



UNIVERSIDADE DE BRASÍLIA - UnB
INSTITUTO DE GEOCIÊNCIAS - IG
PÓS GRADUAÇÃO EM GEOCIÊNCIAS APLICADAS E GEODINÂMICA

VANESSA SOUZA SILVA

**Análise das imagens de radar do satélite ALOS-2/PALSAR-2 para
discriminação de classes de cobertura vegetal na região de transição
Floresta/Cerrado**

*Área de Concentração: Geoprocessamento e Análise Ambiental
Dissertação de Mestrado n° 150*

Brasília - DF
Março de 2019



UNIVERSIDADE DE BRASÍLIA - UnB
INSTITUTO DE GEOCIÊNCIAS - IG
PÓS GRADUAÇÃO EM GEOCIÊNCIAS APLICADAS E GEODINÂMICA

**Análise das imagens de radar do satélite ALOS-2/PALSAR-2 para
discriminação de classes de cobertura vegetal na região de transição
Floresta/Cerrado**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Geociências Aplicadas e Geodinâmica da Universidade de Brasília, como requisito para obtenção do título de Mestre.

Área de concentração: *Geoprocessamento e Análise Ambiental*.

Orientador: Prof. Dr. Edson Eyji Sano

Brasília - DF
Março de 2019

VANESSA SOUZA SILVA

**Análise das imagens de radar do satélite ALOS-2/PALSAR-2 para
discriminação de classes de cobertura vegetal na região de transição
Floresta/Cerrado**

Aprovada em: ____/____/____

BANCA EXAMINADORA

Prof. Dr. Edson Eyji Sano
Embrapa Cerrados – Orientador

Profa. Dra. Tati de Almeida
Universidade de Brasília – Examinador Interno

Dr. Humberto Navarro de Mesquita Júnior
Serviço Florestal Brasileiro/IBAMA – Examinador Externo

FICHA CATALOGRÁFICA

Silva, Vanessa Souza.

Análise das imagens de radar do satélite ALOS-2/PALSAR-2 para discriminação de classes de cobertura vegetal na região de transição Floresta/Cerrado / Vanessa Souza Silva; Orientação de Edson Eyji Sano. Brasília, 2019.

104 p.

Dissertação de Mestrado (M) – Universidade de Brasília / Instituto de Geociências, 2019.

1. Radar de Abertura Sintética; 2. Banda L; 3. Amazônia
4. Coeficiente de Retroespalhamento; 5. Sensoriamento Remoto

REFERÊNCIA BIBLIOGRÁFICA

Silva, Vanessa Souza. Análise das imagens de radar do satélite ALOS-2/PALSAR-2 para discriminação de classes de cobertura vegetal na região de transição Floresta/Cerrado. Brasília, Instituto de Geociências, Universidade de Brasília, 104 p., 2019. Dissertação de Mestrado.

CESSÃO DE DIREITOS

NOME DO AUTOR: Vanessa Souza Silva

TÍTULO DA DISSERTAÇÃO DE MESTRADO: Análise das imagens de radar do satélite ALOS-2/PALSAR-2 para discriminação de classes de cobertura vegetal na região de transição Floresta/Cerrado.

GRAU: Mestre ANO: 2019

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar tais cópias somente para propósitos acadêmicos e científicos. Esse direito poderá ocorrer somente após a publicação deste documento. O autor reserva-se a outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito do autor e sem citar a fonte.

Vanessa Souza Silva
vanessa.geosensoremoto@gmail.com

*“Se você quer saber como um homem é,
veja como ele trata os inferiores, e não os seus iguais.”*
*“Alguns fracassos na vida são inevitáveis. É impossível viver sem falhar em
algo, a menos que você viva de forma tão cautelosa que você pode não ter
vivido de verdade – e nesse caso, você falha por omissão.”*
J. K. Rowling

*“Já tentei. Já falhei. Não importa.
Tente novamente. Falhe novamente. Falhe melhor.”*
Samuel Beckett

Dedico este trabalho a Deus, fonte de minha força e sustento diário;
À Maria, por sempre passar à minha frente abrindo caminhos;
E com todo amor, respeito e admiração, aos meus pais, Conceição e Marconi,
como parte da minha retribuição por tudo que já fizeram e
ainda fazem por mim e minha irmã.
Não poderia ter nascido em família melhor!

AGRADECIMENTOS

A Deus, por me proporcionar o dom da vida, pela saúde, pela infinita bondade e cuidado. E à Maria, por sempre passar à frente abrindo meus caminhos.

Aos meus pais, Conceição e Marconi, por todo amor, dedicação e esforço. Por vocês e para vocês, sempre!

À minha irmã e família, pela força de sempre, especialmente às crianças, fonte de alegria diária, que tornam os dias mais leves. Agradeço também ao meu cunhado Rilton, por ter cedido o *notebook* para realizar os processamentos das imagens.

Ao meu orientador, Prof. Dr. Edson Sano, por toda paciência, disponibilidade e boa vontade em me orientar. Muito obrigada pela parceria!

Às minhas amigas, pelo suporte e permanência nas horas boas e ruins.

À Juliana, pela flexibilização dos meus horários quando precisei.

À iniciativa Kyoto & Carbono, pela cessão das imagens de radar do satélite ALOS-2/PALSAR-2.

A todos aqueles que direta e indiretamente contribuíram para a realização deste trabalho.

RESUMO

Diversas regiões da floresta Amazônica vêm sendo ocupada pelas atividades agropecuárias, especialmente na sua porção sul (estados de Rondônia, norte de Mato Grosso e Pará), conhecida como arco do desmatamento. O presente trabalho teve como objetivo analisar a potencialidade das imagens de radar do satélite ALOS-2, sensor PALSAR-2, banda L, em discriminar as seguintes classes de cobertura vegetal representativas da microrregião de Sinop de Mato Grosso: floresta primária; vegetação secundária; cultura agrícola; e pastagem. Foram analisadas cenas obtidas no modo de imageamento *StripMap*, nível de processamento 1.5 e polarizações HH e HV das estações chuvosa (fevereiro) e seca (setembro). Os seguintes produtos também foram considerados: HH*HV, HH/HV e índice de retroespalhamento por diferença normalizada (NDBI), com redução do ruído *speckle* por meio do filtro adaptativo Gamma (janela de 3 pixels x 3 pixels). Os coeficientes de retroespalhamento extraídos de áreas representativas das quatro classes de cobertura vegetal foram analisados por meio de gráficos de dispersão, agrupamento hierárquico (dendogramas) e *boxplots*. Baseados em amostras de treinamento obtidos em campo e por meio de dados auxiliares (projeto MapBiomas e TerraClass e visualizador de séries temporais de índices de vegetação SATVeg), foi avaliado ainda o potencial dos classificadores *Random Forest* e *Support Vector Machine* para discriminar as classes de cobertura vegetal da área de estudo. A avaliação da acurácia das classificações foi realizada por meio de matrizes de confusão, índices de exatidão global, Kappa e Tau. Os resultados indicaram que a imagem de polarização cruzada (HV) do mês de fevereiro apresentou o melhor potencial para discriminar as classes de cobertura vegetal da área de estudo, entretanto, para utilizar os classificadores, foram utilizadas as polarizações HH, HV e HH*HV de fevereiro. Foi possível discriminar dois grupos de classes temáticas: floresta primária e vegetação secundária; e cultura agrícola e pastagem cultivada. A melhor classificação foi gerada pelo classificador SVM, com índice de exatidão global de 60%, índice Kappa de 0,47 e índice Tau de 47%.

Palavras-Chave: Radar de Abertura Sintética, Banda L, Amazônia, Coeficiente de Retroespalhamento, Sensoriamento Remoto.

ABSTRACT

Several regions of the Amazon rainforest have been occupied by agricultural activities, especially in its southern portion (states of Rondônia, northern Mato Grosso, and Pará), known as the deforestation arch. The objective of this study is to analyze the potential of the ALOS-2 satellite, PALSAR-2 sensor, L-band, to discriminate the following representative land use and land cover (LULC) classes from the northern part of the Mato Grosso State (Sinop micro-region): primary forest; secondary vegetation; cropland; and pastureland. Data obtained in StripMap image acquisition mode, 1.5 processing level, and HH and HV polarizations of rainy (February) and dry (September) seasons were analyzed. The following products were also considered: HH*HV, HH/HV, and normalized difference backscatter index (NDBI), without spatial filtering and with speckle noise reduction by means of the Gamma adaptive filter (3 pixels x 3 pixels window). The backscattering coefficients extracted from representative areas of the four LULC classes were analyzed by means of scatterplots, hierarchical clustering (dendrograms), and boxplots. Based on field training samples and ancillary data (MapBiomas and TerraClass projects and SATVeg vegetation indices time series viewer), the potential of the Random Forest and Support Vector Machine classifiers was also evaluated to discriminate the LULC classes of the study area. The classification accuracy was analyzed through the confusion matrices, overall accuracy, and Kappa and Tau indices. The results indicated that the cross-polarization (HV) images from February presented the best potential to discriminate the LULC classes of the study area. However, for the classifications, the HH, HV and HH*HV polarizations of February were used. It was possible to discriminate two groups of classes: primary forest and secondary vegetation; and croplands and pasturelands. The best classification was generated by the SVM classifier with an overall accuracy index of 60%, Kappa index of 0.47 and Tau index of 47%.

Keywords: Synthetic Aperture Radar, L-Band, Amazon, backscattering coefficient, Remote Sensing.

SUMÁRIO

CAPÍTULO 1	1
CONSIDERAÇÕES INICIAIS	1
1.1 Introdução	1
1.2 Hipótese	3
1.3 Objetivos	3
1.4 Justificativa.....	3
1.5 Estrutura da Dissertação.....	4
CAPÍTULO 2	5
FUNDAMENTAÇÃO TEÓRICA	5
2.1 Desmatamento na Amazônia	5
2.2 Sistemas ópticos de monitoramento do desmatamento na Amazônia	8
2.2.1 PRODES	8
2.2.2 DETER	9
2.2.3 DETER-B.....	10
2.2.4 DEGRAD	10
2.2.5 DETEX.....	11
2.2.6 TerraClass	11
2.2.7 Queimadas	13
2.2.8 MapBiomas.....	13
2.3 Sensores de radar como alternativa aos sensores ópticos	15
2.3.1 Características básicas de radar	16
2.3.1.1 Comprimentos de onda (λ)	16
2.3.1.2 Ângulo de Incidência (Θ).....	18
2.3.1.3 Polarização	19
2.3.1.4 Comportamento dos Alvos	19
2.3.1.5 Constante dielétrica	21
2.3.1.6 Distorções geométricas.....	21
2.3.1.7 Ruído <i>speckle</i>	22
2.4 O satélite ALOS-2.....	23
2.5 Monitoramento do desmatamento na Amazônia com imagens de radar	25
2.5.1 INDICAR.....	26
2.5.2 SipamSAR (Amazônia SAR)	27

2.5.3 Sistema de radar JJ-FAST	28
CAPÍTULO 3	29
CARACTERIZAÇÃO DA ÁREA DE ESTUDO	29
CAPÍTULO 4	32
MATERIAIS E MÉTODOS	32
4.1 Materiais.....	32
4.1.1 Imagens ALOS-2/PALSAR-2	32
4.1.3. <i>Softwares</i> utilizados	34
4.2 Métodos	34
4.2.1 Testes de imagens e softwares.....	35
4.2.2 Pré-Processamento	35
4.2.3.1. Mosaico de imagens	36
4.2.3.2. Coeficiente de retroespalhamento (σ°).....	36
4.2.3.3. Matemática de bandas	36
4.2.3.4. Filtro Gamma (3x3)	38
4.2.3.5. Georreferenciamento	38
4.2.4 Seleção de amostras de retroespalhamento.....	39
4.2.4.1. Dados de campo	39
4.2.4.2. Dados auxiliares.....	42
4.2.4.3. Utilização das áreas de interesse	45
4.2.5 Análises exploratórias dos dados.....	46
4.2.6 Classificações supervisionadas das imagens	47
4.2.6.1. Support Vector Machine.....	48
4.2.6.2. Random Forest	49
4.2.7 Avaliação da acurácia temática.....	51
CAPÍTULO 5	54
RESULTADOS E DISCUSSÃO	54
5.1 Análise exploratória dos dados ALOS-2/PALSAR-2	54
5.2 Avaliação dos classificadores Support Vector Machine e Random Forest	
69	
CAPÍTULO 6	74
CONSIDERAÇÕES FINAIS	74

LISTA DE FIGURAS

Figura 1 - Estimativa anual de desmatamento por corte raso. Fonte: INPE (2018a).....	6
Figura 2 – Etapas do processo de desmatamento da vegetação natural da Amazônia. Fonte: BARLOW e PERES (2008).	7
Figura 3 - Comprimento de onda e frequência das principais bandas de radar. Fonte: JENSEN (2009).....	15
Figura 4 – Exemplo de capacidade de penetração das bandas X, C e L. Fonte: SERVELLO (2010).....	17
Figura 5 - Relação entre a inclinação do pulso da onda e à superfície do terreno onde a onda incide. Fonte: Meneses e Sano (2012).....	18
Figura 6 – Polarizações do sinal de radar enviado pela antena nos planos horizontal, vertical e polarização cruzada. Fonte: COSTA (2011).....	19
Figura 7 – Exemplos de rugosidade da superfície e sua interação com alvos. Fonte: Teixeira (2011).....	20
Figura 8 – Tipos de retroespalhamento das micro-ondas ativas que podem ocorrer em alvos com cobertura vegetal: retroespalhamento do solo (a); retroespalhamento superficial, volumétrico e de solo (b); retroespalhamento volumétrico e superficial (c); retroespalhamento duplo (de canto) de tronco-solo (d); e retroespalhamento variado (e). Fonte: Geomática (2014).	21
Figura 9 - Exemplos das distorções geométricas que podem ocorrer em imagens de radar, conhecidas como <i>foreshortening</i> (encurtamento de rampa) e <i>layover</i> (inversão de relevo). Fonte: Meneses e Sano (2012).	22
Figura 10 – Capacidade de direcionamento de visada para direita ou para esquerda do satélite ALOS-2. Fonte: adaptado de JAXA (2014).	24
Figura 11 - Modos de observação do sensor PALSAR-2. Fonte: JAXA (2018a).	24
Figura 12 - Características dos modos de observação disponíveis no ALOS-2/PALSAR-2. Fonte: adaptado de JAXA (2014).....	25
Figura 13 - Mapa de localização da área de estudo.....	29
Figura 14 - Precipitação acumulada diária da microrregião Sinop/MT (mm). Fonte: adaptado de AGRITEMPO (2018).	31

Figura 15 - Pares de cenas ALOS-2/PALSAR-2, modo de observação <i>StripMap</i> , nível de processamento 1.5, polarizações HH e HV dos meses de fevereiro e setembro de 2016.	32
Figura 16 - Fluxograma do trabalho.	34
Figura 17 - Fluxograma da etapa de pré-processamento das imagens do satélite ALOS-2/PALSAR-2.	35
Figura 18 – Exemplos de fotografias de campo ilustrando a presença de classes de uso e cobertura de terras representativas da área de estudo: vegetação primária (a); vegetação secundária (b); pastagem cultivada (c) e cultura agrícola (d).....	40
Figura 19 - Distribuição espacial dos pontos coletados em campo, mostrada na cena ALOS-2/PALSAR de fevereiro, polarização HH.	41
Figura 20 – Exemplo de coleta de amostras de retroespalhamento com base nos dados de campo.	42
Figura 21 – Exemplo de seleção de área amostral dentro da classe Vegetação Secundária mapeada pelo projeto TerraClass Amazônia.	44
Figura 22 – Exemplo de seleção de área amostral dentro da classe pastagem cultivada, baseada nos dados do projeto MapBiomias.	44
Figura 23 – Ilustração de índices de vegetação por diferença normalizada (NDVI), representativas de vegetação primária (a), pastagem cultivada (b), cultura agrícola (c) e vegetação secundária. Fonte: SATVEG (2018).	45
Figura 24 – Teoria estatística de aprendizagem utilizada pelo classificador <i>Support Vector Machine</i> (SVM). Fonte: adaptado de Lorena e Carvalho (2007).	49
Figura 25 – Exemplo de árvores de decisão utilizadas pelo classificador <i>Random Forest</i> (RF). Fonte: TONIOL (2017).	51
Figura 26 - Valores médios de coeficientes de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado nas polarizações HH e HV dos meses de fevereiro e setembro da imagem ALOS-2/PALSAR-2.	54
Figura 27 - Comparação entre os valores de coeficientes de retroespalhamento (dB) para as estações chuvosa e seca nas polarizações HH e HV da imagem ALOS-2/PALSAR-2.	57

Figura 28 - Valores médios de coeficientes de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado das imagens resultantes de álgebra de bandas dos meses de fevereiro e setembro da imagem ALOS-2/PALSAR-2.....	58
Figura 29 – Gráficos de dispersão dos coeficientes de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado das imagens ALOS-2/PALSAR-2 (Parte 1).	60
Figura 30 - Gráficos de dispersão dos coeficientes de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado das imagens ALOS-2/PALSAR-2 (Parte 2).	61
Figura 31 - Gráficos de dispersão dos coeficientes de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado das imagens ALOS-2/PALSAR-2 (Parte 3).	62
Figura 32 - Gráficos de dispersão dos coeficientes de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado das imagens ALOS-2/PALSAR-2 (Parte 4).	63
Figura 33 - Agrupamento hierárquico entre os valores de coeficiente de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado nas polarizações HH, HV e HH*HV dos meses de fevereiro e setembro extraídos das imagens ALOS-2/PALSAR-2.....	64
Figura 34 - Agrupamento hierárquico entre os valores de coeficiente de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado nas polarizações HH/HV e NDBI dos meses de fevereiro e setembro extraídos das imagens ALOS-2/PALSAR-2.....	65
Figura 35 - <i>Boxplot</i> entre os valores de coeficiente de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado nas polarizações HH e HV dos meses de fevereiro e setembro extraídos das imagens ALOS-2/PALSAR-2.....	66
Figura 36 - <i>Boxplot</i> entre os valores de coeficiente de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado das polarizações HH*HV, HH/HV e índice NDBI dos meses de fevereiro e setembro extraídos das imagens ALOS-2/PALSAR-2.	67

Figura 37 - Resultado da classificação supervisionada pelo algoritmo Support Vector Machine, polarizações HH, HV e HH*HV do mês de fevereiro de 2016, com filtro adaptativo Gamma (janela de 3 pixels x 3 pixels).....	69
Figura 38 - Resultado da classificação supervisionada pelo algoritmo <i>Random Forest</i> , polarizações HH, HV e HH*HV de fevereiro de 2016, com filtro adaptativo Gamma (janela de 3 pixels x 3 pixels).....	71

LISTA DE TABELAS

Tabela 1 - Áreas desmatadas em 2017/2018. Fonte: adaptado de INPE (2018b).	6
Tabela 2 - Códigos da legenda para os valores de pixel na Coleção 3 do MapBiomias.	14
Tabela 3 - Comprimentos de onda e frequências de radar usados em investigações de sensoriamento remoto por micro-ondas ativas. Fonte: adaptado de JENSEN (2009).	17
Tabela 4 - Dados estatísticos dos municípios da microrregião Sinop produzidos pelo sistema Brasil em síntese. Fonte: IBGE (2018a).	30
Tabela 5 - Características das imagens ALOS2/PALSAR-2, modo de observação <i>StripMap</i> , nível de processamento 1.5 utilizadas nesse estudo.	33
Tabela 6 - Precipitação diária acumulada (mm) na microrregião do Sinop/MT (estação pluviométrica automática de Sinop/MT). Fonte: AGRITEMPO (2018).	33
Tabela 7 – Número de amostras de retroespalhamento, discriminadas por classe de uso e cobertura de terras.	39
Tabela 8 - Variáveis utilizadas na construção dos gráficos de dispersão.	47
Tabela 9 - Conceitos das classificações baseados no coeficiente Kappa.	52
Tabela 10 - Matriz de confusão do classificador SVM, utilizando imagem ALOS-2/PALSAR-2, polarizações HH, HV e HH*HV de fevereiro de 2016.	70
Tabela 11 - Matriz de confusão do classificador RF, utilizando imagem ALOS-2/PALSAR-2, polarizações HH, HV e HH*HV de fevereiro de 2016.	71
Tabela 12 - Resultado geral de índice e conceito Kappa para as classificações SVM e RF com e sem filtro.	72

1.1 Introdução

Mudanças na cobertura vegetal natural vêm ocorrendo de forma acelerada e intensa em todo o mundo. Desde a década de 1970, porções significativas de florestas tropicais estão sendo desmatadas como consequência da expansão das fronteiras agrícolas (Correia *et al.*, 2005). Nos últimos 25 anos, as áreas florestais do mundo foram reduzidas de 4,1 bilhões de hectares para menos de 4 bilhões de hectares (FAO, 2016). Ainda de acordo com esse estudo, o Brasil é o segundo país no mundo que possui a maior extensão de cobertura florestal (12% da área total). Entretanto, entre 2010 a 2015, foi o país que apresentou a maior perda líquida anual de área florestal.

Incluído nessas estatísticas está a Floresta Amazônica, o mais extenso dos seis biomas brasileiros, englobando os estados do Acre, Amapá, Amazonas, Mato Grosso, Pará, Rondônia, Roraima e parcialmente, os estados do Maranhão, Mato Grosso e Tocantins. De acordo com IBGE (2015), é a maior floresta tropical do mundo, abrangendo 1/3 das florestas tropicais úmidas do planeta. Nesse bioma, é encontrado um grande número de diferentes espécies animais e vegetais. O seu patrimônio mineral é supostamente desconhecido em sua grande parte. Estima-se que a Floresta Amazônica detém a mais elevada biodiversidade e o maior banco genético do mundo e 1/5 da disponibilidade mundial de água potável (IBGE, 2015).

Segundo Almeida *et al.* (2010), a conversão da floresta em outras classes de uso da terra por meio de práticas de exploração não sustentáveis traz grandes impactos ambientais como a redução de fertilidade do solo, aumento da erosão do solo, aumento da inflamabilidade das florestas e incêndios, alterações nos regimes hidrológicos local e global e emissão de gases de efeito estufa. Essas alterações podem acelerar as mudanças climáticas e que, por sua vez, podem ter efeitos prejudiciais de amplo espectro sobre a distribuição e a severidade de insetos florestais e surtos de doenças (van Lierop *et al.*, 2015). Portanto, considerando-se a importância da Floresta Amazônica na manutenção dos processos biológicos e climáticos tanto em escala local quanto em escala

global, faz-se necessário o estudo e aprimoramento de técnicas que permitam o monitoramento constante dessas áreas.

A utilização dos produtos de sensoriamento remoto é uma forma eficiente para essa finalidade, uma vez que os satélites são capazes de obter imagens de forma periódica, em curto espaço de tempo, de toda a superfície terrestre e em diferentes resoluções espaciais e espectrais. Nesse sentido, o governo federal brasileiro, desde o ano de 1988, vem monitorando a cobertura florestal da Amazônia por meio do sensoriamento remoto, por meio de programas para prevenção e controle da supressão vegetal (INPE, 2008a). Esses mapeamentos fornecem informações sobre as dinâmicas de ocupação, quantificação de áreas desflorestadas e processos de regeneração florestal, permitindo melhor definição de ações e políticas públicas para controle, conservação e recuperação da vegetação.

Em sua grande maioria, esses programas utilizam sensores orbitais ópticos que operam na faixa do espectro eletromagnético do visível e infravermelho. Imagens obtidas por esses sensores apresentam maior facilidade em termos de interpretação de imagens, porém, possuem importante limitação em termos de obtenção de dados na estação chuvosa devido à cobertura de nuvens. Porções tropicais da Terra, como é o caso da região amazônica, possuem elevada cobertura de nuvens. Sensores ópticos, por operarem com comprimentos de onda relativamente curtos, da ordem de micrometros, não conseguem atravessar as nuvens.

Como alternativa, tem-se a utilização de imagens de radar, que operam na faixa espectral de micro-ondas e, portanto, possuem maior comprimento de onda, da ordem de centímetros, permitindo o imageamento da superfície terrestre com menor interferência das condições meteorológicas e atmosféricas, como nuvens e aerossóis. Por operarem com fonte própria de radiação eletromagnética (REM), é possível obter imagens em qualquer época do ano ou hora do dia, diferentemente dos sensores passivos que sofrem interferência das condições de iluminação solar.

Considerando-se o objetivo de monitoramento ambiental, um dos sensores de radar que possui maior potencial para monitorar mudanças na cobertura vegetal em ambiente de floresta tropical é o que está a bordo do satélite japonês *Advanced Land Observing Satellite (ALOS) 2*.

1.2 Hipótese

As imagens de radar do satélite ALOS-2/PALSAR-2 são capazes de discriminar as principais classes de cobertura vegetal da área de transição Amazônia/Cerrado (vegetação primária, vegetação secundária, pastagem e cultura agrícola).

1.3 Objetivos

O objetivo deste estudo é analisar a capacidade das imagens de radar do satélite ALOS-2/PALSAR-2 em mapear as classes de cobertura vegetal da área de transição Amazônia/Cerrado (vegetação primária, vegetação secundária, pastagem e cultura agrícola). Como objetivos específicos, tem-se:

- i. Avaliar o potencial de desempenho das polarizações HH, HV e suas derivações ($HH*HV$, HH/HV e índice NDBI (Índice de Retroespalhamento por Diferença Normalizada) na identificação de classes de cobertura vegetal da área de transição Amazônia/Cerrado;
- ii. Avaliar o potencial de desempenho das imagens ALOS-2/PALSAR-2 em diferentes condições climatológicas (seca e chuva) na identificação classes de cobertura vegetal da área de transição Amazônia/Cerrado; e
- iii. Avaliar e comparar o desempenho dos classificadores *Random Forest* (RF) e *Support Vector Machine* (SVM) na diferenciação das classes de cobertura vegetal da área de estudo.

1.4 Justificativa

Embora o reconhecimento da importância da Amazônia seja a nível global, o Brasil ainda enfrenta dificuldades quanto à preservação desse bioma. Exploração ilegal de madeira, desmatamento indiscriminado para culturas agrícolas, queimadas e mesmo disputas por terra causam desequilíbrios no funcionamento do ecossistema. Portanto, estudos que visam acompanhar os

tipos de uso e ocupação do solo são úteis para monitorar e coibir ações ilegais de degradação ambiental na Amazônia.

A utilização de imagens de radar para monitoramento ambiental vem ganhando espaço, uma vez que possuem capacidade de imagear durante o dia ou à noite e as condições meteorológicas e atmosféricas, como nuvens e chuva, raramente interferem na qualidade do imageamento. As imagens do satélite ALOS-2/PALSAR-2, lançado em 2014, ainda estão sendo testadas para as mais diversas finalidades, a fim de confirmar suas potencialidades e limitações. Dessa maneira, justifica-se essa pesquisa para somar aos estudos recentes das funcionalidades das imagens do referido satélite, assim como utilizar técnicas para o monitoramento do desmatamento e/ou manutenção da floresta natural amazônica em imagens de radar.

Essa pesquisa faz parte do escopo do projeto aprovado pelo Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA) no âmbito da Iniciativa Kyoto & Carbono da Agência de Exploração Aeroespacial do Japão (JAXA). O objetivo geral desse projeto é o uso de imagens do satélite ALOS-2/PALSAR-2 para detecção de indicativos de desmatamento na Amazônia Legal na estação chuvosa e seca.

1.5 Estrutura da Dissertação

Essa dissertação foi estruturada em seis capítulos. No Capítulo 1, foram abordados os objetos de investigação, hipótese, justificativa e objetivos da pesquisa.

No Capítulo 2, foi apresentada a revisão bibliográfica, abordando os principais conceitos, histórico e aplicações das imagens de radar.

No Capítulo 3, a ênfase é dada para uma breve descrição da área de estudo.

O Capítulo 4 compreendeu os materiais e métodos utilizados para o desenvolvimento da pesquisa.

No Capítulo 5, foram apresentados os resultados e discussão.

No Capítulo 6, foram abordadas as considerações finais sobre a pesquisa realizada.

2.1 Desmatamento na Amazônia

Em 1966, foi criada a Amazônia Legal para fins de planejamento político e valorização econômica da Amazônia (Lei 5.173, de 27 de outubro de 1966). Os planos nacionais de desenvolvimento da década de 1970 incentivavam a ocupação do seu extenso território, uma vez que possuíam o objetivo de integrar a região amazônica com o restante do país por meio de atividades econômicas (agricultura, pecuária, infraestrutura, etc.).

A partir de então, acentuou-se o processo de desmatamento da Amazônia, que começou com as aberturas oficiais ou clandestinas de estradas que permitiam a ocupação regular ou irregular de terras para exploração de madeiras nobres (FERREIRA *et al.*, 2005). Estudos evidenciam que esse desmatamento está relacionado com o aumento das atividades econômicas em larga escala, especulação de terra, crescimento das cidades, aumento dramático da pecuária bovina, incêndios florestais, exploração madeireira e agricultura familiar - principalmente ligada ao cultivo de soja e algodão (ALENCAR *et al.*, 2004).

Dados estatísticos coletados desde 1988 demonstram que as taxas de desmatamento na Amazônia (por corte raso) foram diminuindo acentuadamente a partir de 2005 (Figura 1). Entretanto, entre 2014 a 2016, os índices de desmatamento apresentaram ligeiro aumento, voltando a diminuir em 2017.

No tocante às áreas com indícios de algum tipo de alteração de cobertura florestal, no período compreendido entre agosto de 2017 a julho de 2018, foi identificado um total de 27.945,30 km² de mudanças de uso e cobertura da terra, sendo que aproximadamente 69% dessas mudanças foram causadas por incêndios florestais (Tabela 1).




Figura 1 - Estimativa anual de desmatamento por corte raso. Fonte: INPE (2018a).

Classe de Desmatamento		Área Alterada (km²)	Porcentagem (%)
Nível 1	Nível 2		
Desmatamento	Mineração	77,8	0,3
	Desmatamento com vegetação	241,0	0,9
	Desmatamento com solo exposto	3.373,3	12,1
Exploração madeireira	Corte seletivo tipo 1 (desordenado)	695,6	2,5
	Corte seletivo tipo 2 (geométrico)	831,8	3,0
Degradação	Degradação	3.375,00	12,1
	Cicatriz de incêndio florestal	19.350,8	69,2
Total		27.945,3	100,0

Tabela 1 - Áreas desmatadas em 2017/2018. Fonte: adaptado de INPE (2018b).

A identificação de áreas com alterações no uso e cobertura do solo e posterior classificação quanto à forma de retirada da cobertura vegetal resulta em um melhor entendimento quanto às mudanças do padrão de ocupação da Amazônia e as finalidades do desmatamento. De acordo com INPE (2008a), o processo de desmatamento ilegal da Amazônia ocorre de maneira gradual e em etapas, até que a floresta natural seja convertida totalmente em outra cobertura do solo (Figura 2).

O processo inicia-se com o corte seletivo de madeiras mais nobres, em seguida, das utilizadas para construção civil e, posteriormente, das árvores remanescentes que possuem madeiras menos valoradas. Após a retirada das

madeiras interessantes para empreendimentos de diversos ramos da economia, são derrubadas as árvores de menor porte, seguida da derrubada da vegetação arbustiva. No processo de desmatamento, é comum manter algumas espécies de árvores como palmeiras e castanheiras. Nesse ponto, já é possível desenvolver a pecuária por meio da introdução de capins exóticos como a *Brachiaria*, transformando essas áreas desmatadas em áreas de pastagem cultivada.




Figura 2 – Etapas do processo de desmatamento da vegetação natural da Amazônia. Fonte: BARLOW e PERES (2008).

A segunda etapa da degradação da vegetação natural ocorre com a queima da cobertura vegetal remanescente e do capim introduzido, sobrando poucos vestígios da vegetação original. Uma vez que o capim é uma planta que se adapta aos danos produzidos pelo fogo, a área é transformada novamente em área de pastagem tão logo essa gramínea volta a brotar. De outro modo, essas áreas também podem ser destinadas às culturas agrícolas ou mesmo abandonadas, ocorrendo regeneração da vegetação natural (vegetação secundária). Todo esse processo pode ser repetido diversas vezes até não restar vestígios da vegetação natural, sendo esse o último e o mais extremo estágio do desmatamento, chamado de corte raso.

2.2 Sistemas ópticos de monitoramento do desmatamento na Amazônia

Nos últimos anos, com o aumento da preocupação mundial em relação às questões ambientais, o monitoramento do desmatamento na Amazônia Legal por meio de imagens de sensores remotos orbitais e aerotransportados tornou-se uma realidade no Brasil (SOUZA FILHO *et al.*, 2006). O governo brasileiro tem buscado formas de combate às atividades desmatadoras por meio de órgãos fiscalizadores e de pesquisa para aplicação de punições para impor respeito às regras descritas nos códigos de conduta ambientais nacionais e, portanto, restringir o desmatamento na Amazônia Legal (RODRIGUES *et al.*, 2018). Um dos órgãos de pesquisa é o Instituto Nacional de Pesquisas Espaciais (INPE), que, por meio de programas de monitoramento da Amazônia, utiliza dados obtidos por sensores ópticos para o monitoramento florestal amazônico. Os principais programas são:

2.2.1 PRODES

O Projeto de Monitoramento do Desmatamento na Amazônia Legal por Satélite opera desde 1988 e sua principal função é medir as taxas anuais de cortes rasos, considerando desmatamentos com áreas superiores a 6,25 hectares (INPE, 2008a).

Para obtenção dos dados de desmatamento, são empregadas diversas metodologias que foram aprimoradas com o passar dos anos. Segundo INPE (2013), até o ano de 2002, as análises eram realizadas de modo analógico. Um conjunto com 220 cenas do satélite Landsat-5/TM, impressas em papel fotográfico na escala de 1:250.000, eram analisadas pelo método de interpretação visual. Os polígonos identificados eram digitalizados manualmente por meio de um sistema de informações geográficas (SIG).

Entre 2003 e 2005, foi adotado o PRODES Digital, sendo o início da disponibilização dos dados na internet. Todo o processamento digital das imagens (georreferenciamento, classificação, edição e confecção de mapas) era realizado por meio do *software* Sistema de Processamento de Informações Georreferenciadas (SPRING). Segundo INPE (2013), a partir de 2005, os programas de monitoramento da Amazônia passaram a utilizar a plataforma

TerraAmazon. Nesse sistema, são analisadas as imagens dos satélites Landsat, com resolução espacial de 30 metros e resolução temporal de 16 dias, CBERS-2B, com resolução espacial de 20 metros e resolução temporal de 26 dias e Resourcesat, com resolução espacial de 32 metros e resolução temporal quase diária.

A principal limitação do PRODES está relacionado com as condições climáticas (INPE, 2013). Para os casos de alta cobertura de nuvens nas imagens Landsat, são utilizadas imagens dos outros satélites supracitados para tentar compor a cena e estimar as taxas anuais de desmatamento.

2.2.2 DETER

No Sistema de Detecção de Desmatamento em Tempo Real, em operação desde 2004, toda alteração da cobertura vegetal é apontada como área de alerta para possível fiscalização (INPE, 2008b). Dessa maneira, diferente do que ocorre no PRODES, qualquer estágio de desmatamento é identificado como: corte raso, degradação florestal preparativa para o desmatamento ("brocagem"), cicatrizes de incêndios florestais e atividades de exploração madeireira.

O DETER utiliza imagens dos sensores *Moderate Resolution Imaging Spectroradiometer* (MODIS) da plataforma Terra e *Wide Field Imager* (WFI) do satélite CBERS-2B. Com resolução espacial de 250 metros e 260 metros, respectivamente, e resolução temporal variando de 2 a 5 dias, a detecção é feita apenas para áreas superiores a 25 hectares. Devido à maior frequência de imagens, é possível produzir mapas e tabelas com focos de desmatamento a cada 15 dias.

A identificação e classificação dos polígonos de desmatamentos são realizados a partir de interpretação visual, com base na resposta espectral da composição colorida de bandas RGB/143, verificando-se os elementos de interpretação de imagens correspondentes à tonalidade, textura e contexto (INPE, 2008b). Assim como ocorre com PRODES, a grande dificuldade é selecionar imagens com baixa ocorrência de nuvens. Entretanto, devido à alta frequência de imagens, as limitações de observação impostas pelas condições

atmosféricas adversas são reduzidas, ao mesmo tempo em que compensa a limitação da resolução espacial (INPE, 2008c).

Nesse sistema, desde o ano de 2008, é realizada a validação e qualificação amostral dos dados. Para tal, é realizada a sobreposição dos polígonos identificados pelo PRODES com dados obtidos por técnicas de foto-interpretação em imagens TM/Landsat-5, adquiridas em período equivalente ao das imagens MODIS (INPE, 2009).

2.2.3 DETER-B

O DETER-B é um sistema aprimorado do DETER, em operação desde 2015. A maior parte das áreas desmatadas vêm sofrendo redução de tamanho, tornando o DETER limitado. Dessa forma, a atualização do projeto surgiu com o objetivo de detectar áreas menores, uma vez que identifica e mapeia, em tempo quase real, desmatamentos e demais alterações na cobertura florestal com área mínima próxima a 1 hectare (INPE, 2018c). Entretanto, para o público em geral, os dados são disponibilizados com as mesmas dimensões do PRODES, de 6,25 hectares.

São utilizadas imagens do sensor WFI do satélite sino-brasileiro CBERS-4, com resolução espacial de 64 metros e resolução temporal de 5 dias, e o sensor AWiFS do satélite indiano Resourcesat 1-2, com resolução espacial de 56 metros e resolução temporal de 5 dias. A produção das poligonais é realizada em sete etapas: aquisição e composição de imagens; correção geométrica; modelo linear de mistura espectral; avaliação de áreas não-observadas (cobertas por nuvens ou sombras); geração de máscaras PRODES; interpretação visual; e auditoria (DINIZ *et al.*, 2015).

2.2.4 DEGRAD

O Mapeamento da Degradação Florestal na Amazônia Brasileira teve início em 2007 e é um sistema destinado a mapear áreas em processo de desmatamento, onde a cobertura florestal ainda não foi totalmente removida (INPE, 2008a). Dessa forma, esse sistema tem o objetivo de mapear as áreas

que não são identificadas pelo PRODES, como áreas de queimadas e exploração madeireira por corte seletivo.

O DEGRAD também utiliza as imagens dos satélites Landsat e *High Resolution Camera* (HRC) do CBERS-2B, com resolução espacial de 2,7 metros. A área mínima mapeada é de 6,25 hectares. De acordo com INPE (2008a), a metodologia de identificação consiste em aplicar realces de contraste nas imagens selecionadas para destacar as evidências de degradação. Assim como nos programas anteriores, a seleção de imagens é prejudicada devido à alta ocorrência de nuvens, característica da região Amazônica.

2.2.5 DETEX

O Sistema de Detecção de Exploração Seletiva (DETEX) é um sistema criado para monitorar áreas de manejo florestal, isto é, verificar se a exploração florestal, sob contrato de concessão expedido pelo Serviço Florestal Brasileiro, está ocorrendo no local, na intensidade e nos períodos estabelecidos no Plano de Manejo Sustentável e detecção de atividades madeireiras ilegais (INPE, 2010).

Também são utilizadas imagens Landsat e a metodologia de identificação consiste em cinco etapas: aplicação do modelo linear de mistura espectral; álgebra entre as imagens-fração de solo e vegetação, resultantes da primeira etapa; realce das imagens resultantes; mapeamento das áreas de exploração por interpretação visual; e auditoria (ALMEIDA, 2009).

2.2.6 TerraClass

O projeto TerraClass faz parte do Programa de Monitoramento Ambiental dos Biomas Brasileiros, criado com o objetivo de mapear e monitorar as conversões de uso do solo após desmatamento, avaliar a cobertura vegetal e o uso/cobertura da terra e sua dinâmica, as queimadas, a extração seletiva de madeira e a recuperação da vegetação (MMA, 2017). Esse projeto é direcionado para os biomas brasileiros Amazônia e Cerrado. O TerraClass diferencia-se dos projetos anteriores por promover a qualificação dos desmatamentos na

Amazônia Legal. Portanto, é possível verificar as finalidades das mudanças de uso e cobertura do solo.

As possíveis causas das mudanças na cobertura vegetal da Amazônia Legal são classificadas em 12 classes temáticas: agricultura anual; área não-observada; área urbana; mineração; mosaico de ocupações; pasto com solo exposto; pasto limpo; pasto sujo; regeneração com pasto; reflorestamento; vegetação secundária; e outros (INPE, 2018d). Os resultados são divulgados a cada dois anos, incluindo-se os dados estatísticos e mapas sistemáticos na escala cartográfica de 1:100.000 (COUTINHO *et al.*, 2013).

Esse projeto utiliza diferentes metodologias para identificação das diferentes classes temáticas. De acordo com Coutinho *et al.* (2013), foi considerada a mesma base de 229 cenas Landsat-5/TM do projeto Prodes, composição colorida falsa-cor RGB/345. Também foram utilizadas imagens do sensor MODIS para auxiliar na diferenciação de classes.

Para identificação das áreas de vegetação secundária, foi utilizada a máscara de desmatamento do projeto Prodes, em que foi aplicado o modelo linear de mistura espectral (MLME) para identificação de solo, sombra e vegetação. A partir da determinação do intervalo de valor digital da classe de vegetação secundária, foi realizada a técnica de fatiamento da imagem. Para identificação das demais classes, foi realizada a segmentação de imagem nas demais áreas da máscara de desflorestamento. A classe Agricultura Anual foi determinada a partir do comportamento espectro-temporal do índice de vegetação pela diferença normalizada (NDVI) obtida pelo sensor MODIS. A classe de Pastagem Cultivada foi determinada a partir do algoritmo de classificação supervisionado *Battacharya*, com as amostras selecionadas em campo e feições espectrais presentes nas imagens. A classe Mosaico de Ocupações foi determinada a partir dos mesmos procedimentos da classe de pastagens, o que se resume à imagem segmentada, seleção de amostras e classificação supervisionada. Por fim, as classes Área Urbana, Mineração e Outros foram identificadas a partir interpretação das feições restantes do processo de segmentação das imagens.

2.2.7 Queimadas

O programa Queimadas, em operação desde 1998, possui a finalidade de detectar e monitorar possíveis focos de queimadas e de incêndios florestais, assim como realizar cálculos e previsões dos riscos de fogo na vegetação da América do Sul, América Central, África e Europa (INPE, 2018d).

Segundo INPE (2018d), esse programa utiliza satélites distintos que operam na faixa termal-média de 4 μm , sendo as imagens oriundas do sensor AVHRR/3 dos satélites com órbitas polares NOAA-15, NOAA-18, NOAA-19 e METOP-B, imagens MODIS das plataformas Terra e Aqua, imagens VIIRS do satélite NPP-Suomi e as imagens dos satélites geoestacionários GOES-13 e MSG-3.

Com a utilização dos satélites citados, são geradas, em média, 250 imagens por dia. A identificação dos focos de queimadas ocorre por meio de identificação de classes com faixas com temperaturas acima de 60°C (BRASIL, 2017). A cada 3 horas são gerados relatórios técnicos contendo gráficos e tabelas atualizadas das cicatrizes de queimadas encontradas.

2.2.8 MapBiomass

Embora não seja de responsabilidade governamental, o MapBiomass é um projeto de mapeamento anual da cobertura e uso do solo no Brasil que teve início em julho de 2015. É uma iniciativa do Sistema de Estimativas de Emissões de Gases de Efeito Estufa do Observatório do Clima e é produzido por uma rede colaborativa de co-criadores formado por ONGs, universidades e empresas de tecnologia organizados por biomas brasileiros (Amazônia, Caatinga, Pampas, Cerrado, Mata Atlântica e Pantanal) e temas transversais (Pastagem, Agricultura, Zona Costeira e Áreas Urbanas - Terra) (MAPBIOMASS, 2018a).

Este projeto utiliza processamento em nuvem e classificadores automatizados desenvolvidos e operados a partir da plataforma *Google Earth Engine* para gerar séries históricas de mapas anuais de cobertura e uso da terra do Brasil. São gerados diversos produtos, como mapas de cobertura e uso do solo, mosaico de imagens, coleções de scripts, dentre outros.

A metodologia para gerar o mosaico de imagens anuais consiste em diferentes etapas. De acordo com MapBiomas (2018b), o primeiro passo é selecionar todas as imagens Landsat disponíveis para o ano desejado e calcular frações e índices espectrais, como NDVI, NDFI, NPV. Em seguida, é gerado os mosaicos das imagens anuais para otimizar o contraste espectral e discriminar as classes de cada bioma. O passo seguinte é estabelecer as características espectrais de cada classe para executar a classificação *Random Forest*. Essa classificação é baseada nas amostras de treinamento geradas na coleção 2.3, em mapas de referência e amostragem manual. Em seguida, são aplicados filtros espaciais e temporais para remover ruídos das imagens. O seguinte passo é integrar os mapas de cada bioma com suas respectivas classificações para gerar o mapa final, em formato geotiff (raster). A partir desse, são realizadas as análises de mudança de cobertura do solo, assim como análises de acurácia, por meio da matriz de confusão, e estatísticas dos dados. As classes geradas nesse projeto podem ser observadas na Tabela 2.

COLEÇÃO 3 - PORTUGUÊS	NEW ID
1. Floresta	1
1.1. Floresta Natural	2
1.1.1. Formação Florestal	3
1.1.2. Formação Savânica	4
1.1.3. Mangue	5
1.2. Floresta Plantada	9
2. Formação Natural não Florestal	10
2.1. Área Úmida Natural não Florestal	11
2.2. Formação Campestre	12
2.3. Apicum	32
2.4. Outra Formação Natural não Florestal	13
3. Agropecuária	14
3.1. Pastagem	15
3.2. Agricultura	18
3.2.1. Cultura Anual e Perene	19
3.2.2. Cultura Semi-Perene	20
3.3. Mosaico de Agricultura e Pastagem	21
4. Área não vegetada	22
4.1. Praia e Duna	23
4.2. Infraestrutura Urbana	24
4.3. Afloramento Rochoso	29
4.4. Mineração	30
4.5. Outra Área não Vegetada	25
5. Corpos D'água	26
5.1 Rio, Lago e Oceano	33
5.2 Aquicultura	31
6. Não observado	27

Tabela 2 - Códigos da legenda para os valores de pixel na Coleção 3 do MapBiomas.
Fonte: MAPBIOMAS (2018).

2.3 Sensores de radar como alternativa aos sensores ópticos

Produtos de sensores que trabalham na faixa espectral do visível, principalmente as imagens multiespectrais, são os mais utilizados em análises ambientais. Além de maior acessibilidade aos dados, grande é o volume de estudos e técnicas para manipulação dessas imagens. Todavia, esses dados apresentam algumas limitações, especialmente em áreas tropicais. Na maior parte do ano, essas áreas estão parcialmente ou totalmente cobertas por nuvens, dificultando ou impedindo a coleta de dados e o monitoramento contínuo da região por meio dessas imagens de satélite.

Nesse contexto, as imagens geradas por radares imageadores tornam-se uma alternativa interessante, uma vez que interferências externas como nuvens, fumaça, bruma e chuva, as quais restringem o uso de sensores ópticos, são mínimas em produtos de radar (PARADELLA *et al.*, 2005), possibilitando a aquisição de dados independente das condições atmosféricas e meteorológicas. Para Meneses e Sano (2012), outra vantagem é o imageamento que poder ser realizado em qualquer hora do dia ou da noite, exatamente por não depender da presença do Sol ou de outra fonte de REM. Isso só é possível porque os radares imageadores operam com sua própria fonte de energia eletromagnética (artificial). Sendo assim, são considerados sensores ativos. Esses sensores operam na faixa do espectro eletromagnético das micro-ondas, que varia de 1 cm a 1 m de comprimento de onda (Figura 3).




Figura 3 - Comprimento de onda e frequência das principais bandas de radar. Fonte: JENSEN (2009).

Os radares imageadores compreendem os sistemas constituídos de antenas rotatórias e os de visada lateral (*Side Looking Airborne Radar - SLAR*). Os sistemas SLAR englobam os radares do tipo *Real Aperture Radar (RAR -*

radar de abertura real) e o *Synthetic Aperture Radar* (SAR - radar de abertura sintética) (COSTA, 2011), como o sensor ALOS-2/PALSAR-2.

Os radares de abertura sintética empregam uma antena lateral de tamanho físico pequeno que sintetiza uma antena de tamanho de centenas de metros (MENEZES e SANO, 2012). O princípio do funcionamento desses radares consiste na emissão de sucessivos pulsos de energia eletromagnética em direção ao alvo. Ao atingi-lo, a energia é retroespalhada e uma parcela desses pulsos, agora modificados pelos alvos, retornam para a mesma antena, que recebe os sinais à medida que se desloca. A energia retroespalhada é medida pelo coeficiente de retroespalhamento (σ^0), razão da energia emitida pelo sensor de radar pela energia refletida pelo alvo e captada pelo mesmo sensor. A magnitude do retroespalhamento depende do comprimento de onda do radar, da polarização e do ângulo de incidência, bem como das condições do terreno e dos parâmetros do alvo (RAHMAN e SUMANTYO, 2010). A identificação desses alvos é realizada a partir da energia retroespalhada que carrega as informações das propriedades físicas (geometria, forma), relacionadas com atributos da superfície dos objetos, e propriedades dielétricas, caracterizadas pela constante dielétrica do solo e da vegetação para um dado comprimento de onda (MORAN *et al.*, 2002).

2.3.1 Características básicas de radar

As imagens de radar imageador são formadas a partir do retroespalhamento da REM emitida pelo próprio sensor, variando em função dos parâmetros do radar, caracterizados pelo comprimento de onda (λ), ângulo de incidência (θ) e polarizações, e variáveis do alvo, caracterizadas pela constante dielétrica dos solos e da planta, rugosidade do terreno e estrutura da vegetação.

2.3.1.1 Comprimentos de onda (λ)

Em radares imageadores, as ondas eletromagnéticas artificiais são classificadas em bandas, de acordo com seu comprimento e frequência (Tabela

3). Quanto maior o comprimento de onda, maior será a capacidade de penetração do pulso de radar no alvo (Figura 4).

Banda	Comprimento de Onda (cm)	Frequência (GHz)
Ka	0,75 - 1,18	40,0 - 26,5
K	1,19 - 1,67	26,5 - 18,0
Ku	1,67 - 2,4	18,0 - 12,5
X	2,4 - 3,75	12,5 - 8,0
C	3,9 - 7,5	8,0 - 4,0
S	7,5 - 15,0	4,0 - 2,0
L	15,0 - 30,0	2,0 - 1,0
P	30,0 - 100,0	1,0 - 0,3

Tabela 3 - Comprimentos de onda e frequências de radar usados em investigações de sensoriamento remoto por micro-ondas ativas. Fonte: adaptado de JENSEN (2009).




Figura 4 – Exemplo de capacidade de penetração das bandas X, C e L. Fonte: SERVELLO (2010).

Segundo Costa (2011), as bandas X e C são comumente usadas em estudos relacionados com mapeamento geológico. Para estudos de vegetação, esses comprimentos de onda menores possibilitam obter informações acerca das camadas superiores da vegetação (dossel), pois interagem com as partes menores, como folhas e galhos (TEIXEIRA, 2011). Já os dados gerados em bandas L e P dispõem de grande potencial na identificação de diferentes coberturas da terra, pois são sensíveis à estrutura da vegetação, sendo capazes de penetrar em camadas inferiores, como caules e troncos e solo, dependendo da densidade e umidade do meio (PRADO *et al.*, 2010).

2.3.1.2 Ângulo de Incidência (Θ)

De acordo com KUPLICH (2003), o ângulo de incidência do radar é aquele formado entre o pulso de micro-ondas incidentes e uma reta vertical estabelecida em relação à Terra. Imageamentos realizados por radares recobrem grandes áreas e o retroespalhamento gerado varia em função da distância entre o sensor e o alvo (formando o ângulo). Portanto, as regiões mais próximas ao sensor (denominadas de *near range*) tendem a gerar valores maiores de retroespalhamento que as regiões mais distantes (denominadas de *far range*) em consequência das alterações no ângulo de incidência. Terrenos com diferentes declividades possuem diferentes ângulos de incidência, denominados ângulos de incidência local, ao contrário de terrenos planos, que possuem ângulos de incidência local fixos (Figura 5). Assim, ângulos de incidência elevados resultam em menor retroespalhamento (KUPLICH, 2003).




Figura 5 - Relação entre a inclinação do pulso da onda e à superfície do terreno onde a onda incide. Fonte: Meneses e Sano (2012).

Sendo o retroespalhamento o responsável pela tonalidade das imagens, os diferentes tons de cinza representarão na imagem a forma textural do terreno. Nesse contexto, surge outra característica da imagem: o sombreamento. Áreas dorsais do terreno declivoso podem não receber iluminação pelo sensor e, em consequência, não oferecer sinal de retorno, o que significa que não haverá informações do alvo, sendo este apresentado nas imagens com tonalidade cinza muito escura.

2.3.1.3 Polarização

Polarização se refere à orientação do campo elétrico utilizado. As antenas de radar podem ser configuradas para receber e emitir REM com uma direção pré-definida. Mais especificamente, as antenas podem enviar pulsos polarizados horizontalmente (H), verticalmente (V) ou com polarização cruzada. Desta forma, na mesma direção que o pulso foi enviado, será recebido (HH ou VV) ou o sinal emitido é enviado em direção diferente da recebida (HV ou VH) (Figura 6).




Figura 6 – Polarizações do sinal de radar enviado pela antena nos planos horizontal, vertical e polarização cruzada. Fonte: COSTA (2011).

Para Meneses e Sano (2012), sensores multipolarizados (que operam com os quatro tipos de polarização) aumentam as chances de discriminação dos materiais em função das variações de rugosidade da superfície. Para vegetação, essa discriminação é evidenciada, uma vez que diferentes respostas são obtidas em cada polarização, devido à despolarização da REM pelos múltiplos retroespalhamentos dos galhos e folhas.

2.3.1.4 Comportamento dos Alvos

De acordo com Meneses e Sano (2012), a REM é uma forma de energia capaz de interagir com objetos de acordo com o modelo corpuscular, que consiste na interação dessa radiação com os átomos e moléculas dos materiais constituintes dos objetos, ou de acordo com o modelo ondulatório, onde a radiação interage com o formato do objeto.

Em sistemas de radar, que operam com comprimentos de ondas relativamente longos, a interação da REM com o alvo é macroscópica, característica do modelo ondulatório. Nesse modelo, as informações apresentadas nas imagens dizem respeito ao retroespalhamento resultante da interação da onda com a textura do objeto que possui relação com dimensões e formatos (MENESES, 2012).

Para uma imagem de radar, as superfícies podem ser rugosas ou lisas. De acordo com Meneses e Sano (2012), uma superfície rugosa pode ser um refletor difusor que retroespalha o sinal em todas as direções, apresentando um tom de cinza mais claro na imagem, enquanto uma superfície lisa pode ser um refletor especular, onde não há o retorno do sinal retroespalhado em direção à antena, produzindo tons de cinza mais escuros (Figura 7).



Figura 7 – Exemplos de rugosidade da superfície e sua interação com alvos. Fonte: Teixeira (2011).

Em áreas florestais, é comum haver diferentes formas de interação com o alvo (Figura 8): retroespalhamento direto da superfície do solo; retroespalhamento oriundo da interação com o volume da folhagem, dossel arbustivo e da folha; retroespalhamento direto de grandes galhos e troncos; retroespalhamento oriundo de reflexão de canto de troncos de árvores; e outros componentes de interação devido à dispersão múltipla entre a folhagem e a superfície do solo, grandes galhos e superfície, folhagem e dossel arbustivo, e assim por diante.




Figura 8 – Tipos de retroespalhamento das micro-ondas ativas que podem ocorrer em alvos com cobertura vegetal: retroespalhamento do solo (a); retroespalhamento superficial, volumétrico e de solo (b); retroespalhamento volumétrico e superficial (c); retroespalhamento duplo (de canto) de tronco-solo (d); e retroespalhamento variado (e). Fonte: Geomática (2014).

2.3.1.5 Constante dielétrica

Além da rugosidade do terreno, a constante dielétrica também é um parâmetro que interfere na intensidade de retroespalhamento da radiação incidente. A constante dielétrica corresponde à capacidade dos materiais em formar dipolos na presença de um campo elétrico externo e em armazenar e conduzir energia elétrica (MENESES e SANO, 2012).

Em outras palavras, é uma medida das propriedades elétricas dos materiais, incluindo a capacidade de absorver, refletir e transmitir a radiação das micro-ondas em resposta a um sinal incidente (TEIXEIRA, 2011). A quantidade de água no conteúdo dos alvos é um fator que influencia a aparência do mesmo na imagem. Quanto maior a constante dielétrica do alvo, mais intenso é o retorno do sinal.

2.3.1.6 Distorções geométricas

Radares de abertura sintética possuem visada lateral para imageamento dos alvos. Segundo Meneses e Sano (2012), a imagem é originalmente construída pelo registro dos sinais medidos no plano inclinado, o

que causa uma deformação dos alvos, comprimindo ou achatando as formas dos objetos que se situam mais próximos à antena.

As duas principais distorções referentes às geometrias dos alvos são o *foreshortening* (encurtamento de rampa) e o *layover* (inversão de relevo) (Figura 9). A inversão de relevo ocorre quando o pulso alcança primeiro o topo da feição (como uma montanha) para depois atingir a base, o que faz com que o sinal de retorno do topo chegue primeiro ao sensor, provocando, na imagem, a inversão do terreno, isto é, as partes mais altas são mapeadas como mais baixas e as partes mais baixas são mapeadas como mais altas. Já o encurtamento de rampa se expressa como uma compressão ou encurtamento da encosta frontal, relativo à encosta dorsal do relevo (MENESES e SANO, 2012), o que leva à montanha ser representada na imagem com sua face frontal encurtada em tonalidades mais claras e a face dorsal alongada com tonalidades mais escuras.

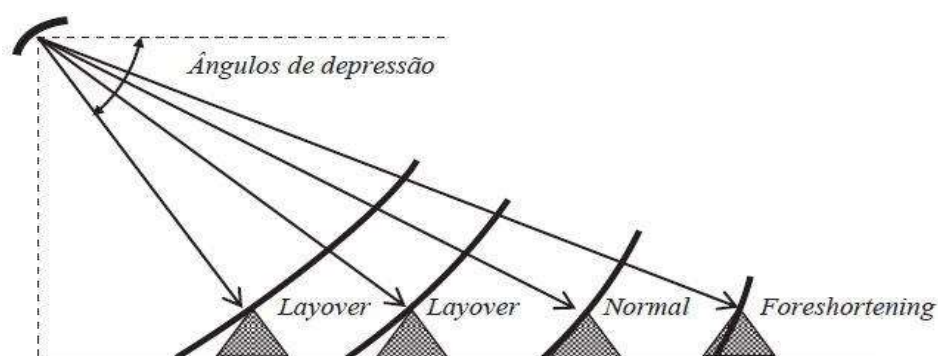


Figura 9 - Exemplos das distorções geométricas que podem ocorrer em imagens de radar, conhecidas como *foreshortening* (encurtamento de rampa) e *layover* (inversão de relevo).
Fonte: Meneses e Sano (2012).

2.3.1.7 Ruído *speckle*

O ruído *speckle* está associado à qualidade radiométrica e textural da imagem de radar. O *speckle* é usualmente considerado como um ruído multiplicativo, sendo mais intenso onde a intensidade do sinal for maior (COSTA, 2011).

Conforme Meneses e Sano (2012), em uma célula de resolução no terreno, pode existir um número muito grande de alvos difusores, aleatoriamente distribuídos, de tal forma que esses alvos podem interferir uns aos outros, construtivamente e destrutivamente. A interferência destrutiva causa o

cancelamento do sinal refletido e a interferência construtiva a sua soma, fazendo aparecer variações súbitas na intensidade da imagem.

Como consequência dessa interferência, as imagens apresentam aspectos granulados, semelhante à textura “sal e pimenta”, que conseqüentemente dificultam a interpretação visual dos alvos e interferem nos processamentos de classificação.

2.4 O satélite ALOS-2

O satélite avançado de observação de terra 2 (*Advanced Land Observing Satellite - ALOS-2*) foi lançado pela Agência de Exploração Aeroespacial Japonesa (JAXA) em maio de 2014. Esse satélite é o sucessor do satélite ALOS, lançado em 2006 e que, devido a uma anomalia de geração de energia, terminou oficialmente sua missão em 2011 (TADONO et al., 2014).

De acordo com JAXA (2016), esse satélite tem dois objetivos: contribuir com o governo do Japão e outros países para a resolução de problemas gerados pelos desastres naturais, observando a área atingida em detalhes, independentemente da hora do dia ou condições climáticas e estabelecer um sistema para obter, processar e compartilhar rapidamente dados de observação; e promover a utilização de dados de observação constantes para atender às necessidades dos usuários, como monitorar a infraestrutura social, entender as condições agrícolas, monitoramento das calotas polares, exploração de minerais e florestas.

Com vida útil da missão de cinco anos (podendo estender-se a sete anos), o satélite com órbita síncrona ao Sol está a 628 km de altitude (acima da linha do Equador) e o tempo de revisita a um mesmo ponto é de 14 dias (SHIMADA *et al.*, 2011). De acordo com JAXA (2014), o ALOS-2 foi aprimorado em aspectos de resolução, faixa de observação, intervalo de tempo para fornecimento de dados e capacidade básica do satélite para suportar o desempenho do radar, como velocidade de transmissão de dados e retenção de posicionamento com alta precisão.

Para ampliação da faixa de observação, a antena está orientada ao nadir do satélite e a partir da alteração da altitude desse é possível direcionar a radiação de onda de rádio para a esquerda ou direita, possibilitando a

observação em ambos os lados do satélite (Figura 10). O imageamento pode ser realizado ainda em modo ascendente (em direção ao norte) ou modo descendente (em direção ao sul).




Figura 10 – Capacidade de direcionamento de visada para direita ou para esquerda do satélite ALOS-2. Fonte: adaptado de JAXA (2014).

Segundo JAXA (2014), o ALOS-2 está equipado com o sensor SAR na banda L do tipo *Phased Array* (PALSAR-2) que utiliza a faixa de frequência de 1,2 GHz e possui três modos de observação (Figura 11).

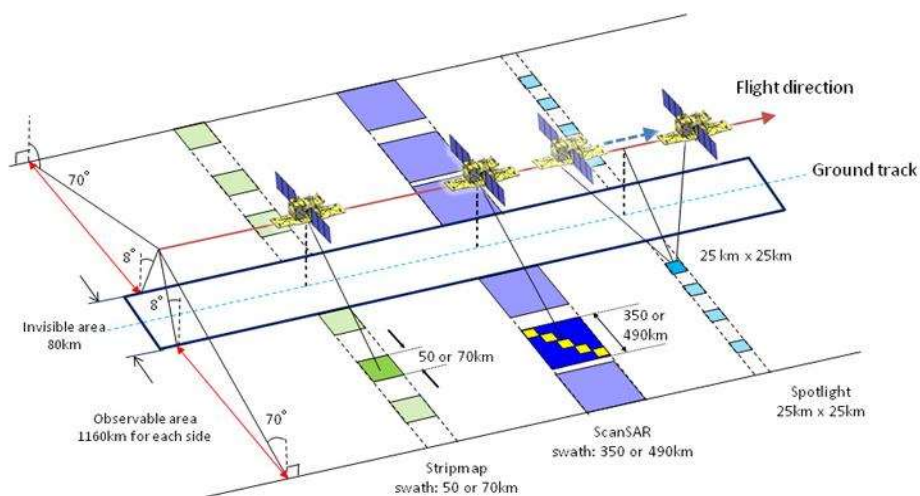


Figura 11 - Modos de observação do sensor PALSAR-2. Fonte: JAXA (2018a).

- **Modo Spotlight:** Esse modo de observação não estava disponível no ALOS/PALSAR e permite aumentar o tempo de iluminação, orientando o feixe eletrônico na direção do azimute para longe do nadir. Como resultado, é possível capturar a superfície da Terra com mais detalhes (JAXA, 2018b). É o modo de observação com melhor resolução espacial (1 m x 3 m), cobrindo faixas de observação de 25 km.

- **Modo Stripmap:** É um sistema de feixe duplo que permite manter uma alta resolução e faixa larga de imageamento (JAXA, 2018b). Fornece imagens com resolução espacial de 3 m, 6 m e 10 m, cobrindo faixas de observação que variam de 50 km a 70 km.

- **Modo ScanSAR:** Esse modo de observação pode realizar observações contínuas em até 48 minutos, percorrendo metade da Terra em uma única observação. Seus instrumentos aprimorados permitem monitoramento contínuo e expandem a faixa observável, que varia de 350 km a 490 km (JAXA, 2018b). Em compensação, possui a pior resolução espacial, que varia de 100 m a 50 m.

Os modos de observação possuem polarizações simples e/ou duplas (Figura 12). Esses produtos do PALSAR-2 são disponibilizados em quatro diferentes níveis de processamento: 1.1; 1.5; 2.1; e 3.1. Quanto maior o nível de processamento, maior o nível de refinamento (pré-processamento) do dado.

Modo de Observação		Resolução	Faixa	Polarizações
Spotlight (code SBS)		1m(Az)×3m (Rg)	25km×25km (Rg)	HH, HV, VH ou VV
Strip map	Ultra Fine (code UBS/UBD)	3m	50km	HH, HV, VH, VV ou HH+HV, VH+VV
	High sensitivity (code HBS/HSD)	6m	70km	
	Fine (code FBS/FBD)	10m	70km	
Scan SAR	Nominal (code WWS/WWD e WBS/WBD)	100m	350km	HH, HV, VH, VV ou HH+HV, VH+VV
	Wide (code VBS/VBD)	60m	490km	

Figura 12 - Características dos modos de observação disponíveis no ALOS-2/PALSAR-2.
Fonte: adaptado de JAXA (2014).

2.5 Monitoramento do desmatamento na Amazônia com imagens de radar

Embora seja uma geotecnologia propícia para operação em áreas com predominante cobertura de nuvens, programas governamentais federais utilizando imagens de radar para monitoramento da Amazônia Legal não são tão abundantes quanto programas utilizando imagens multiespectrais.

Um dos projetos mais importantes e conhecidos utilizando imagens de radar foi o RADAMBRASIL, criado em meados de 1970 com o objetivo principal de efetuar o levantamento de recursos naturais do país utilizando imagens de radar. A partir de metodologias específicas, foram realizadas

interpretações e mapeamentos referentes à geologia, geomorfologia, pedologia, vegetação e uso potencial da terra (BRASIL, 1978).

O aerolevanteamento foi realizado com o sistema de radar GEMS-1000 (*Goodyear Eletronic Mapping System*), operando na banda X, frequência de 9.600 MHz e polarização HH (OLIVEIRA *et al.*, 2011). Os registros foram disponibilizados em 551 mosaicos na escala de 1:250.000. O RADAMBRASIL foi, portanto, em âmbito nacional, o grande projeto que explorou as potencialidades da utilização de imagens de radar para análises ambientais.

Em 2002, foi desenvolvido o Sistema de Vigilância da Amazônia (SIVAM), parte do Sistema de Proteção da Amazônia (SIPAM – hoje CENSIPAM) com o objetivo de proteger o bioma Amazônia, garantindo sua exploração sustentável, com ações de monitoramento ambiental, monitoramento do uso dos recursos naturais, vigilância e controle do espaço aéreo (ALMEIDA, 2002). Um dos equipamentos utilizados para esse monitoramento foram os radares de abertura sintética instalados nas aeronaves R-99B.

Os trabalhos descritos abordaram diversas variáveis ambientais, mas não foram realizados exclusivamente para monitoramento do desmatamento na Amazônia Legal. Os projetos mais relevantes criados especificamente para essa finalidade são descritos abaixo.

2.5.1 INDICAR

O sistema Indicativo de Desmatamento por Imagens de Radar foi desenvolvido em 2007 (fora de operação desde meados de 2010) a partir de um acordo entre o Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA) e a Agência de Exploração Aeroespacial Japonesa (JAXA).

O objetivo desse sistema era identificar áreas para orientação das ações de controle e fiscalização mesmo que as condições atmosféricas e meteorológicas não fossem favoráveis e desenvolver novas metodologias de identificação e monitoramento de desmatamentos através da utilização de imagens de radar (MATOS e FREITAS, 2011). O sistema utilizava imagens do sensor PALSAR, satélite ALOS, modo de observação ScanSAR com resolução espacial de 100 m e operando na banda L.

A metodologia para detecção utilizava a diferença de reflectância dos alvos e comparações temporais. Para evitar a sobreposição com áreas já detectadas anteriormente, era feita uma máscara com os desmatamentos identificados pelo PRODES, pelo DETER e pelo próprio INDICAR. Portanto, através dessas análises nas imagens de 50 m de resolução (modo fino) e também nas imagens de 100 m de resolução (modo grosso), após a detecção das áreas desmatadas ocorria o processamento e a manipulação dos dados com o intuito de produzir mapas e planilhas que serviam para orientar e apoiar as operações de fiscalização (MATOS e FREITAS, 2011).

2.5.2 SipamSAR (Amazônia SAR)

O Sistema Integrado de Detecção de Desmatamento com Radar Orbital é um programa recente do governo federal, que ainda está em fase de conclusão para total operação. Desenvolvido no âmbito do CENSIPAM, sob responsabilidade do Ministério da Defesa, o SipamSAR surgiu a partir do programa Amazônia SAR, que tem como objetivo monitorar o desmatamento nos meses de intensas nuvens (outubro a abril) usando a tecnologia de radar orbital, possibilitando a identificação precisa dos ilícitos (CENSIPAM, 2015).

De 2013 a 2015, as análises de desmatamento foram realizadas a partir das imagens geradas pela constelação de satélites COSMO-SkyMed (banda X) e pelos sensores aerotransportados da aeronave R-99 da Força Aérea Brasileira. Entretanto, devido ao alto custo e limitações operacionais, em 2015, foi aprovado um projeto junto ao Banco Nacional de Desenvolvimento Econômico e Social (BNDES) com recursos do Fundo Amazônia para substituição dessa metodologia.

Desta maneira, será implantada uma estação terrestre de recepção de dados de sensoriamento remoto provenientes de satélites de observação da Terra para captação direta dos dados, com previsão de operação para 2019. O objetivo desse programa, portanto, é criar um sistema de detecção sistemático de desmatamento na Amazônia com uso de imagens de radar orbital e aerotransportadas, no período de alta cobertura de nuvens, em complemento ao DETER (COSTA e FERREIRA, 2015).

2.5.3 Sistema de radar JJ-FAST

Entre novembro e dezembro de 2015, na 21ª Conferência das Partes (COP-21) da Convenção-Quadro das Nações Unidas sobre Mudança do Clima (UNFCCC), realizada em Paris, França, a Agência de Cooperação Internacional do Japão (JICA), em parceria com a JAXA, lançaram a “Iniciativa de Governança Florestal” (*Forest Governance Initiative*). Essa iniciativa visa contribuir para a conservação das florestas tropicais e da biodiversidade em âmbito global, assim como para a mitigação das mudanças climáticas utilizando a tecnologia avançada de satélites artificiais do Japão e também servindo-se das parcerias celebradas com múltiplos participantes (JICA, 2018). Como compromisso dessa iniciativa, em junho de 2016, foi lançado o “Sistema de advertência antecipada contra o desmatamento da floresta tropical”. Esse é um sistema de acesso aberto disponível na web que monitora regiões tropicais de aproximadamente 80 países, liberando os dados de qualquer tipo de desmatamento e perda florestal para visualização e/ou *downloads* em computadores ou dispositivos móveis a cada 45 dias (JICA/JAXA, 2018).

São utilizadas imagens do satélite ALOS-2/PALSAR-2, no modo de observação ScanSAR, nível de processamento 2.2. Os dados de desmatamento são obtidos por meio do método de segmentação *mean-shift*, gerando polígonos, e a frequência de observação é a cada 45 dias. A imagem no formato TIFF tem resolução radiométrica de 16 bits, com resolução espacial de 50 metros e polarizações HH, HV e HH/HV. O tamanho mínimo de detecção do polígono é de 5 hectares, com expectativa de diminuição para 1 hectare. Essa observação é feita com imagens produzidas em qualquer hora do dia ou noite, independentemente da presença de chuva ou nuvens (SHIMADA *et al.*, 2017).

A área de estudo coberta pelas cenas ALOS-2/PALSAR-2 englobou os nove municípios da microrregião Sinop, no estado de Mato Grosso: foram cobertos parcialmente os municípios de Sinop, Itaúba, Marcelândia, Vera, Feliz Natal, Nova Santa Helena e União do Sul, enquanto os municípios de Cláudia e Santa Carmem foram quase que totalmente cobertos (Figura 13).

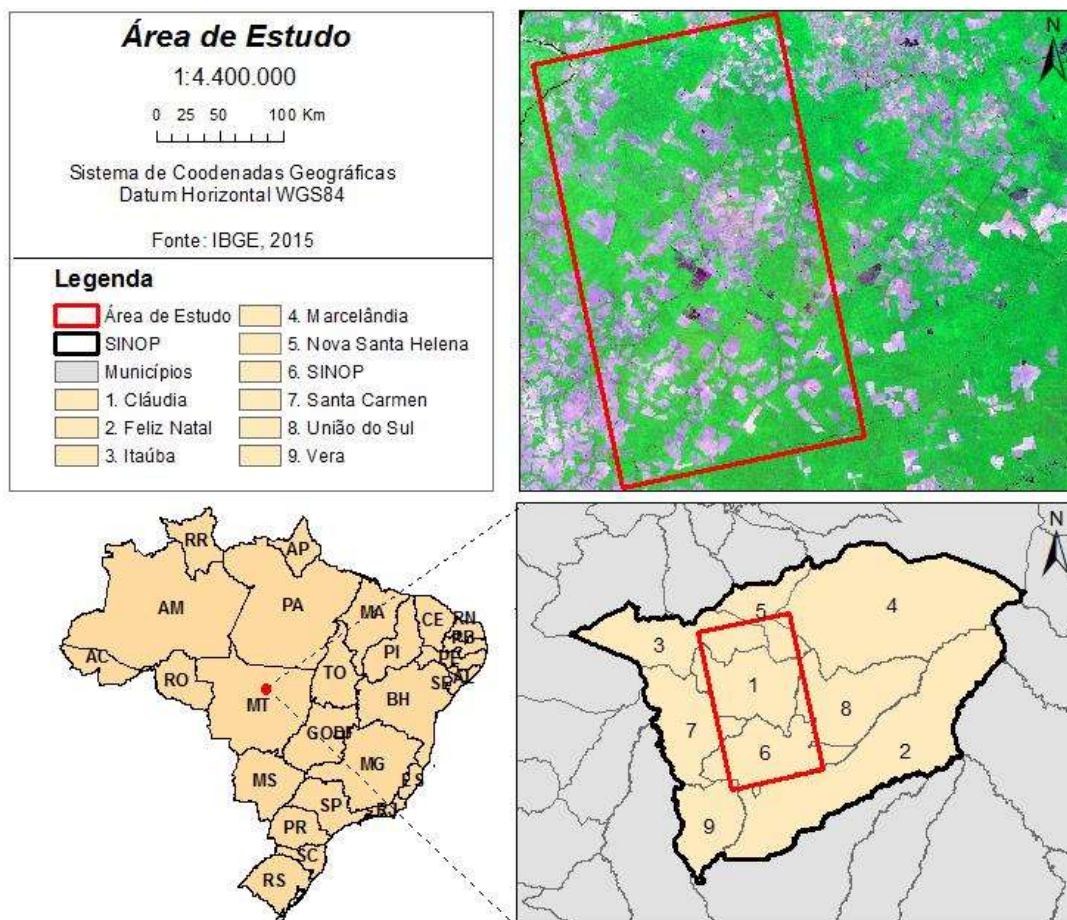


Figura 13 - Mapa de localização da área de estudo.

Os principais dados estatísticos dos municípios abrangidos pela área de estudo são apresentados na Tabela 4 (IBGE, 2018a). Esses municípios formam a microrregião de Sinop, na região norte do estado. Essa microrregião faz parte das áreas de influência da rodovia BR-163, que por sua vez faz parte do projeto estratégico para ocupação do Centro-Oeste e da Amazônia (ALENCAR *et al.*, 2011). Segundo os mesmos autores, é uma região com

economia baseada no agronegócio, com fazendas de gado e monoculturas (soja, cana e algodão), extração de minérios e retirada ilegal de madeiras nobres.

Município	Criação	População (2018)	Densidade Demográfica (hab/km ²)	Unidade Territorial (km ²)
Cláudia	04/07/1988	12.050	2,86	3.850.000
Feliz Natal	1995	13.856	0,95	11.679
Itaúba	13/05/1983	3.901	1,01	4.529.600
Marcelândia	13/05/1986	10.700	0,98	12.274
Nova Santa Helena	21/01/1998	3.700	1,47	2.375.580
Santa Carmem	19/12/1991	4.490	1,06	3.856.000
Sinop	14/09/1974	140.000	28,69	3.950.000
União do Sul	28/01/1998	3.560	0,82	4.581.900
Vera	13/05/1986	11.216	3,45	2.954

Tabela 4 - Dados estatísticos dos municípios da microrregião Sinop produzidos pelo sistema Brasil em síntese. Fonte: IBGE (2018a).

O tipo de solo predominante dessa microrregião é o Latossolo, típico de regiões tropicais. São caracterizados como solos em avançado estágio de intemperização, geralmente ácidos, apresentam deficiência de minerais e baixa reserva de elementos nutritivos, são normalmente muito profundos e variam de fortemente a bem drenados (SANTANA e SANS, 2007).

De acordo com os dados do projeto RADAMBRASIL (IBGE, 2018b), a vegetação predominante da região é a Floresta Estacional Semidecidual submontana. Por ser uma região de transição entre a Floresta Amazônica e o Cerrado, a vegetação encontrada varia entre fitosônias encontradas no Cerrado, Cerradão e Matas. É comum a ocorrência de duas espécies do mesmo gênero em floresta de transição, em que uma é típica da formação savânica enquanto a outra é encontrada predominantemente na formação florestal (ROSSATTO *et al.*, 2009; IBGE, 2012). É uma área caracterizada pela ocorrência de árvores de até 20 metros de altura, espécies de plantas lenhosas entrelaçadas que se assemelham a cipós e árvores baixas, de menor índice de área foliar e retorcidas, arbustos e ervas (VILANI *et al.*, 2006).

Conforme a classificação climática de Köppen-Geiger (KÖPPEN, 1936), o clima da região é tropical monçônico (Am). É um clima quente e úmido,

com temperaturas médias anuais de 24°, com pouca precipitação entre os meses de maio a setembro (mínimo de 0 mm) e maior precipitação nos meses restantes (máximo de 370 mm) (Figura 14).




Figura 14 - Precipitação acumulada diária da microrregião Sinop/MT (mm). Fonte: adaptado de AGRITEMPO (2018).

A escolha da área como objeto desse estudo deveu-se principalmente pela sua localização estratégica, ao longo de uma importante rodovia federal, o que ocasiona intensas mudanças no uso do solo da região. Aliada a essa motivação, a área também faz parte dos estudos da iniciativa Kyoto & Carbono da JAXA. O objetivo deste projeto é definir, desenvolver e validar produtos temáticos derivados principalmente de dados de radar na banda L para apoiar as necessidades de informações das convenções ambientais internacionais, ciência dos ciclos do carbono e conservação do meio ambiente (ROSENQVIST *et al.*, 2010).

4.1 Materiais

4.1.1 Imagens ALOS-2/PALSAR-2

Para o desenvolvimento desse trabalho, foram disponibilizadas pela JAXA dois conjuntos de imagens de banda L de duas datas diferentes (Figura 15), em amplitude e em valores digitais (DN), com nível de processamento 1.5, ângulo de incidência $34,3^\circ$, faixa imageada de 70 km, resolução radiométrica de 16 bits, resolução espacial de 6,25 metros, projeção UTM, fuso 21S e referenciadas ao *datum* WGS84 (Tabela 5).




Figura 15 - Pares de cenas ALOS-2/PALSAR-2, modo de observação *StripMap*, nível de processamento 1.5, polarizações HH e HV dos meses de fevereiro e setembro de 2016.

Identificação da cena	Polarização	Data de passagem
ALOS2093006950	HH	12 de fevereiro de 2016
	HV	
ALOS2093006960	HH	
	HV	
ALOS2126126950	HH	23 de setembro de 2016
	HV	
ALOS2126126960	HH	
	HV	

Tabela 5 - Características das imagens ALOS2/PALSAR-2, modo de observação *StripMap*, nível de processamento 1.5 utilizadas nesse estudo.

O objetivo de utilizar imagens em épocas do ano diferentes foi abranger diferentes períodos e índices de precipitação, com a finalidade de obter diferentes resultados das interações da radiação em micro-ondas frente as condições ambientais. Portanto, foi considerada a precipitação média de 10 dias anteriores à obtenção da imagem (Tabela 6). Observa-se que a precipitação média de setembro, mês característico de tempo seco, foi maior que no mês de fevereiro, mês característico de tempo chuvoso. Desta maneira, para esse trabalho, foi considerada a situação inversa, com as imagens de fevereiro representando o tempo seco e as imagens de setembro representando o tempo chuvoso.

Precipitação Acumulada (mm)			
Fevereiro		Setembro	
Dia	(mm)	Dia	(mm)
02/02/2016	0,8	13/09/2016	0,6
03/02/2016	0,9	14/09/2016	2,1
04/02/2016	0,8	15/09/2016	2,1
05/02/2016	3,0	16/09/2016	10,5
06/02/2016	2,5	17/09/2016	8,6
07/02/2016	2,6	18/09/2016	10,6
08/02/2016	2,5	19/09/2016	9,2
09/02/2016	2,4	20/09/2016	9,1
10/02/2016	2,5	21/09/2016	9
11/02/2016	3,1	22/09/2016	10,3
Total	21,1	Total	72,1

Tabela 6 - Precipitação diária acumulada (mm) na microrregião do Sinop/MT (estação pluviométrica automática de Sinop/MT). Fonte: AGRITEMPO (2018).

4.1.3. Softwares utilizados

Para pré-processamento e processamento das imagens, confecção de mapas e análises estatísticas, foram utilizados os *softwares* QGIS, versão 2.18.22 - Las Palmas, o ArcGIS, versão 10.1, o ENVI, versão 5.3, o SNAP, versão 6.0, e o Statistica, versão 13.3.

4.2 Métodos

Os métodos adotados nesse trabalho estão descritos no fluxograma da Figura 16, contendo o detalhamento dos procedimentos nas seções subsequentes.

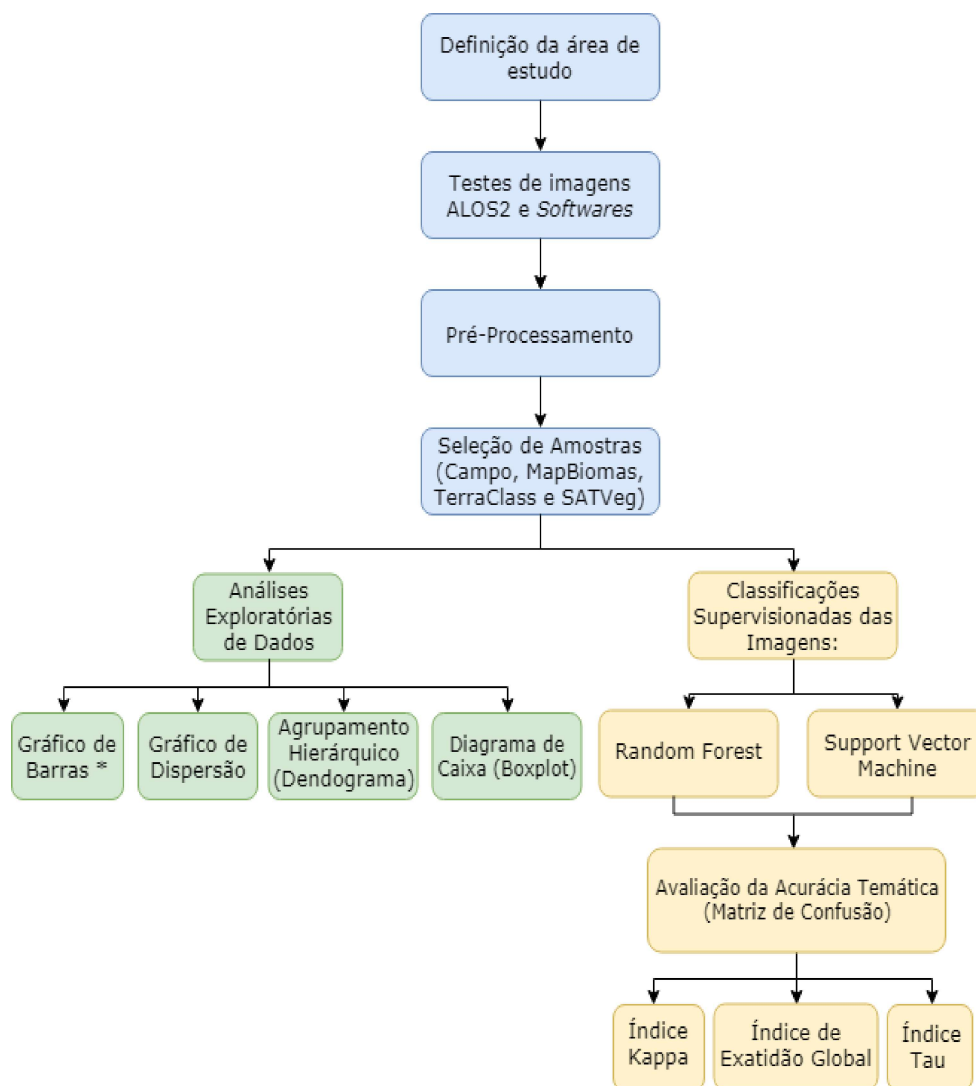


Figura 16 - Fluxograma do trabalho.

4.2.1 Testes de imagens e softwares

As imagens ALOS-2/PALSAR-2 são relativamente novas (desde 2014), e, portanto, as técnicas de processamento e *softwares* capazes de processá-las ainda estão sendo disponibilizados e/ou atualizados. A própria manipulação das imagens, ainda na fase de pré-processamento, foi uma etapa desafiadora pela dificuldade de informações e demandou mais tempo do que o previsto.

Utilizando as imagens com nível de processamento 1.5 foram aplicadas as etapas de pré-processamento das imagens ALOS/PALSAR e de imagens SAR em geral, assim como testes de *softwares* de processamento de imagens, como ENVI, SNAP, Abilio, ALOS-2 Image Viewer. Entretanto, os resultados obtidos não foram satisfatórios.

Assim, foram realizados testes com os diferentes formatos destas imagens (CEOS, geotiff), até que com o recebimento de novas informações, conseguiu-se a manipulação e processamento correto por meio dos *softwares* QGIS e Envi, com as imagens em formato 5RUA.

4.2.2 Pré-Processamento

A sequência de procedimentos para pré-processamento das imagens ALOS-2/PALSAR-2 está demonstrada na Figura 17, seguindo a ordem de realização.




Figura 17 - Fluxograma da etapa de pré-processamento das imagens do satélite ALOS-2/PALSAR-2.

4.2.3.1. Mosaico de imagens

A primeira etapa do pré-processamento das imagens ALOS-2/PALSAR-2 foi o mosaico de imagens, realizado no *software* ENVI 5.3. Do conjunto com oito imagens distintas, para formação da área de estudo, foram unidas as imagens de ID ALOS2093006950 e ALOS2093006960, e as imagens ALOS2126126950 e ALOS2126126960. Portanto, para diminuição do número de imagens e melhor manipulação dos dados, foi feito o mosaico que formou quatro imagens distintas.

4.2.3.2. Coeficiente de retroespalhamento (σ^0)

A segunda etapa consistiu na conversão dos valores de número digital (DN) para valores de coeficiente de retroespalhamento (σ^0). Segundo Teixeira (2011), a conversão dos números digitais é feita com a finalidade de aumentar o contraste das imagens, possibilitando melhor diferenciação dos alvos. Convencionalmente, por serem razões de potência, os valores de σ^0 são medidos em decibéis (dB) (Eq. 1).

$$\sigma^0 = 10 \log(DN^2) + CF \quad (1)$$

onde DN = valor digital e CF = fator de calibração disponibilizado pela JAXA (-83 dB; JAXA, 2018c). As imagens foram convertidas por meio do *software* QGIS 2.18.22.

4.2.3.3. Matemática de bandas

Na terceira etapa, foi realizada a matemática de bandas no *software* QGIS 2.18.22. As operações matemáticas em imagens de satélite são realizadas para gerar uma outra imagem contendo a combinação das informações de duas ou mais imagens, realçando similaridades e/ou disparidades entre essas, pixel a pixel, o que permite o contraste de diferentes alvos. Além dos pares de imagens

HH e HV, foram gerados outros três pares de imagens a partir das seguintes aritméticas:

a) multiplicação - nesta operação, as informações comuns a ambas as imagens são realçadas. É aplicada a seguinte equação (Eq. 2):

$$\sigma_{HH.HV}^0 = \sigma_{HH}^0 \cdot \sigma_{HV}^0 \quad (2)$$

b) razão - nessa operação, ocorre o efeito contrário à operação anterior, e, portanto, as informações díspares entre as imagens são realçadas. É aplicada a seguinte equação (Eq. 3):

$$\sigma_{HH/HV}^0 = \frac{\sigma_{HH}^0}{\sigma_{HV}^0} \quad (3)$$

c) NDBI - o Índice de Retroespalhamento por Diferença Normalizada (NDBI - Normalized Difference Backscatter Index), anteriormente introduzido por Mitchard *et al.* (2012) como Índice de Degradação Florestal por Radar (RFDI) (GARCIA *et al.*, 2018), é um índice normalizado derivado das respostas nas polarizações horizontal (HH) e vertical (HV), com potencial melhora nas respostas da vegetação, uma vez que o retroespalhamento de polarizações HH são sensíveis às interações com volume e reflexão de canto de vegetação, enquanto as polarizações HV são sensíveis às interações de dispersão de volume da copa das árvores (MITCHARD *et al.*, 2012). Segundo os mesmos autores, quando há mais florestas, a resposta esperada para este índice é maior do que quando se imageia uma área degradada ou sem floresta. Este índice é obtido pela seguinte equação (GARCIA *et al.*, 2018) (Eq. 4):

$$NDBI = \frac{\sigma_{HH}^0 - \sigma_{HV}^0}{\sigma_{HH}^0 + \sigma_{HV}^0} \quad (4)$$

4.2.3.4. Filtro Gamma (3x3)

A quarta etapa foi de redução do ruído *speckle*, realizado no *software* ENVI 5.3. Em imagens de radar, os filtros adaptativos são utilizados para redução do ruído *speckle* com a preservação de aspectos radiométricos e texturais, sendo esses os aspectos responsáveis pela discriminação de alvos. Dessa maneira, a redução do referido ruído teoricamente melhora a discriminação entre diferentes tipos de uso da terra, tornando os classificadores convencionais texturais ou baseados no pixel mais eficientes nas imagens de radar (LOPES *et al.*, 2010).

Foram testados diversos filtros, sendo escolhido o filtro adaptativo Gamma com janela 3 x 3, que utiliza valores de intensidade dentro da janela e o método de máxima verossimilhança para realizar a filtragem (EVANS, 1996). A escolha deveu-se principalmente pela preservação da textura e dos contornos dos alvos nas imagens, conseqüentemente, facilitando a diferenciação de alvos.

4.2.3.5. Georreferenciamento

A quinta e última etapa do pré-processamento foi o georreferenciamento das imagens de radar com base na imagem Landsat-8/OLI ortorretificada para futura seleção de amostras de treinamento e validação. Para melhor precisão cartográfica quanto ao posicionamento dos alvos, foi realizado o registro das imagens ALOS-2/PALSAR-2 com a imagem Landsat-8/OLI, órbita/ponto 226/68, do dia 23/08/2016, com resolução espacial de 30 metros e periodicidade de 16 dias, obtida gratuitamente por meio da página eletrônica da Agência Espacial Norte-Americana (USGS, 2018) (<https://earthexplorer.usgs.gov/>). O procedimento foi realizado no aplicativo ArcGIS 10.1. Foram selecionados quatro pontos de controle próximos às bordas da imagem, com registro através de polinômio de 1ª ordem, onde o erro médio total (RMSE - *Root Mean Square Error*) obtido foi de aproximadamente 0,00025.

4.2.4 Seleção de amostras de retroespalhamento

As áreas representativas de classes encontradas na microrregião Sinop foram definidas por meio dos dados de trabalho de campo e dados auxiliares, totalizando 200 pontos. Foram identificadas as seguintes classes temáticas de mapeamento: vegetação primária, vegetação secundária, pastagem cultivada e cultura agrícola.

Conforme citado anteriormente, a vegetação primária corresponde a áreas de floresta nativa que não sofreram interferências antrópicas. A classe de vegetação secundária corresponde a áreas em que já ocorreram processos de desmatamento e/ou exploração da vegetação florestal, mas que apresentam processos leves, médios ou avançados de regeneração vegetal. A classe de pastagem corresponde às áreas que sofreram corte raso e apresentam ou não cobertura do solo por espécies de gramíneas com a finalidade de desenvolvimento de atividades agropastoris. A classe de cultura agrícola corresponde a porções de áreas destinadas ao cultivo agrícola, como soja.

Uma vez que foram utilizadas duas fontes de dados diferentes para identificação das classes de cobertura vegetal da região de estudo, também foram desenvolvidas duas metodologias para coleta das amostras. A distribuição entre dados de campo e auxiliares é mostrada na Tabela 7.

Regiões de Interesse		
Classe	Dados de Campo	Dados Secundários
Vegetação Primária	18	32
Vegetação Secundária	09	41
Pastagem	06	44
Cultura Agrícola	32	18
Total	65	135

Tabela 7 – Número de amostras de retroespalhamento, discriminadas por classe de uso e cobertura de terras.

4.2.4.1. Dados de campo

No período de 24 a 29 de outubro de 2016, foi realizado um trabalho de campo pela equipe técnica do IBAMA na microrregião de Sinop. Os objetivos

foram: coletar pontos amostrais por meio de aparelho GPS (*Global Positioning System*), documentar o local com fotografias e identificar as classes vegetativas de pontos representativos da área coberta pelas imagens ALOS-2/PALSAR-2. Com base na imagem Landsat-8/OLI, órbita/ponto 226/68, foram coletados 65 pontos, distribuídos entre as diferentes classes supracitadas (Figura 18).

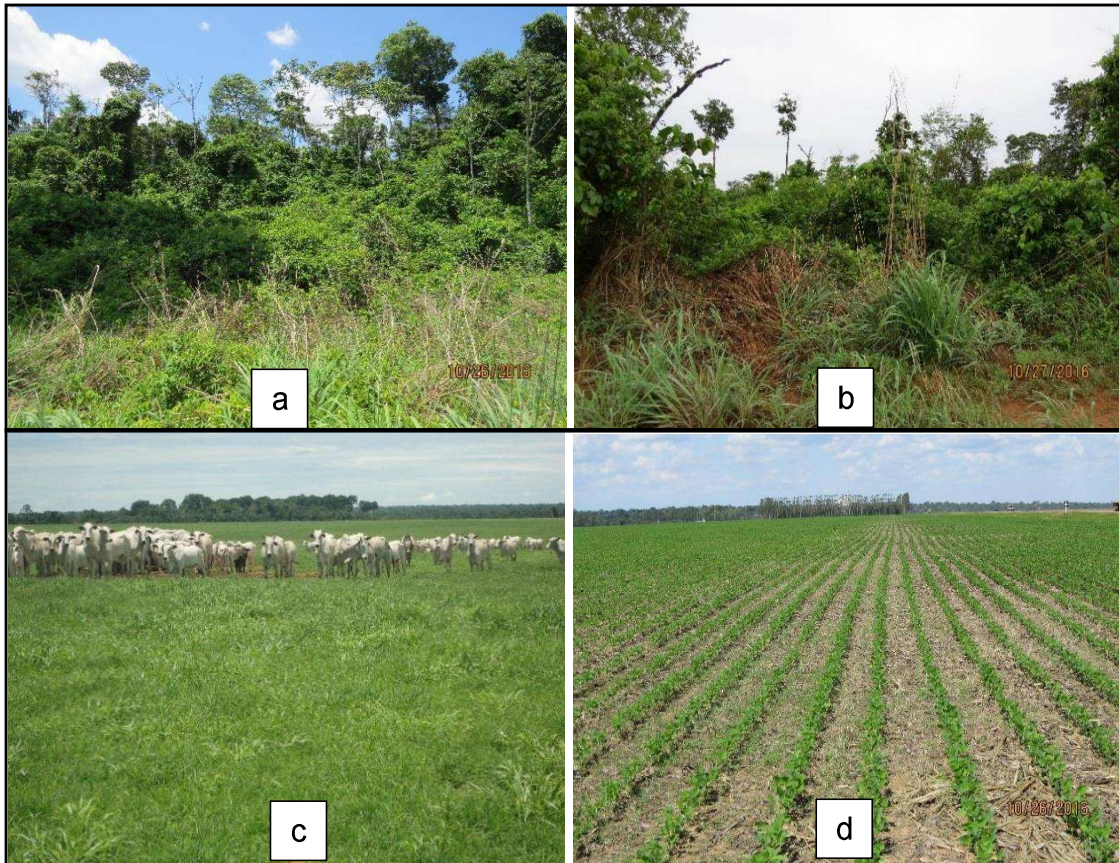


Figura 18 – Exemplos de fotografias de campo ilustrando a presença de classes de uso e cobertura de terras representativas da área de estudo: vegetação primária (a); vegetação secundária (b); pastagem cultivada (c) e cultura agrícola (d).

A etapa inicial de seleção de amostras consistiu na utilização dos pontos coletados em campo (Figura 19).




Figura 19 - Distribuição espacial dos pontos coletados em campo, mostrada na cena ALOS-2/PALSAR de fevereiro, polarização HH.

Foi gerado um arquivo *shapefile* de polígonos no aplicativo ArcGIS 10.1 utilizando como base para seleção das amostras, a imagem ALOS-2/PALSAR-2, polarização HH do mês de setembro. Os polígonos foram padronizados com tamanhos de 60 m x 60 m de modo que cada amostra fosse composta por pelo menos 100 pixels, evitando-se a coleta de áreas próximas às bordas a fim de evitar erros de omissão e comissão (Figura 20).



Figura 20 – Exemplo de coleta de amostras de retroespalhamento com base nos dados de campo.

4.2.4.2. Dados auxiliares

Foram selecionadas 135 áreas de interesse abrangendo as mesmas classes anteriormente coletadas por GPS utilizando quatro diferentes bases de dados visando a complementação de amostras de treinamentos e de teste para realização das análises estatísticas e classificadores. Os procedimentos foram feitos no aplicativo ArcGIS 10.1 com escala aproximada de 1:6.000.

Foi utilizada a base de dados geográficos de desflorestamento do projeto TerraClass Amazônia, do ano de 2014, órbita/ponto 226/68, sendo estes os dados mais recentes disponibilizados. Os dados digitais, em formato vetorial (*shapefile*), estão disponíveis para *download* na página eletrônica do INPE (http://www.inpe.br/cra/projetos_pesquisas/terraclass2014.php). Esses dados estão organizados de acordo com suas respectivas órbitas/ponto do satélite Landsat-8/OLI, sistema de coordenadas geográficas e referenciadas ao *datum* SAD69.

Também foi utilizada a coleção 3 de dados geográficos de cobertura de uso do solo do projeto MapBiomias (lançada em agosto de 2018, cobrindo o período de 1985 a 2017), do ano de 2016, para o estado de Mato Grosso. Os dados digitais, em formato matricial (*geotiff*), estão disponíveis para *download* na página eletrônica do projeto (<http://mapbiomas.org/map#coverage>). Os arquivos

estão em sistema de coordenadas geográficas e referenciadas ao *datum* WGS84.

Foram utilizados ainda os perfis temporais dos índices vegetativos NDVI e EVI do sensor MODIS para checagem da escolha das áreas de interesse. Os perfis estão disponibilizados no sistema web do SATVeg (Sistema de Análise Temporal da Vegetação) desenvolvido pela Embrapa Informática Agropecuária (<https://www.satveg.cnptia.embrapa.br/satveg/login.html>).

O sistema web SATVeg é destinada à observação de perfis temporais de índices vegetativos, que expressam as variações da biomassa vegetal na superfície terrestre ao longo do tempo (SATVEG, 2018). Nesse sistema, as séries temporais dos índices vegetativos NDVI e EVI fazem parte da coleção 6 dos produtos MOD13Q1 (satélite Terra) e MYD13Q1 (satélite Aqua). Os dados, disponibilizados a partir do ano 2000, possuem composição máxima de 16 dias e resolução espacial de aproximadamente 250 m. Os valores dos índices são disponibilizados em gráficos na escala de 0 e 1, uma vez que essa é a faixa onde se concentra a maior parte dos comportamentos dos alvos agrícolas e naturais, que englobam desde solo exposto até altos valores de biomassa vegetal, encontrados em cultivos agrícolas e áreas de florestas.

Para as amostras coletadas com base nos dados auxiliares, foram selecionadas aleatoriamente as áreas de cada classe temática em áreas distintas da imagem, isto porque, para a classificação de imagens, coletar amostras distribuídas espacialmente em diferentes regiões proporciona maior representatividade estatística dos valores de cada classe.

Para a seleção das áreas de vegetação secundária, foi utilizada a base vetorial do projeto TerraClass Amazônia sobrepondo à imagem ALOS-2/PALSAR-2, polarização HH do mês de setembro, classificando o vetor para mostrar apenas a classe desejada (Figura 21). A vetorização dos polígonos seguiu os mesmos critérios dos polígonos criados a partir dos dados de campo. O TerraClass subdivide a classe pastagem em pasto limpo, pasto sujo e pasto com solo exposto, assim como agricultura em cultura anual e perene e cultura semi-perene, mas para este trabalho, essas classes foram consideradas como o mesmo tipo de uso e cobertura do solo.




Figura 21 – Exemplo de seleção de área amostral dentro da classe Vegetação Secundária mapeada pelo projeto TerraClass Amazônia.

Para as áreas de pastagem cultivada, vegetação primária e cultura agrícola, a mesma base vetorial foi sobreposta ao mapa do projeto MapBiomias. Para seleção dos ROIs, foram consideradas áreas em que as duas bases de dados coincidiam, indicando a mesma classe de uso e ocupação do solo (Figura 22).




Figura 22 – Exemplo de seleção de área amostral dentro da classe pastagem cultivada, baseada nos dados do projeto MapBiomias.

A etapa seguinte de seleção de áreas de interesse por dados secundários foi utilizar os perfis temporais de índices de vegetação apenas para checar a equivalência das áreas selecionadas. Desta forma, foram utilizados os padrões encontrados a partir dos pontos de campo em conjunto com a biblioteca

espectral disponível no sistema para comparação com os padrões obtidos a partir dos dados secundários (Figura 23).

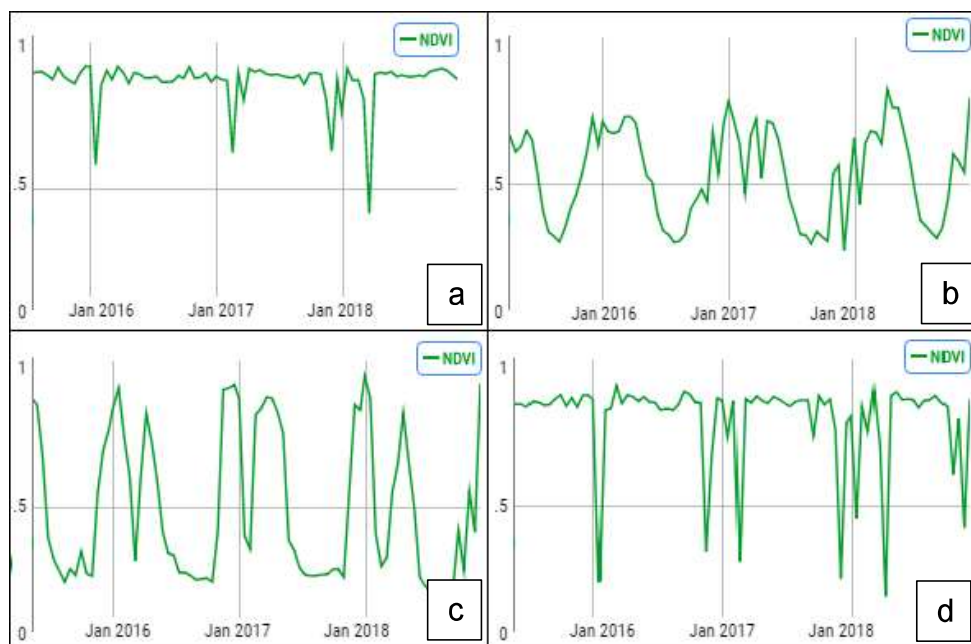


Figura 23 – Ilustração de índices de vegetação por diferença normalizada (NDVI), representativas de vegetação primária (a), pastagem cultivada (b), cultura agrícola (c) e vegetação secundária. Fonte: SATVEG (2018).

4.2.4.3. Utilização das áreas de interesse

Neste trabalho, os pontos amostrais foram utilizados em duas etapas diferentes. Segundo Jensen (2009), existem dois tipos de amostras: as amostras de treinamento, que são utilizadas como referência para as análises que se deseja realizar, e as amostras de testes, que são utilizadas como referência de campo para validação da acurácia dos resultados. Neste estudo, os 200 pontos amostrais foram divididos em dois subconjuntos: 60% das áreas selecionadas foram utilizadas para análises estatísticas e classificação das imagens de radar, e os outros 40% foram utilizados para validação dos resultados encontrados. Foram sorteados 120 polígonos para as amostras de treinamento e os 80 polígonos restantes foram utilizados para amostras de testes. Os polígonos foram transformados em ROIs no *software* ENVI 5.3.

4.2.5 Análises exploratórias dos dados

A análise exploratória de dados é uma tradição estatística bem estabelecida que fornece ferramentas conceituais e computacionais para descobrir padrões, possibilitando o desenvolvimento e o refinamento de hipóteses (BEHRENS, 1997). Para Anselin e Bao (1997), técnicas estatísticas espaciais permitem descrever e visualizar distribuições espaciais, verificar a existência de agrupamentos entre valores semelhantes, encontrar padrões de associação ou outras formas de heterogeneidade espacial. Portanto, o objetivo de utilizar análises estatísticas é extrair e explorar informações de um conjunto de dados, possibilitando a identificação de tendências, comparação de comportamentos e correlações.

Com a finalidade de encontrar as respostas para os objetivos específicos, foram aplicados três métodos estatísticas nos dados de amostras de classes por meio dos programas Excel e Statistica. Foram obtidas as médias aritméticas simples de cada conjunto de 120 amostras de treinamento de cada uma das 10 imagens, sendo esses valores calculados automaticamente pelo programa ENVI 5.3. Com os dados inseridos em uma planilha Excel, o primeiro gráfico construído foi o de barras, como forma de resumir e comparar os valores de retroespalhamento (dB) encontrados para cada classe em cada uma das 10 imagens.

O segundo gráfico foi o de dispersão, com o objetivo de verificar a similaridade ou discrepância entre os valores de retroespalhamento encontrados para as classes em cada imagem. Para construção dos mesmos no Excel, foram realizadas comparações entre as imagens (Tabela 8) a partir dos 1.200 valores de retroespalhamento (10 colunas referentes às polarizações contendo os 120 valores das quatro classes de vegetação).

Fevereiro	Setembro
Polarizações	Polarizações
HH x HV	HH x HV
HH x HH*HV	HH x HH*HV
HH x HH/HV	HH x HH/HV
HH x RFDI	HH x RFDI
HV x HH*HV	HV x HH*HV
HV x HH/HV	HV x HH/HV
HV x RFDI	HV x RFDI
HH*HV x HH/HV	HH*HV x HH/HV
HH*HV x RFDI	HH*HV x RFDI
HH/HV x RFDI	HH/HV x RFDI

Tabela 8 - Variáveis utilizadas na construção dos gráficos de dispersão.

O terceiro gráfico foi de agrupamento hierárquico, gerando os dendogramas, tendo como objetivo verificar qual imagem proporciona a melhor diferenciação de classes. Para esse trabalho, foi definido o nível de similaridade pela métrica de distância euclidiana e método hierárquico pelo método de ligação completa, comumente utilizados em trabalhos de sensoriamento remoto (FREITAS *et al.*, 2007; ADAMI *et al.*, 2008). Os gráficos foram gerados no *software* Statistica 13.3.

O quarto gráfico foi o *boxplot*, realizado no Excel, e assim como a análise estatística anterior, o objetivo de se utilizar o gráfico de caixas foi para verificar qual imagem proporciona a melhor diferenciação de classes.

4.2.6 Classificações supervisionadas das imagens

A classificação de imagens é o processo de associar os pixels da imagem a um número finito de classes individuais que representam os objetos do mundo real com base nos seus valores digitais. Se um pixel satisfaz um determinado conjunto de critérios, normalmente avaliados por medidas estatísticas, o pixel é atribuído à classe que melhor satisfaz os critérios estabelecidos (MENESES e SANO, 2012).

Dentre os métodos de classificação de imagens mais comuns e utilizadas estão as classificações supervisionadas. Nesse método, a partir do conhecimento prévio do analista, seja por dados de campo, conhecimento

empírico ou fontes secundárias, são selecionadas amostras de cada classe temática presente no local de estudo. Essas amostras de pixels com identidade conhecida são utilizadas como base para classificação dos pixels de identidade desconhecida.

Dentre os classificadores supervisionados estão o *Support Vector Machine* e *Random Forest*. Na literatura, é possível encontrar diversos trabalhos com imagens de radar na Amazônia em que são utilizados esses classificadores (LI *et al.*, 2012; MASCARO *et al.*, 2014; PAVANELLI *et al.*, 2018). O objetivo de utilizá-los nesse trabalho foi para avaliar e comparar o desempenho dos classificadores, assim como obter a imagem ALOS-2/PALSAR-2 classificada quanto às suas classes de cobertura vegetal.

4.2.6.1. Support Vector Machine

Classificações que utilizam os algoritmos de aprendizagem de máquina (SVM), introduzida por meio da teoria estatística de aprendizagem por Vapnik (1995), tem como objetivo realizar uma separação ótima entre classes por meio da minimização de erros. O SVM consiste em uma técnica computacional de aprendizado que estabelece uma série de princípios que devem ser seguidos na obtenção de classificadores com boa generalização, definida como a sua capacidade de prever corretamente a classe de novos dados. Portanto, a representação gerada deve ser capaz de produzir saídas corretas para novas entradas não apresentadas previamente (LORENA e CARVALHO, 2007). Utilizando um hiperplano de separação ótimo como referência, os pontos próximos à margem do hiperplano ideal são os vetores de suporte (Figura 24). Em espaço de entrada de padrões não-linearmente separáveis, é formado um novo espaço de características onde os padrões serão linearmente separáveis (RUFINO *et al.*, 2016).




Figura 24 – Teoria estatística de aprendizagem utilizada pelo classificador *Support Vector Machine* (SVM). Fonte: adaptado de Lorena e Carvalho (2007).

Nesse algoritmo, podem ser empregadas funções simétricas, chamadas funções kernel, que satisfazem a algumas condições com o objetivo de produzir superfícies de separação mais complexas (COSTA, 2011). O programa ENVI 5.3 dispõe de quatro funções kernel (linear, polinomial, sigmoide e função de base radial). O programa também permite definir valores de parâmetros de penalidade, onde é permitida alguma tolerância de erro na definição dos hiperplanos de separação. Entretanto, é preciso cuidado ao definir os valores, uma vez que maiores penalidades reduzem as tolerâncias ao erro, o que pode ocasionar em definição de hiperplanos menos flexíveis e maiores generalizações nas classificações. Ainda, podem ser definidos valores de gamma, definidos pela função $1/n$, em que n é o número de bandas utilizadas e *Classification Probability Threshold* (CPT), que define a probabilidade requerida para o classificador considerar um determinado pixel.

Para esse trabalho foi utilizada a função kernel de base radial, com parâmetro Gamma igual a 1, parâmetro de penalidade com padrão do *software* de 100 e parâmetro CPT com padrão do *software* de 0 (MEDEIROS *et al.*, 2011; ROZA e RIBEIRO, 2013; MOREIRA *et al.*, 2014).

4.2.6.2. Random Forest

O *Random Forest* é um algoritmo definido por Breiman (2001) como forma de melhorar a árvore de classificação e regressão (classification and regression tree - CART) por meio da combinação de um grande número de

conjuntos de árvores de decisão. Cada árvore contribui com um único voto, e a classificação final é determinada pela maioria dos votos de todas as árvores da floresta, nomenclatura dada a uma coleção de árvores de decisão (SOTHE *et al.*, 2017).

Esse classificador é formado por uma coleção de classificadores estruturados em árvores $\{h(x, \theta_k), k=1, \dots\}$, as quais realizam um processo de votação da classe mais popular. θ_k são vetores aleatórios independentes e identicamente distribuídos; k é o número de árvores que crescem em função do conjunto de treinamento e de θ_k ; e x é o vetor de entrada a partir do qual ocorre a votação de cada árvore para a classe mais popular (TONIOL, 2017).

De acordo com Girolamo Neto (2018), cada árvore de decisão é definida por uma técnica de amostragem com reposição chamado *Bootstrap*. Nessa técnica, as árvores de decisão são criadas utilizando subconjuntos de características selecionadas aleatoriamente de acordo com o conjunto original. Amostras que não são utilizadas no sorteio inicial são chamadas de *out-of-bag* e podem ser utilizadas para estimar erros de classificação e obter a importância das variáveis (Adam *et al.*, 2014).

Portanto, nesse classificador, o primeiro nó da árvore é o nó-raiz. A partir dos atributos desse nó, são gerados outros subconjuntos que possuem suas respectivas árvores. Cada árvore possui seus atributos de classificação que, ao final, após votação de qual classe os atributos devem pertencer, é realizada a combinação das árvores, gerando a classificação *Random Forest* (Figura 25).

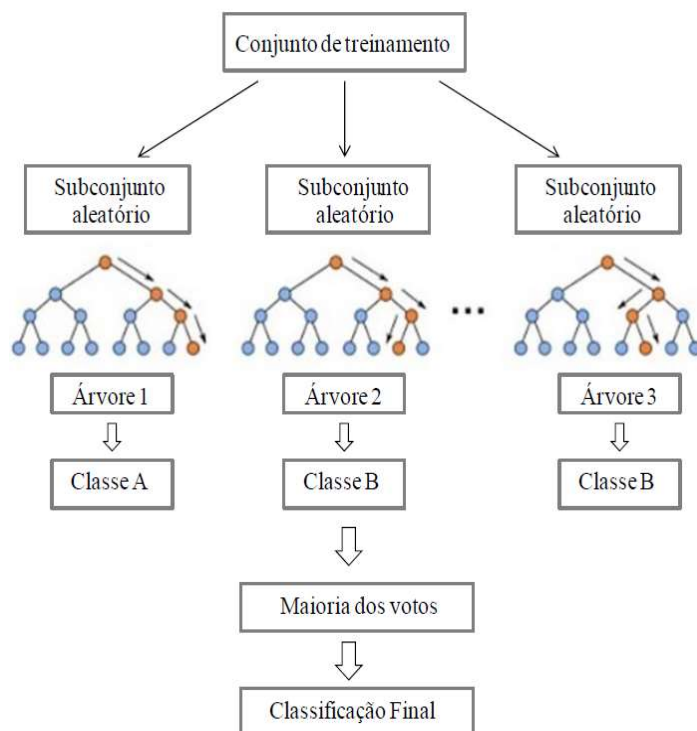


Figura 25 – Exemplo de árvores de decisão utilizadas pelo classificador *Random Forest* (RF).
 Fonte: TONIOL (2017).

Para utilização desse classificador no SNAP 6.0, é necessário definir dois parâmetros: o número de amostras, referentes ao número de pixels das amostras de treinamento e número de árvores. Não há consenso sobre o número mínimo de árvores para alcançar um desempenho ideal do classificador (AKAR e GÜNGÖR, 2015). Portanto, após testes realizados, optou-se por manter os padrões determinados pelo *software*, que são de 5.000 e 10, respectivamente.

4.2.7 Avaliação da acurácia temática

Analisar a acurácia temática de um produto de sensoriamento remoto significa verificar a proximidade dos dados gerados com a verdade de campo, possibilitando analisar a confiabilidade dos mesmos. Portanto, geralmente, mapas gerados a partir de classificações passam por análises estatísticas para validação dos dados.

Índices de exatidão temática são obtidos a partir de matriz de confusão, que verifica erros de atribuição de pixels a uma determinada classe. O objetivo da elaboração da matriz de confusão para esse trabalho foi para

verificar a concordância entre as imagens geradas a partir das classificações supervisionadas e o ambiente real, a partir das amostras de teste, possibilitando checar a quantidade de pixels classificados corretamente ou erroneamente e os erros de omissão e comissão. A partir das matrizes são obtidos os índices de exatidão global, Tau e Kappa. Esses índices foram utilizados como indicadores do melhor classificador entre o SVM e RF.

O índice de exatidão global é calculado dividindo a soma da diagonal principal da matriz de erros X_{ii} , pelo número total de amostras coletadas n , conforme Eq. 5 (BRITES *et al.*, 1996):

$$G = \frac{\sum_{i=1}^c x_{ii}}{n} \quad (5)$$

O índice Kappa é um dos principais métodos utilizados para avaliar a concordância entre a verdade terrestre e o mapa temático produzido. Esse índice, que utiliza todos os valores da matriz de confusão, é calculado a partir da Eq. 6, em que P_o = proporção de unidades que concordam plenamente; e P_e = proporção de unidades que concordam por casualidade (BRITES *et al.*, 1996):

$$\hat{K} = \frac{\hat{p}_o - \hat{p}_e}{1 - \hat{p}_e} \quad (6)$$

Para interpretação dos valores, Landis & Koch (1977) propuseram a classificação dos resultados em seis classes diferentes (Tabela 9):

Índice Kappa	Classificação
<0	Péssima
0 - 0,20	Ruim
0,21 - 0,40	Razoável
0,41 - 0,60	Bom
0,61 - 0,80	Muito Boa
0,81 - 1,00	Excelente

Tabela 9 - Conceitos das classificações baseados no coeficiente Kappa.

Por fim, o índice Tau é um ajuste do percentual de concordância (considera somente elementos da diagonal da matriz) pelo número de categorias (Eq. 7).

$$T = (P_o - \frac{1}{M}) / (1 - \frac{1}{M}) \quad (7)$$

Onde M = número de categorias na classificação (BRITES *et al.*, 1996).

Neste capítulo, apresentam-se os resultados e discussões encontrados após processamento das imagens. Inicialmente são descritas as análises exploratórias dos dados ALOS-2/PALSAR-2, mostrando os coeficientes de retroespalhamento de cada classe temática da área de estudo. Na sequência, são analisados os resultados das classificações por meio dos algoritmos *Support Vector Machine* e *Random Forest* com suas respectivas matrizes de confusão para validação e avaliação dos classificadores. Nas matrizes de confusão, são descritos os valores dos índices de exatidão global, Kappa e Tau.

5.1 Análise exploratória dos dados ALOS-2/PALSAR-2

Na Figura 26 são mostrados os coeficientes de retroespalhamento das imagens HH e HV referentes às quatro classes de cobertura vegetal da área de estudo.




Figura 26 - Valores médios de coeficientes de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado nas polarizações HH e HV dos meses de fevereiro e setembro da imagem ALOS-2/PALSAR-2.

Ao comparar os coeficientes de retroespalhamento entre as polarizações, observou-se que as polarizações HH apresentam valores mais altos em relação às polarizações HV. Segundo Lewis e Henderson (1998), essas diferenças ocorrem porque em polarizações cruzadas, o retroespalhamento é

originado de espalhamento volumétrico, portanto, a energia é espalhada múltiplas vezes no interior dos dosséis, atenuando o retorno da REM para a antena do radar. O coeficiente de retroespalhamento é representado pela soma das reflexões do dossel, da interação da radiação direto do solo e de múltiplos espalhamentos entre os elementos difusores do dossel e sob a superfície do solo (ULABY *et al.*, 1984). Já polarizações paralelas possuem espalhamento superficial, resultantes de reflexão única dos componentes do dossel, como as folhas, troncos e galhos (JENSEN, 2009), e essa interação faz com que o sinal de retorno para o radar seja mais alto em relação às polarizações cruzadas.

O segundo ponto a ser analisado é a diferença entre os coeficientes de retroespalhamento das classes de cobertura vegetal. É possível perceber uma tendência entre todas as polarizações, de forma que os coeficientes de retroespalhamento de vegetação primária e secundária não apresentam muita discrepância, sendo esse padrão observado para as classes cultura agrícola e pastagem. Diferenças significativas são encontradas quando são realizadas comparações entre essas classes (vegetação primária e pastagem ou cultura agrícola e vegetação secundária).

A variabilidade e equivalência de valores é explicada tanto pelo tipo de polarização, como explicado anteriormente, quanto pelas características do alvo e pela profundidade de penetração da onda, que envolve a constante dielétrica. Segundo Jensen (2009), as florestas são geralmente caracterizadas por dosséis espessos e fechados, fazendo com que ocorra o espalhamento volumétrico ou superficial dos pulsos de radar incidentes no dossel e que, por sua vez, propicia maior retorno de sinal para a antena do radar. Conseqüentemente, vegetação típica de florestas são mostradas em imagens de radar em tons mais claros de cinza. Já na vegetação herbáceo-arbustiva, como as culturas agrícolas e pastagens, o efeito é reduzido, pois o volume de biomassa é menor. Além disso, soma-se o fato de que em locais com vegetações rasteiras, há maior interação com o solo, por isso, nas imagens, essas áreas aparecem em tons de cinza mais escuro.

Os valores de vegetação primária nesse estudo estiveram em torno de -8,8 dB para polarização HH e -13,4 dB para polarização HV. Valores de vegetação secundária estiveram em torno de -9 dB para polarização HH e -13,7 dB para polarização HV. Valores de σ° para cultura agrícola estiveram em torno

de -15 dB para polarização HH e - 25 dB para polarização HV. Valores de pastagem estiveram em torno de -16 dB para polarização HH e - 23 dB para polarização HV.

Devido à incipiência de estudos relacionando coeficientes de retroespalhamento das imagens ALOS-2/PALSAR-2 às classes de cobertura vegetal da Amazônia, também se fez necessário comparar os valores encontrados neste estudo com estudos utilizando imagens ALOS/PALSAR. Almeida-Filho *et al.* (2009), em seu trabalho de detecção de desmatamento na Amazônia, encontraram valores de σ° para florestas naturais de -8 dB e -16 dB para polarizações HH e HV, respectivamente. Prado (2009), em seu estudo de identificação dos tipos de cobertura de terra na Amazônia, região norte de Mato Grosso, encontrou valores de floresta primária, floresta secundária e cultura agrícola para a polarização HH de -7,4 dB, -9,6 dB e -20 dB e para a polarização HV de -15,7 dB, -17,9 dB e -29,5 dB, respectivamente.

Em Sano *et al.* (2009), no mapeamento de uso e cobertura do solo no DF, áreas de mata de galeria apresentaram valores de -7 dB para polarização HH e -12 dB para polarização HV, assim como para culturas agrícolas, os valores foram de -12 dB e -23 dB para as polarizações HH e HV, respectivamente. Para pastagens, os valores foram de -14 dB e -23 dB para as polarizações HH e HV, respectivamente.

Rahman e Sumantyo (2010) em seu estudo de mapeamento de cobertura florestal e desmatamento em áreas tropicais de Bangladesh, encontraram valores de -7 dB e -13 dB para as polarizações HH e HV para a classe de floresta natural. Evans e Costa (2013), em seu trabalho de classificação de cobertura da terra no Pantanal, encontraram valores de floresta para polarização HH de -7 dB e -15 dB para polarização HV, assim como para agricultura os valores foram de -15 dB para HH e -24 dB para HV.

Na Figura 27, é mostrada a diferença de valores de coeficiente de retroespalhamento entre as estações chuvosa e seca.




Figura 27 - Comparação entre os valores de coeficientes de retroespalhamento (dB) para as estações chuvosa e seca nas polarizações HH e HV da imagem ALOS-2/PALSAR-2.

Em complemento aos gráficos da Figura 28, o gráfico anterior demonstra que não houveram grandes variações entre os coeficientes de retroespalhamento das estações seca e chuvosa, representados neste trabalho pelas imagens de fevereiro e setembro, respectivamente.

Uma vez que não foram coletados dados de umidade do solo e vegetação, possivelmente esses valores similares foram decorrentes dos eventos de precipitação registrados durante os 10 dias anteriores às duas datas de passagem, onde mesmo com diferenças de volume de precipitação, as respostas das micro-ondas nas imagens não foram distantes, embora as imagens de setembro apresentaram valores levemente mais altos do que as imagens de fevereiro.

Sendo assim, o terceiro ponto a ser analisado é a quantidade de água encontrada nos alvos. Quanto maior for a constante dielétrica do material, maior é a interação do campo elétrico do pulso de micro-ondas com a molécula de água e mais intenso é o retorno do sinal (MENESES e SANO, 2012). Portanto, classes vegetativas fotossinteticamente ativas, com estrutura foliar densa e presença de água em sua estrutura, assim como solos com umidade elevada, são os principais responsáveis por valores relativamente mais altos de coeficientes de retroespalhamento (KASISCHKE e BORGEAUCHAVES, 1997).

Contudo, é importante ressaltar que, aliada à resposta da vegetação com as micro-ondas, está a resposta do solo, que considera, além da rugosidade

superficial, a constante dielétrica (JENSEN, 2009). Solos úmidos acarretam aumento de energia retroespalhada, o que, ocasionalmente, pode interferir e confundir a resposta da vegetação. Deste modo, o aumento no conteúdo de água nos solos tende a reduzir a capacidade de discriminar os tipos vegetacionais presentes na região de interesse (LEWIS e HENDERSON, 1998). Portanto, a diferenciação de alvos em imagens de radar é realizada com base na constante dielétrica (da vegetação e solo) e nos parâmetros de rugosidade e estrutura da vegetação (PARADELLA *et al.*, 2005). Os resultados das imagens resultantes da álgebra de mapas podem ser observados na Figura 28, onde o padrão de equilíbrio dos coeficientes de retroespalhamento para as classes de vegetação também foram mantidos.




Figura 28 - Valores médios de coeficientes de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado das imagens resultantes de álgebra de bandas dos meses de fevereiro e setembro da imagem ALOS-2/PALSAR-2.

Os gráficos de dispersão construídos possibilitam uma melhor visualização da similaridade e discrepância entre os valores de retroespalhamento encontrados para as classes em cada imagem (Figuras 29 a 32).

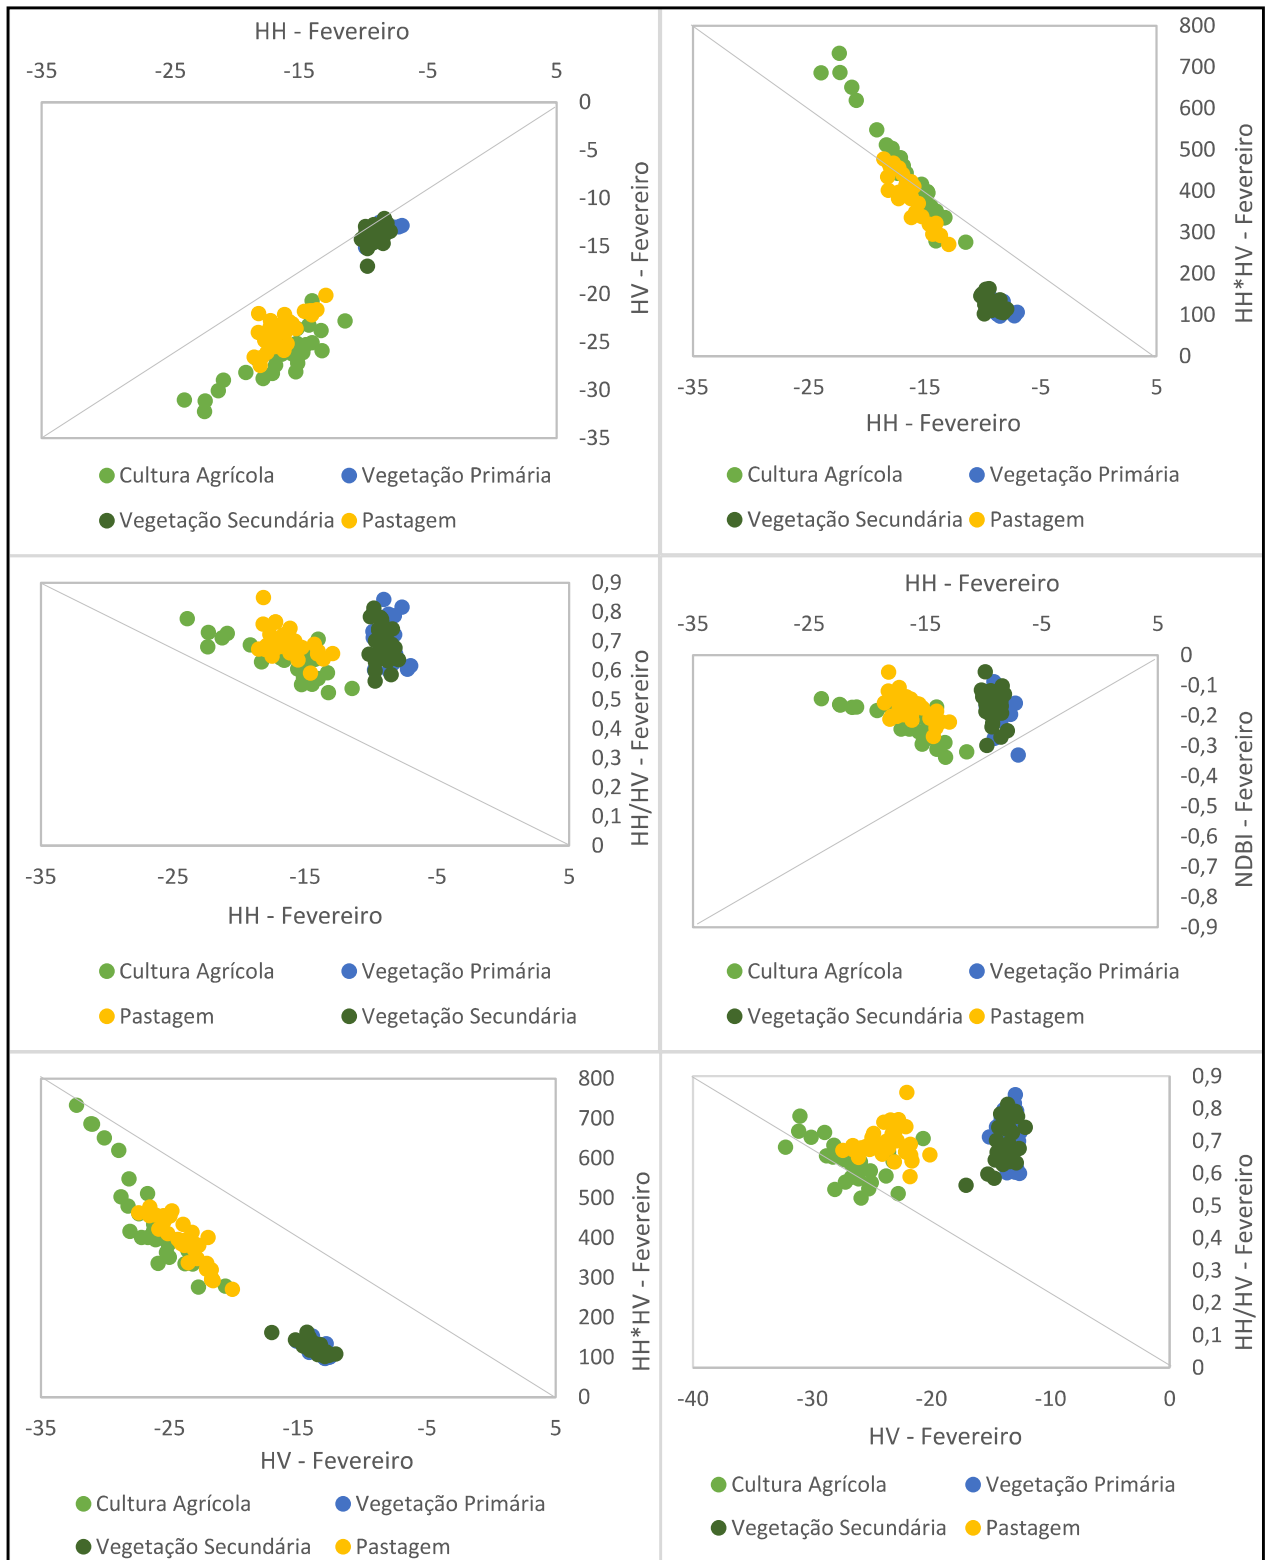


Figura 29 – Gráficos de dispersão dos coeficientes de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado das imagens ALOS-2/PALSAR-2 (Parte 1).

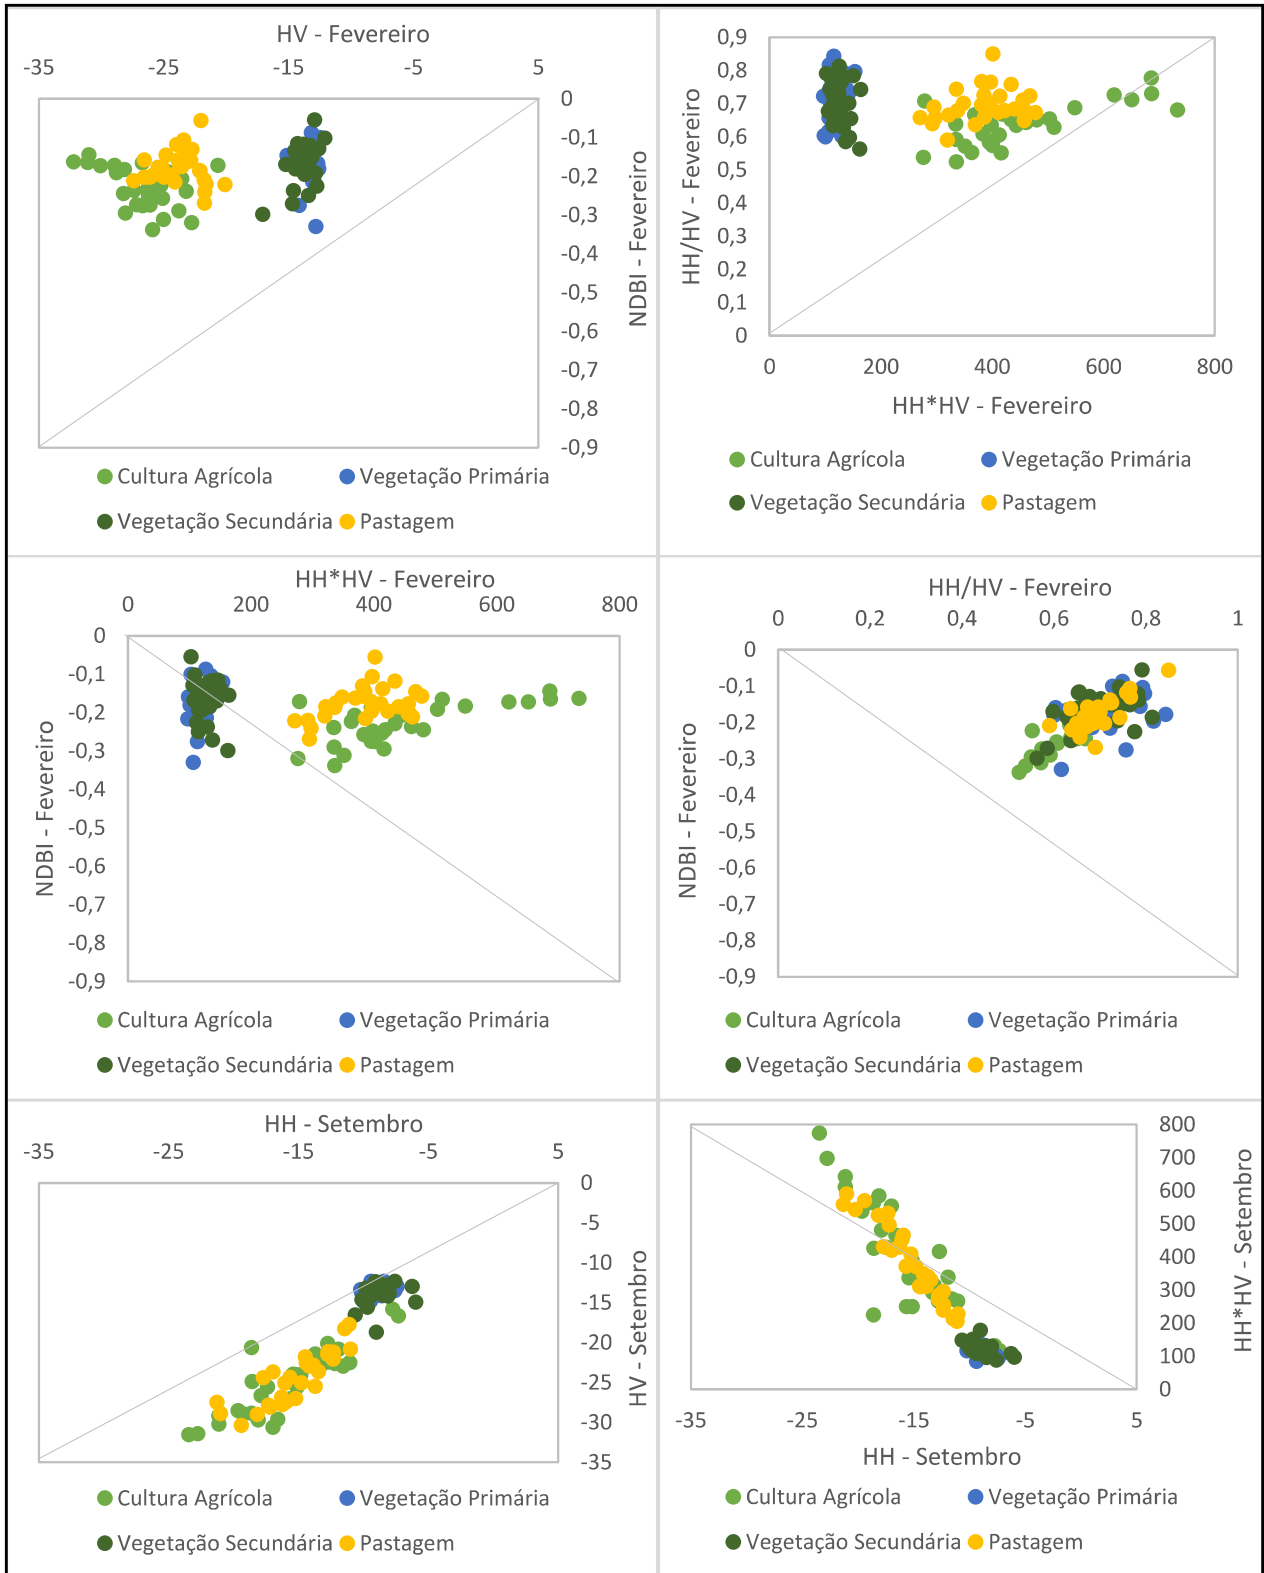


Figura 30 - Gráficos de dispersão dos coeficientes de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado das imagens ALOS-2/PALSAR-2 (Parte 2).

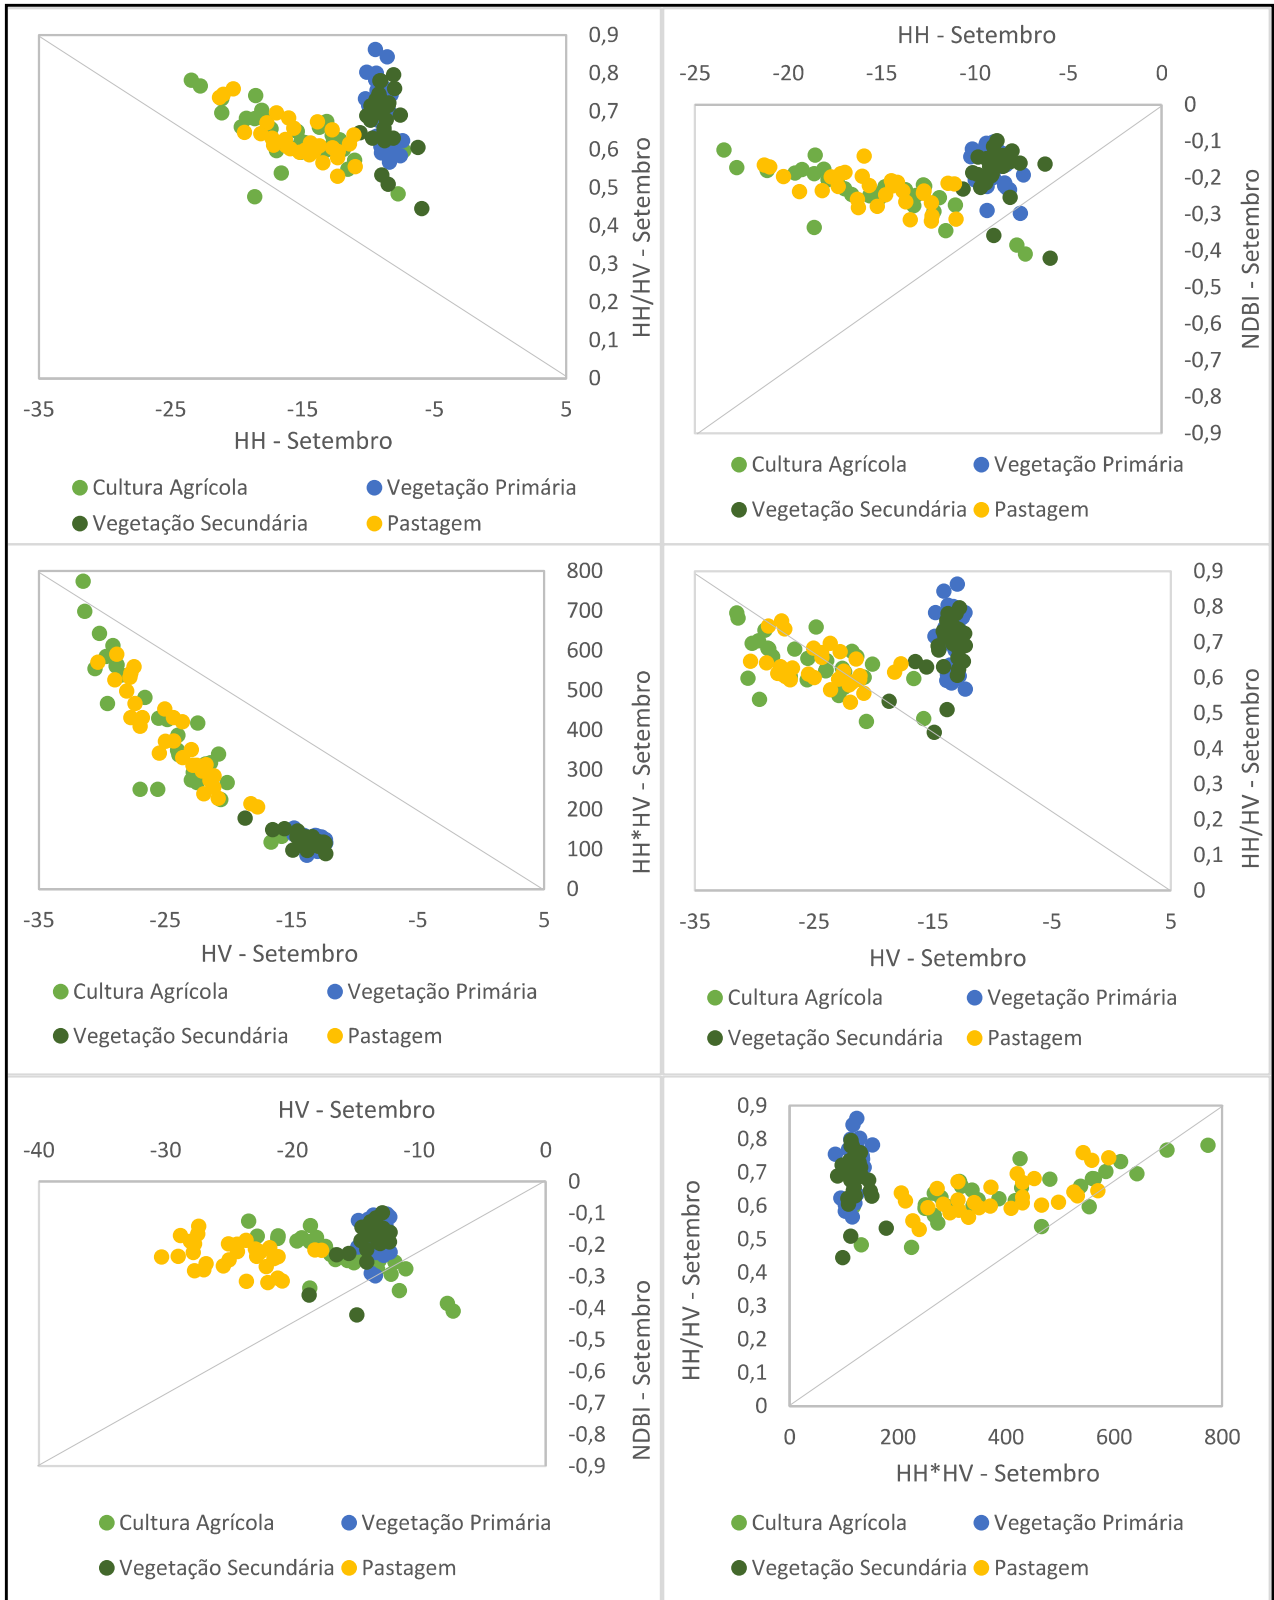


Figura 31 - Gráficos de dispersão dos coeficientes de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado das imagens ALOS-2/PALSAR-2 (Parte 3).




Figura 32 - Gráficos de dispersão dos coeficientes de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado das imagens ALOS-2/PALSAR-2 (Parte 4).

Com exceção dos gráficos comparativos entre HH/HV – fevereiro & NDBI – fevereiro, HV – setembro & NDBI – setembro e HH/HV – setembro & NDBI – setembro, em todos os outros gráficos é possível verificar a formação de dois grupos distintos de classes vegetativas: o primeiro, formado por vegetação primária e vegetação secundária e o segundo, formado por cultura agrícola e pastagem.

Também é possível observar que, em todos os gráficos, as classes que menos se separam é a de vegetação primária e vegetação secundária, o que significa menor dispersão de valores, e, portanto, esses alvos interagiram com a REM de forma semelhante.

Coberturas vegetais frondosas e com pouco espaçamento entre as árvores produzirão coeficientes de retroespalhamento maiores, desde que haja pouca influência da constante dielétrica. Couto Júnior et al. (2011) encontraram resultados similares, de modo que, na discriminação de alvos no bioma Cerrado, os menores coeficientes de retroespalhamento foram relacionados às áreas com cobertura homogênea e rasteira, relacionada às classes campestre e agrícola.

Quanto às classes de cultura agrícola e pastagem, os valores de coeficiente de retroespalhamento estão mais dispersos, mas seguem o padrão de difícil separação. As únicas imagens que possibilitam uma maior separação são as resultantes do NDBI.

Portanto, os gráficos demonstram que só é possível separar as classes de vegetação primária e vegetação secundária de cultura agrícola e pastagem, mas não é possível fazer uma perfeita separação entre todas elas.

Os resultados das análises de agrupamento hierárquico são apresentados nas Figuras 33 e 34. Nos dendogramas obtidos, é possível verificar as similaridades entre as classes de cobertura vegetal representativas da Amazônia para cada polarização.

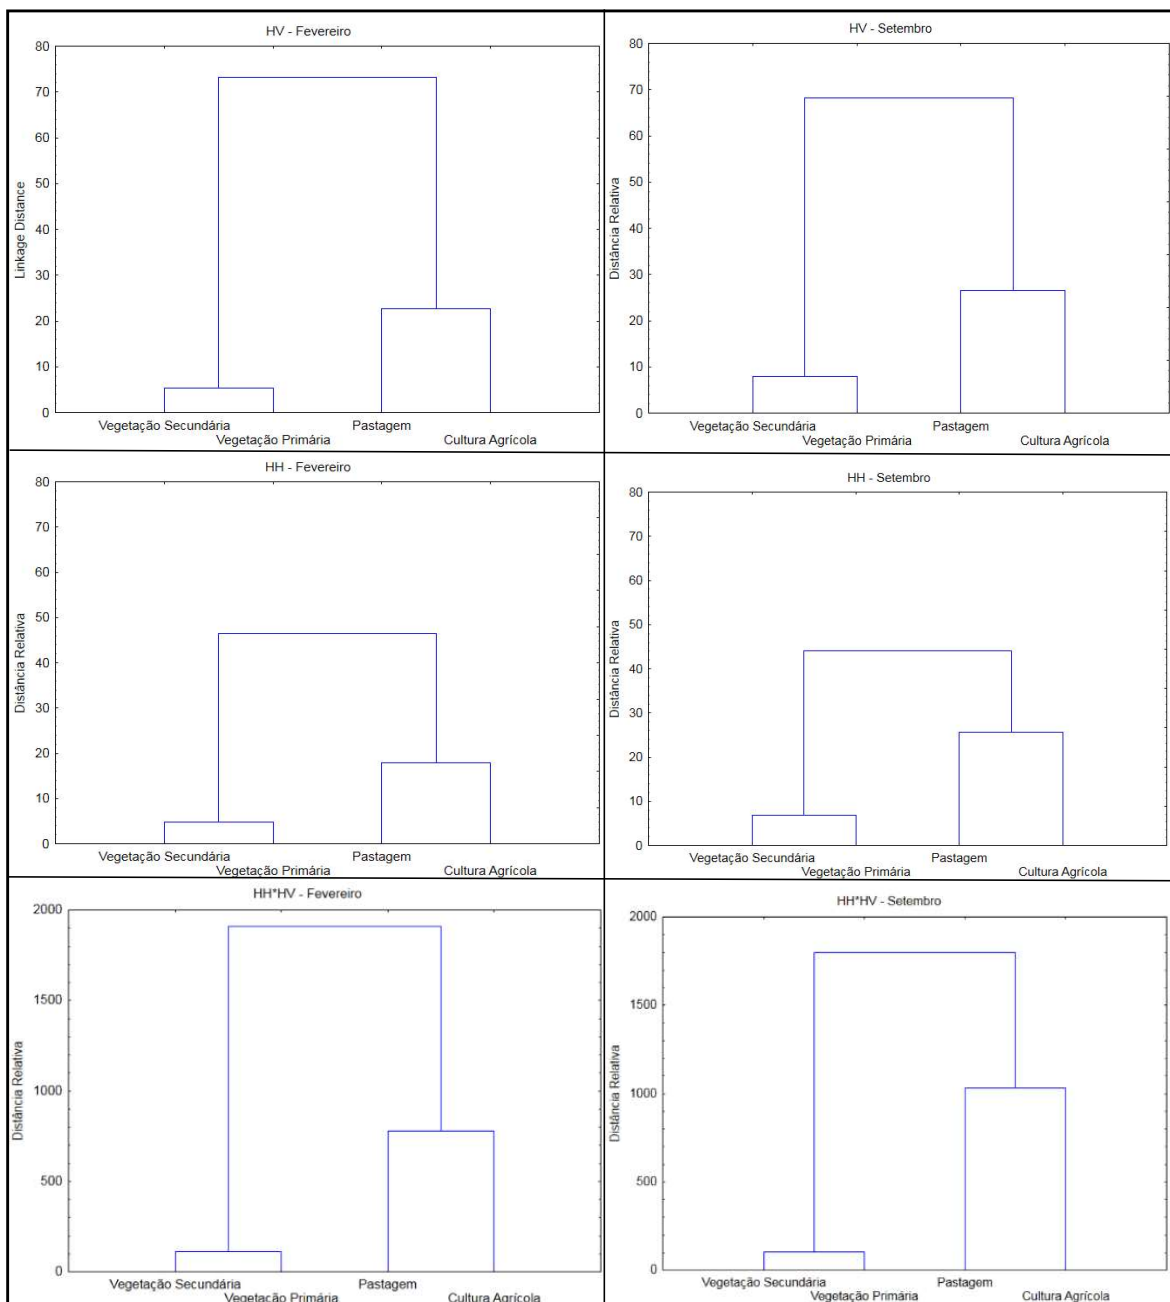


Figura 33 - Agrupamento hierárquico entre os valores de coeficiente de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado nas polarizações HH, HV e HH*HV dos meses de fevereiro e setembro extraídos das imagens ALOS-2/PALSAR-2.

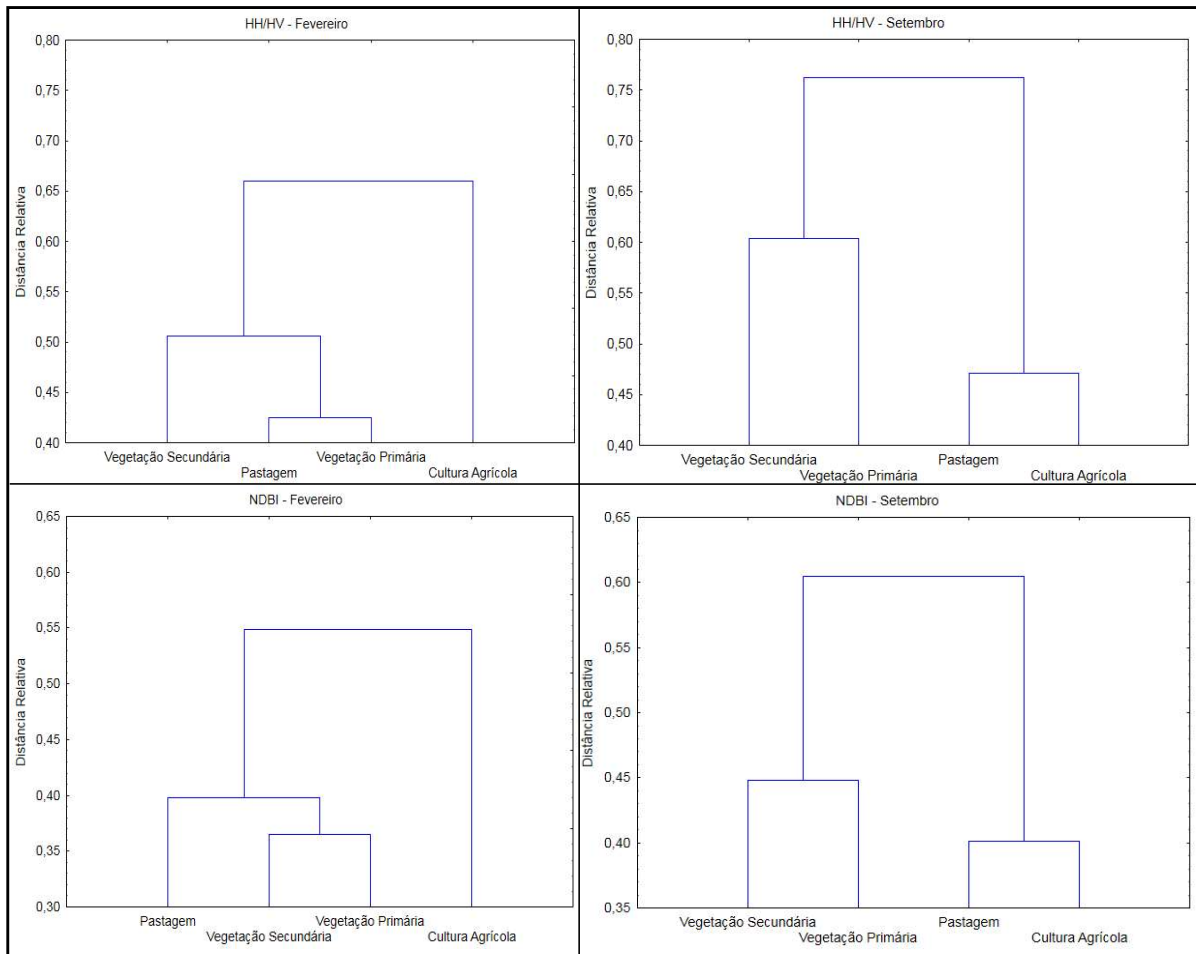


Figura 34 - Agrupamento hierárquico entre os valores de coeficiente de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado nas polarizações HH/HV e NDBI dos meses de fevereiro e setembro extraídos das imagens ALOS-2/PALSAR-2.

Confirmando as informações anteriormente expostas, percebe-se que foram formados dois grupos, um composto por vegetação primária e secundária, e o outro formado por cultura agrícola e pastagem. É possível verificar também que o primeiro grupo é mais difícil de discriminar do que o segundo. Ainda, há uma clara possibilidade de separar as classes vegetação primária e secundária de cultura agrícola e pastagem.

A diferença nos padrões fica por conta das imagens HH/HV de fevereiro e setembro e NDBI de fevereiro e setembro. Nas imagens de setembro, os resultados ficaram invertidos, tornando as classes cultura agrícola e pastagem mais homogêneas que as classes vegetação primária e secundária.

Quanto às imagens de fevereiro, a imagem HH/HV mostra que os valores mais similares foram de vegetação primária e pastagem. Somente após a formação desse grupo, é formado o grupo seguinte com a vegetação secundária e

por último a cultura agrícola. A imagem NDBI mostra que o primeiro grupo formado é de vegetação primária e secundária, seguido de pastagem e por último, a cultura agrícola.

Os resultados derivados da análise hierárquica indicam que mesmo imagens de diferentes polarizações e diferentes épocas do ano apresentam resultados similares de potencial de diferenciação de classes. Em geral, as imagens do mês de setembro conseguem diferenciar as classes dos dois grupos formados sutilmente melhor do que as imagens do mês de fevereiro. Entretanto, ao diferenciar os dois grupos, as imagens de fevereiro produzem melhores resultados. Os resultados estatísticos por meio de *boxplot* indicaram a mesma padronização de separação de classes (Figuras 35 e 36).

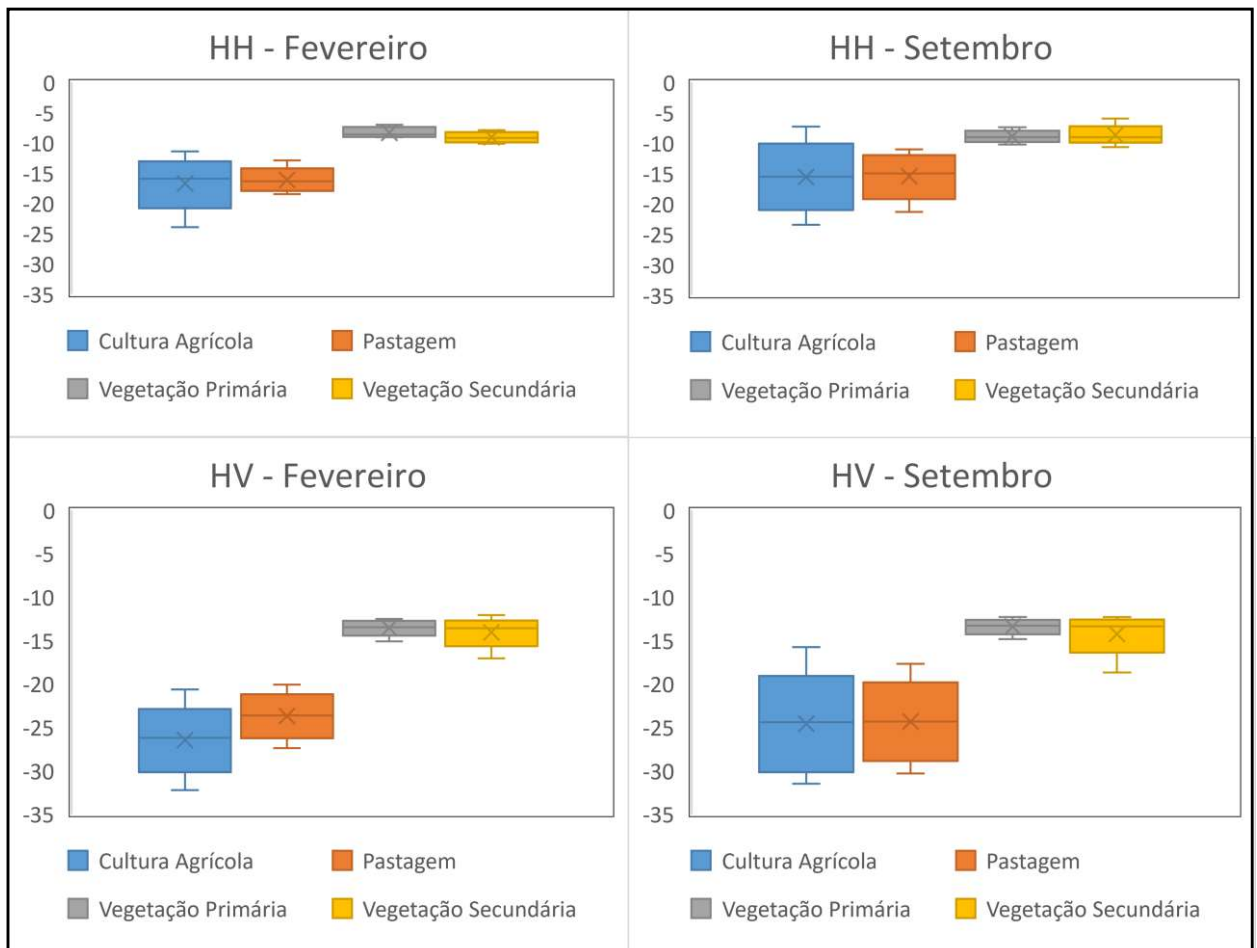


Figura 35 - *Boxplot* entre os valores de coeficiente de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado nas polarizações HH e HV dos meses de fevereiro e setembro extraídos das imagens ALOS-2/PALSAR-2.

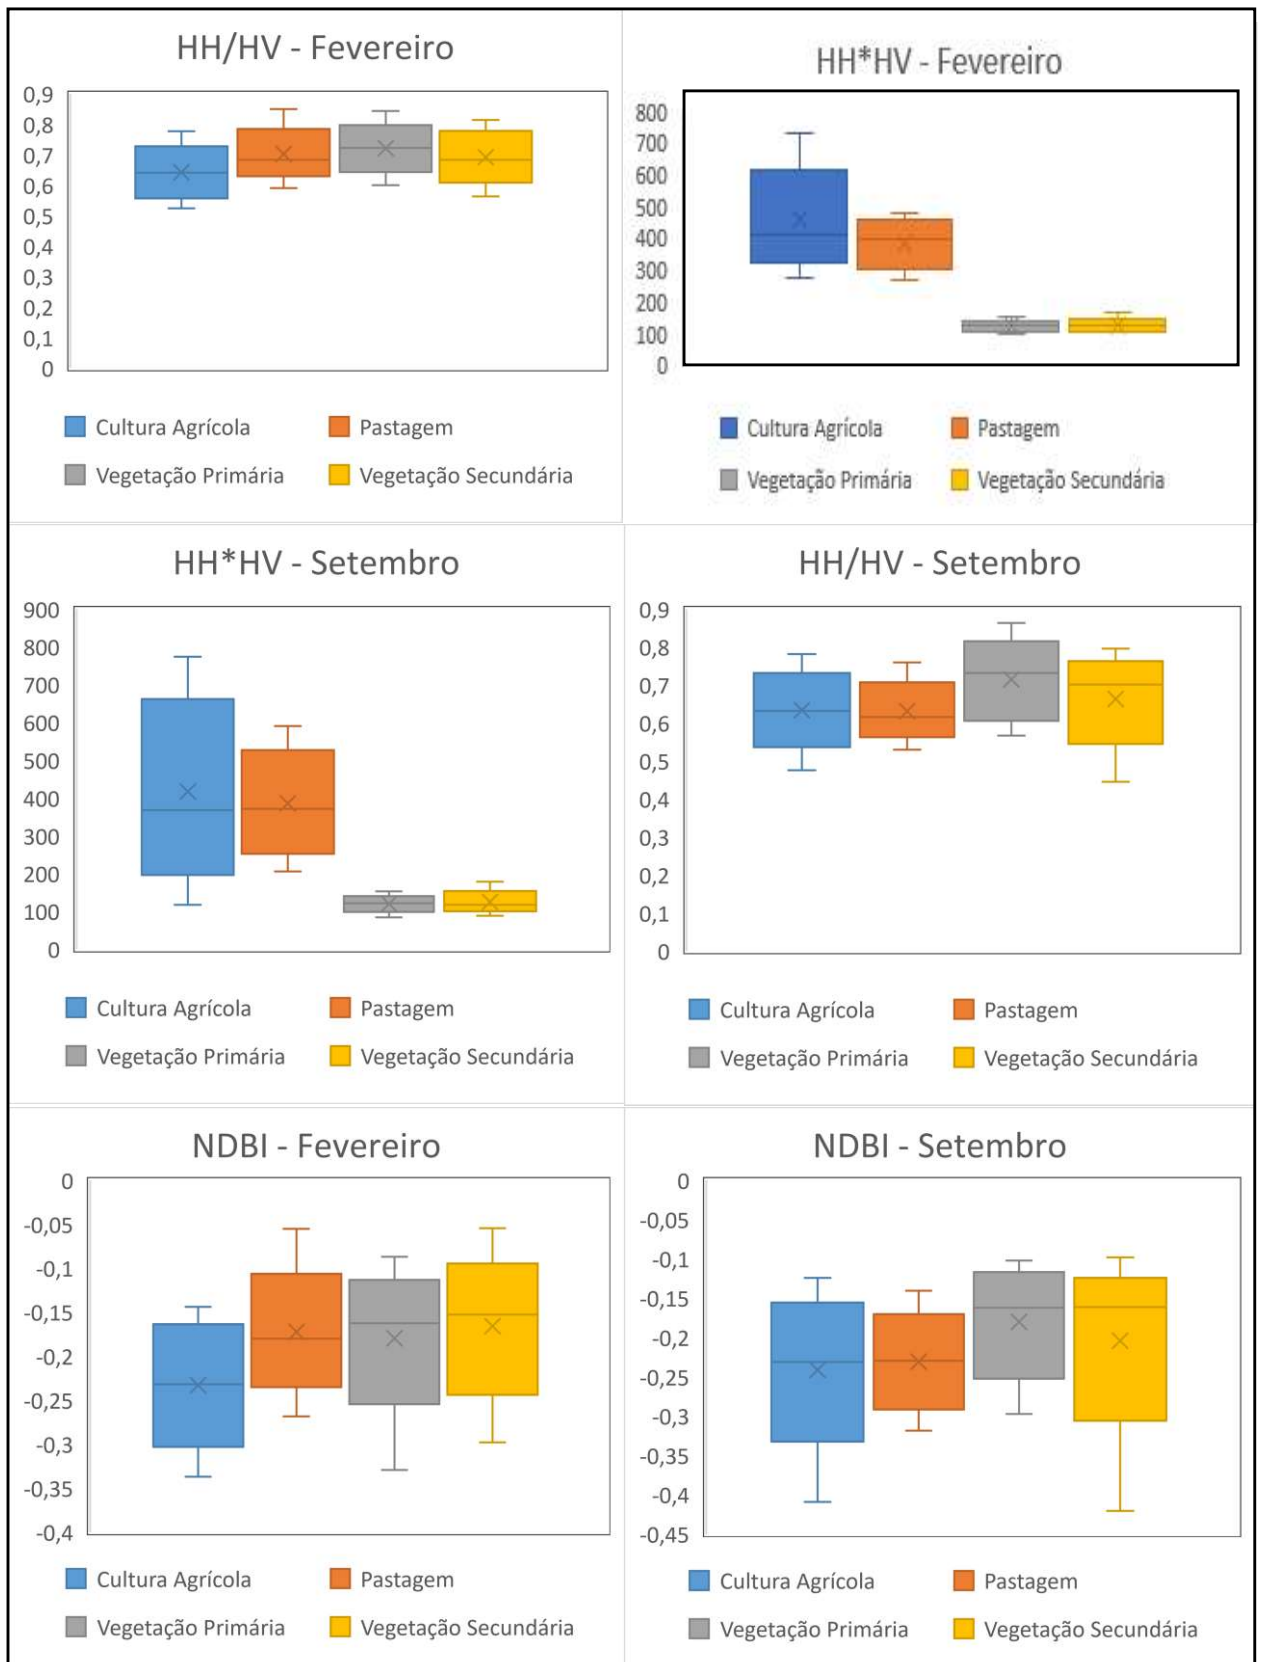


Figura 36 - *Boxplot* entre os valores de coeficiente de retroespalhamento (dB) das quatro classes de cobertura vegetal na área de transição Amazônia/Cerrado das polarizações HH*HV, HH/HV e índice NDBI dos meses de fevereiro e setembro extraídos das imagens ALOS-2/PALSAR-2.

É possível analisar que os coeficientes de retroespalhamento das classes vegetação primária e vegetação secundária apresentam dispersão muito próxima, assim como os valores das classes pastagem e cultura agrícola, portanto, são formados os dois grupos de classes de cobertura vegetal. As imagens HH/HV de fevereiro e setembro e NDBI de fevereiro e setembro fogem ao padrão, demonstrando maior equilíbrio entre os valores de retroespalhamento e consequentemente, maior dificuldade de separação entre as quatro classes.

No geral, a vegetação primária é a classe que apresenta a menor variação de valores de coeficiente de retroespalhamento, seguido da vegetação secundária. Esse padrão provavelmente indica grande homogeneidade de estrutura e estágios avançados de desenvolvimento da vegetação típica de florestas naturais. Embora a expectativa fosse no sentido de que os dados de vegetação secundária apresentassem maior separação em relação aos dados de vegetação primária, os resultados podem indicar que a vegetação já está em estágio de desenvolvimento similar à vegetação primária e/ou seus fragmentos resultantes do desflorestamento, como galhos e troncos, podem servir como alvos refletores de radiação, o que aumentaria os valores de retroespalhamento.

A classe de cultura agrícola apresentou os menores valores e maior dispersão, seguida da classe pastagem. Possivelmente esse padrão de baixo sinal de retorno para o radar foi encontrado por essas classes disporem de vegetação baixa e áreas de solo exposto, o que promove maior reflexão especular.

Para a escolha das imagens para utilização nas classificações, esperava-se que as diferentes épocas com diferentes índices de precipitação resultassem em diferenças significativas para separação de classes, o que acabou não se confirmando, embora a dispersão dos valores de retroespalhamento seja maior em setembro do que em fevereiro. Os resultados das álgebras de mapas e índice NDBI não apresentaram grandes diferenças em relação às polarizações simples, uma vez que não apresentaram valores expressivos que indicassem melhor diferenciação das classes vegetativas da Amazônia.

A partir das análises estatísticas realizadas por meio dos coeficientes de retroespalhamento, a imagem que apresentou os melhores resultados foi a de polarização cruzada HV de fevereiro, referente à época de seca. Polarizações cruzadas vêm apresentando os melhores resultados em discriminação de alvos vegetativos (MITCHARD *et al.*, 2009; MOTOHKA *et al.*, 2014; LIAO *et al.*, 2017;

GARCÍA *et al.*, 2018). Entretanto, na etapa de análise de classificadores, foram utilizadas as imagens HH, HV e HH*HV da seca, levando em consideração as menores dispersões de valores e maior diferenciação de classes.

5.2 Avaliação dos classificadores Support Vector Machine e Random Forest

Na Figura 37, é apresentada a classificação resultante do emprego do algoritmo SVM. Como já esperado, houve grande confusão na classificação entre vegetação primária e vegetação secundária. Em nenhum ponto da imagem é possível fazer uma separação satisfatória entre essas classes. Já as classes de cultura agrícola e pastagem apresentam uma diferenciação ligeiramente melhor, podendo ser observado polígonos quase totalmente pertencentes a uma única classe.

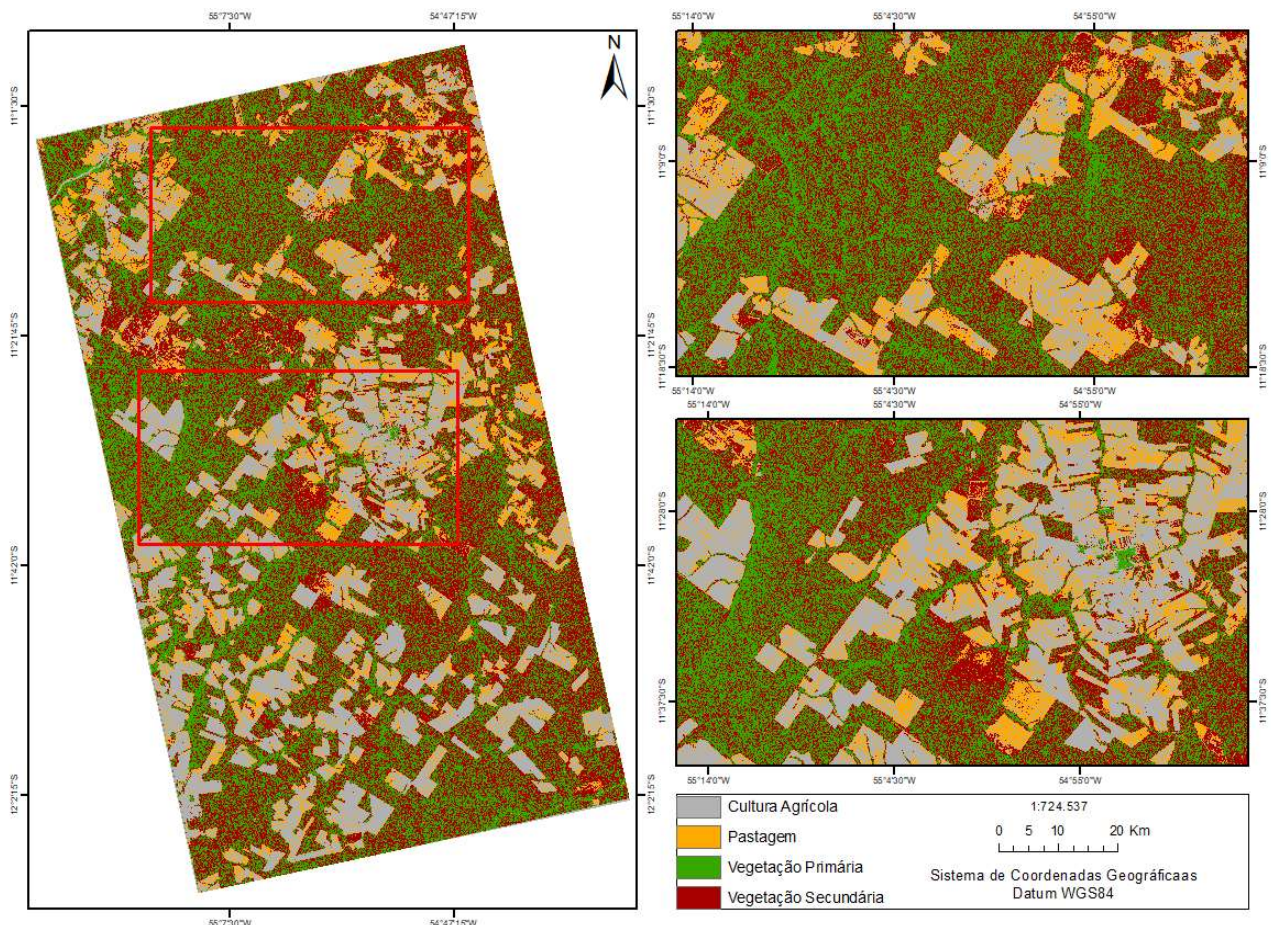


Figura 37 - Resultado da classificação supervisionada pelo algoritmo Support Vector Machine, polarizações HH, HV e HH*HV do mês de fevereiro de 2016, com filtro adaptativo Gamma (janela de 3 pixels x 3 pixels).

A matriz de confusão da classificação SVM pode ser observada na tabela 10. Na tabela também foram incluídos os erros de comissão e omissão. O primeiro é referente à inclusão de uma área em uma classe à qual ela não pertence, enquanto o erro de omissão refere-se à exclusão de uma área da classe que ela deveria pertencer.

SVM - Polarizações HH, HV e HH*HV de Fevereiro							
Classes	Vegetação Primária	Vegetação Secundária	Cultura Agrícola	Pastagem	Total	% EO	% EC
Vegetação Primária	7	7	0	0	14	50,00	65,00
Vegetação Secundária	13	13	1	0	27	51,85	35,00
Cultura Agrícola	0	0	15	7	22	31,82	25,00
Pastagem	0	0	4	13	17	23,53	35,00
Total	20	20	20	20	80		
Exatidão global	0,60						
Kappa	0,47						
Tau	0,47						

Tabela 10 - Matriz de confusão do classificador SVM, utilizando imagem ALOS-2/PALSAR-2, polarizações HH, HV e HH*HV de fevereiro de 2016.

A classe vegetação primária apresentou os maiores valores de erro de comissão, com 65%. Já a classe de vegetação secundária apresentou os maiores valores de erro de omissão, com 51,85%. A classe que apresentou o menor índice de erro de omissão foi pastagem, enquanto a classe que apresentou o menor índices de erro de comissão foi cultura agrícola. Do total de 80 pontos amostrais, 48 foram mapeados corretamente, resultando em índice de exatidão global de 60%, índice Kappa de 0,47 e índice τ de 47%.

Na Figura 38 é apresentada a classificação resultante do emprego do algoritmo RF. Visualmente, é possível perceber que as classes vegetação primária e vegetação secundária apresentam maior confusão do que a encontrada pelo classificador SVM. Em contrapartida, as classes cultura agrícola e pastagem apresentara uma ligeira melhora na diferenciação.

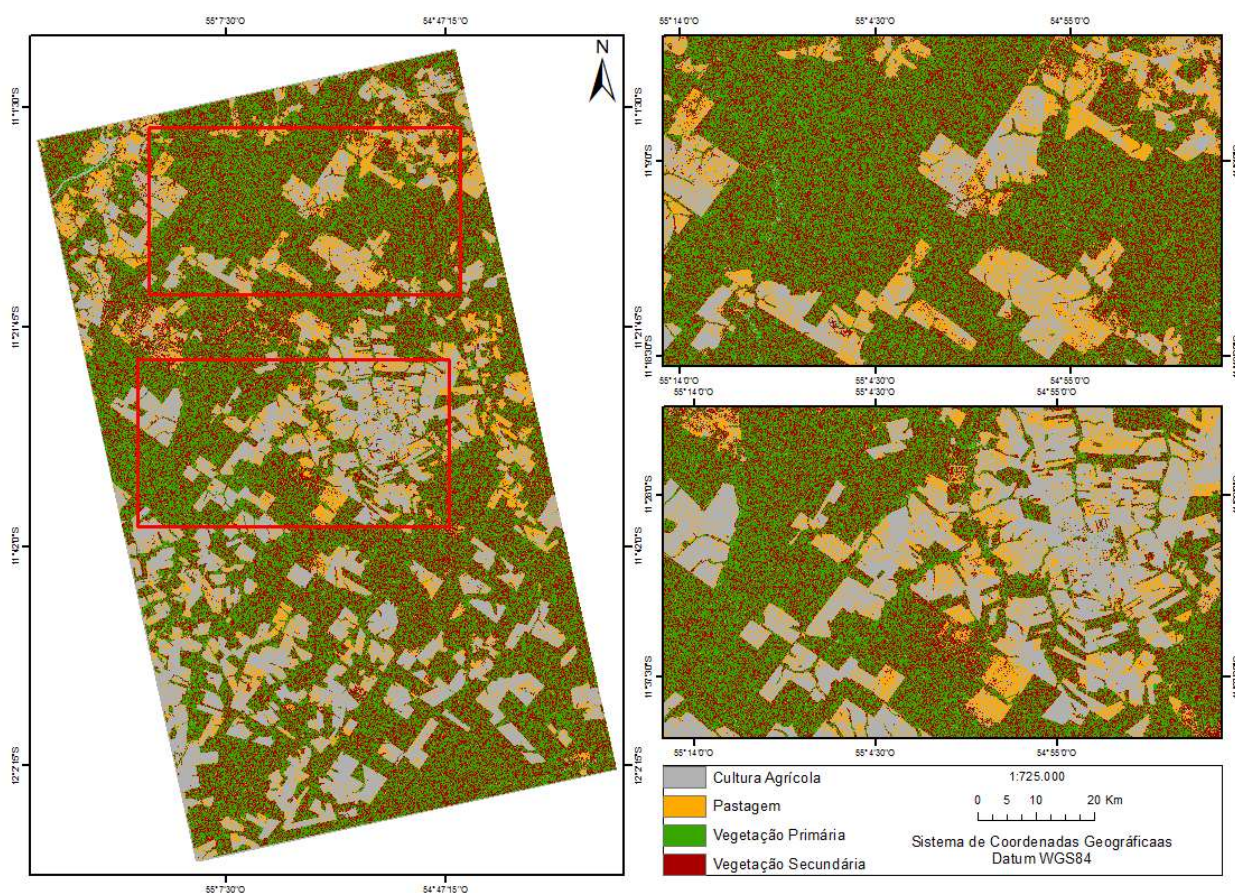


Figura 38 - Resultado da classificação supervisionada pelo algoritmo *Random Forest*, polarizações HH, HV e HH*HV de fevereiro de 2016, com filtro adaptativo Gamma (janela de 3 pixels x 3 pixels).

A matriz de confusão da classificação RF pode ser observada na Tabela 11.

RF - Polarizações HH, HV e HH*HV de Fevereiro							
Classes	Vegetação Primária	Vegetação Secundária	Cultura Agrícola	Pastagem	Total	% EO	% EC
Vegetação Primária	8	10	1	0	19	57,89	60,00
Vegetação Secundária	12	9	0	0	21	57,14	55,00
Cultura Agrícola	0	1	15	5	21	28,57	25,00
Pastagem	0	0	4	15	19	21,05	25,00
Total	20	20	20	20	80		
Exatidão global	0,59						
Kappa	0,45						
Tau	0,45						

Tabela 11 - Matriz de confusão do classificador RF, utilizando imagem ALOS-2/PALSAR-2, polarizações HH, HV e HH*HV de fevereiro de 2016.

As classes que apresentaram os maiores erros de omissão foram vegetação primária e vegetação secundária, com valores de 57,89% e 57,14%.

Conforme esperado, os maiores erros de comissão também foram encontrados nessas classes, com porcentagem de 60% para vegetação primária e 55% para vegetação secundária. As classes cultura agrícola e pastagem apresentaram erros de omissão e comissão em torno de 30%. Do total de 80 pontos amostrais, 47 foram mapeados corretamente, resultando em índice de exatidão global de 59%, índice Kappa de 0,45 e índice τ de 45%.

A Tabela 12 permite concluir que os classificadores não apresentaram resultados ótimos na diferenciação entre todas as classes, conforme as análises já vinham indicando. Entretanto, pode-se afirmar que, a partir do índice Kappa, a classificação que apresentou os melhores resultados foi obtida por meio do classificador SVM, considerando os demais resultados apresentados nas matrizes de confusão.

	Kappa	Conceito
SVM	0,60	Bom
RF	0,59	Bom

Tabela 12 - Resultado geral de índice e conceito Kappa para as classificações SVM e RF com e sem filtro.

Os resultados apresentados indicam que classes vegetais com características semelhantes, como vegetação primária e vegetação secundária ou cultura agrícola e pastagem, não são possíveis de discriminar a partir de imagens de radar de banda L. Estudos com a mesma temática de discriminação de classes de cobertura vegetal de diversas áreas de estudo utilizando radares de banda L também apresentaram resultados semelhantes.

Prado (2009), para discriminação de uso e cobertura do solo no Mato Grosso, utilizando imagens ALOS/PALSAR, polarização HV e os classificadores Bhattacharyya e Maxver-ICM, encontrou índices de exatidão global e Kappa de 66,03% e 0,55 para a primeira área e 48,19% e 0,31 para a segunda área, com o objetivo de discriminar as classes floresta primária, floresta secundária, floresta degradada e agricultura.

Costa (2011), a partir do uso de imagens do sistema SAR-R99B, polarização HV e utilizando o classificador SVM para discriminar as classes floresta primária, floresta secundária, agricultura, pastagem, sombreamento e solo exposto, encontrou índices de exatidão global de 59,9% e Kappa de 0,51.

Somente com a combinação de três polarizações (HH, HV e VV) os resultados foram classificados como muito bons (exatidão global de 74,8% e Kappa de 0,69). Li *et al.* (2012), utilizando imagens ALOS/PALSAR da região de Altamira/PA, com combinação de polarizações HH e HV, também tiveram dificuldade na diferenciação de classes de cobertura vegetal (floresta primária, secundária, pastagem, áreas urbanas, água e pântanos), obtendo valores de exatidão global de 56,6% e índice Kappa de 0,50 para a classificação SVM.

Entretanto, ao discriminar as classes vegetação primária de pastagem e/ou vegetação secundária de cultura agrícola, os resultados foram satisfatórios, o que indica que para discriminação entre classes florestais e não florestais, os níveis de acurácia temática aumentariam, o que demonstra que as imagens ALOS-2/PALSAR-2 possuem potencial para identificar áreas de desmatamento e áreas de vegetação natural.

As imagens ALOS-2/PALSAR-2 devem ser consideradas para estudos de monitoramento das mudanças de uso e cobertura vegetal de áreas florestais. Este estudo mostrou que, independente da polarização, os resultados foram satisfatórios quanto à detecção de áreas desmatadas, ou seja, por meio dessas imagens é possível verificar áreas onde a vegetação primária foi convertida em outros tipos de uso, como culturas agrícolas ou pastagens. No entanto, essas imagens devem ser consideradas limitadas quanto à discriminação entre classes vegetativas que apresentam características semelhantes, como vegetação primária e vegetação secundária ou pastagem e cultura agrícola.

Por meio das análises exploratórias dos dados, observou-se que as imagens com polarização cruzada apresentam ligeira vantagem no que diz respeito à discriminação de classes em relação às polarizações paralelas. Isto porque ao interagirem volumetricamente com dosséis, galhos e muitas vezes o solo, há maior possibilidade de identificação dos estágios em que a vegetação se encontra.

Em consequência, os classificadores SVM e RF mostraram-se incapazes de produzir mapas de cobertura vegetal com completa dissociação de classes. Verificou-se que o classificador SVM apresentou uma melhor acurácia temática que o classificador RF. Em contrapartida, em relação à vantagens operacionais e computacionais, incluída o tempo de processamento das imagens, o classificador RF apresenta resultados mais rápidos.

Este trabalho buscou apresentar resultados para o estudo das potencialidades das imagens ALOS-2/PALSAR-2 na discriminação de classes de cobertura vegetal da Amazônia. Observou-se que a melhor polarização foi a HV, embora as outras polarizações apresentassem resultados semelhantes. Não foi possível avaliar a influência da constante dielétrica no solo e vegetação, uma vez que não havia dados disponíveis, assim não houve grande variação de valores de retroespalhamento entre as imagens consideradas da chuva (setembro) e da seca (fevereiro).

Recomenda-se que esse estudo seja continuado, mas utilizando técnicas de processamento mais complexas, como as técnicas de decomposição de alvos propostos por Cloude e Pottier (1997) e Yamaguchi *et al.* (2005). Essas técnicas possuem o objetivo de representar o mecanismo médio de espalhamento como uma soma de elementos independentes, associando, a cada um desses elementos, um mecanismo físico de espalhamento (CLOUDE; POTTIER, 1996). Para que seja possível realizar o estudo de classificação de alvos com cobertura vegetal é necessário que as imagens ALOS-2/PALSAR-2 sejam obtidas em nível de processamento 1.1 – *Single Look Complex*.

REFERÊNCIAS BIBLIOGRÁFICAS

ADAM, E.; MUTANGA, O.; ODINDI, J.; ABDEL-RAHMAN, E. M. Land-use/cover classification in a heterogeneous coastal landscape using RapidEye imagery: evaluating the performance of random forest and support vector machines classifiers. **International Journal of Remote Sensing**, v. 35, n. 10, p. 3440-3458, 2014.

ADAMI, M.; FREITAS, R. M.; PADOVANI, C. A.; SHIMABUKURO, Y. E.; MOREIRA, M. A. Estudo da dinâmica espaço-temporal do bioma Pantanal por meio de imagens MODIS. **Pesquisa Agropecuária Brasileira**, v. 43, n. 10, p.1371-1378, 2008.

AGRITEMPO. **Sistema de monitoramento agrometeorológico**. Disponível em: <<https://www.agritempo.gov.br/agritempo/jsp/grafico/graficomicroregiao.jsp?siglauf=mt>>. Acesso em: 19 set. 2018.

AKAR, Ö.; GÜNGÖR, O. Integrating multiple texture methods and NDVI to the random forest classification algorithm to detect tea and hazelnut plantation areas in northeast Turkey. **International Journal of Remote Sensing**, v. 36, p. 442–464, 2015.

ALENCAR, A.; NEPSTAD, D.; MCGRATH, D.; MOUTINHO, P.; PACHECO, P.; DIAZ, M. D. C. V; SOARES FILHO, B. **Desmatamento na Amazônia: indo além da “emergência crônica”**. Belém: IPAM, 89 p., 2004.

ALENCAR, L. A.; ALMEIDA, L. V. C.; PIGNATI, W. A.; PIGNATTI, M. G. **População, desmatamento e produção agrícola temporária na área de influência da BR- 163 – Mato Grosso**. População, ambiente e desenvolvimento: mudanças climáticas e urbanização no Centro-Oeste. 1ª ed. Campinas/SP: Núcleo de Estudos de População-Nepo/Unicamp; Brasília: UNFPA. 192 p., 2011.

ALMEIDA-FILHO, R., SHIMABUKURO, Y. E., ROSENQVIST, A., SÁNCHEZ, G. A. Using dual-polarized ALOS PALSAR data for detecting new fronts of deforestation in the Brazilian Amazônia. **International Journal of Remote Sensing**, v. 30, n. 14, p. 3735–374, 2009.

ALMEIDA, C. W. L. Sistema de Vigilância da Amazônia – SIVAM, perspectivas da economia da defesa. **A Defesa Nacional**, v. 793, p. 42-57, 2002.

ALMEIDA, C. **PROJETO DETEX**. São José dos Campos: INPE, 2009.

ALMEIDA, C. A.; VALERIANO, D. M.; ESCADA, M. I. S.; RENNÓ, C. D. Estimativa de área de vegetação secundária na Amazônia Legal Brasileira. **Acta Amazonica**, v. 40, n. 2, p. 289-301, 2010.

ANSELIN, L.; BAO, S. Exploratory Spatial Data Analysis Linking SpaceStat and ArcView. In: Fischer, M. M. & Getis, A. **Recent Developments in Spatial Analysis**. Nova York: Springer, p. 35-59, 1997.

BARLOW, J.; PERES, C. Fire-mediated dieback and compositional cascade in an Amazonian forest. **Philosophical Transactions of the Royal Society B: Biological Sciences**, v. 363, n. 1498, p.1787-1794, 2008.

BEHRENS, J. T. Principles and procedures of exploratory data analysis. **Psychological Methods**, v. 2, n. 2, p. 131–160, 1997.

BRASIL. **Projeto RADAMBRASIL: Programa de Integração Nacional – Levantamento de Recursos Naturais**. Folha SC.20 Porto Velho. Rio de Janeiro: Departamento Nacional da Produção Mineral, v. 16, 668 p, 1978.

BRASIL. **Saiba como funciona o sistema de monitoramento de queimadas no país**. Disponível em: <<http://www.brasil.gov.br/noticias/meio-ambiente/2016/08/saiba-como-funciona-o-sistema-de-monitoramento-de-queimadas-no-pais>>. Acesso em: 22 ago. 2018.

BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5–32. 2001.

BRITES, R. S.; SOARES, V. P.; RIBEIRO, C. A. A. S. Verificação da exatidão em classificação de uma imagem orbital mediante a utilização de três índices. **Revista Árvore**, v. 20, n. 3, p. 415-424, 1996.

CENSIPAM. (2015). **Relatório de Atividades 2015. Centro Gestor e Operacional do Sistema de Proteção da Amazônia**. Disponível em: <<http://www.sipam.gov.br/sobre/arquivos/relatorios/relatorio-de-atividades-2015.pdf>>. Acesso em: 04 set. 2018.

CLOUDE, S. R.; POTTIER, E. A review of target decomposition theorems in radar polarimetry. **IEEE Transactions on Geoscience and Remote Sensing**, v. 34, n. 2, p. 498– 518, 1996.

CLOUDE, S. R.; POTTIER, E. An entropy based classification scheme for land applications of polarimetric SAR. **IEEE Transactions on Geoscience Remote Sensing**, v. 35, n. 1, p. 68– 78, 1997.

CORREIA, A. H.; FORMAGGIO, A. R.; SHIMABUKURO, Y. E.; DUARTE, V. Utilização de dados reflectância MODIS (composições de 8 dias) para detecção de desmatamentos na Amazônia. In: Simpósio Brasileiro De Sensoriamento Remoto, 12., Goiânia/GO, **Anais...** São José dos Campos: INPE, p. 481-488, 2005.

COSTA, J. A. L. **Avaliação de dados de radar do sensor SAR-R99B no mapeamento do uso e cobertura da terra na Amazônia Central, município de Manaus, AM**. Dissertação (Mestrado em Ciências Florestais e Ambientais), Manaus: Universidade Federal do Amazonas, 2011, 116 f.

COSTA, D. P.; FERREIRA, B. C. Programas especiais e inovação no âmbito do Sistema de Proteção da Amazônia: o Programa Amazônia - SAR e Sistema ADS-80 impulsos para reestruturação organizacional e produção do conhecimento. In:

Simpósio Brasileiro De Sensoriamento Remoto, 17., João Pessoa, PB. **Anais...** São José dos Campos: INPE, p. 4151-4158, 2015.

COUTINHO, A. C.; ALMEIDA, C.; VENTURIERI, A.; ESQUERDO, J. C. D. M.; SILVA, M. **Uso e cobertura da terra nas áreas desflorestadas da Amazônia Legal: TerraClass 2008**. Brasília: Embrapa; Belém: INPE, 108 p., 2013.

COUTO JUNIOR, A. F.; MENESES, P. R.; SANO, E. E. Uso de Radar de Abertura Sintética e Índices de Vegetação para Discriminação de Alvos no Bioma Cerrado. In: Simpósio Brasileiro De Sensoriamento Remoto, Curitiba/PR. **Anais...** São José dos Campos: INPE, p. 8075-8082, 2011.

DINIZ, C. G.; SOUZA, A. A. A.; SANTOS, D. C.; DIAS, M. C.; LUZ, N. C.; MORAES, D. R. F; MAIA< J. S.; GOMES, A. R.; NARVAES, I. S.; VALERIANO, D. M; MAURANO, L. E. P; ADAMI, M. DETER-B: the new Amazon near real-time deforestation detection system. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 8, n. 7, p. 3619-3628, 2015.

EVANS, A. N. A gamma filter for multi-look synthetic aperture radar images. **International Symposium on Signal Processing and its Applications - ISSPA**, Gold Coast/Australia, ago. 1996.

EVANS, T. L.; COSTA, M. Landcover classification of the Lower Nhecolândia subregion of the Brazilian Pantanal Wetlands using ALOS/PALSAR, RADARSAT-2 and ENVISAT/ASAR imagery. **Remote Sensing of Environment**, v. 128, p. 118–137, 2013.

FAO. Food and Agriculture Organization of the United Nations. **Global forest resources assessment 2015: How are the world's forests changing?. 2^a** ed. Roma: FAO, 54 p., 2016.

FERREIRA, L. V.; VENTICINQUE, E.; ALMEIDA, S. O desmatamento na Amazônia e a importância das áreas protegidas. *Estudos avançados*, São Paulo, v. 19, n. 53, p. 157-166, abr. 2005.

FREITAS, R. M.; ADAMI, M.; SUGAWARA, M.; SHIMABUKURO, Y. E.; MOREIRA, M. A. Dinâmica da resposta espectral de duas sub-regiões do Pantanal Sul-Matogrossense. In: *Simpósio Brasileiro De Sensoriamento Remoto*, 13., Florianópolis, SC. **Anais...** São José dos Campos: INPE, p. 3921-3928, 2007.

GARCIA, M.; SAATCHI, S.; USTIN, S.; BALZTER, H. DETER-B: Modelling forest canopy height by integrating airborne LiDAR samples with satellite radar and multispectral imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 66, n. 8, p.159-163, 2018.

GEOMATICA. **SAR processing with Geomatica. PCI Geomatics**. Ontario/Canadá, 200 p., 2014.

GIROLAMO NETO, C. **Identificação de fitofisionomias de Cerrado no Parque Nacional de Brasília utilizando Random Forest aplicado a imagens de alta e média resoluções espaciais**. Tese (Doutorado em Sensoriamento Remoto), São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2018.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Manual técnico da vegetação brasileira**: Sistema fitogeográfico, Inventário das formações florestais e campestres, Técnicas e manejo de coleções botânicas, Procedimentos para mapeamentos. Rio de Janeiro: IBGE, n. 1, 271 p., 2012.

IBGE, Instituto Brasileiro de Geografia e Estatística. **Indicadores de desenvolvimento sustentável: Brasil 2015**. Rio de Janeiro: IBGE, p. 348, 2015.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Conheça as cidades e estados do Brasil 2016**. Disponível em: <<https://cidades.ibge.gov.br/>>.

Acessado em: 15 set. 2018a.

IBGE, **Projeto RADAMBRASIL.** Disponível em:
<<https://mapas.ibge.gov.br/bases-e-referenciais/bases-cartograficas/cartas>>.

Acesso em: 20 set. 2018b.

INPE. Instituto Nacional de Pesquisas Espaciais. **Monitoramento da cobertura florestal da Amazônia por satélites: Sistemas PRODES, DETER, DEGRAD E Queimadas 2007-2008.** São José dos Campos/SP. P. 47, 2008a.

INPE. Instituto Nacional de Pesquisas Espaciais. **Monitoramento da cobertura florestal da Amazônia por satélites.** São José dos Campos/SP. 143 p. 2008b.

INPE. Instituto Nacional de Pesquisas Espaciais. **Sistema de detecção do desmatamento em tempo real na Amazônia – DETER: aspectos gerais, metodológicos e plano de desenvolvimento.** São José dos Campos/SP, 16 p., 2008c.

INPE. Instituto Nacional de Pesquisas Espaciais. **Avaliação dos dados de desmatamento do município de Paragominas/PA: DETER – Detecção do Desmatamento em Tempo Real.** São José dos Campos/SP, 14 p., 2009.

INPE. 2010. **Inpe e serviço florestal firmam parceria para monitorar concessões.** Disponível em: <http://www.inpe.br/noticias/noticia.php?cod_noticia=2250>. Acesso em: 22 ago. 2018.

INPE. Instituto Nacional de Pesquisas Espaciais. **Metodologia para o cálculo da taxa anual de desmatamento na Amazônia Legal.** Programa Amazônia – Projeto PRODES. São José dos Campos/SP, 37 p., 2013.

INPE. 2018a. **Taxas anuais de desmatamento na Amazônia Legal Brasileira (AMZ).** Disponível em: <<http://www.obt.inpe.br/prodes/dashboard/prodes-rates.html>>. Acesso em: 11 set. 2018.

INPE. 2018b. **Projeto: DETER-B.** Disponível em: <<http://terrabilis.info/composer/deter-b>>. Acesso em: 11 set. 2018.

INPE. 2018c. **Deter-B**. Disponível em: <http://www.inpe.br/cra/projetos_pesquisas/deterb.php>. Acesso em: 22 ago. 2018.

INPE. 2018d. **Queimadas**. Disponível em: <<http://www.inpe.br/queimadas/portal/informacoes/perguntas-frequentes>>. Acesso em: 22 ago. 2018.

JAXA. **Advanced Land Observing Satellite-2 (ALOS-2) DAICHI-2: The Earth needs a health check**. Japan Aerospace Exploration Agency. Japão. 11 p. Abr. 2014.

JAXA. **ALOS-2: The Advanced Land Observing Satellite-2 "DAICHI-2"**. Jaxa website, p. 2–3, 2016.

JAXA. 2018a. **Alos-2 project / palsar-2**. Disponível em: <<https://www.eorc.jaxa.jp/alos-2/en/about/palsar2.htm>>. Acesso em: 31 ago. 2018.

JAXA. 2018b. **Alos-2 solution book: Proposals for "DAICHI 2" SAR Data Utilization**. 3ª ed., 44 p., 2018.

JAXA. 2018c. **ALOS-2/PALSAR-2 Calibration and Validation Results**. Disponível em: <https://www.eorc.jaxa.jp/alos-2/en/calval/palsar2_calval_results_jaxa_201808.pdf>. Acesso em: 11 out. 2018.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres**. São José dos Campos: Parentese, 585 p., 2009.

JICA - Japan International Cooperation Agency. (2015) **JICA and JAXA Announce Forest Monitoring System Using ALOS-2 Satellite: Constant monitoring of deforestation throughout the tropics and open data access on the Internet**. Disponível em: <https://www.jica.go.jp/english/news/press/2015/151215_01.html>. Acesso em: 11 out. 2018.

JICA/JAXA. (2017). **JICA-JAXA Forest Early Warning System in the Tropics**. Disponível em: <https://www.eorc.jaxa.jp/jjfast/docs/JJ-FAST_EN.pdf>. Acesso em: 11 out. 2018.

KASISCHKE, E. S.; BOURGEOU-CHAVEZ, L. L. Monitoring South Florida wetlands using ERS-1 SAR imagery. **Photogrammetric Engineering & Remote Sensing**, v. 63, n. 3, p.281-291, 1997.

KOPPEN, W. Das geographische System der Klimate. – KOPPEN, W.; R. GEIGER (Eds.): Handbuch der Klimatologie. – Gebruder Borntrager, Berlin, v. 1, p. 1–44, part C, 1936.

KUPLICH, T. M. Estudos florestais com imagens de radar. **Espaço & Geografia**, v. 16, n. 1, p. 65-90, 2003.

LANDIS, J.; KOCH, G. G. The measurements of agreement for categorical data. **Biometrics**, v. 33, n. 3, p. 159-179, 1977.

LEWIS, A. J.; HENDERSON, F. M. Radar fundamentals: the geosciences perspective. In: HENDERSON, F. M.; LEWIS, A. J. (Eds.), **Principles and Applications of Imaging Radar**. Manual of Remote Sensing. Nova Iorque: John Wiley & Sons, 3ª ed., v. 2, Cap. 3, p. 131-181, 1998.

LI, G., LU, D., MORAN, E., DUTRA, L., BATISTELLA, M. A comparative analysis of ALOS PALSAR L-band and RADARSAT-2 C-band data for land-cover classification in a tropical moist region. **Journal of Photogrammetry and Remote Sensing**, v. 70, 26–38, 2012.

LIAO, C., WANG, J., SHANG, J., HUANG, X., LIU, J., & HUFFMAN, T. Sensitivity study of Radarsat-2 polarimetric SAR to crop height and fractional vegetation cover of corn and wheat. **International Journal of Remote Sensing**, v. 39, n. 5, p. 1475–1490, 2017.

LOPES, A.; TOUZI, R.; NEZRY, E. Adaptive speckle filters and scene heterogeneity. **IEEE Transactions on Geoscience and Remote Sensing**, v. 28, n. 6, p. 992–1000, 1990.

LORENA, A. C.; CARVALHO, A. C. P. L. F. Uma Introdução às Support Vector Machines. **Revista de Informática Teórica e Aplicada**. v. 14, n. 2, p. 43 - 67, 2007.

MAPBIOMAS, 2018a. **O que é o MapBiomias**. Disponível em: <<http://mapbiomas.org/pages/about/about>>. Acesso em: 11 out. 2018.

MAPBIOMAS. **MapBiomias General “Handbook” - Algorithm Theoretical Basis Document (ATBD) - Collection 3**. Disponível em: <https://storage.googleapis.com/mapbiomas/base-de-dados/metodologia/colecao-3_0/1-ATBD-Collection-3-version-1.pdf>. Acesso em: 11 out. 2018b.

MASCARO, J.; ASNER, G. P.; KNAPP, D. E.; KENNEDY-BOWDOIN, T.; MARTIN, R. E., ANDERSON, C.; HIGGINS, M.; CHADWICK, K. D. **A tale of two “forests”: Random forest machine learning aids tropical forest carbon mapping**. Stanford: Universidade de Stanford, 2014.

MEDEIROS, I. P.; CASTRO FILHO, C. A. P.; ERTHAL, G. J.; DUTRA, L. V. Classificação de imagens pelo método de árvore de decisão oblíqua. In: Simpósio Brasileiro De Sensoriamento Remoto, 15., Curitiba, PR. **Anais...** São José dos Campos: INPE, p. 4255 - 4262, 2011.

MENESES, P. R. Princípios do Sensoriamento Remoto In: MENESES, P. R.; ALMEIDA, T. (Org.). **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. Brasília: UnB, Cap. 1, p. 1-31, 2012.

MENESES, P. R.; SANO, E. E. Sensor Radar de Abertura Sintética. In: MENESES, P. R.; ALMEIDA, T. (Org.). **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. Brasília: UnB, Cap. 4, p. 57-76, 2012.

MATOS, F. L. L. C. C.; FREITAS, D. M. Monitoramento ambiental da Amazônia Legal e aplicabilidade dos dados nas ações de fiscalização do IBAMA. **Anais...** Curitiba/PR: INPE, p. 2841 - 2848, 2011.

MITCHARD, E. T. A.; SAATCHI, S. S.; WOODHOUSE, I. H.; NANGENDO, G.; RIBEIRO, N. S.; WILLIAMS, M.; RYAN, C. M.; LEWIS, S. L.; FELDPAUSCH, T. R.; MEIR, P. Using satellite radar backscatter to predict above-ground woody biomass: A consistent relationship across four different African landscapes. **Geophysical Research Letters**, v. 36, n. 23, 2009.

MITCHARD, E. T. A.; SAATCHI, S. S.; WHITE, L. J. T.; ABERNETHY, K. A.; JEFFERY, K. J.; LEWIS, S. L.; COLLINS, M.; LEFSKY, M. A.; LEAL, M. E.; WOODHOUSE, I. H.; MEIR, P. Mapping tropical forest biomass with radar and spaceborne LiDAR in Iopé National Park, Gabon: Overcoming problems of high biomass and persistent cloud. **Biogeosciences**, v. 9, p. 179–191, 2012.

MMA. Ministério do Meio Ambiente. **Estratégia do Programa Nacional de Monitoramento Ambiental dos Biomas Brasileiros**. 2ª ed., rev. atualizada. Brasília: MMA. 51 p., 2017.

MORAN, M. S.; HYMER, D. C.; QI, J.; KERR, Y. Comparison of ERS-2 and Landsat TM imagery for monitoring agricultural crop and soil condition. **Remote Sensing of Environment**. v. 79, p. 243-252, 2002.

MOREIRA, A. A.; FERNANDES, F. H. S.; ALMEIDA, R. P.; NERY, C. V. M. O algoritmo Support Vector Machine aplicado ao mapeamento do uso e ocupação do solo. **Revista Brasileira de Geografia Física**, v. 7, n. 2, p. 291-303, 2014.

MOTOHKA, T., SHIMADA, M., URYU, Y., SETIABUDI, B. Using time series PALSAR gamma nought mosaics for automatic detection of tropical deforestation: a test study in Riau, Indonesia. **Remote Sensing of Environment**, v. 155, p. 79–88, 2014.

USGS. National Aeronautics and Space Administration. **Landsat**. Disponível em: <https://www.nasa.gov/mission_pages/landsat/main/index.html>. Acesso em: 06 nov. 2018.

OLIVEIRA, A. M. O.; LIMA, S. P. S.; PEREIRA, L. S.; RANGEL, M. C.; FASSARELA, R.A. Digitalização e disponibilização dos filmes originais dos Projetos RADAM/RADAMBRASIL - Exemplos para aplicação. In: Simpósio Brasileiro De Sensoriamento Remoto, 15., Curitiba, PR. **Anais...** São José dos Campos: INPE, p. 8303 - 8309, 2011.

PAVANELLI, J. A. P.; SANTOS, J. R.; GALVÃO, L. S.; XAUD, M.; XAUD, H. A. M. PALSAR-2/ALOS-2 and OLI/Landsat-8 data integration for land use and land cover mapping in northern Brazilian Amazon. **Boletim de Ciências. Geodésicas**, Curitiba/PR, v. 24, n. 2, p. 250-269, 2018.

PARADELLA, W. R.; OLIVEIRA, C. G.; CECARELLI, C. F.; COTTINI, C. P.; OKIDA, R. Operational use of RADARSAT-1 Fine Stereoscapy integrated with Landsat-5 Thematic Mapper data for cartographic application in the Brazilian Amazon. **Canadian Journal of Remote Sensing**. v. 31, n. 2, p.139-148, 2005.

PRADO, B. R. **Análise dos dados ALOS/PALSAR (modo de imageamento FBD) para identificação dos tipos de cobertura da terra na região norte do estado do Mato Grosso**. Dissertação (Mestrado em Geografia), São José dos Campos: INPE, p. 173, 2009.

PRADO, B. R.; MARTINS, V. A.; HAYAKAWA, E. H.; TAVARES JUNIOR, J. B.; SHIMABUKURO, Y. E. Identificação de classes de cobertura da terra na Amazônia utilizando imagens ALOS/PALSAR e classificação orientada a objeto. **Revista Brasileira de Cartografia**. n° 62/3. Out. 2010.

RAHMAN, M. M.; SUMANTYO, J. T. S. Mapping tropical forest cover and deforestation using synthetic aperture radar (SAR) images. **Applied Geomatics**, v. 2, n. 3, p.113-121, 2010.

RODRIGUES, M.; SILVA, D. C. C.; AZEVEDO JUNIOR, W. C. Redução do desmatamento na Amazônia: o papel dos mecanismos institucionais. **Revista de Administração e Negócios da Amazônia**, v. 10, n. 1, p.108-123, 2018.

ROSSATTO, D. R.; HOFFMANN, W. A.; FRANCO, A. C. Características estomáticas de pares congêneros de cerrado e mata de galeria crescendo numa região transicional no Brasil Central. **Acta Botanica Brasilica**, v. 23, n. 2, p. 499-508, 2009.

ROSENQVIST, A.; SHIMADA, M.; LUCAS, R.; CHAPMAN, B.; PAILLOU, P.; HESS, L.; LOWRI, J. The Kyoto & Carbon Initiative — A brief summary. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 3, n. 4, p. 551-553, 2010.

ROZA, W. S. S.; RIBEIRO, S. R. A. Integração de dados orbitais de sensoriamento remoto para estimar áreas da Floresta Ombrófila Densa do estado do Paraná. In: Simpósio Brasileiro De Sensoriamento Remoto, 16., Foz do Iguaçu, PR. **Anais...** São José dos Campos: INPE, p. 2250 – 2257, 2013.

RUFINO, H. L. P.; VEIGA, A. C. P.; NAKAMOTO, P. T. Smote_easy: um algoritmo para tratar o problema de classificação em bases de dados reais. **Journal of Information Systems and Technology Management**, v. 13, n. 1. p. 61-80, 2016.

SANO, E. E.; SANTOS, L. M.; MENESES, P. R. Análise de imagens do satélite ALOS PALSAR para o mapeamento de uso e cobertura da terra do Distrito Federal. **Geociências**. UNESP/São Paulo, v. 28, n. 4, p. 441-451, 2009.

SANTANA, D. P.; SANS, L. M. A. **Classes de solo e irrigação**. Uso e Manejo de Irrigação. Brasília: Embrapa Informação Tecnológica. p. 528, 2007.

SATVEG. 2018. **Sistema de análise temporal da vegetação**. Disponível em: <<https://www.satveg.cnptia.embrapa.br/satveg/pages/home.html>>. Acesso em: 06 nov. 2018.

SERVELLO, E. L. **Dados polarimétricos do Radarsat-2 (banda C) na discriminação de uso e cobertura da terra na região da Floresta Nacional de Tapajós.** Dissertação (Mestrado em Sensoriamento Remoto), São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2010.

SHIMADA, M.; KANKAKU, Y.; WATANABE, M.; MOTOOKA, T. **Current status of the ALOS-2/PALSAR-2 and the CALVAL Program.** Tsukuba: Japan Aerospace Exploration Agency, 40 p., 2011.

SHIMADA, M.; MIURA, M.; ENDO, T. **JICA-JAXA Forest Early Warning System in the Tropics (JJ-FAST).** Ho chi Minh City/Vietnã. Abr. 2017.

SOTHE, C.; LIESENBERG, V.; ALMEIDA, C. M. Abordagens para classificação do estágio sucessionais da vegetação do Parque Nacional de São Joaquim empregando imagens Landsat-8 e Rapideye. **Bulletin of Geodetic Sciences**, v. 23, nº3, p.389 -404, 2017.

SOUZA FILHO, P. W. M; PARADELLA, W. R.; SOUZA JÚNIOR, C.; VALERIANO, D. M.; MIRANDA, F. P. Sensoriamento remoto e recursos naturais da Amazônia. **Ciência e Cultura**, São Paulo, v. 58, n. 3, p. 37-41, set. 2006

TADONO, T.; ISHIDA, H.; ODA, F.; NAITO, S.; MINAKAWA, K.; IWAMOTO, H. Precise global DEM generation by ALOS PRISM. **ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 4, p.71-76, 2014.

TEIXEIRA, S. G. **Radar de abertura sintética aplicado ao mapeamento e reconhecimento de zonas úmidas costeiras.** 2011. 127 f. Tese (Doutorado em Geologia), Belém: Universidade Federal do Pará, 2011.

TONIOL, A. C. **Uso de diferentes classificadores e de simulação estocástica para discriminação de fitofisionomias do Cerrado usando atributos hiperespectrais do sensor Hyperion/EO-1.** 2017. 139 f. Dissertação (Mestrado

em Sensoriamento Remoto), São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2017.

ULABY, F. T.; ALLEN, C. T.; EGER, G.; KANEMASU, E. Relating the microwave backscattering coefficient to leaf area index. **Remote Sensing Environment**, v. 14, n. 1-3, p. 113 – 133, jan. 1984.

VAN LIEROP, P.; LINDQUIST, E.; SATHYAPALA, S.; FRANCESCHINI, G. Global forest area disturbance from fire, insect pests, diseases and severe weather events. **Forest Ecology and Management**, v. 352, p.78-88, 2015.

VAPNIK, V. **The Nature of Statistical Learning Theory**. New York: Springer-Verlag, 1995.

VILANI, M. T.; SANCHES, L.; NOGUEIRA, J. S.; PRIANTE FILHO, N. Sazonalidade da radiação, temperatura e umidade em uma floresta de transição Amazônia Cerrado. **Revista Brasileira de Meteorologia**, v. 21, n. 3b, p. 119-131, 2006.

YAMAGUCHI, Y.; MORIYAMA, T.; ISHIDO, M.; YAMADA, H. Four-component scattering model for polarimetric SAR image decomposition. **IEEE Transactions on Geoscience Remote Sensing**, v. 43, n. 8, p. 1699–1706, 2005.