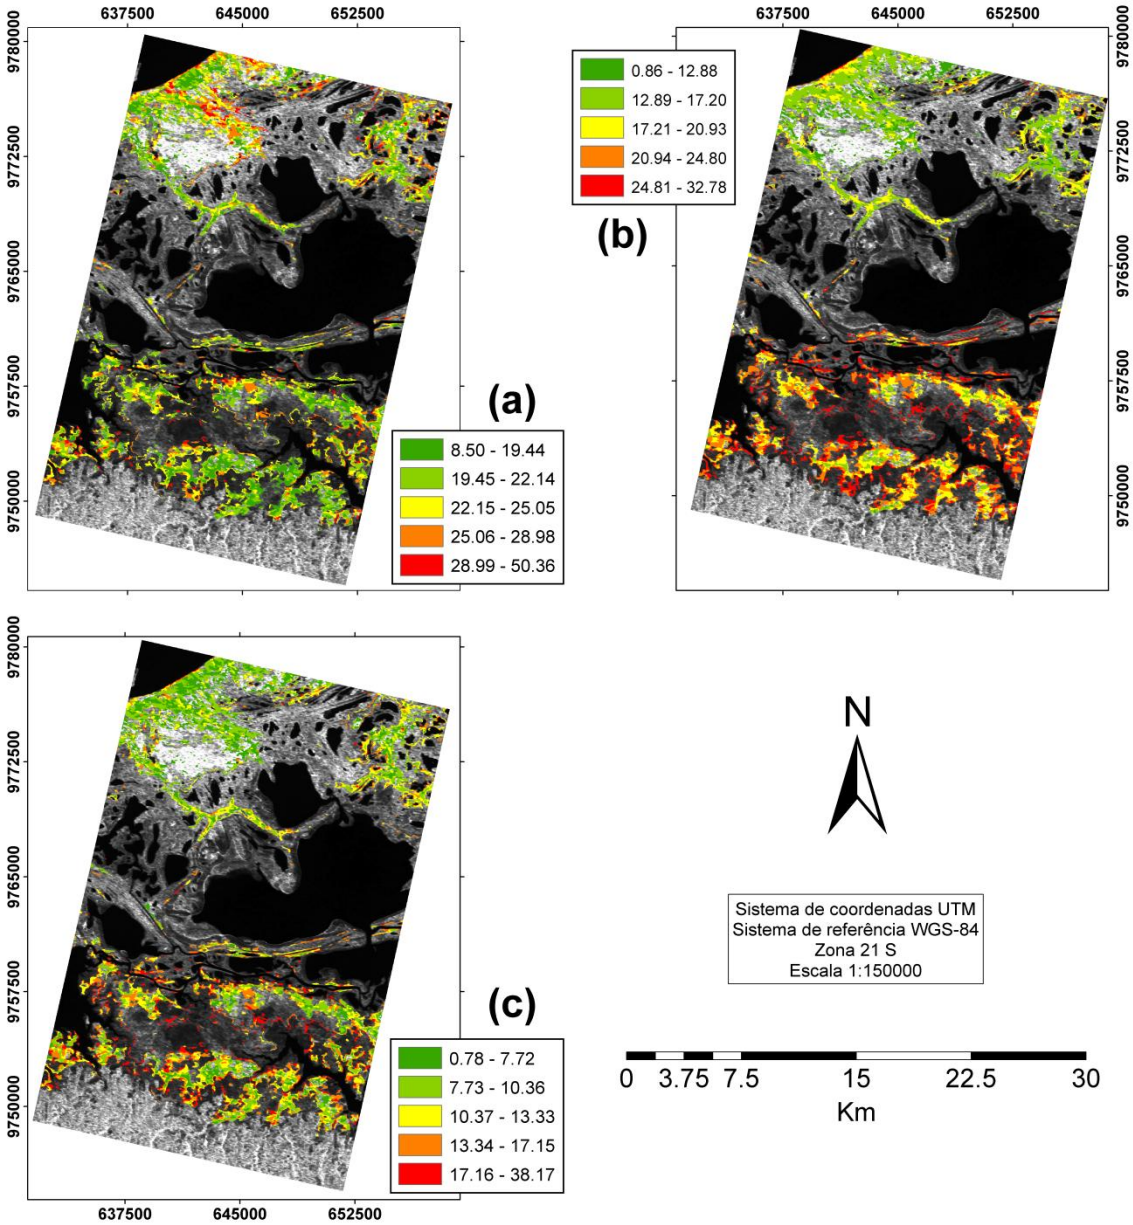


Figura D.11 – Modelos para estimativa do DAP (cm). Em (a), modelo SQ7 VV x DAP (dB x linear); em (b), modelo SQ14 VZ *double-bounce* x DAP (Linear x Linear); em (c) modelo SQ27 VV x DAP (dB x linear).

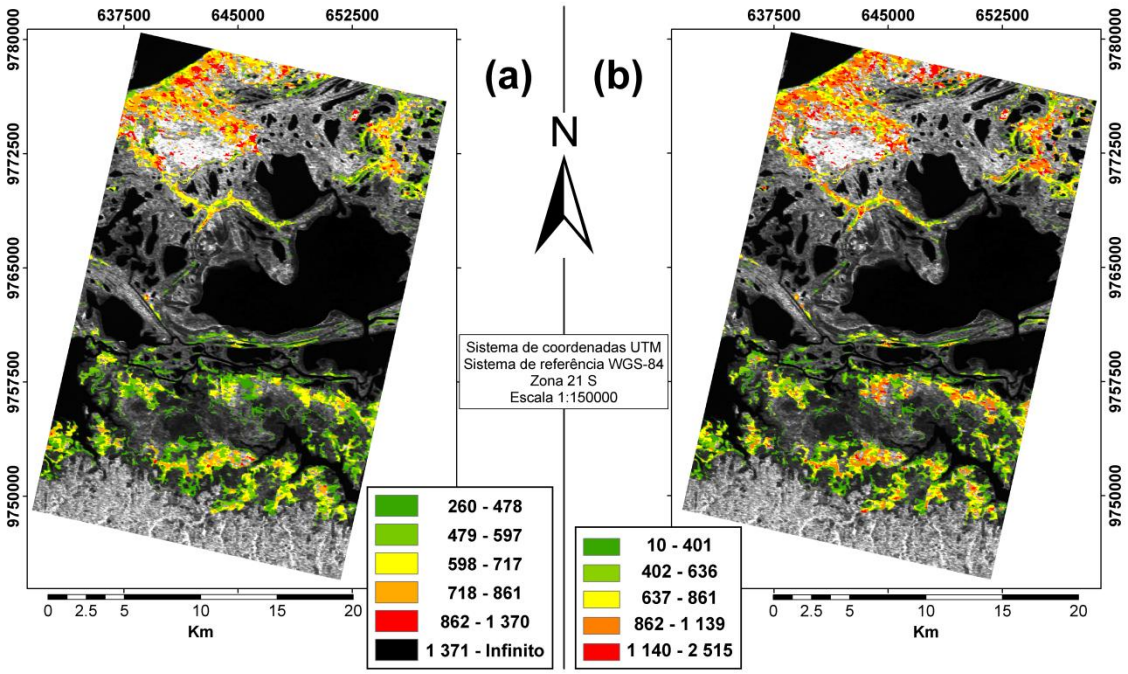


Figura D.12 – Modelos para estimativa da Densidade de Indivíduos (indivíduos / ha). Em (a), modelo SQ14 VV x Densidade de Indivíduos (linear x log10) e em (b), modelo SQ27 van Zyl volumétrico x Densidade de Indivíduos (dB x log10).

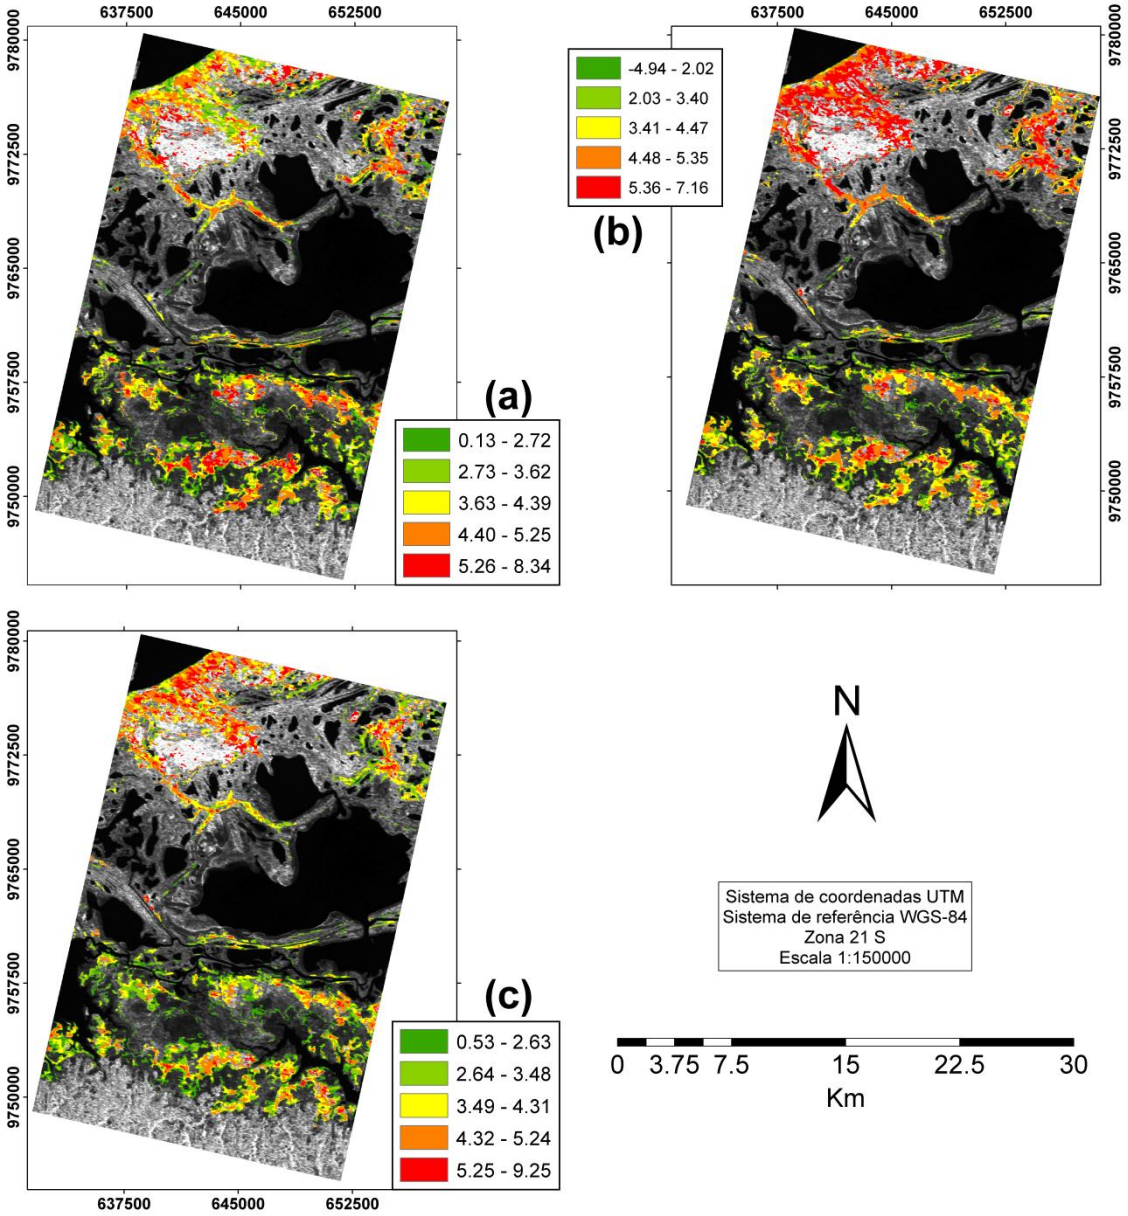


Figura D.13 – Modelos para estimativa do IAF. Em (a), modelo SQ7 van Zyl volumétrico x IAF (dB x log10); em (b), modelo SQ14 van Zyl volumétrico x IAF (dB x linear) e em (c), modelo SQ27 van Zyl superficial x IAF (dB x log10).

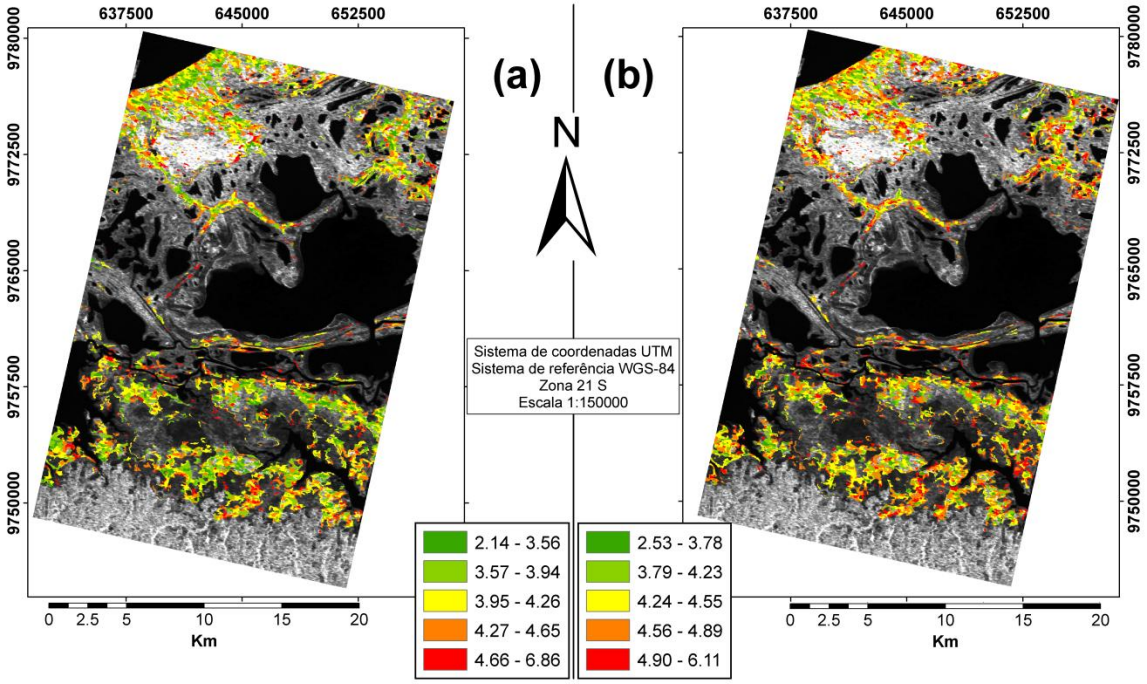


Figura D.14 – Modelos para estimativa da Altura de Inundação (metros). Em (a), modelo SQ7 CP anisotropia x altura de inundação (linear x linear) e em (b), modelo SQ27 CP anisotropia x altura de inundação (log10 x linear).

## APÊNDICE E – MATRIZES DE CONFUSÃO DAS CLASSIFICAÇÕES

Tabela E.1 – Matriz de confusão da classificação do ângulo de incidência SQ7, para as classes gerais, utilizando os descritores de amplitude + textura. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

| Classes | A | AB | TF | FI | ME | MF | SE | Total | Proporção |
|---|---|---|---|---|---|---|---|---|---|
| **A** | **100** | 0 | 0 | 0 | 0 | 27 | 0 | 127 | 0.326 |
| **AB** | 0 | **15** | 0 | 8 | 12 | 0 | 1 | 36 | 0.093 |
| **FT** | 0 | 1 | **14** | 6 | 4 | 0 | 16 | 41 | 0.105 |
| **FI** | 0 | 7 | 0 | **22** | 24 | 0 | 4 | 57 | 0.147 |
| **ME** | 0 | 10 | 1 | 11 | **36** | 1 | 4 | 63 | 0.162 |
| **MF** | 0 | 0 | 0 | 0 | 0 | **36** | 1 | 37 | 0.095 |
| **SE** | 0 | 0 | 5 | 4 | 3 | 1 | **15** | 28 | 0.072 |
| **Total** | 100 | 33 | 20 | 51 | 79 | 65 | 41 | **388** | 1 |
| **Proporção** | 0.257 | 0.085 | 0.051 | 0.131 | 0.203 | 0.167 | 0.105 | 1 | |

Tabela E.2 – Matriz de confusão da classificação do ângulo de incidência SQ14, para as classes gerais, utilizando os descritores de amplitude + textura. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

| Classes | A | AB | TF | FI | ME | MF | SE | Total | Proporção |
|---|---|---|---|---|---|---|---|---|---|
| **A** | **104** | 0 | 0 | 0 | 0 | 22 | 1 | 127 | 0.327 |
| **AB** | 0 | **18** | 1 | 3 | 11 | 0 | 3 | 36 | 0.093 |
| **FT** | 0 | 0 | **18** | 7 | 0 | 0 | 15 | 40 | 0.103 |
| **FI** | 0 | 16 | 3 | **20** | 6 | 0 | 12 | 57 | 0.147 |
| **ME** | 0 | 15 | 3 | 12 | **24** | 2 | 7 | 63 | 0.162 |
| **MF** | 0 | 0 | 1 | 0 | 0 | **35** | 1 | 37 | 0.095 |
| **SE** | 0 | 0 | 2 | 3 | 0 | 1 | **22** | 28 | 0.072 |
| **Total** | 104 | 49 | 28 | 45 | 41 | 60 | 61 | **388** | 1 |
| **Proporção** | 0.268 | 0.126 | 0.072 | 0.116 | 0.106 | 0.155 | 0.157 | 1 | |

Tabela E.3 – Matriz de confusão da classificação do ângulo de incidência SQ27, para as classes gerais, utilizando os descritores de amplitude + textura. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

| Classes | A | AB | TF | FI | ME | MF | SE | Total | Proporção |
|---|---|---|---|---|---|---|---|---|---|
| **A** | **110** | 0 | 0 | 0 | 0 | 17 | 0 | 127 | 0.327 |
| **AB** | 0 | **24** | 0 | 10 | 0 | 0 | 2 | 36 | 0.093 |
| **FT** | 0 | 0 | **4** | 35 | 0 | 0 | 1 | 40 | 0.103 |
| **FI** | 0 | 8 | 1 | **39** | 2 | 0 | 7 | 57 | 0.147 |
| **ME** | 0 | 20 | 0 | 23 | **14** | 3 | 3 | 63 | 0.162 |
| **MF** | 9 | 0 | 0 | 0 | 0 | **28** | 0 | 37 | 0.095 |
| **SE** | 0 | 0 | 0 | 8 | 0 | 1 | **19** | 28 | 0.072 |
| **Total** | 119 | 52 | 5 | 115 | 16 | 49 | 32 | **388** | 1 |
| **Proporção** | 0.307 | 0.134 | 0.013 | 0.296 | 0.041 | 0.126 | 0.082 | 1 | |

Tabela E.4 – Matriz de confusão da classificação do ângulo de incidência SQ7, para as classes gerais, utilizando o descritor amplitude. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

| Classes | A | AB | TF | FI | ME | MF | SE | Total | Proporção |
|---|---|---|---|---|---|---|---|---|---|
| **A** | **100** | 0 | 0 | 0 | 0 | 27 | 0 | 127 | 0.327 |
| **AB** | 0 | **15** | 0 | 17 | 3 | 0 | 1 | 36 | 0.093 |
| **FT** | 0 | 0 | **19** | 10 | 0 | 0 | 11 | 40 | 0.103 |
| **FI** | 0 | 7 | 0 | **45** | 1 | 0 | 4 | 57 | 0.147 |
| **ME** | 0 | 10 | 1 | 26 | **21** | 1 | 4 | 63 | 0.162 |
| **MF** | 0 | 0 | 0 | 0 | 0 | **36** | 1 | 37 | 0.095 |
| **SE** | 0 | 0 | 2 | 7 | 0 | 1 | **18** | 28 | 0.072 |
| **Total** | 100 | 32 | 22 | 105 | 25 | 65 | 39 | **388** | 1 |
| **Proporção** | 0.258 | 0.082 | 0.057 | 0.271 | 0.064 | 0.168 | 0.101 | 1 | |

Tabela E.5 – Matriz de confusão da classificação do ângulo de incidência SQ14, para as classes gerais, utilizando o descritor amplitude. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

| Classes | A | AB | TF | FI | ME | MF | SE | Total | Proporção |
|---|---|---|---|---|---|---|---|---|---|
| **A** | **104** | 0 | 0 | 0 | 0 | 22 | 0 | 126 | 0.326 |
| **AB** | 0 | **18** | 1 | 3 | 11 | 0 | 3 | 36 | 0.093 |
| **FT** | 0 | 0 | **18** | 7 | 0 | 0 | 15 | 40 | 0.103 |
| **FI** | 0 | 16 | 3 | **20** | 6 | 0 | 12 | 57 | 0.147 |
| **ME** | 0 | 15 | 3 | 12 | **24** | 2 | 7 | 63 | 0.163 |
| **MF** | 0 | 0 | 1 | 0 | 0 | **35** | 1 | 37 | 0.096 |
| **SE** | 0 | 0 | 2 | 3 | 0 | 1 | **23** | 28 | 0.072 |
| **Total** | 104 | 49 | 28 | 45 | 41 | 60 | 60 | **388** | 1 |
| **Proporção** | 0.269 | 0.127 | 0.072 | 0.116 | 0.106 | 0.155 | 0.155 | 1 | |

Tabela E.6 – Matriz de confusão da classificação do ângulo de incidência SQ27, para as classes gerais, utilizando o descritor amplitude. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

| Classes | A | AB | TF | FI | ME | MF | SE | Total | Proporção |
|---|---|---|---|---|---|---|---|---|---|
| **A** | **100** | 0 | 0 | 0 | 0 | 27 | 0 | 127 | 0.327 |
| **AB** | 0 | **24** | 3 | 5 | 4 | 0 | 0 | 36 | 0.093 |
| **FT** | 0 | 0 | **28** | 10 | 1 | 0 | 1 | 40 | 0.103 |
| **FI** | 0 | 8 | 21 | **20** | 6 | 0 | 2 | 57 | 0.147 |
| **ME** | 0 | 20 | 10 | 12 | **17** | 3 | 1 | 63 | 0.162 |
| **MF** | 1 | 0 | 0 | 0 | 0 | **36** | 0 | 37 | 0.095 |
| **SE** | 0 | 0 | 7 | 4 | 1 | 2 | **14** | 28 | 0.072 |
| **Total** | 101 | 52 | 69 | 51 | 29 | 68 | 18 | **388** | 1 |
| **Proporção** | 0.260 | 0.134 | 0.178 | 0.131 | 0.075 | 0.175 | 0.046 | 1 | |

Tabela E.7 – Matriz de confusão da classificação do ângulo de incidência SQ7, para as classes gerais, utilizando o descritor textura. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

| Classes | A | AB | TF | FI | ME | MF | SE | Total | Proporção |
|---|---|---|---|---|---|---|---|---|---|
| **A** | **79** | 0 | 11 | 16 | 11 | 3 | 7 | 127 | 0.327 |
| **AB** | 0 | **1** | 4 | 12 | 19 | 0 | 0 | 36 | 0.093 |
| **FT** | 0 | 3 | **13** | 13 | 11 | 0 | 0 | 40 | 0.103 |
| **FI** | 0 | 0 | 6 | **20** | 28 | 0 | 3 | 57 | 0.147 |
| **ME** | 0 | 1 | 4 | 21 | **35** | 1 | 1 | 63 | 0.162 |
| **MF** | 4 | 2 | 9 | 4 | 9 | **4** | 5 | 37 | 0.095 |
| **SE** | 0 | 0 | 4 | 16 | 7 | 0 | **1** | 28 | 0.072 |
| **Total** | 83 | 7 | 51 | 102 | 120 | 8 | 17 | **388** | 1 |
| **Proporção** | 0.214 | 0.018 | 0.131 | 0.263 | 0.309 | 0.021 | 0.044 | 1 | |

Tabela E.8 – Matriz de confusão da classificação do ângulo de incidência SQ14, para as classes gerais, utilizando o descritor textura. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

| Classes | A | AB | TF | FI | ME | MF | SE | Total | Proporção |
|---|---|---|---|---|---|---|---|---|---|
| **A** | **62** | 17 | 3 | 5 | 1 | 34 | 5 | 127 | 0.327 |
| **AB** | 0 | **1** | 1 | 12 | 7 | 0 | 15 | 36 | 0.093 |
| **FT** | 0 | 2 | **13** | 13 | 7 | 0 | 5 | 40 | 0.103 |
| **FI** | 0 | 2 | 3 | **20** | 15 | 0 | 17 | 57 | 0.147 |
| **ME** | 0 | 3 | 3 | 19 | **20** | 0 | 18 | 63 | 0.162 |
| **MF** | 0 | 11 | 14 | 5 | 2 | **2** | 3 | 37 | 0.095 |
| **SE** | 0 | 3 | 6 | 7 | 6 | 1 | **5** | 28 | 0.072 |
| **Total** | 62 | 39 | 43 | 81 | 58 | 37 | 68 | **388** | 1 |
| **Proporção** | 0.160 | 0.101 | 0.111 | 0.209 | 0.149 | 0.095 | 0.175 | 1 | |

Tabela E.9 – Matriz de confusão da classificação do ângulo de incidência SQ27, para as classes gerais, utilizando o descritor textura. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

| Classes | A | AB | TF | FI | ME | MF | SE | Total | Proporção |
|---|---|---|---|---|---|---|---|---|---|
| **A** | **93** | 0 | 4 | 0 | 3 | 24 | 3 | 127 | 0.327 |
| **AB** | 0 | **12** | 1 | 1 | 22 | 0 | 0 | 36 | 0.093 |
| **FT** | 2 | 18 | **0** | 3 | 17 | 0 | 0 | 40 | 0.103 |
| **FI** | 0 | 17 | 0 | **3** | 36 | 0 | 1 | 57 | 0.147 |
| **ME** | 0 | 16 | 0 | 9 | **37** | 0 | 1 | 63 | 0.162 |
| **MF** | 3 | 11 | 13 | 2 | 3 | **3** | 2 | 37 | 0.095 |
| **SE** | 1 | 6 | 0 | 6 | 15 | 0 | **0** | 28 | 0.072 |
| **Total** | 99 | 80 | 18 | 24 | 133 | 27 | 7 | **388** | 1 |
| **Proporção** | 0.255 | 0.206 | 0.046 | 0.062 | 0.343 | 0.070 | 0.018 | 1 | |

Tabela E.10 – Matriz de confusão da classificação do ângulo de incidência SQ7, para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes.

| Classes | A | AB | FI | ME | MF | Total | Proporção |
|---|---|---|---|---|---|---|---|
| **A** | **100** | 0 | 0 | 0 | 27 | 127 | 0.397 |
| **AB** | 0 | **15** | 18 | 3 | 0 | 36 | 0.113 |
| **FI** | 0 | 7 | **49** | 1 | 0 | 57 | 0.178 |
| **ME** | 0 | 10 | 31 | **21** | 1 | 63 | 0.197 |
| **MF** | 0 | 0 | 1 | 0 | **36** | 37 | 0.116 |
| **Total** | 100 | 32 | 99 | 25 | 64 | **320** | 1 |
| **Proporção** | 0.313 | 0.100 | 0.309 | 0.078 | 0.200 | 1 | |

Tabela E.11 – Matriz de confusão da classificação do ângulo de incidência SQ14, para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes.

| Classes | A | AB | FI | ME | MF | Total | Proporção |
|---|---|---|---|---|---|---|---|
| **A** | **104** | 0 | 1 | 0 | 22 | 127 | 0.397 |
| **AB** | 0 | **18** | 7 | 11 | 0 | 36 | 0.113 |
| **FI** | 0 | 16 | **35** | 6 | 0 | 57 | 0.178 |
| **ME** | 0 | 15 | 22 | **24** | 2 | 63 | 0.197 |
| **MF** | 0 | 0 | 2 | 0 | **35** | 37 | 0.116 |
| **Total** | 104 | 49 | 67 | 41 | 59 | **320** | 1 |
| **Proporção** | 0.325 | 0.153 | 0.209 | 0.128 | 0.184 | 1 | |

Tabela E.12 – Matriz de confusão da classificação do ângulo de incidência SQ27, para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes.

| Classes | A | AB | FI | ME | MF | Total | Proporção |
|---|---|---|---|---|---|---|---|
| **A** | **101** | 0 | 0 | 0 | 26 | 127 | 0.397 |
| **AB** | 0 | **24** | 12 | 0 | 0 | 36 | 0.113 |
| **FI** | 0 | 8 | **46** | 2 | 1 | 57 | 0.178 |
| **ME** | 0 | 20 | 24 | **16** | 3 | 63 | 0.197 |
| **MF** | 0 | 0 | 0 | 0 | **37** | 37 | 0.116 |
| **Total** | 101 | 52 | 82 | 18 | 67 | 320 | 1 |
| **Proporção** | 0.316 | 0.163 | 0.256 | 0.056 | 0.209 | 1 | |

Tabela E.13 – Matriz de confusão da classificação da decomposição de Cloude - Pottier, para as classes gerais. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

| Classes | A | AB | TF | FI | ME | MF | SE | Total | Proporção |
|---|---|---|---|---|---|---|---|---|---|
| **A** | **71** | 13 | 0 | 12 | 15 | 7 | 9 | 127 | 0.327 |
| **AB** | 2 | **8** | 2 | 7 | 3 | 9 | 5 | 36 | 0.093 |
| **FT** | 3 | 0 | **30** | 7 | 0 | 0 | 0 | 40 | 0.103 |
| **FI** | 5 | 9 | 4 | **25** | 3 | 4 | 7 | 57 | 0.147 |
| **ME** | 2 | 17 | 0 | 4 | **24** | 16 | 0 | 63 | 0.162 |
| **MF** | 1 | 5 | 0 | 0 | 5 | **24** | 2 | 37 | 0.095 |
| **SE** | 0 | 0 | 7 | 14 | 1 | 2 | **4** | 28 | 0.072 |
| **Total** | 84 | 52 | 43 | 69 | 51 | 62 | 27 | **388** | 1 |
| **Proporção** | 0.216 | 0.134 | 0.111 | 0.178 | 0.131 | 0.160 | 0.070 | 1 | |

Tabela E.14 – Matriz de confusão da classificação da decomposição de Cloude – Pottier + Matriz C, para as classes gerais. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

| Classes | A | AB | TF | FI | ME | MF | SE | Total | Proporção |
|---|---|---|---|---|---|---|---|---|---|
| **A** | **101** | 0 | 0 | 0 | 0 | 26 | 0 | 127 | 0.327 |
| **AB** | 0 | **20** | 2 | 5 | 9 | 0 | 0 | 36 | 0.093 |
| **FT** | 0 | 0 | **38** | 1 | 0 | 0 | 1 | 40 | 0.103 |
| **FI** | 0 | 11 | 7 | **22** | 15 | 0 | 2 | 57 | 0.147 |
| **ME** | 0 | 10 | 1 | 2 | **47** | 3 | 0 | 63 | 0.162 |
| **MF** | 0 | 0 | 0 | 0 | 0 | **37** | 0 | 37 | 0.095 |
| **SE** | 0 | 0 | 4 | 3 | 2 | 1 | **18** | 28 | 0.072 |
| **Total** | 101 | 41 | 52 | 33 | 73 | 67 | 21 | **388** | 1 |
| **Proporção** | 0.260 | 0.106 | 0.134 | 0.085 | 0.188 | 0.173 | 0.054 | 1 | |

Tabela E.15 – Matriz de confusão da classificação da decomposição de Cloude – Pottier + decomposição de van Zyl, para as classes gerais. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

| Classes | A | AB | TF | FI | ME | MF | SE | Total | Proporção |
|---|---|---|---|---|---|---|---|---|---|
| **A** | **102** | 0 | 0 | 0 | 0 | 25 | 0 | 127 | 0.327 |
| **AB** | 0 | **29** | 0 | 6 | 1 | 0 | 0 | 36 | 0.093 |
| **FT** | 0 | 0 | **34** | 3 | 0 | 0 | 3 | 40 | 0.103 |
| **FI** | 0 | 15 | 2 | **34** | 0 | 0 | 6 | 57 | 0.147 |
| **ME** | 0 | 28 | 0 | 9 | **23** | 0 | 3 | 63 | 0.162 |
| **MF** | 0 | 0 | 0 | 0 | 0 | **37** | 0 | 37 | 0.095 |
| **SE** | 0 | 1 | 3 | 4 | 0 | 1 | **19** | 28 | 0.072 |
| **Total** | 102 | 73 | 39 | 56 | 24 | 63 | 31 | **388** | 1 |
| **Proporção** | 0.263 | 0.188 | 0.101 | 0.144 | 0.062 | 0.162 | 0.080 | 1 | |

Tabela E.16 – Matriz de confusão da classificação da decomposição de Cloude – Pottier + decomposição de van Zyl + Matriz C, para as classes gerais. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

| Classes | A | AB | TF | FI | ME | MF | SE | Total | Proporção |
|---|---|---|---|---|---|---|---|---|---|
| **A** | **100** | 0 | 0 | 0 | 0 | 27 | 0 | 127 | 0.327 |
| **AB** | 0 | **21** | 1 | 3 | 10 | 0 | 1 | 36 | 0.093 |
| **FT** | 0 | 0 | **35** | 5 | 0 | 0 | 0 | 40 | 0.103 |
| **FI** | 0 | 4 | 9 | **28** | 10 | 0 | 6 | 57 | 0.147 |
| **ME** | 0 | 2 | 0 | 4 | **51** | 1 | 5 | 63 | 0.162 |
| **MF** | 0 | 0 | 0 | 0 | 0 | **37** | 0 | 37 | 0.095 |
| **SE** | 0 | 0 | 2 | 5 | 1 | 1 | **19** | 28 | 0.072 |
| **Total** | 100 | 27 | 47 | 45 | 72 | 66 | 31 | **388** | 1 |
| **Proporção** | 0.258 | 0.070 | 0.121 | 0.116 | 0.186 | 0.170 | 0.080 | 1 | |

Tabela E.17 – Matriz de confusão da classificação da decomposição de van Zyl, para as classes gerais. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

| Classes | A | AB | TF | FI | ME | MF | SE | Total | Proporção |
|---|---|---|---|---|---|---|---|---|---|
| **A** | **102** | 0 | 0 | 0 | 0 | 25 | 0 | 127 | 0.327 |
| **AB** | 0 | **8** | 0 | 14 | 14 | 0 | 0 | 36 | 0.093 |
| **FT** | 0 | 0 | **34** | 3 | 0 | 0 | 3 | 40 | 0.103 |
| **FI** | 0 | 0 | 2 | **41** | 8 | 0 | 6 | 57 | 0.147 |
| **ME** | 0 | 4 | 0 | 16 | **40** | 0 | 3 | 63 | 0.162 |
| **MF** | 0 | 0 | 0 | 0 | 0 | **37** | 0 | 37 | 0.095 |
| **SE** | 0 | 0 | 3 | 5 | 0 | 1 | **19** | 28 | 0.072 |
| **Total** | 102 | 12 | 39 | 79 | 62 | 63 | 31 | **388** | 1 |
| **Proporção** | 0.263 | 0.031 | 0.101 | 0.204 | 0.160 | 0.162 | 0.080 | 1 | |

Tabela E.18 – Matriz de confusão da classificação da decomposição de van Zyl + Matriz C, para as classes gerais. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

| Classes | A | AB | TF | FI | ME | MF | SE | Total | Proporção |
|---|---|---|---|---|---|---|---|---|---|
| **A** | **100** | 0 | 0 | 0 | 0 | 27 | 0 | 127 | 0.327 |
| **AB** | 0 | **24** | 0 | 4 | 6 | 0 | 2 | 36 | 0.093 |
| **FT** | 0 | 0 | **36** | 4 | 0 | 0 | 0 | 40 | 0.103 |
| **FI** | 0 | 4 | 3 | **34** | 10 | 0 | 6 | 57 | 0.147 |
| **ME** | 0 | 17 | 0 | 4 | **34** | 1 | 7 | 63 | 0.162 |
| **MF** | 0 | 0 | 0 | 0 | 0 | **37** | 0 | 37 | 0.095 |
| **SE** | 0 | 0 | 3 | 4 | 1 | 1 | **19** | 28 | 0.072 |
| **Total** | 100 | 45 | 42 | 50 | 51 | 66 | 34 | **388** | 1 |
| **Proporção** | 0.258 | 0.116 | 0.108 | 0.129 | 0.131 | 0.170 | 0.088 | 1 | |

Tabela E.19 – Matriz de confusão da classificação da decomposição de Cloude - Pottier, para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes.

| Classes | A | AB | FI | ME | MF | Total | Proporção |
|---|---|---|---|---|---|---|---|
| **A** | **63** | 13 | 29 | 15 | 7 | 127 | 0.396 |
| **AB** | 0 | **8** | 16 | 3 | 9 | 36 | 0.112 |
| **FI** | 1 | 9 | **40** | 3 | 4 | 57 | 0.178 |
| **ME** | 1 | 17 | 5 | **24** | 16 | 63 | 0.196 |
| **MF** | 1 | 5 | 2 | 5 | **24** | 37 | 0.115 |
| **Total** | 66 | 52 | 92 | 50 | 60 | **320** | 1 |
| **Proporção** | 0.206 | 0.162 | 0.287 | 0.156 | 0.187 | 1 | |

Tabela E.20 – Matriz de confusão da classificação da decomposição de Cloude – Pottier + Matriz C, para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes.

| Classes | A | AB | FI | ME | MF | Total | Proporção |
|---|---|---|---|---|---|---|---|
| **A** | **101** | 0 | 0 | 0 | 26 | 127 | 0.397 |
| **AB** | 0 | **22** | 5 | 9 | 0 | 36 | 0.113 |
| **FI** | 0 | 16 | **26** | 15 | 0 | 57 | 0.178 |
| **ME** | 0 | 11 | 2 | **47** | 3 | 63 | 0.197 |
| **MF** | 0 | 0 | 0 | 0 | **37** | 37 | 0.116 |
| **Total** | 101 | 49 | 33 | 71 | 66 | **320** | 1 |
| **Proporção** | 0.316 | 0.153 | 0.103 | 0.222 | 0.206 | 1 | |

Tabela E.21 – Matriz de confusão da classificação da decomposição de Cloude – Pottier + decomposição de van Zyl, para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes.

| Classes | A | AB | FI | ME | MF | Total | Proporção |
|---|---|---|---|---|---|---|---|
| **A** | **102** | 0 | 0 | 0 | 25 | 127 | 0.396 |
| **AB** | 0 | **21** | 14 | 1 | 0 | 36 | 0.112 |
| **FI** | 0 | 8 | **49** | 0 | 0 | 57 | 0.178 |
| **ME** | 0 | 25 | 19 | **19** | 0 | 63 | 0.196 |
| **MF** | 0 | 0 | 0 | 0 | **37** | 37 | 0.115 |
| **Total** | 102 | 54 | 82 | 20 | 62 | **320** | 1 |
| **Proporção** | 0.318 | 0.168 | 0.256 | 0.062 | 0.193 | 1 | |

Tabela E.22 – Matriz de confusão da classificação da decomposição de Cloude – Pottier + decomposição de van Zyl + Matriz C, para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes.

| Classes | A | AB | FI | ME | MF | Total | Proporção |
|---|---|---|---|---|---|---|---|
| **A** | **100** | 0 | 0 | 0 | 27 | 127 | 0.396 |
| **AB** | 0 | **16** | 12 | 8 | 0 | 36 | 0.112 |
| **FI** | 0 | 1 | **51** | 5 | 0 | 57 | 0.178 |
| **ME** | 0 | 12 | 19 | **31** | 1 | 63 | 0.196 |
| **MF** | 0 | 0 | 0 | 0 | **37** | 37 | 0.115 |
| **Total** | 100 | 29 | 82 | 44 | 65 | 320 | 1 |
| **Proporção** | 0.312 | 0.090 | 0.256 | 0.137 | 0.203 | 1 | |

Tabela E.23 – Matriz de confusão da classificação da decomposição de van Zyl, para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes.

| Classes | A | AB | FI | ME | MF | Total | Proporção |
|---|---|---|---|---|---|---|---|
| **A** | **102** | 0 | 0 | 0 | 25 | 127 | 0.397 |
| **AB** | 0 | **8** | 14 | 14 | 0 | 36 | 0.113 |
| **FI** | 0 | 0 | **49** | 8 | 0 | 57 | 0.178 |
| **ME** | 0 | 4 | 19 | **40** | 0 | 63 | 0.197 |
| **MF** | 0 | 0 | 0 | 0 | **37** | 37 | 0.116 |
| **Total** | 102 | 12 | 82 | 62 | 62 | **320** | 1 |
| **Proporção** | 0.319 | 0.038 | 0.256 | 0.194 | 0.194 | 1 | |

Tabela E.24 – Matriz de confusão da classificação da decomposição de van Zyl + Matriz C, para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes.

| Classes | A | AB | FI | ME | MF | Total | Proporção |
|---|---|---|---|---|---|---|---|
| **A** | **100** | 0 | 0 | 0 | 27 | 127 | 0.397 |
| **AB** | 0 | **16** | 12 | 8 | 0 | 36 | 0.113 |
| **FI** | 0 | 1 | **51** | 5 | 0 | 57 | 0.178 |
| **ME** | 0 | 12 | 19 | **31** | 1 | 63 | 0.197 |
| **MF** | 0 | 0 | 0 | 0 | **37** | 37 | 0.116 |
| **Total** | 100 | 29 | 82 | 44 | 65 | **320** | 1 |
| **Proporção** | 0.313 | 0.091 | 0.256 | 0.138 | 0.203 | 1 | |

Tabela E.25 – Matriz de confusão da classificação multitemporal para as classes gerais. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

| Classes | A | AB | TF | FI | ME | MF | SE | Total | Proporção |
|---|---|---|---|---|---|---|---|---|---|
| **A** | **47** | 0 | 0 | 0 | 3 | 2 | 0 | 52 | 0.134 |
| **AB** | 0 | **25** | 4 | 4 | 3 | 0 | 0 | 36 | 0.093 |
| **FT** | 0 | 0 | **28** | 5 | 6 | 0 | 1 | 40 | 0.103 |
| **FI** | 0 | 8 | 19 | **13** | 12 | 0 | 5 | 57 | 0.147 |
| **ME** | 0 | 8 | 7 | 0 | **111** | 7 | 5 | 138 | 0.356 |
| **MF** | 0 | 0 | 0 | 0 | 1 | **36** | 0 | 37 | 0.095 |
| **SE** | 0 | 0 | 4 | 1 | 2 | 1 | **20** | 28 | 0.072 |
| **Total** | 47 | 41 | 62 | 23 | 138 | 46 | 31 | **388** | 1 |
| **Proporção** | 0.121 | 0.106 | 0.160 | 0.059 | 0.356 | 0.119 | 0.080 | 1 | |

Tabela E.26 – Matriz de confusão da classificação multitemporal com razões de bandas para as classes gerais. As classes são: A – Água, AB – Vegetação Arbustiva, TF – Floresta de Terra Firme, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes, SE – Solo Exposto.

| Classes | A | AB | TF | FI | ME | MF | SE | Total | Proporção |
|---|---|---|---|---|---|---|---|---|---|
| **A** | **47** | 0 | 0 | 0 | 0 | 5 | 0 | 52 | 0.134 |
| **AB** | 0 | **19** | 3 | 6 | 8 | 0 | 0 | 36 | 0.093 |
| **FT** | 0 | 0 | **25** | 11 | 1 | 0 | 3 | 40 | 0.103 |
| **FI** | 0 | 8 | 11 | **23** | 7 | 0 | 8 | 57 | 0.147 |
| **ME** | 0 | 0 | 1 | 0 | **114** | 2 | 6 | 123 | 0.317 |
| **MF** | 0 | 0 | 0 | 0 | 0 | **52** | 0 | 52 | 0.134 |
| **SE** | 0 | 0 | 0 | 2 | 5 | 1 | **20** | 28 | 0.072 |
| **Total** | 47 | 27 | 40 | 42 | 135 | 60 | 37 | **388** | 1 |
| **Proporção** | 0.121 | 0.070 | 0.103 | 0.108 | 0.348 | 0.155 | 0.095 | 1 | |

Tabela E.27 – Matriz de confusão da classificação multitemporal para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes.

| Classes | A | AB | FI | ME | MF | Total | Proporção |
|---|---|---|---|---|---|---|---|
| **A** | **47** | 0 | 0 | 3 | 2 | 52 | 0.163 |
| **AB** | 0 | **25** | 7 | 4 | 0 | 36 | 0.113 |
| **FI** | 0 | 8 | **31** | 18 | 0 | 57 | 0.178 |
| **ME** | 0 | 8 | 3 | **120** | 7 | 138 | 0.431 |
| **MF** | 0 | 0 | 0 | 1 | **36** | 37 | 0.116 |
| **Total** | 47 | 41 | 41 | 146 | 45 | 320 | 1 |
| **Proporção** | 0.147 | 0.128 | 0.128 | 0.456 | 0.141 | 1 | |

Tabela E.28 – Matriz de confusão da classificação multitemporal com razões de bandas para as classes de várzea. As classes são: A – Água, AB – Vegetação Arbustiva, FI – Floresta Inundável, ME – Macrófitas Emersas, MF – Macrófitas Flutuantes.

| Classes | A | AB | FI | ME | MF | Total | Proporção |
|---|---|---|---|---|---|---|---|
| **A** | **47** | 0 | 0 | 0 | 5 | 52 | 0.163 |
| **AB** | 0 | **24** | 9 | 3 | 0 | 36 | 0.113 |
| **FI** | 0 | 8 | **46** | 3 | 0 | 57 | 0.178 |
| **ME** | 0 | 0 | 7 | **114** | 0 | 121 | 0.378 |
| **MF** | 0 | 0 | 0 | 2 | **52** | 54 | 0.169 |
| **Total** | 47 | 32 | 62 | 122 | 57 | **320** | 1 |
| **Proporção** | 0.147 | 0.100 | 0.194 | 0.381 | 0.178 | 1 | |