



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21b/2018/01.23.15.57-TDI

**MUDANÇA DE USO E COBERTURA DA TERRA A
PARTIR DOS DADOS POLARIMÉTRICOS
ALOS/PALSAR-2 EM UMA PORÇÃO DA FLORESTA
NACIONAL DO TAPAJÓS E ÁREAS ADJACENTES**

Natalia Cristina Wiederkehr

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Fábio Furlan Gama, e
José Claudio Mura, aprovada em
16 de fevereiro de 2018.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3QE2MAL>>

INPE
São José dos Campos
2018

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GBDIR)

Serviço de Informação e Documentação (SESID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

E-mail: pubtc@inpe.br

**COMISSÃO DO CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO
DA PRODUÇÃO INTELECTUAL DO INPE (DE/DIR-544):****Presidente:**

Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação (CPG)

Membros:

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

Dr. André de Castro Milone - Coordenação-Geral de Ciências Espaciais e Atmosféricas (CGCEA)

Dra. Carina de Barros Melo - Coordenação de Laboratórios Associados (COCTE)

Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia e Tecnologia Espacial (CGETE)

Dr. Hermann Johann Heinrich Kux - Coordenação-Geral de Observação da Terra (CGOBT)

Dr. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos Climáticos (CGCPT)

Silvia Castro Marcelino - Serviço de Informação e Documentação (SESID)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon

Clayton Martins Pereira - Serviço de Informação e Documentação (SESID)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Duca Barbedo - Serviço de Informação e Documentação (SESID)

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

EDITORAÇÃO ELETRÔNICA:

Marcelo de Castro Pazos - Serviço de Informação e Documentação (SESID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SESID)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21b/2018/01.23.15.57-TDI

**MUDANÇA DE USO E COBERTURA DA TERRA A
PARTIR DOS DADOS POLARIMÉTRICOS
ALOS/PALSAR-2 EM UMA PORÇÃO DA FLORESTA
NACIONAL DO TAPAJÓS E ÁREAS ADJACENTES**

Natalia Cristina Wiederkehr

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Fábio Furlan Gama, e
José Claudio Mura, aprovada em
16 de fevereiro de 2018.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3QE2MAL>>

INPE
São José dos Campos
2018

Dados Internacionais de Catalogação na Publicação (CIP)

Wiederkehr, Natalia Cristina.

W633m Mudança de uso e cobertura da terra a partir dos dados polarimétricos ALOS/PALSAR-2 em uma porção da Floresta Nacional do Tapajós e áreas adjacentes / Natalia Cristina Wiederkehr. – São José dos Campos : INPE, 2018.

xxvi + 146 p. ; (sid.inpe.br/mtc-m21b/2018/01.23.15.57-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018.

Orientadores : Drs. Fábio Gurlan Gama, e José Claudio Mura.

1. Mudança do uso e cobertura da terra. 2. Floresta Nacional do Tapajós. 3. Sensoriamento remoto. 4. Dados SAR. 5. Polarimetria. I.Título.

CDU 528.8:332.3



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

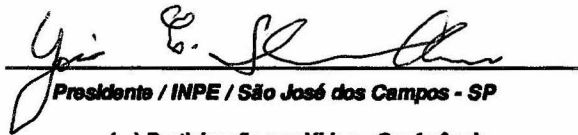
This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): **Natalia Cristina Wiederkehr**

Título: "MUDANÇA DE USO E COBERTURA DA TERRA A PARTIR DOS DADOS POLARIMÉTRICOS ALOS/PALSAR-2 EM UMA PORÇÃO DA FLORESTA NACIONAL DO TAPAJÓS E ÁREAS ADJACENTES"

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

Dr. Yosio Edemir Shimabukuro



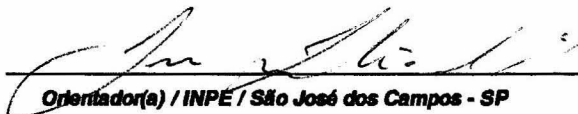
Presidente / INPE / São José dos Campos - SP
() Participação por Vídeo - Conferência

Dr. Fábio Furlan Gama



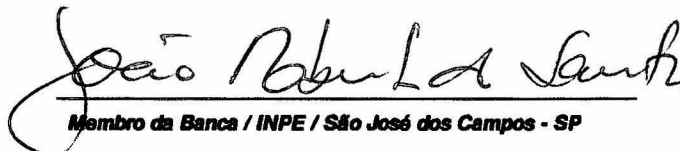
Orientador(a) / INPE / São José dos Campos - SP
() Participação por Vídeo - Conferência

Dr. José Claudio Mura



Orientador(a) / INPE / São José dos Campos - SP
() Participação por Vídeo - Conferência

Dr. João Roberto dos Santos




Membro da Banca / INPE / São José dos Campos - SP
() Participação por Vídeo - Conferência

Dr. Edson Eyji Sano



Convidado(a) / EMBRAPA Cerrados / Brasília - DF
() Participação por Vídeo - Conferência

Dra. Polyanna da Conceição Bispo



Convidado(a) / Univ. of Leicester / United Kingdom - UK
 Participação por Vídeo - Conferência

Este trabalho foi aprovado por:

() maioria simples

unanimidade

São José dos Campos, 16 de fevereiro de 2018.

“Você tem que estar preparado para se queimar em sua própria chama: como se renovar sem primeiro se tornar cinzas?”

Friedrich Nietzsche

A meus pais, Ana Bernadete e Valdemar

A minha tia Maria

AGRADECIMENTOS

Aos meus orientadores Doutores Fabio Furlan Gama e José Cláudio Mura, por todos os ensinamentos compartilhados, paciência, dedicação para comigo durante o mestrado. Agradeço ainda pela confiança depositada em mim, pela convivência e incentivo em continuar minha caminhada na área da pesquisa.

Ao Doutor João Roberto dos Santos por toda ajuda durante os dois anos de mestrado, por todo conhecimento partilhado comigo, paciência, apoio e incentivo. Com certeza esta nova caminhada na área da pesquisa se tornou mais enriquecedora!

Ao Instituto Nacional de Pesquisas Espaciais (INPE), em especial ao Programa de Pós-Graduação em Sensoriamento Remoto, pela oportunidade de estudo e apoio financeiro para o trabalho de campo. Aos pesquisadores e servidores pelo auxílio durante toda a realização do curso.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de pesquisa de pós-graduação.

Ao ICMBio, por autorizar a execução do trabalho científico nas áreas da Floresta Nacional do Tapajós e à equipe da base do Programa de Larga Escala da Biosfera-Atmosfera na Amazônia – LBA/Santarém pelo suporte necessário para a realização das atividades de campo, em especial ao Louro e Adão e ao querido Peu, por todo o seu conhecimento e disposição durante a realização do trabalho de campo.

Aos Doutores Yosio Shimabukuro, Sidnei Sant'Anna e Lenio Galvão, por todo conhecimento compartilhado, pelos esclarecimentos de minhas dúvidas e pela paciência em me ajudar no desenvolvimento da pesquisa.

À Doutora Polyanna da Conceição Bispo, pela concessão das imagens, apoio financeiro para o trabalho de campo, paciência e amorosidade para comigo nos momentos de ansiedade e aflição durante a realização das atividades de campo e no processamento dos dados desta dissertação.

Aos Doutores Edson Sano e Veraldo Liesenberg, pela concessão das imagens, possibilitando a realização desta pesquisa.

Agradeço a minha família, em especial a meus pais Ana Bernadete e Valdemar, a minha tia Maria e as minhas irmãs Larissa, Ana Paula e Aline. O apoio e o carinho de vocês durante essa caminhada foram essenciais!

Ao meu querido Be, pelo apoio, incentivo, confiança, paciência, amorosidade e companheirismo. Parte desta caminhada se tornou muito mais feliz e leve ao ser compartilhada com você!

Às minhas amigas de infância Isis e Franciele Hodecker, por me acompanharem nesta caminhada, pela amizade e carinho. À minha amiga Luma, por me amparar em muitos momentos difíceis. A meus pais de Florianópolis, Paulino e Vera, obrigada por nunca desistirem de mim, por muitas vezes acreditarem mais em mim do que eu mesma.

Agradeço as minhas amigas Paula e Priscila pelo companheirismo destes dois anos intensos vividos no INPE e também no nosso lar. Obrigada pela nossa amizade, pelos momentos de paciência, compreensão, tolerância e incentivo.

Agradeço ainda, aos amigos de curso pelas inúmeras contribuições, apoio e carinho, em especial ao Bruno Montibeller, Alindomar, Bruno de Oliveira, Maurano, Anderson Jorge, Anderson Reis, Hilton, Thales, Erone e Guilherme Gregório. Às minhas amigas Cris, Sandra e Ercília e todos os demais colegas de curso. Sem dúvida meus dias foram mais felizes com a presença de vocês!

RESUMO

A Floresta Amazônica apresenta uma grande biodiversidade, sendo considerada uma das maiores e mais importantes florestas tropicais do mundo. Entretanto, está sendo submetida a diversas pressões que impactam a dinâmica climática, hidrológica e os ciclos biogeoquímicos. Tais forças, principalmente as antropogênicas, podem provocar modificações e até mesmo conversões completas da floresta em outras classes de uso e cobertura da terra. Devido às dimensões das áreas da floresta Amazônica, o uso do sensoriamento remoto em nível orbital torna-se uma ferramenta adequada para monitorar as mudanças de uso e cobertura da terra na região. Neste contexto, o presente estudo teve como objetivo avaliar a capacidade das imagens polarimétricas do satélite ALOS/PALSAR-2 para a estratificação temática de mudanças de uso e cobertura da terra em uma porção da Floresta Nacional do Tapajós e áreas adjacentes entre os anos de 2015 e 2016. Os atributos polarimétricos extraídos a partir do retroespalhamento (Razão de Polarização Cruzada, Razão de Polarização Paralela e o *Radar Forest Degradation Index*) e de informação de fase (teoremas de decomposição de alvos de Cloude-Pottier, Freeman-Durden e Yamaguchi) resultaram em seis grupos de atributos. Um sétimo grupo de atributos, denominado de subconjunto ótimo, foi formado a partir de procedimentos de seleção de atributos. Dados coletados em trabalho de campo foram utilizados como conjunto amostral de referência para o treinamento do classificador e validação dos resultados. Os grupos foram classificados pelo algoritmo MAXVER-ICM, e os resultados classificatórios apontaram que os grupos formados a partir da decomposição de Cloude-Pottier e do subconjunto ótimo (H , A , α e P_v) apresentaram os melhores valores de $Kappa$ com 0,78 e 0,75 respectivamente, para o ano de 2015 e 0,75 e 0,74 respectivamente, para 2016. A partir dos subconjuntos ótimos de 2015 e 2016, foram elaborados os mapas temáticos e realizada a técnica de subtração de mapas a partir do resultado classificatório de 2015 pelo resultado de 2016. Como resultado da validação das detecções, obteve-se valor $Kappa$ de 0,60. Os resultados classificatórios das decomposições de Cloude-Pottier, Freeman-Durden e Yamaguchi apresentaram desempenho superiores, quando comparados aos resultados classificatórios pelos grupos de coeficientes de retroespalhamento, indicando a potencialidade destes teoremas de decomposição de alvos para estudos de uso e cobertura da terra na área sob investigação. No que concernem às mudanças que ocorreram no período analisado (2015/2016), houve uma diminuição da cobertura florestal natural em relação às áreas em processo de produção. As maiores perdas das áreas florestais estão associadas principalmente com a degradação florestal a partir das queimadas que ocorreram na região. As áreas agrícolas, de silvicultura e de pastagens continuam a avançar, suprimindo principalmente as áreas de florestas.

Palavras-chave: Mudança do Uso e Cobertura da Terra. Floresta Nacional do Tapajós. Sensoriamento Remoto. Dados SAR. Polarimetria.

CHANGE IN LAND USE AND LAND COVER FROM ALOS/PALSAR-2 POLARIMETRIC DATA IN A PORTION OF TAPAJÓS NATIONAL FOREST AND ADJACENT AREAS

ABSTRACT

The Amazon rainforest presents a great biodiversity being considered one of the largest and most important tropical forests in the world. However, has been subjected to several pressures that impact climate dynamics and hydrological and biogeochemical cycles. Such forcing factors, especially anthropogenic ones, can cause modifications and even complete conversions of the forest in other land use and land cover classes. The orbital remote sensing data applied to the dimensions of the Amazonian forest becomes a suitable tool to monitor how land use and land cover changes. In this context, this work aimed to evaluate the ALOS/PALSAR-2 full polarimetric images for the thematic stratification of changes in land use and land cover in a portion of the Tapajós National Forest and adjacent areas between 2015 and 2016. Polarimetric attributes derived from radar backscatter (Cross-Polarized Ratio, Parallel-Polarized Ratio and Radar Forest Degradation Index) and phase information (Cloude-Pottier, Freeman-Durden and Yamaguchi target decomposition techniques) resulted in six groups of attributes. A seventh group of attributes, called the optimal subset, was formed from attribute selection procedures. Field data samples were used as a reference samples for training the Classification algorithm and for validation of the results. The seven groups were classified by the MAXVER-ICM algorithm, and the classification results showed that the groups formed by the Cloude-Pottier decomposition and the optimal subset (H , A , α e P_v) showed the highest Kappa values of 0.78 and 0.75, respectively, for the year 2015 and 0.75 and 0.74, respectively for the year 2016. From the optimum subsets 2015 and 2016, we elaborated the maps and performed the technique of subtraction of maps from the qualifying result of 2015 by the result of 2016. As a result of the validity of the detections, a Kappa value of 0.60 was obtained. The classification results for the groups of the Cloude-Pottier, Freeman-Durden and Yamaguchi decompositions showed superior performance, when compared to the classification results of the backscatter coefficients groups, indicating the potential of these techniques of targets decomposition for studies of land use and land cover in the research area. In relation to changes of occurrence in the analyzed period (2015/2016), there was a decrease of the forest cover in relation to the areas in process of production. The greatest losses of the forest areas were associated mainly with forest degradation from the fires that occurred in the region. Agricultural, forestry and pasture areas continue increasing, suppressing mainly the forest area

Keywords: Land Use and Land Cover Change. Tapajós National Forest. Remote Sensing. SAR data. Polarimetry.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1- Geometria SAR.....	7
Figura 2.2- Campo elétrico da onda eletromagnética.....	11
Figura 2.3 - Elipse de polarização em um plano xy para representar o campo elétrico.....	12
Figura 3.1 – Pontos coletados em campo que compõem o mosaico das imagens ALOS/PALSAR-2.....	25
Figura 3.2 – Localização da área de estudo com o mosaico das imagens 2016 do ALOS/PALSAR-2	26
Figura 3.3 - Chuva acumulada entre os dias 19 e 28/12/2014 na estação de Belterra.....	35
Figura 3.4 - Chuva acumulada entre os dias 10 e 19/04/2015 na estação de Belterra.....	36
Figura 3.5 - Chuva acumulada entre os dias 24/04 e 03/05/2015 na estação de Belterra.....	36
Figura 3.6 - Chuva acumulada entre os dias 08 e 17/04/2016 na estação de Belterra.....	37
Figura 3.7 - Chuva acumulada entre 23/04 e 01/05/2016 na estação de Belterra.....	37
Figura 3.8 - Etapas metodológicas adotadas.	39
Figura 3.9 - Procedimentos metodológicos adotados no pré-processamento..	40
Figura 4.1 – Análise visual da atenuação do efeito <i>Speckle</i>	53
Figura 4.2 – Análise visual da suavização de bordas.....	54
Figura 4.3 – Análise quantitativa da atenuação do efeito <i>Speckle</i>	54
Figura 4.4- Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas para o ano de 2015 no atributo <i>H</i> da decomposição de Cloude-Pottier.	55

Figura 4.5 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo α da decomposição de Cloude-Pottier.	56
Figura 4.6 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo A da decomposição de Cloude-Pottier.	57
Figura 4.7 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo P_v da decomposição de Freeman-Durden.	58
Figura 4.8 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo P_d da decomposição de Freeman-Durden.	59
Figura 4.9 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo P_s da decomposição de Freeman-Durden.	60
Figura 4.10 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo Y_d da decomposição de Yamaguchi.	61
Figura 4.11 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo Y_v da decomposição de Yamaguchi.	62
Figura 4.12- Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo Y_s da decomposição de Yamaguchi.	63
Figura 4.13 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo Y_H da decomposição de Yamaguchi.	64
Figura 4.14 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo RC.	65

Figura 4.15 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo RP.	66
Figura 4.16 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo RFDI.	67
Figura 4.17 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo <i>H</i> da decomposição de Cloude-Pottier.	68
Figura 4.18 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo α da decomposição de Cloude-Pottier.	68
Figura 4.19 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo <i>A</i> da decomposição de Cloude-Pottier.	69
Figura 4.20 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo P_v da decomposição de Freeman-Durden.	70
Figura 4.21 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo P_d da decomposição de Freeman-Durden.	71
Figura 4.22 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo P_s da decomposição de Freeman-Durden.	72
Figura 4.23 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo Y_v da decomposição de Yamaguchi.	73
Figura 4.24 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo Y_d da decomposição de Yamaguchi.	74

Figura 4.25 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo Y_s da decomposição de Yamaguchi.	75
Figura 4.26 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo Y_H da decomposição de Yamaguchi.	76
Figura 4.27 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo RC.	77
Figura 4.28 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo RP.	78
Figura 4.29 - Gráfico <i>boxplot</i> representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo RFDI.	79
Figura 4.30 - <i>Ranking</i> segundo a importância dos atributos em relação a todas as classes do ano 2015.	80
Figura 4.31 - <i>Ranking</i> segundo a importância dos atributos em relação a todas as classes do ano 2016.	81
Figura 4.32 – Espaço de atributos de acordo com a decomposição de Cloude-Pottier do ano de 2015 para as classes de uso e cobertura da terra.	85
Figura 4.33 – Espaço de atributos de acordo com o subconjunto ótimo do ano de 2015 para as classes de uso e cobertura da terra.	88
Figura 4.34 – Mapa de uso e cobertura da terra 2015 da área de estudo elaborada a partir da classificação do subconjunto ótimo.	90
Figura 4.35 – Espaço de atributos de acordo com a decomposição de Cloude-Pottier do ano de 2016 para as classes de uso e cobertura da terra.	92
Figura 4.36 – Espaço de atributos de acordo com o subconjunto ótimo do ano de 2016 para as classes de uso e cobertura da terra.	95

Figura 4.37 – Mapa de uso e cobertura da terra 2016 da área de estudo elaborada a partir da classificação do subconjunto ótimo.	97
Figura 4.38 – Mapa de referência de uso e cobertura da terra do ano 2016 utilizado na etapa de validação.	100
Figura 4.39 – Representação das classes temáticas em área (Km ²) e percentual (%).	103
Figura 4.40 – Mapa de diferença na detecção de mudanças de uso e cobertura da terra entre os anos de 2015 e 2016	107
Figura 5.1 – Áreas degradadas por incêndios.....	123
Figura A.4 – Cena 2102617130 de 17/04/2016.....	144
Figura A.5 – Cena 2104687120 de 01/05/2016.....	145
Figura A.6 – Cena 2104687130 de 01/05/2016.....	146

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 3.1 - Comparação entre as missões ALOS-1 e 2.	28
Tabela 3.2 - Principais características das imagens utilizadas do ALOS/PALSAR-2.	29
Tabela 3.3 - Discriminação das classes temáticas.	32
Tabela 3.4 - Atributos extraídos a partir de dados polarimétricos.	43
Tabela 3.5 – Número de pixels selecionados para treinamento e validação das classes temáticas.	45
Tabela 3.6 – Índice de concordância <i>Kappa</i>	48
Tabela 3.7 – Conjunto amostral selecionado para elaboração do mapa de referência.	51
Tabela 4.1 – Valores de <i>Kappa</i> obtidos a partir das classificações dos Subconjuntos Ótimos de 2015 e 2016.	82
Tabela 4.2 – Valores de <i>Kappa</i> obtidos a partir das classificações de 2015 e 2016.	83
Tabela 4.3 - Teste Z aplicado aos valores <i>Kappa</i> das classificações realizadas para os anos de 2015 e 2016.	84
Tabela 4.4 - Matriz de confusão da classificação da Decomposição de Cloude- Pottier do ano de 2015.	86
Tabela 4.5 - Matriz de confusão da classificação do subconjunto ótimo do ano de 2015.	87
Tabela 4.6 - Matriz de confusão da classificação da Decomposição de Cloude- Pottier do ano de 2016.	93
Tabela 4.7 - Matriz de confusão da classificação do subconjunto ótimo do ano de 2016.	94
Tabela 4.8 - Matriz de confusão da classificação do mapa de referência.	98
Tabela 4.9 - Matriz de confusão da classificação de detecção de mudança. .	102
Tabela 4.10 – Detecção de mudanças de uso e cobertura da terra entre os anos de 2015 e 2016.	106

Tabela 5.1 – Porcentagem de acertos das classes temáticas em seus respectivos conjuntos de atributos do ano de 2015.	115
Tabela 5.2 – Porcentagem de acertos das classes temáticas em seus respectivos conjuntos de atributos do ano de 2016.	118

LISTA DE SIGLAS E ABREVIATURAS

AC	Área Cultivada
ALOS	<i>Advanced Land Observing Satellite</i>
BOS	<i>Basic Observation Scenario</i>
CA	Corpo d'água
CV	Coeficiente de Variação
DEGRAD	Floresta Degradada
ENVI	<i>Excelis Visual Information Solutions</i>
FNT	Floresta Nacional do Tapajós
FP	Floresta Primária/Floresta Primária com extração de madeira
GPS	<i>Global Positioning System</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
ICM	<i>Iterated Conditional Modes</i>
INMET	Instituto Nacional de Meteorologia
INPE	Instituto Nacional de Pesquisas Espaciais
JAXA	<i>Japan Aerospace Exploration Agency</i>
LAF	Laboratório de Sensoriamento Remoto Aplicado à Agricultura e Floresta
MDE	Modelo Digital de Elevação
PALSAR	<i>Phase Array L-band Synthetic Aperture Radar</i>
PL	Pasto Limpo
PS	Pasto Sujo
RADAR	<i>Radio Detection and Ranging</i>
RFDI	<i>Radar Forest Degradation Index</i>
SAR	<i>Synthetic Aperture Radar</i>
SATVeg	Sistema de Análise Temporal da Vegetação
SLC	<i>Single Look Complex</i>
SNAP	<i>Sentinel Application Platform</i>
SP	Solo em Pousio/Solo Exposto Preparado
SRTM	<i>Shuttle RADAR Topographic Mission</i>

SSA	Sucessão Secundária Avançada
SSI	Sucessão Secundária Inicial
SSInt	Sucessão Secundária Intermediária
SVM	<i>Support Vector Machine</i>
USGS/NASA	<i>Earth Explorer – United States Geological Survey</i>
UTM	<i>Universal Transversa de Mercator</i>
WEKA	<i>Waikato Environment for Knowledge Analysis</i>
WGS	<i>World Geodetic System</i>

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO.....	1
1.1. Hipótese de trabalho.....	3
1.2. Objetivos.....	3
2 FUNDAMENTAÇÃO TEÓRICA	5
2.1. Princípios básicos de sensoriamento remoto SAR	5
2.2. Tipos de interação com os alvos.....	7
2.3. Fundamentos básicos da Polarimetria.....	9
2.4. Polarização de ondas eletromagnéticas	10
2.5. Espalhamento de ondas eletromagnéticas	13
2.6. Teoremas de decomposição de alvos	16
2.7. Atributos derivados do retroespalhamento	20
2.8. Classificação.....	21
2.9. Análise de mudanças.....	23
3 METODOLOGIA	25
3.1. Delimitação e caracterização da área de estudo	25
3.2. Base de dados	28
3.2.1 Dados do ALOS PALSAR-2.....	28
3.2.2. Dados de campo	30
3.2.3. Aferição temporal	33
3.2.4. Dados auxiliares.....	34
3.3. Processamento SAR.....	38
3.3.1. Pré-processamento das imagens ALOS/PALSAR	40
3.3.2. Seleção das amostras.....	44
3.3.3. Seleção e análise exploratória dos atributos	46
3.3.4. Classificação e validação dos resultados.....	47
3.3.5. Detecção de mudança e validação dos resultados	49
4 RESULTADOS.....	53
4.1. Definição do tamanho da janela de filtragem.....	53

4.2. Sensibilidade dos atributos polarimétricos para discriminar as classes de uso e cobertura da terra	55
4.3. Seleção do subconjunto ótimo	79
4.4. Classificações	83
4.5. Resultados da classificação do mapa de referência	98
4.6. Resultados da validação da detecção de mudança	101
4.7. Resultados de detecção de mudança	102
5 DISCUSSÃO DOS RESULTADOS	109
5.1. Decomposição de Cloude-Pottier frente às classes temáticas abordadas neste estudo para os anos de 2015 e 2016	109
5.2. Decomposições de Freeman-Durden e Yamaguchi frente às classes temáticas abordadas neste estudo para os anos de 2015 e 2016	110
5.3. Atributos extraídos a partir do coeficiente de retroespalhamento: RC, RP e RFDI frente às classes temáticas abordadas neste estudo para os anos de 2015 e 2016.....	112
5.4. Classificações a partir: das decomposições, dos subconjuntos ótimos e dos coeficientes de retroespalhamento para os anos de 2015 e 2016	114
5.5. Análise comparativa interanual dos resultados das classificações	119
5.6. Análise de detecção de mudança	122
6 CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES	127
REFERÊNCIAS BIBLIOGRÁFICAS	131
APÊNDICE A – VERIFICAÇÃO DO PADRÃO DA ANTENA.....	141

1 INTRODUÇÃO

O bioma Amazônia apresenta uma rica biodiversidade, que corresponde a uma área com mais de 4 milhões de km² do território brasileiro (LEMOS; SILVA 2011). Este bioma vem sofrendo um significativo nível de degradação de seus recursos naturais, decorrente da expansão das fronteiras agrícola e da pecuária, expansão da urbanização e do desenvolvimento de infraestruturas, bem como da exploração irracional de seus recursos madeireiros e minerais.

As estimativas de desflorestamento bruto da Amazônia brasileira indicaram um total de 7.893 km² de corte raso entre 2015 e 2016, apontando um aumento de 29% da taxa de desmatamento em relação ao período de 2015 (INPE, 2017). A derrubada da cobertura florestal tem provocado alterações parciais no ecossistema, como a perda do potencial edáfico e hídrico, a redução da biodiversidade florística e faunística, e significativo nível de fragmentação de habitats. As elevadas taxas brutas de desflorestamento praticadas nessas últimas décadas, derivadas de uma alta dinâmica de uso e cobertura da terra, têm contribuído para o aumento de gases do efeito estufa, propiciando alterações climáticas em nível regional e global (PIELKEP, 2003; FOLEY et al., 2005).

Dentre as unidades de conservação inseridas no bioma Amazônia, destaca-se a Floresta Nacional do Tapajós (FNT), localizada nas margens do rio Tapajós, no estado do Pará. A FNT apresenta, em seus domínios, os remanescentes de florestas ombrófilas densa e aberta, com algumas áreas sob regime de exploração sustentável, além de porções em estádios de sucessão secundária decorrentes de processos de degradação. Nas zonas limítrofes dessa Unidade de Conservação, encontram-se, a leste da rodovia BR-163, extensas áreas de agricultura mecanizada (com destaque para as culturas de soja, arroz e milho), pastagens plantadas e, em certos setores específicos, áreas destinadas à agricultura familiar, onde se destacam os plantios de mandioca, feijão e pimenta. Manchas de floresta degradada e de sucessão secundária complementam o mosaico paisagístico da região.

Produtos e metodologias de sensoriamento remoto, sobretudo em nível orbital, mostram ser ferramentas úteis para detectar, mapear e analisar as modificações na paisagem (LU et al., 2003). Isso tem permitido, nos procedimentos de fiscalização e monitoramento ambiental, uma análise mais detalhada de causas e efeitos, possibilitando também estudos de prognose quanto aos processos de degradação em diferentes parcelamentos da terra (GUERRA et al., 2010).

Sistemas sensores ópticos são comumente utilizados no mapeamento e monitoramento de uso e cobertura da terra, porém, a frequente cobertura de nuvens em regiões tropicais, como a Amazônica, muitas vezes dificulta a obtenção de informações baseadas nestes sensores (ASNER, 2001). Uma alternativa para esta limitação tem sido o emprego de sensores ativos de micro-ondas, denominados RADAR, que produzem sua própria fonte de radiação eletromagnética e são pouco influenciados pela presença de nuvens ou aerossóis (HENDERSON; LEWIS 1998). Além de permitir a obtenção de informações a respeito das características físicas e dielétricas dos alvos, quando ponderadas as características intrínsecas do sensor de radar e da periodicidade de imageamento.

Os dados *Synthetic Aperture Radar* (SAR) são sensíveis às variações da estrutura florestal (KASISCHKE et al., 1997; YANASSE et al., 1997; SANTOS et al., 2003), permitindo a compreensão de fenômenos de interação da energia emitida com os diferentes estratos constituintes da cobertura florestal em diferentes estádios de sucessão ecológica. Isso possibilita aprimorar o nível de caracterização temática da paisagem, viabilizando a discriminação de diferentes usos da terra (DUTRA et al., 2009; NEGRI, 2009; Li et al., 2012; PÔSSA, 2016).

Dentre os diversos radares imageadores hoje disponíveis, destaca-se o sensor *Phase Array L-band Synthetic Aperture Radar* (PALSAR) que opera na banda L (15 cm a 30 cm de comprimento de onda) a bordo do satélite ALOS-2 da JAXA. Esse sistema radar fornece medidas de interação do sinal com o interior do dossel e, dependendo da estrutura florestal, até mesmo com a superfície do terreno (JENSEN, 2009).

1.1. Hipótese de trabalho

A hipótese desta pesquisa é que as informações advindas do sensor PALSAR-2, utilizando técnicas polarimétricas de decomposição de alvos, razões de polarização e índice, permitem a discriminação temática para o monitoramento interanual das variações da paisagem, suportada pelas melhorias na resolução espacial e de frequência de observação desse sistema imageador.

1.2. Objetivos

O objetivo geral do trabalho é explorar a capacidade das imagens *full* polarimétricas do ALOS/PALSAR- 2 para a discriminação interanual de mudanças de uso e cobertura da terra, tendo como área de investigação uma porção da Floresta Nacional do Tapajós e áreas adjacentes. Os seguintes objetivos específicos foram definidos:

- Avaliar atributos polarimétricos baseados nos dados complexos do ALOS/PALSAR-2 através das técnicas de decomposição de alvos desenvolvidas por Cloude-Pottier, Yamaguchi e Freeman-Durden;
- Avaliar a sensibilidade dos coeficientes de retroespalhamento e do índice RFDI (*Radar Forest Degradation Index*) na discriminação de mudanças de uso e cobertura da terra;
- Avaliar o desempenho dos mapeamentos gerados a partir do uso dos atributos SAR, combinados ou não, tendo como referência dados observacionais georreferenciados coletados em campo;
- Avaliar as transformações que ocorreram no uso e cobertura da terra no período entre 2015 e 2016, com os atributos de melhor desempenho na discriminação temática interanual da área de estudo.

2 FUNDAMENTAÇÃO TEÓRICA

2.1. Princípios básicos de sensoriamento remoto SAR

Os SAR são sistemas ativos que normalmente operam com uma única antena, a qual transmite pulso de energia eletromagnética que ilumina e interage com o alvo, produzindo um retroespalhamento e cuja parte da energia refletida retorna ao sensor radar e é registrada (HENDERSON; LEWIS, 1998). Os radares operam no espectro eletromagnético na porção do micro-ondas que inclui os comprimentos de onda de 1 mm até 1 m, sendo as principais bandas utilizadas: X (2,4 – 3,75 cm), C (3,75 – 7,5 cm), L (15 – 30 cm) e P (30 – 100 cm) (JENSEN, 2009).

A orientação do vetor campo elétrico da onda eletromagnética emitida pelo radar pode ser horizontal (H) ou vertical (V), definindo a polarização da onda ao longo do plano de propagação (ULABY; ELACHI, 1990; RICHARDS, 2009). As quatro possíveis combinações de polarizações lineares emitidas e recebidas em uma mesma frequência do sinal são as polarizações co-polarizadas (HH e VV) e as polarizações cruzadas (HV e VH) (ULABY; ELACHI, 1990). Desta forma, os sistemas SAR podem gerar os seus dados em diferentes combinações de polarização, sendo considerados simples quando operam com uma única polarização: HH ou VV; ou podem apresentar polarizações múltiplas, como a polarização dupla (HH e HV, VV e VH ou HH e VV) ou quádrupla (HH, VV, HV e VH). Quanto maior o número de polarizações disponíveis no sistema de radar, maior a quantidade de informação disponível para a interpretação das propriedades e comportamentos dos alvos.

A interação entre a energia eletromagnética emitida pelo radar e os alvos na superfície terrestre são influenciadas tanto pelos parâmetros relacionados ao sistema radar, como o comprimento de onda (λ), polarização, a configuração do imageamento (ângulo de incidência (θ_i) e direção do espalhamento (θ_s)), como também, pelos parâmetros dos alvos imageados, como suas propriedades dielétricas e geométricas, relevo e ângulo de incidência local (θ_{loc}) (LEE; POTTIER, 2009).

A relação entre a transmissão dos pulsos e o recebimento dos ecos refletidos, devido à interação da energia eletromagnética com os alvos na superfície, conforme supracitado podem ser representados em uma imagem SAR na forma de uma matriz de pixels (RICHARDS, 2009). A matriz é formada por linhas e colunas, onde cada pixel está associado a uma pequena área da superfície imageada. Cada pixel é representado por um número complexo que contém informações sobre as componentes do sinal de amplitude e fase associado à refletividade de todos os dispersores contidos na célula de resolução do SAR (LEE; POTTIER, 2009).


Os dados de radar normalmente são representados em números complexos, onde, a componente do sinal em fase (*In Phase* – I) corresponde à parte real, e a parte imaginária é relacionada a componente de quadratura de fase (*Quadrature* – Q) (RANEY, 1998). Estes dados podem ser processados para obtenção de imagens em amplitude (A) e intensidade (I), conforme as Equações 2.1 e 2.2:

$$A = \sqrt{I^2 + Q^2} \quad (2.1)$$

$$I = I^2 + Q^2 \quad (2.2)$$

O sistema de imageamento SAR apresenta geometria de visada lateral com uma iluminação perpendicular à direção de linha de voo. A linha de voo é denominada de direção de azimute e o eixo ortogonal à direção de azimute é denominado de direção de alcance (*range*). A superfície imageada que se encontra mais próxima do sensor, ao longo da linha de visada é denominada de *near range* e a região mais distante iluminada pelo pulso de energia é denominada de *far range* (Figura 2.1) (LEE; POTTIER, 2009).

Figura 2.1- Geometria SAR.



Fonte: Adaptada de Lewis et al. (1998).

Devido à geometria de visada lateral, as imagens de radar podem apresentar distorções geométricas, efeitos típicos presentes são: o encurtamento de rampa (*foreshortening*), inversão de relevo (*layover*) e sombreamento (RICHARDS, 2009). As imagens também apresentam um aspecto granuloso denominado de *Speckle*, que ocorre em função da natureza coerente da radiação em micro-ondas, causando interferência aleatória construtiva e/ou destrutiva, que resulta em áreas aleatórias com tonalidades claras e escuras nas imagens (WOODHOUSE, 2006). O *Speckle* pode ser atenuado através da aplicação de filtros e/ou aplicação da técnica *Multilook* na etapa de pré-processamento da imagem.

2.2. Tipos de interação com os alvos

Para que seja possível interpretar imagens de radar é importante compreender como ocorre a interação entre os alvos presentes na superfície terrestre e os diferentes tipos de mecanismos de espalhamento da energia eletromagnética. O comprimento de onda e o ângulo de incidência influenciam diretamente no retroespalhamento de radar. Alguns parâmetros ambientais, como a geometria dos alvos (rugosidade superficial e a forma) inseridos na célula de resolução no terreno e as propriedades elétricas (constante dielétrica complexa) também são responsáveis pelo retroespalhamento da energia incidente (LEWIS; HENDERSON, 1998; JENSEN, 2009).

Os principais tipos de mecanismos de espalhamentos são: superficial, *double-bounce* e volumétrico. O espalhamento do tipo superficial é caracterizado pela dispersão da energia da superfície do alvo e depende da constante dielétrica e da rugosidade da superfície do mesmo (RICHARDS, 2009).

A rugosidade da superfície é a propriedade do terreno que influencia fortemente a intensidade do retroespalhamento de radar, podendo ser analisada em três níveis de escala: meso e/ou macro e microescala. Nos níveis de macro e mesoescala o retroespalhamento está relacionado com as mudanças decamétricas da declividade topográfica (ondulações do terreno) ou da altura do alvo, que englobam diversas células de resolução, e pode possibilitar, por exemplo, cobrir até o dossel de uma floresta. Em imagens SAR a rugosidade está associada ao atributo textural da imagem (LEWIS; HENDERSON, 1998; JENSEN, 2009).

A rugosidade superficial em microescala refere-se às variações de heterogeneidades topográficas na escala centimétrica (como por exemplo: tamanho de folhas ou galhos de árvores) presentes em uma célula individual de resolução. A quantidade de energia de micro-ondas retroespalhada para o sensor, é função do comprimento de onda da energia incidente (λ), ângulo de depressão (γ) e altura dos objetos (h). Nas imagens SAR estão associadas às áreas com tonalidades escuras da célula de resolução (LEWIS; HENDERSON, 1998; JENSEN, 2009).

O espalhamento superficial ocorre quando a energia é dispersa na superfície dos alvos. O espalhamento do tipo *double-bounce* está associado ao retroespalhamento da onda quando a mesma é rebatida em duas superfícies perpendiculares. Já o espalhamento volumétrico ocorre a partir das múltiplas reflexões da energia dentro de um meio homogêneo (LEWIS; HENDERSON, 1998; RICHARDS, 2009). No ambiente florestal, quando o espalhamento ocorre através dos galhos, ramos e troncos, para todo o conjunto estrutural de árvores, é então considerado como do tipo volumétrico (JENSEN, 2009).

No ambiente florestal, quanto maior o comprimento de onda em que opera o radar, maior a penetração no dossel, como nos casos das bandas L e P. Em menores comprimentos de onda, como por exemplo, a banda X, a radiação eletromagnética praticamente não penetra no dossel, fazendo simplesmente a interação com o topo foliar do alvo florestal. Já a energia no comprimento de onda da banda C é submetida ao espalhamento superficial na copa das árvores e, em parte, ao espalhamento volumétrico na estrutura desse dossel, sendo que, pouca energia chega até o solo.

Como mencionado anteriormente, os maiores comprimentos de onda, como por exemplo, as bandas L e P, possibilitam uma maior penetração na vegetação, sendo a reflexão ocasionada principalmente pelos galhos maiores e troncos. Dependendo da intensidade do pulso emitido, a reflexão pode ocorrer pela superfície do solo (VAN DER SANDEN, 1997; LEWIS; HENDERSON, 1998).

2.3. Fundamentos básicos da Polarimetria

Imagens SAR compostas somente pela amplitude do sinal (ou intensidade), podem fornecer informações a respeito da textura (rugosidade das superfícies) e do brilho (constante dielétrica - umidade) dos alvos. Neste caso, estas imagens SAR não registram os tipos de mecanismo de espalhamento contidos nas propriedades da polarização da onda eletromagnética, devido à grandeza vetorial da onda de retorno ter sido desprezada (VAN DER SANDEN, 1997).

Quanto maior o número de polarizações disponíveis num sistema SAR, maior a possibilidade de complementar a informação para a interpretação das propriedades e comportamento dos alvos. Quando um SAR produz dados de amplitude em diferentes polarizações, é considerado multipolarizado e o termo “polarimétrico” se dá quando estes mesmos sistemas fornecem dados com informação de amplitude e fase das ondas eletromagnéticas (WOODHOUSE, 2006).


As informações de amplitude e fase em diferentes polarizações permitem analisar os tipos de mecanismos de espalhamentos que ocorrem durante o processo de interação entre o alvo e a radiação eletromagnética. Essa análise possibilita inferir sobre as propriedades físicas da superfície terrestre. Os mecanismos de espalhamentos presentes em ambientes florestais são fortemente influenciados pela polarização, no qual caracterizam os diferentes tipos de espalhamentos provenientes diretamente da copa das árvores, dos troncos, solo, interação entre a copa e o solo e também da reflexão dupla no binômio “tronco-solo” (GLOBESAR-2, 2016).

2.4. Polarização de ondas eletromagnéticas

A radiação eletromagnética é constituída pela oscilação de um campo elétrico e um campo magnético, situados em planos ortogonais e com propagação na direção perpendicular a estes campos (WOODHOUSE, 2006). A orientação do vetor campo elétrico da onda eletromagnética pode ser horizontal ou vertical, definindo a polarização da onda ao longo do plano de propagação (ULABY; ELACHI, 1990; RICHARDS, 2009).

As componentes vertical e horizontal do campo elétrico permitem descrever os tipos de trajetória: linear, circular ou elíptica (Figura 2.2). Quando as componentes (vertical e horizontal) apresentarem a mesma amplitude e diferença do ângulo de orientação da polarização de 90° , a polarização é denominada circular. Caso as duas componentes apresentem ângulo de orientação com diferença igual à zero ou um múltiplo de 180° , a onda é considerada linearmente polarizada. Em casos que o vetor campo elétrico descreve uma elipse perpendicular na direção de propagação da onda, há uma polarização elíptica (ULABY; ELACHI, 1990; BOERNER et al., 1998).


Figura 2.2- Campo elétrico da onda eletromagnética.



(a) Onda eletromagnética na polarização vertical (V). (b) Onda eletromagnética na polarização horizontal (H). Ilustração do comprimento de onda (λ), amplitude (A), fase (Φ) variando de 0 a 2π e os campos elétricos horizontal (E_h) e vertical (E_v). Fonte: Adaptada de Van Der Sanden (1997).

A representação do estado de polarização de um campo elétrico pode ser determinada pela elipse de polarização, pelo vetor de Jones ou ainda pelo vetor de Stokes. Existem duas propriedades da elipse de polarização que se relacionam diretamente com o estado de polarização da radiação. A primeira está relacionada ao ângulo de elipticidade ou excentricidade (χ) que descreve a forma da elipse e o sentido de rotação do vetor. A segunda propriedade se refere ao ângulo de orientação (rotação) (ψ) relativo à inclinação em relação à horizontal, sendo o ângulo formado entre o eixo maior (ξ) e o eixo X (Figura 2.3) (RICHARDS, 2009).

Figura 2.3 - Elipse de polarização em um plano xy para representar o campo elétrico.



Fonte: Adaptada de Hellmann (2001).

No vetor de Stokes a onda pode ser caracterizada por quatro parâmetros reais e mensuráveis que permitem uma discriminação completa da polarização de uma onda (i.e., permitem caracterizar a magnitude e fase relativa) (LEE; POTTIER, 2009) (Equação 2.3):

$$I_0^2 = Q^2 + U^2 + V^2 \quad (2.3)$$

O primeiro parâmetro (I_0) é relacionado à intensidade total da onda, os outros três termos descrevem o estado de polarização da onda, sendo o segundo parâmetro (Q) referente à diferença entre a intensidade da onda vertical e horizontal e expressa à quantidade da polarização da onda ser na direção vertical ou horizontal. O terceiro e quarto termo (U e V respectivamente) representam as diferenças de fase entre as componentes da onda polarizadas verticalmente e horizontalmente (ULABY; ELACHI, 1990; WOODHOUSE, 2006) e podem ser consideradas como a quantidade de polarização circular da onda na direção da direita ou esquerda.

O vetor de Jones pode ser determinado por meio do vetor complexo bidimensional, correspondendo às informações sobre a amplitude e fase da onda (LEE; POTTIER, 2009). Na representação da onda plana, o vetor do campo complexo \vec{E}_{ab} é a combinação linear de dois estados arbitrários

ortogonais de polarização (\vec{a}, \vec{b}), ponderado pelas respectivas amplitudes (E_a, E_b) e fases (δ_a, δ_b) (Equação 2.4) (HELLMANN, 2001).

$$\vec{E}_{ab} = \begin{bmatrix} E_{a0} \\ E_{b0} \end{bmatrix} = \begin{bmatrix} E_{a0} \exp(j\delta_a) \\ E_{b0} \exp(j\delta_b) \end{bmatrix} \quad (2.4)$$

2.5. Espalhamento de ondas eletromagnéticas

Os sensores SAR emitem pulsos que interagem com os alvos na superfície terrestre, as ondas eletromagnéticas sofrem alterações em suas características e retornam para a antena receptora por reflexão ou espalhamento. Essas transformações ocorrem de forma linear e podem ser representadas pelas matrizes de espalhamento (RICHARDS 2009).

Dentre as matrizes de representação de espalhadores determinísticos, uma das mais comumente utilizadas é a matriz de espalhamento [S] (Equação 2.5). Os alvos determinísticos (coerentes) ao interagirem com um mecanismo físico geram ondas perfeitamente polarizadas, preservando a polarização da onda incidente (LEE; POTTIER, 2009).

$$[S] = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix} \longrightarrow k = \frac{1}{2} \text{Traço}([S] \psi) = [k_0, k_1, k_2, k_3]^T \quad (2.5)$$

A matriz [S] modela a forma como os espalhadores transformam o campo elétrico incidente (E_{inc}) no campo elétrico espalhado (E_{esp}), descrevendo o processo de espalhamento (Equação 2.6). A matriz é composta por quatro elementos complexos que dependem da frequência/comprimento de onda, do ângulo incidente e orientação dos espalhadores, ou seja, depende das propriedades físicas e geométricas dos alvos imageados (ULABY; ELACHI, 1990; RICHARDS 2009).

$$\vec{K}_B = [S_{hh} \ S_{hv} \ S_{vh} \ S_{vv}]^T \quad (2.6)$$

O Traço ([S]) representa a soma dos elementos da diagonal da matriz de espalhamento [S] e ψ é a base matricial 2x2.

Em sistemas monoestáticos, supõe-se que o meio entre o alvo e a antena receptora é recíproco (sem considerar o efeito da rotação de *Faraday*), sendo a matriz [S] simétrica ($S_{vh} = S_{hv}$), podendo ser representada pelo vetor de espalhamento que possui três elementos independentes (BOERNER et al., 1998; RICHARDS, 2009).

Nas aplicações de sensoriamento remoto, a suposição de espalhadores determinísticos puros não é válida, uma vez que a célula de resolução é maior que o comprimento de onda emitido pelo sistema sensor e os alvos são compostos por muitos espalhadores determinísticos distribuídos espacialmente de forma aleatória. Dentro da célula de resolução, o retorno é a soma vetorial da contribuição desses espalhadores elementares (HELLMANN, 2001).

Muitos alvos na superfície se encontram em ambientes dinâmicos e estão suscetíveis às variações de natureza espacial e/ou temporal (LEE; POTTIER, 2009). Estes alvos são considerados alvos não determinísticos (incoerentes), que ao interagirem com um mecanismo físico, a onda é retroespalhada e parcialmente polarizada. Isto ocorre quando o alvo tem mais de um centro de espalhamento, fazendo com que o sinal medido seja a sobreposição de um grande número de ondas com várias polarizações (BOERNER et al., 1998).

Para tratar da natureza não determinística dos espalhadores, podem ser empregadas as matrizes de covariância [C] ou coerência [T] (CLOUDE; POTTIER, 1996; LEE; POTTIER, 2009). Ambas apresentam as mesmas informações sobre amplitude, fase e correlações, com autovalores reais e iguais, mas diferentes autovetores.

A matriz [C] é definida como o valor esperado (i.e., uma média em relação ao número de medições). Ela é composta a partir do Vetor de *Borgeaud* e, seus complexos conjugados transpostos, no qual terá uma matriz 4x4 pela seguinte forma (Equação 2.7):

$$[C]_{4 \times 4} = E \langle k k^{*T} \rangle = \begin{bmatrix} \langle |S_{HH}|^2 \rangle & \langle S_{HH} S_{HV}^* \rangle & \langle S_{HH} S_{HV}^* \rangle & \langle S_{HH} S_{VV}^* \rangle \\ \langle S_{HV} S_{HH}^* \rangle & \langle |S_{HV}|^2 \rangle & \langle S_{HV} S_{HV}^* \rangle & \langle S_{HV} S_{VV}^* \rangle \\ \langle S_{VH} S_{HH}^* \rangle & \langle S_{VH} S_{HV}^* \rangle & \langle |S_{VH}|^2 \rangle & \langle S_{VH} S_{VH}^* \rangle \\ \langle S_{VV} S_{VV}^* \rangle & \langle S_{VV} S_{HV}^* \rangle & \langle S_{VV} S_{HV}^* \rangle & \langle |S_{VV}|^2 \rangle \end{bmatrix} \quad (2.7)$$

Onde $\langle \dots \rangle$ denota média espacial, assumindo homogeneidade de um meio de espalhamento aleatório. Os elementos da diagonal da matriz [C] representam a intensidade do sinal.

A matriz [T] é formada a partir da matriz [S] na base vetorial de Pauli (Equação 2.8). Esta matriz se relaciona com as propriedades físicas e geométricas dos processos de espalhamento e possibilita uma melhor e direta interpretação física dos alvos.

$$[T]_{4 \times 4} = E \langle k_p k_p^{*T} \rangle \quad (2.8)$$

Considerando o Teorema de reciprocidade ($S_{hv} = S_{vh}$), o Vetor de Pauli é reduzido a 3 dimensões, sem perda de informação (Equação 2.9):

$$\overrightarrow{K_p} = \frac{1}{\sqrt{2}} [(S_{HH} + S_{VV}) (S_{HH} - S_{VV}) 2(S_{HV})]^T \quad (2.9)$$

Nestas condições, a matriz [T] é representada por (Equação 2.10):

$$[T]_{3 \times 3} = \overrightarrow{\langle k_{p3} k_{p3}^{*T} \rangle} = \frac{1}{2} \begin{bmatrix} \langle |A|^2 \rangle & \langle AB^* \rangle & \langle AC^* \rangle \\ \langle A^* B \rangle & \langle |B|^2 \rangle & \langle BC^* \rangle \\ \langle A^* C \rangle & \langle B^* C \rangle & \langle |C|^2 \rangle \end{bmatrix} \quad (2.10)$$

Onde, $A = S_{hh} + S_{vv}$; $B = S_{hh} - S_{vv}$ e $C = 2 S_{hv}$. Em que $S_{hh} + S_{vv}$ está relacionado ao tipo de espalhamento superficial, $S_{hv} + S_{vh}$ relacionado ao tipo de espalhamento volumétrico e $S_{hh} - S_{vv}$ associado ao espalhamento *double-bounce*.

As informações sobre os processos de espalhamentos contidas nas matrizes de espalhamento auxiliam na identificação e análise dos diferentes mecanismos de espalhamento. Isso possibilita inferir sobre as propriedades físicas da superfície terrestre através de técnicas

estatísticas e técnicas polarimétricas como, por exemplo, a decomposição de alvos.

2.6. Teoremas de decomposição de alvos

O teorema da decomposição de alvos tem como objetivo expressar o mecanismo médio de espalhamento dos alvos como uma soma de elementos independentes e associar, a cada componente, um mecanismo físico (CLOUDE; POTTIER, 1996). Por sua vez, a decomposição de alvos permite extrair informações sobre as características dos alvos (LEE; POTTIER, 2009).

As decomposições de alvos podem ser agrupadas em duas classes principais (CLOUDE; POTTIER, 1996):

- Decomposição coerente: descreve os espalhadores determinísticos e podem ser representados pela matriz Sinclair [S].
- Decomposição incoerente: descreve os espalhadores não determinísticos representados pelas matrizes de covariância [C], coerência [T], *Muller* [M] e *Kennaugh* [K].

O teorema de decomposição de alvos incoerentes formulado por Cloude-Pottier (1996) é baseado na extração de atributos de Entropia (H), Anisotropia (A) e Ângulo Alfa (α) gerados a partir da matriz de coerência [T]. A matriz consiste na soma de três alvos independentes $\{T_{0i}\}_{i=1,2,3}$, sendo que cada um deles, representa um mecanismo de espalhamento associado a uma única matriz de espalhamento. A contribuição de cada mecanismo de espalhamento é representada pelos autovetores e autovalores (LEE; POTTIER, 2009).

Os autovetores (e_i) consistem no tipo de mecanismo de espalhamento, enquanto que os autovalores (λ_i) representam a contribuição do mecanismo de espalhamento (Equação 2.11) (LEE; POTTIER, 2009):

$$\text{Sendo, } \langle (T_3) \rangle = \sum_{i=1}^3 [T_{3i}] = \lambda_1 (e_1 e_1^{*T}) + \lambda_2 (e_2 e_2^{*T}) + \lambda_3 (e_3 e_3^{*T}) \quad (2.11)$$

A entropia (H) mede o grau de aleatoriedade da distribuição dos mecanismos de espalhamento, sendo que $H \cong 0$ indica que a matriz [T] apresenta apenas um autovalor diferente de zero, representando apenas um processo determinístico de espalhamento (Equação 2.12). Valores médios de entropia, entre $0 \leq H \leq 1$ indicam que não há apenas um mecanismo de espalhamento dominante. Entropia de $H \cong 1$ significa que os autovalores da matriz [T] são todos iguais (i.e., não há um tipo de espalhamento dominante), indicando a presença de três alvos que ao interagir com a onda incidente à despolariza completamente com a mesma contribuição. Esse processo de espalhamento é considerado um espalhamento do tipo “ruído aleatório”.

$$H = -\sum_{i=1}^3 p_i \log_3(p_i), \text{ com } p_i = \frac{\lambda_i}{\sum_{j=1}^3 \lambda_k} \quad (2.12)$$

Onde p_i pode ser interpretado como a intensidade relativa do processo de espalhamento “ i ”.

O parâmetro anisotropia (A) (Equação 2.13) é um parâmetro complementar à entropia e corresponde à importância dos mecanismos de espalhamento secundários através da relação entre seus respectivos autovalores (λ_2 e λ_3). Este parâmetro é mais representativo quando ocorre a média entropia ($H \geq 0,7$), a qual possibilita auxiliar na identificação dos alvos. Valores de baixa anisotropia indicam que existe também a contribuição do terceiro mecanismo de espalhamento, por outro lado, a alta anisotropia indica que apenas o segundo mecanismo de espalhamento é importante (HELLMANN, 2001).

$$A = \frac{\lambda_2 - \lambda_3}{\lambda_2 + \lambda_3} \quad (2.13)$$

O atributo ângulo alfa possibilita identificar e descrever o tipo de mecanismo de espalhamento do alvo (Equação 2.14), sendo:

$\alpha = 0^\circ$ é considerado espalhamento do tipo superficial;

$\alpha = 45^\circ$ indica um mecanismo de espalhamento dipolo e

$\alpha = 90^\circ$ é considerado um espalhamento *double-bounce*.

$$\bar{\alpha} = \sum p_i \alpha_i \quad (2.14)$$

De acordo com Freeman-Durden (1998), alguns tipos de alvos compostos por materiais mais rígidos, tais como esferas metálicas, diedros e triedros, podem não ser representados nos espalhamentos de alvos naturais, como por exemplo, em áreas com vegetação e floresta. Assim, Freeman-Durden (1998) propõem um modelo baseado na física do espalhamento a partir da matriz [C] como a soma das contribuições dos espalhamentos do tipo superficial (P_s), *double-bounce* (P_d) e volumétrico (P_v) (Equação 2.15):

$$\langle |C_3| \rangle = \langle |C_3| \rangle_v + \langle |C_3| \rangle_s + \langle |C_3| \rangle_d \quad (2.15)$$

O espalhamento superficial é modelado a partir de superfícies que apresentam feições ligeiramente rugosas ou em superfícies onduladas (Equação 2.16):

$$P_s = f_s (1 + |\beta|^2) \quad (2.16)$$

A contribuição do espalhamento *double-bounce* é modelada a partir de refletores de canto do tipo diedro, onde as superfícies refletoras podem ser constituídas por diferentes materiais dielétricos (Equação 2.17):

$$P_d = f_d (1 + |\alpha|^2) \quad (2.17)$$

O espalhamento volumétrico é modelado a partir de dipolos (conjunto de espalhadores cilíndricos e muito finos) orientados aleatoriamente que causam a despolarização da energia quando interagem com o meio (Equação 2.18):

$$P_v = \frac{8f_v}{3} \quad (2.18)$$

Sendo, f_s , f_d e f_v as contribuições dos espalhadores provenientes da matriz [C], β é a razão entre os coeficientes de reflexão da onda polarizada na direção horizontal e vertical e α_i se refere aos efeitos de mudança de fase, coeficientes de reflexão e atenuação da propagação.

Com base no modelo de espalhamento da matriz [C] elaborado por Freeman e Durden (1998), Yamaguchi et al., (2005) propuseram um modelo que introduziu um quarto componente. Este componente corresponde ao espalhamento do tipo hélice. Neste tipo de espalhamento, um alvo de hélice (alvo com forma e/ou estrutura artificial, refletor não simétrico) gera uma polarização circular para a esquerda ou para a direita.

A segunda importante contribuição proposta por Yamaguchi et al., (2005) refere-se à modificação na modelagem da decomposição da matriz de espalhamento do tipo volumétrico de acordo com as magnitudes relativas do retroespalhamento de $\langle |S_{HH}|^2 \rangle$ versus $\langle |S_{VV}|^2 \rangle$. No modelo teórico do espalhamento volumétrico, a nuvem de dipolos é aleatoriamente orientada e é modelada por uma função probabilidade uniforme de diferentes ângulos de orientação. Entretanto, para ambientes com vegetação, constituídos principalmente por estruturas verticais, os espalhamentos provenientes de troncos e galhos das árvores exibem ângulos de distribuição preferenciais. Com o intuito de modelar esta característica, foi realizada uma alteração na função de densidade de probabilidade, considerando o aspecto da orientação vertical dominante dos troncos das árvores e na distribuição dos ramos (YAMAGUCHI et al., 2005).

A nova distribuição de probabilidade proposta é dada por (Equação 2.19):

$$p(\theta) = \begin{cases} \frac{1}{2} \sin \theta, & \text{para } 0 < \theta < \pi \\ 0, & \text{para } \pi < \theta < 2\pi \end{cases} \quad \text{com } \int_0^{2\pi} p(\theta) d\theta = 1 \quad (2.19)$$

Além da extração de informações da fase relativa dos atributos coerentes, também é possível extrair informações das propriedades de diferentes polarizações dos dados sobre as medidas de intensidade de cada pixel provenientes dos atributos incoerentes. Como por exemplo, através da razão de polarização paralela e cruzada descritas por Henderson e Lewis

(1998) e pelo Índice de Radar de Degradação Florestal elaborado por Saatchi et al. (2010).

2.7. Atributos derivados do retroespalhamento

Os atributos derivados do retroespalhamento conhecidos como coeficiente de retroespalhamento (σ°), representam uma medida de potência em escala logarítmica (dB) ou em escala linear (m^2/m^2) (VAN DER SANDEN, 1997). Os atributos extraídos a partir do coeficiente de retroespalhamento apresentam apenas a informação da parte real (amplitude do sinal) da matriz de espalhamento complexa. Sendo o coeficiente de retroespalhamento nas polarizações VV (σ°_{VV}), HH (σ°_{HH}), e HV (σ°_{HV}) e as Razões de Polarização Paralela (RP) e Cruzada (RC) alguns dos atributos mais comumente utilizados.

A Razão de Polarização Paralela (RP) realça as diferenças entre os mecanismos de espalhamento sensíveis à polarização VV e aqueles sensíveis à polarização HH (Equação 2.20) (RICHARDS, 2009). Esta Razão extrai informações a partir da geometria (forma e orientação) preferencial dos elementos espalhadores. Em ambientes florestais, pode ser representado por galhos de árvores.

$$Rp = \frac{\sigma^\circ_{VV}}{\sigma^\circ_{HH}} \quad (2.20)$$

A Razão de Polarização Cruzada (RC) é um parâmetro que indica a dominância entre os retroespalhamentos nas polarizações HV (Equação 2.21) e apresenta maior sensibilidade na polarização HH e para os eventos de espalhamento volumétrico (incluindo a vegetação) (RICHARDS, 2009).

$$Rc = \frac{\sigma^\circ_{HV}}{\sigma^\circ_{HH}} \text{ ou } \frac{\sigma^\circ_{VH}}{\sigma^\circ_{HH}} \quad (2.21)$$

No *Radar Forest Degradation Index* (RFDI), o retroespalhamento na polarização HH é sensível aos espalhamentos do tipo volumétrico e *double-bounce*, e o retroespalhamento nos canais HV mostram-se mais

sensíveis ao espalhamento volumétrico de coberturas florestais (SAATCHI et al., 2010). Este Índice objetiva auxiliar na discriminação de diferentes tipos de vegetação, possibilitando extrair mais informações em dupla polarização (Equação 2.22):

$$\text{RFDI} = \frac{\sigma_{HH}^0 - \sigma_{HV}^0}{\sigma_{HH}^0 + \sigma_{HV}^0} \quad (2.22)$$

Os valores de retroespalhamento estão associados às componentes da estrutura florestal, orientação e fatores como a cobertura do dossel (MITCHARD et al., 2011). Valores do RFDI próximos a 1,0 estão associadas às áreas sem cobertura florestal (i.e., áreas totalmente limpas), enquanto que valores variando de 0,3 a 0,4 estão associados com coberturas florestais não perturbadas (SAATCHI, 2007).

2.8. Classificação

O processo de classificação de imagens digitais busca a extração de informação visando reconhecimento de padrões de alvos ou regiões homogêneas (CROSTA, 1992). Nesse processo, diversas abordagens podem ser aplicadas.

Uma das abordagens é o método de classificação pixel a pixel, que busca atribuir a cada pixel uma “classe” derivada das suas características espectrais e/ou espaciais. Outra é o classificador por regiões, que extrai informações a partir das propriedades espectrais e espaciais, sendo que as informações espaciais envolvem a relação entre os pixels e seus vizinhos (BLASCHKE et al., 2011).

Os métodos de classificação de dados SAR polarimétricos podem ser divididos em quatro classes:

- Algoritmos baseados em técnicas de classificação supervisionada, como por exemplo: Redes Neurais Artificiais, *Support Vector Machine*, *Random Forest*, ou não supervisionada, como por exemplo: K-means e Isodata sem a utilização de modelos estatísticos para os dados;

- Algoritmos de classificação supervisionada baseados em um modelo estatístico para os dados;
- Algoritmos de classificação supervisionada ou não-supervisionada baseados nos Teoremas de Decomposição de Alvos (mecanismos de espalhamento dos alvos);
- Algoritmos híbridos (classificação supervisionada ou não) compostos a partir da combinação entre as classes supracitadas.

A classificação de Máxima Verossimilhança (MaxVer) é um método supervisionado, pixel a pixel, que considera as distâncias médias, utilizando parâmetros estatísticos de distribuição dos pixels dentro de uma determinada classe (CRÓSTA, 1992). Entretanto, este método não considera a equiprobabilidade das classes e a dependência espacial entre as mesmas, informações estas, importantes quando aplicadas aos dados SAR (CORREIA, 1999).

O algoritmo ICM integrado ao classificador MaxVer é um método de refinamento de uma classificação inicial que incorpora a dependência espacial (FREITAS et al., 2007). Ele consiste em substituir a classe de cada elemento que maximiza a distribuição a *posteriori*, dada a influência das classes dos elementos vizinhos (CORREIA, 1999).

Negri (2009) utilizou imagens ALOS/PALSAR-1 e métodos de classificação a partir do classificador MaxVer-ICM e K-Médias *Wishart* $H/A/\alpha$ para avaliar o potencial dos dados polarimétricos para a classificação da cobertura da terra na região da Amazônia. Como resultado, o classificador MaxVer-ICM apresentou maior capacidade na discriminação de diferentes tipos de culturas e de pastagens.

Guerra et al. (2010) utilizaram o classificador MaxVer-ICM para discriminar incrementos anuais de desflorestamento na Amazônia com dados multipolarizados de banda L e concluíram que esse classificador apresentou bom potencial, obtendo como resultado Índice *Kappa* de 0,68.

Pereira et al. (2011) realizaram uma análise comparativa dos métodos de classificação SVM e MaxVer-ICM das imagens polarimétricas do

ALOS/PALSAR-1 em uma área do município de Belterra. O classificador MaxVer-ICM apresentou o melhor resultado, com uma exatidão global de 80,24%, enquanto o SVM apresentou uma exatidão de 74,23%.

Pereira et al. (2016) avaliaram os dados ALOS/PALSAR-1 combinados com imagens ópticas para o uso e cobertura da terra em uma determinada porção da FNT, utilizando o classificador MaxVer-ICM, o qual novamente apresentou bons resultados para a discriminação dos alvos.

2.9. Análise de mudanças

O conceito detecção de mudanças pode ser definido como o processo de identificar diferenças nos objetos ou fenômenos observados em diferentes intervalos de tempo. Essencialmente envolve a capacidade de quantificar os efeitos temporais utilizando um conjunto de dados multitemporais (SINGH, 1989).

Existem diversas técnicas para detectar mudanças na paisagem a partir de imagens SAR, tais como a análise pelas componentes principais, vetor de mudanças, razão ou diferença entre sequências temporais de imagens. Ainda podem ser utilizadas técnicas de detecção de mudanças coerentes e incoerentes. A detecção de mudanças coerentes utiliza a informação da amplitude e fase das imagens SAR complexas para identificar as mudanças. Já a técnica de detecção de mudanças incoerentes utiliza somente as informações de amplitude para identificação, normalmente através da razão de bandas.

A técnica de Análise de Vetores de Mudanças além de detectar mudanças, determina os tipos de mudanças através das características multiespectrais do conjunto de dados. A análise do vetor formado pelos valores de um mesmo pixel com datas distintas permite, por meio da magnitude, detectar se houve ou não mudança. Pela análise da direção da mudança, em determinados casos, pode-se identificar o tipo de alteração (JOHNSON; KASISCHKE, 1998). Um dos métodos mais comumente utilizado é a subtração de duas imagens pixel a pixel (REIS,

2014). Os resultados podem variar bastante de acordo com o conjunto de dados utilizados, a complexidade da área de estudo, e os tipos de mudanças a serem detectados. A técnica empregada também é um fator relevante, sendo recomendável testar mais de uma metodologia (LU et al., 2014).

Lorena (2001) aplicou a técnica de Análise por Mudança de Vetor em dados ópticos multitemporais e multiespectrais para detectar mudanças na dinâmica da cobertura vegetal e de uso do solo em uma porção da Amazônia Ocidental (Acre). Os resultados demonstraram capacidade da técnica em estratificar diferentes tipos de modificações relacionadas ao uso e cobertura da terra na região.

Lu et al. (2005) utilizaram imagens ópticas multiespectrais e multitemporais, e aplicaram 10 diferentes métodos para detectar mudanças de uso e cobertura da terra em uma porção da floresta da Amazônia (Rondônia). O melhor método obtido foi baseado na subtração das imagens de uma data pela de outra.


No estudo de detecção de mudanças na FNT, através da imagem de diferença e de dados multitemporais do RADARSAT-2, Anjos et al. (2013) concluíram que o método de imagem de diferença apresenta capacidade de detecção de mudanças podendo ser aplicado para este fim.

3 METODOLOGIA

3.1. Delimitação e caracterização da área de estudo

Para compor a área sob investigação utilizou-se um mosaico de trechos de três imagens que se sobre posicionam (Figura 3.1), considerando a abrangência da disponibilidade das imagens PALSAR, o mapeamento histórico e também àquele correspondente a fase de trabalho de campo de certa maneira representativo ao período recente do imageamento que compõe a análise da dinâmica.

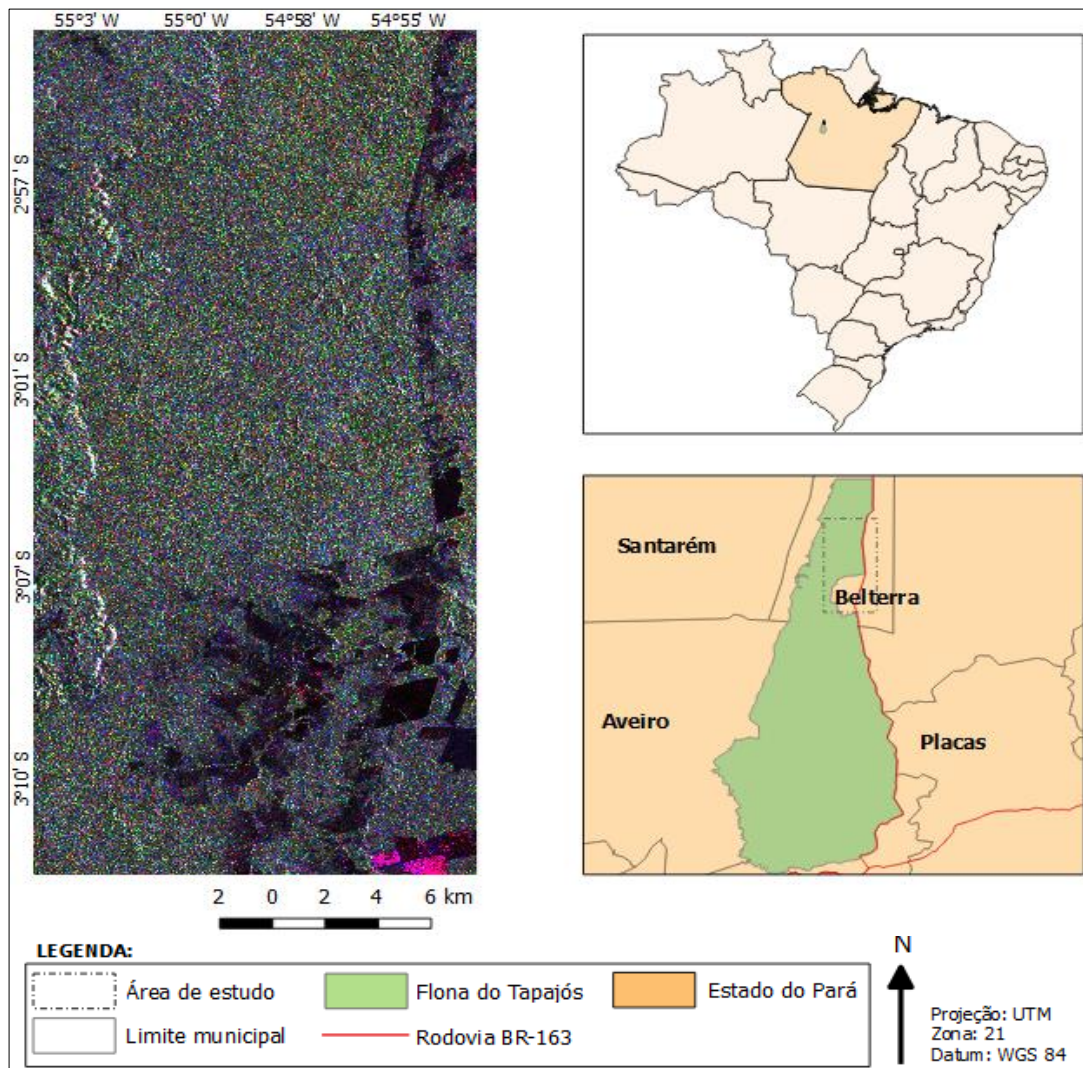
Figura 3.1 – Pontos coletados em campo que compõem o mosaico das imagens ALOS/PALSAR-2.



Fonte: Produção do autor.

A área de estudo está localizada na zona UTM 21, entre as latitudes 2°53'42" e 3°12'30" Sul e entre as longitudes 55°3'39" e 54°54'27" Oeste, situada na porção de abrangência da FNT e áreas adjacentes próximas a BR-163 Santarém-Cuiabá (Figura 3.2).

Figura 3.2 – Localização da área de estudo com o mosaico das imagens 2016 do ALOS/PALSAR-2



Composição: R: VV, G: HV e B: HH
Fonte: Produção do autor.

Segundo o sistema de Köppen, o clima da região é classificado como Tropical úmido e de acordo com os dados meteorológicos coletados na estação de Belterra pelo INMET, há uma temperatura média anual de 25°C e precipitação média em torno de 162 mm, apresentando uma distribuição do regime de chuvas regular durante o ano (MMA, 2004; INMET, 2017).

A área de estudo está inserida na unidade morfoestrutural Planalto Rebaixado da Amazônia (Médio Amazonas), formado por colinas com ravinhas, vales encaixados e vales dissecados, com altitudes em torno de 100 m. A região também é constituída pela unidade Planalto Tapajós-

Xingu (região de planalto), caracterizado por extensas superfícies de formação tabular com cotas altimétricas variando entre 120 e 170 m. O desnível entre a região de planalto e o planalto rebaixado na margem do Rio Tapajós pode chegar até 150 m (MMA, 2004). Os solos argilosos são predominantes, principalmente o tipo Latossolo Amarelo Distrófico e em menores proporções pelos Argissolos Vermelho-Amarelo (RADAMBRASIL, 1976).

A Floresta Nacional do Tapajós situa-se em escala regional na zona de Floresta Ombrófila Densa (MMA, 2004), podendo também apresentar cobertura florestal uniforme ou ainda com a presença de árvores emergentes (NEGRI, 2009).

Com o intuito de promover maior integração da região Norte na economia nacional, o governo federal criou o Programa de Integração Nacional na década de 70 para financiar o plano de obras de infraestrutura. Através do Decreto-Lei (nº 1.106/70), foi realizada a primeira etapa do Programa, constituído pela construção das rodovias Transamazônica e Cuiabá-Santarém. Foram resguardados para a colonização e reforma agrária da região, uma faixa de terra de até 10 km à direita e esquerda das novas rodovias (BRASIL, 1970).

Decorrente dos históricos incentivos das políticas públicas se iniciou um intenso processo de pressões sob a cobertura florestal nativa, principalmente nas áreas próximas das rodovias amazônicas (ALVES, 2002). Tal fato foi típico também dessa região da FNT, com significativa atividade humana ocorrendo ao longo da estrada BR 163, que liga Santarém à Cuiabá, sendo intensificadas mais recentemente com a expansão da fronteira agrícola, com a implantação de extensas fazendas de produção de grãos, algumas em substituição às áreas antes ocupadas por pastagens e ou decorrentes de novas conversões florestais, perante as facilidades de infraestrutura local, com instalação de um polo portuário graneleiro em Santarém para o escoamento desses grãos e melhorias da malha viária (CORAZZA et al., 2011).

Outro importante fator da fragmentação florestal, segundo o MMA (2004); TCU (2008) é decorrente dos assentamentos de pequenos agricultores na comunidade de São Jorge, cuja paisagem bem antropizada é constituída de pequenos cultivos de subsistência, pastos limpos e sujos, e áreas em pousio de diferentes estádios de sucessão. A Comunidade pertencia à área de proteção ambiental do Tapajós, porém, com as alterações no código florestal no ano de 2012, ela foi desmembrada da Unidade de Conservação, localizando-se atualmente numa parte central limítrofe da FNT, assim, possibilitando uma maior dinâmica nos usos e coberturas da terra nestas áreas adjacentes à Flona.

3.2. Base de dados

3.2.1 Dados do ALOS PALSAR-2

O ALOS-2 foi lançado em 2014 com o objetivo de dar continuidade à missão do ALOS-1. O sensor PALSAR-2 opera em três modos: *Spotlight*, *Strip Map* e *ScanSAR* e apresenta uma capacidade significativamente melhorada, principalmente quanto aos aspectos de resolução espacial e observação de frequência, conforme pode ser observado na Tabela 3.1:

Tabela 3.1 - Comparação entre as missões ALOS-1 e 2.

Parâmetros de observação	ALOS-1 (2006)	ALOS-2 (2014)
Frequência da observação	Tempo de revisita: 46 dias (BOS) Ângulo de incidência: 8 - 60° Visada lateral a direita	Tempo de revisita: 14 dias (BOS) Ângulo de incidência: 8 - 70° Visada lateral a direita ou esquerda
Resolução espacial	Modo Strip Map: 10 m Modo ScanSAR: 100 m -----	Strip Map: 3, 6 ou 10 m ScanSAR: 100 m Spotlight: 1 m x 3 m

Fonte: Adaptada de JAXA (2014).

No presente estudo foram consideradas para a análise as imagens *Strip Map* do satélite PALSAR-2 adquiridas no modo de operação *Polarimetry* (SM2) de múltiplas polarizações: HH, VV, HV e VH (*quad-pol*), com nível de processamento L1.1. Os dados neste nível se referem a um dado no formato complexo (SLC) em geometria *slant range* com compressão em

alcance e um *look* em azimute. Isto é, apresentam informações sobre a radiometria e fase do sinal (Tabela 3.2).

Tabela 3.2 - Principais características das imagens utilizadas do ALOS/PALSAR-2.

ID	Data de aquisição	Órbita	Espaçamento entre pixel em <i>Range</i>	Espaçamento entre pixel em Azimute	Número de linhas	Número de colunas	Ângulo de incidência no centro da faixa
2032237120	28/12/14	Ascendente	3,13 m	2,86 m	23210	7496	33,869°
2048797130	19/04/15				22608	8112	33,878°
2050867130	03/05/15				23209	7496	31,104°
2102617130	17/04/16				22608	8112	33,872°
2104687120	01/05/16				23209	7496	31,088°
2104687130	01/05/16				23209	7496	31,091°

As características radiométricas dos dados PALSAR, assim como os parâmetros e as calibrações polarimétricos são definidos pela JAXA. Dados *full* polarimétricos (SM2 - L1.1) são fornecidos com a calibração relativa polarimétrica dos efeitos *Cross-talk* e *Channel Imbalance* e com a correção radiométrica do efeito do padrão da antena (LAVALLE; WRIGHT 2009).

O efeito *Cross-talk* pode ser compreendido como a influência da energia de uma determinada polarização interferindo diretamente na outra polarização do sistema SAR polarimétrico. Ou seja, há uma contaminação de um canal para outro, e esta interferência pode ser causada durante a transmissão ou recepção do sinal (SHIMADA et al., 2004). O *Channel Imbalance* ocorre quando há um desequilíbrio de fase e amplitude entre as componentes. Já o efeito do padrão da antena está relacionado com as distorções causadas pelas condições de iluminação da plataforma e da cena imageada, apresentando distorção gradual na iluminação decorrente da variação do ângulo de incidência da onda eletromagnética entre o *near range* e *far range* (NEGRI, 2009).

Com o intuito de averiguar se os dados *full* polarimétricos utilizados no presente estudo estavam radiometricamente adequados para as posteriores análises, foi selecionada uma faixa da imagem, em geometria

slant range, que se estende do *near* ao *far range*. Esta faixa contém alvos que apresentam teoricamente respostas radiométricas homogêneas, e assim, foi possível calcular a média aritmética de cada coluna de pixels desta faixa em todas as componentes de polarização em intensidade (Apêndice A, Figuras A.1, A.2, A.3, A.4 e A.5) para efeito de análise. Por sua vez, em uma das imagens não foi possível selecionar uma faixa em geometria *slant range* com respostas radiométricas similares, devido à presença de alvos heterogêneos ao longo das mesmas. No Apêndice A, Figura A.6, pode ser observado que houve um abrupto decaimento da média do sinal em todas as componentes de polarização, decorrente da presença do Rio Tapajós.

Conforme análise das faixas homogêneas supracitadas foi possível constatar que os dados *full* polarimétricos utilizados estão radiometricamente adequados para os procedimentos de processamento das imagens.

3.2.2. Dados de campo

Os dados foram coletados a partir do trabalho de campo realizado entre os dias 11 e 23 de setembro de 2016 na área de estudo. Para que seja possível temporalmente, detectar mudanças no uso e cobertura da terra, o trabalho de campo consistiu na revisita de 350 pontos temáticos, selecionados e identificados em um trabalho de campo realizado no mês de setembro do ano de 2014 (PÔSSA, 2016).

Para cada ponto identificado foi realizado o registro das coordenadas através do Sistema de Posicionamento Global (GPS), utilizando o aparelho Garmin, modelo eTrex10, na projeção UTM, datum WGS 84, como também foi efetuado o registro fotográfico.








Na amostragem de campo foram identificadas as seguintes tipologias de uso e cobertura da terra: Floresta Primária; Floresta Primária com Extração Madeireira (corte seletivo); Floresta Degradada; Sucessão Secundária Avançada; Sucessão Secundária Intermediária; Sucessão Secundária Inicial; Área Cultivada; Solo em Pousio; Solo Exposto

(Preparado para cultivo); Pasto Limpo; Pasto Sujo (com ou sem a presença de Babaçu ou Inajá) e Corpos d'água (Tabela 3.3).






Dentre as possibilidades de acesso de cada ponto revisitado, buscou-se manter a menor distância possível entre o ponto coletado no ano de 2014 e seu correspondente ponto demarcado durante a revisita em 2016, considerando um erro médio de até 3 metros de distância.

Além dos 350 pontos revisitados, adicionalmente foram coletados 50 novos pontos que apresentam mudanças no uso e cobertura no período considerado, para auxiliar na interpretação e análise dos resultados.

Tabela 3.3 - Discriminação das classes temáticas.

Classe	Uso e Cobertura	Descrição	Registro fotográfico
FP	Floresta Primária	Florestas sem alteração antrópica	
	Floresta Primária com extração madeireira	Florestas com corte seletivo	
Degrad	Floresta Degradada	Florestas que sofrem perda de densidade por atividades de corte indiscriminado e/ou queimada	
SSA	Sucessão Secundária Avançada	Regeneração natural com mais de 15 anos	
SSInt	Sucessão Secundária Intermediária	Regeneração natural de 5 a 15 anos	
SSI	Sucessão Secundária Inicial	Regeneração natural com menos de 5 anos	
AC	Área Cultivada	Cultivos agrícolas ao longo da fase de desenvolvimento fenológico	

(Continua)

SP	Solo em Pousio	Áreas de descanso agrícola temporário entre períodos de cultivo	
	Solo Exposto Preparado	Áreas gradeadas para receber o cultivo	
PL	Pasto Limpo	Áreas de pastagens manejadas, com cobertura graminóide do capim implantado e pouca ocorrência de espécies invasoras	
PS	Pasto Sujo com ou sem presença de Babaçu e/ou Inajá	Áreas de pastagens abandonadas com e sem a presença de espécies invasoras arbustivas	
CA	Corpo d'água	Rede de drenagem formada por lâminas d'água de rios, córregos, lagoas, açudes	

Fonte: Adaptado de Pôssa, 2016.

3.2.3. Aferição temporal

Considerando que o levantamento de campo de setembro de 2014 ocorreu antes da aquisição da imagem SAR de 28/12/2014 e que o segundo levantamento de campo realizado em setembro de 2016, ocorreu após a aquisição das demais imagens SAR (03/05/2015, 17/04/2015 e 01/05/2015), e que, neste intervalo de tempo poderia ter ocorrido certa dinâmica de uso e cobertura da terra, foi necessário realizar uma aferição temporal de concordância entre os pontos coletados e o estado da paisagem no momento do registro dos dados pelo SAR. Esta aferição foi realizada a partir da sobreposição dos pontos coletados em campo e fotointerpretados nas imagens multiespectrais do Landsat-8/OLI e da constelação de satélites do RapidEye, correspondentes ao período anual de interesse.

As imagens OLI foram obtidas na plataforma USGS/NASA, sendo utilizadas cenas de órbita 227 e ponto 062 datadas de 29 de junho e 16 de agosto de 2016. Estas apresentam resolução espacial de 30 metros, resolução radiométrica de 12 bits e nível de processamento 1T, sendo estes dados ortorretificados.

As imagens RapidEye foram obtidas no catálogo de imagens do Ministério do Meio Ambiente (MMA), e para o recobrimento da área de estudo, foram utilizadas as cenas de órbitas 23 e 24 e pontos 376 e 377 respectivamente, adquiridas em 17 de julho de 2015. Estas imagens possuem resolução espacial de 6,5 metros, 12 bits de resolução radiométrica e nível de processamento 3A, que se refere a dados já ortorretificados.

Com o intuito de estabelecer maior rigor científico durante a etapa de análise de mudanças de uso e cobertura da terra, foram utilizadas ainda como informação complementar, as séries temporais do MODIS disponibilizadas para visualização pelo LAF e o SATVeg. O LAF disponibiliza o sistema de visualização de séries temporais que representam a variação dos valores do índice de vegetação (EVI2) a partir das imagens do sensor MODIS do produto MOD13, com resolução espacial de 250m e resolução temporal de 16 dias, desde o ano de 2000. O SATVeg também disponibiliza um sistema de visualização, com séries históricas dos índices vegetativos NDVI e EVI derivados do sensor MODIS que apresentam os mesmos parâmetros técnicos supracitados.

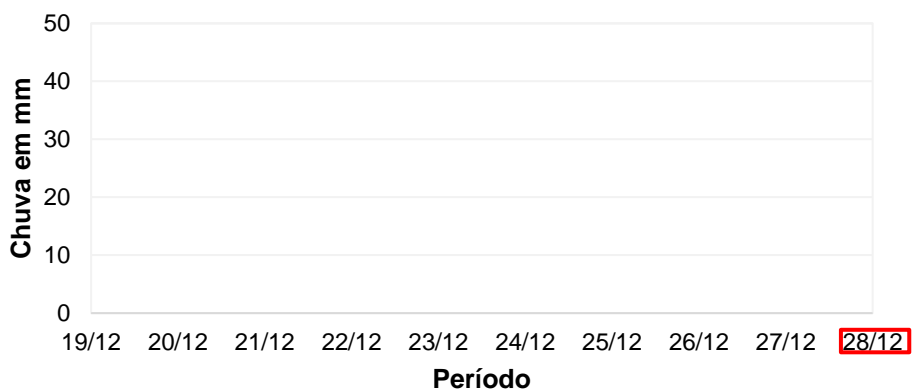
3.2.4. Dados auxiliares

Considerando ainda a multitemporalidade dos produtos utilizados, realizou-se um levantamento dos parâmetros meteorológicos disponibilizados pelo INMET de precipitação pluviométrica diária acumulada no período próximo das aquisições das imagens PALSAR-2.

Essas informações auxiliaram no entendimento e análise de possível influência da quantidade de umidade nas propriedades dielétricas dos materiais e no seu retroespalhamento SAR. Segundo Lewis et al. (1998)

alguns materiais idênticos podem apresentar diferentes respostas radiométricas em momentos e locais distintos, em função da quantidade de água que os compõem, podendo influenciar na sua interpretabilidade. Assim, foram considerados para as análises um período de dezembro de 2014, abril e maio de 2015, e, abril e maio de 2016, sendo estes os períodos em que foram adquiridos os dados PALSAR-2, conforme ilustrado nas Figuras 3.3, 3.4, 3.5, 3.6 e 3.7.

Figura 3.3 - Chuva acumulada entre os dias 19 e 28/12/2014 na estação de Belterra.




Dia de Aquisição da imagem PALSAR.

Fonte: INMET (2017).

De acordo com os dados climáticos disponibilizados pelo INMET, não foi detectado a ocorrência de precipitações durante o mês de dezembro de 2014, conforme pode ser observado na Figura 3.3.

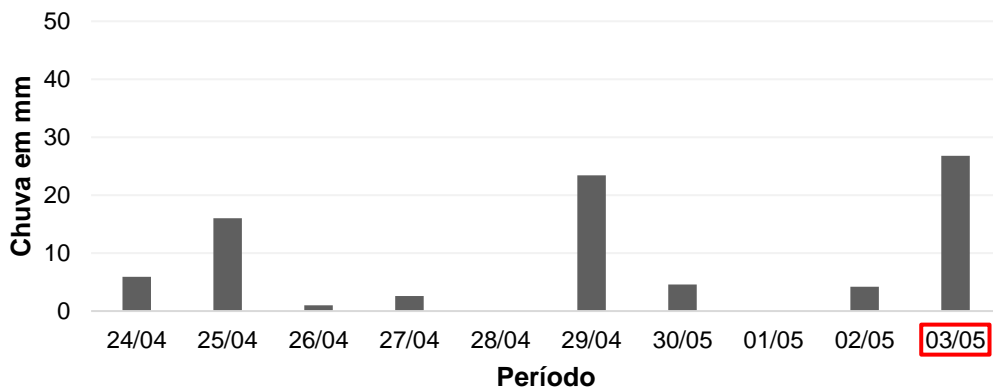
Figura 3.4 - Chuva acumulada entre os dias 10 e 19/04/2015 na estação de Belterra.



Dia de Aquisição da imagem PALSAR.

Fonte: INMET (2017).


Figura 3.5 - Chuva acumulada entre os dias 24/04 e 03/05/2015 na estação de Belterra.



Dia de Aquisição da imagem PALSAR.

Fonte: INMET (2017).


Figura 3.6 - Chuva acumulada entre os dias 08 e 17/04/2016 na estação de Belterra.



Dia de Aquisição da imagem PALSAR.

Fonte: INMET (2017).

Figura 3.7 - Chuva acumulada entre 23/04 e 01/05/2016 na estação de Belterra.



Dia de Aquisição da imagem PALSAR.

Fonte: INMET (2017).

A partir das informações meteorológicas pode-se observar que nas datas de imageamento dos dados ALOS/PALSAR-2 utilizados no presente estudo nos dias 28 de dezembro de 2014, 19 de abril de 2015 e 17 de abril de 2016 (Figuras 3.3, 3.4 e 3.6 respectivamente) apresentaram baixos valores de precipitação pluviométrica (< 10 mm). Dessa forma, pode-se considerar que não houve significativa influência nos valores de retroespalhamento dos alvos nos produtos-radar empregados. Os dados obtidos nas datas de imageamento nos dias 03 de maio de 2015 e 01 de

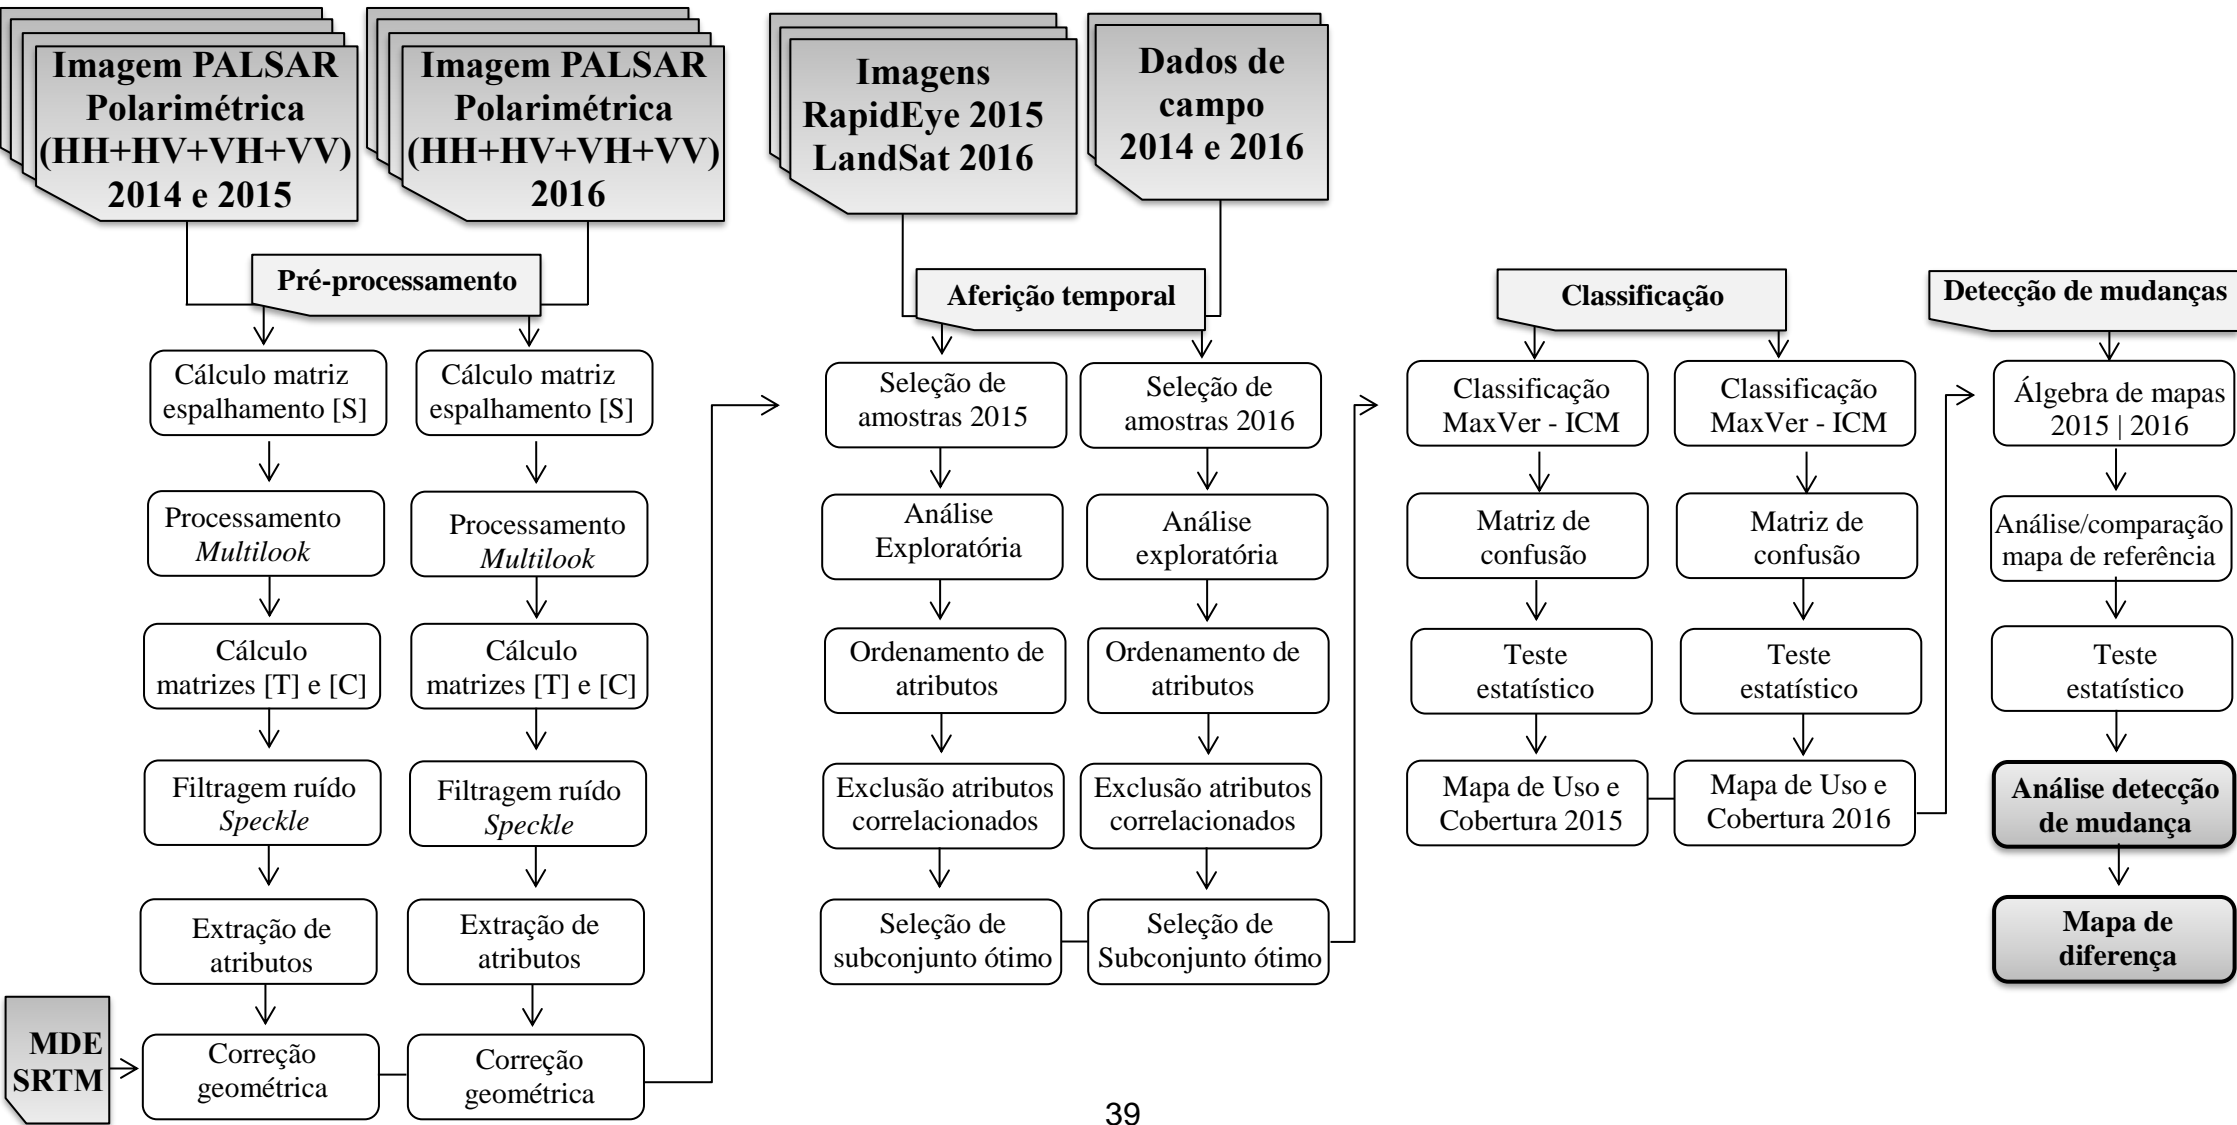
maio de 2016 apresentaram valores de precipitação pluviométrica $> 20 \leq 29$ mm (Figuras 3.5 e 3.7 respectivamente).

Foi utilizado também como dado auxiliar para a ortorretificação das imagens SAR, um Modelo Digital de Elevação (MDE) com resolução espacial de 30 metros. O MDE foi obtido a partir de dados SRTM, disponibilizado pela USGS.

3.3. Processamento SAR

O processamento das imagens SAR foi realizado em quatro etapas principais: pré-processamento, aferição temporal, classificação e detecção de mudanças, conforme ilustrado no fluxograma abaixo (Figura 3.8).

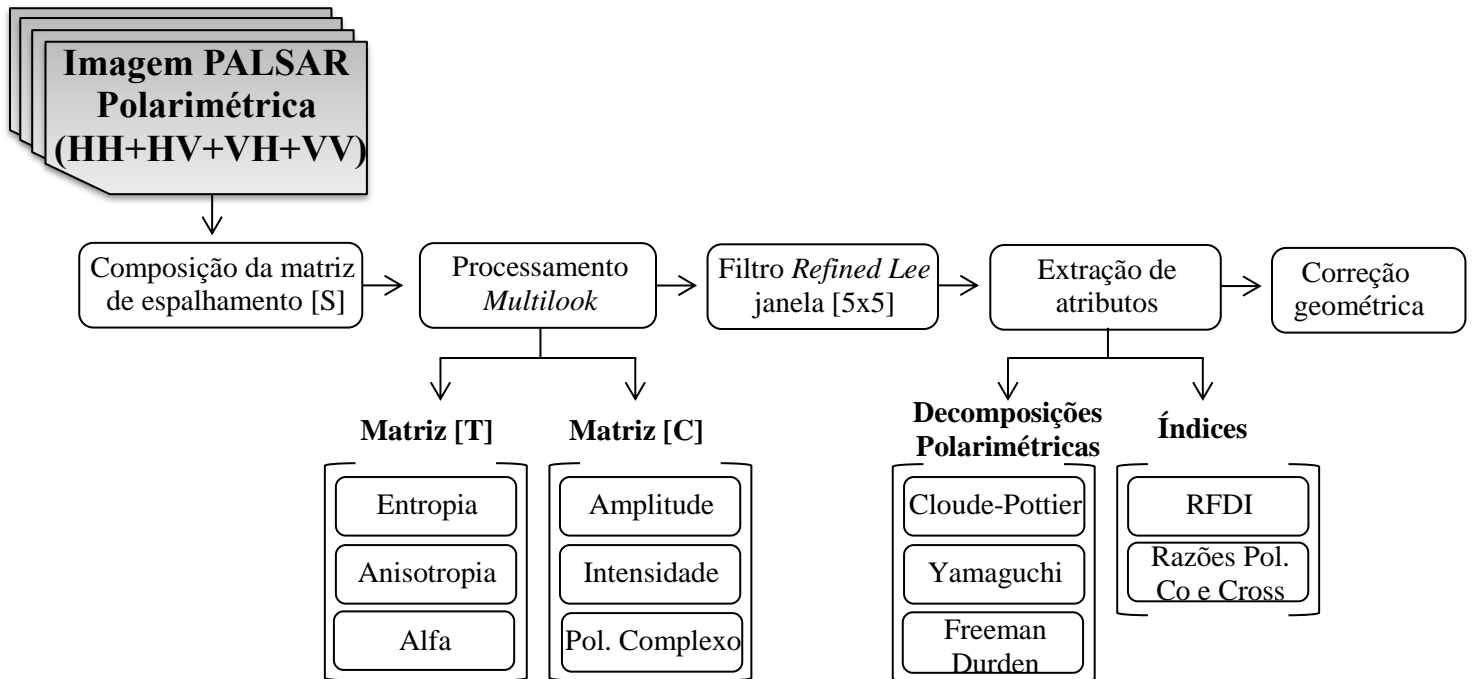
Figura 3.8 - Etapas metodológicas adotadas.



3.3.1. Pré-processamento das imagens ALOS/PALSAR

Os procedimentos metodológicos desenvolvidos na etapa de pré-processamento estão representados na Figura 3.9.

Figura 3.9 - Procedimentos metodológicos adotados no pré-processamento.



A etapa de pré-processamento consistiu inicialmente na importação das imagens ALOS/PALSAR formato SLC para o ambiente SNAP (5.0). Sequencialmente, foram calculados os elementos complexos que são descritos pela matriz de espalhamento [S]. A partir da matriz de espalhamento, foram geradas as matrizes de Covariância [C] e Coerência [T] que representam os espalhadores não determinísticos. Nesta etapa, foi necessário aplicar uma média espacial denominada de processo *Multilook*, obtida por uma janela de tamanho 3 x 3 pixels. Este processo converteu o espaçamento entre pixels de 2,86 x 3,13 m em direção de azimute e *range* respectivamente para o espaçamento entre pixels de aproximadamente 8,5 x 9,5 m em direção de azimute e *ground range*.

Esse processo além de gerar imagens de dimensões regulares dos elementos em resolução espacial nas direções em *range* e azimute auxiliou na atenuação do efeito *Speckle*. Ainda, para o tratamento efetivo

do efeito *Speckle*, foi aplicado nas matrizes de covariância e coerência o Filtro *Refined Lee* (LEE et al., 1999) com janela de tamanho 5x5 pixels.

A escolha do Filtro *Refined Lee* baseou-se nos resultados de estudos anteriores, como de Narvaes (2010) ao tratar imagens ALOS/PALSAR-1 para modelar e estimar biomassa florestal de uma parte da área da FNT. A escolha desse tipo de filtragem foi também utilizada por Bispo (2012) ao relacionar dados polarimétricos do ALOS/PALSAR-1, dados geomorfológicos àqueles florístico-estruturais de tipologias vegetais na FNT. Além desses trabalhos citados, o uso desse tipo de filtro foi empregado para tratar dados ALOS/PALSAR-1 (banda L) e da missão TanDEM-X/TerraSAR para modelagem de biomassa (SILVA, 2014) e por Pôssa (2016) ao avaliar o potencial dos atributos polarimétricos desses mesmos citados produtos para discriminação temática de uso e cobertura da terra.

Para definir o tamanho da janela de filtragem foram realizados testes variando o tamanho da janela de 3x3 a 9x9 pixels. Os critérios avaliados para determinar o efetivo tamanho da janela de filtragem foram baseados na análise qualitativa e quantitativa, considerando os seguintes parâmetros:

- Análise visual da integridade das informações (preservação de bordas, nível de borramento, preservação de pontos) contidas nas feições das imagens SAR após a aplicação dos filtros polarimétricos;
- Redução do efeito *Speckle* através da análise dos valores do CV.

O Coeficiente de Variação (CV) é determinado pela razão entre o desvio padrão e a média local de uma vizinhança próxima do pixel ruidoso (PENNA, 2014). Segundo Rosa (2012), o CV tende a apresentar baixos valores (~0) em áreas uniformes e altos valores (~1) em regiões de contornos (i.e., regiões de alto contraste). Em geral, o CV tende a apresentar baixos valores em áreas homogêneas estando estes valores do CV associados à maior redução do efeito *Speckle*. Assim, neste

estudo foram adotadas as áreas de Floresta Primária como sendo regiões homogêneas.

A partir das matrizes [C] e [T] filtradas foi realizada a extração de atributos polarimétricos por meio das decomposições de Cloude-Pottier, Freeman-Durden e Yamaguchi. A definição dos atributos polarimétricos utilizados foram baseados no trabalho de Pôssa (2016), a partir da análise do potencial dos atributos polarimétricos (sem a integração da coerência interferométrica) testados, onde foram obtidos valores do Índice *Kappa* de 0,70 na decomposição de Cloude-Pottier; 0,54 na de Freeman-Durden; 0,53 de Yamaguchi e 0,42 no Coeficiente de Retroespalhamento.

Assim, este trabalho aplicou as técnicas de decomposição de alvos que apresentaram os melhores resultados, isto é, valores Índice *Kappa* acima de 0,50, como também, introduziu um método adicional de avaliação, fazendo uso do Índice Radar de Degradação Florestal e da Razão de Polarização Paralela e Cruzada, com o objetivo de investigar se estes “atributos” poderiam melhorar o desempenho da classificação.

Para se calcular as Razões e o Índice conforme supracitado, foi necessário realizar a calibração radiométrica dos dados a fim de se obter os valores dos coeficientes de retroespalhamento (σ^0) na medida de potência em escala linear (m^2/m^2), a partir do processamento no *software* SNAP. De acordo com Shimada et al. (2010) a calibração radiométrica de imagens polarimétricas SLC do sensor ALOS/PALSAR-2 com nível de processamento 1.1, podem ser calculadas a partir da Equação 23:

$$\sigma^0 = 10 \cdot \log_{10} \langle I^2 + Q^2 \rangle + CF - A \quad (23)$$

Sendo, *I* e *Q* a parte real e imaginária respectivamente dos produtos SLC; *CF* o fator de calibração radiométrica, que corresponde ao valor de -83, e *A* o fator de conversão que é 32, determinados a partir de 572 pontos coletados e calibrados em nível global, incluindo também a floresta Amazônica (SHIMADA et al., 2010).

Os atributos derivados das Razões e Índice foram processados na medida de potência em escala linear (m^2/m^2).

A partir das decomposições de Cloude-Pottier, Freeman-Durden e Yamaguchi, Coeficientes de retroespalhamento e Índice Radar de Degradação Florestal foi possível extrair os atributos apresentados abaixo (Tabela 3.4):

Tabela 3.4 - Atributos extraídos a partir de dados polarimétricos.

Atributo Extraído	Símbolo	Descrição	Fonte	
A partir de informação das decomposições	Ângulo alfa	A	Mecanismo de espalhamento dominante	Cloude-Pottier (1996)
	Entropia	H	Número de mecanismos de espalhamento dominantes	
	Anisotropia	A	Mede a importância relativa do segundo e terceiro tipo de espalhadores	
	Espalhamento Volumétrico	P_v	Modelado por uma nuvem de dispersores cilíndricos e finos aleatoriamente distribuídos	Freeman-Durden (1998)
	Espalhamento <i>double-bounce</i>	P_d	Modelado a partir de duas superfícies ortogonais	
	Espalhamento Superficial	O_s	Parcela do espalhamento superficial	
	Espalhamento Volumétrico	Y_v	Nuvem de espalhadores cilíndricos e muito finos aleatoriamente distribuídos	Yamaguchi (et al.; 2005)
	Espalhamento <i>double-bounce</i>	Y_d	Modelado por duas superfícies ortogonais	
	Espalhamento Superficial	Y_s	Parcela do espalhamento superficial	
	Espalhamento do tipo hélice	Y_H	Espalhamento em forma de hélice	
A partir do retroespalhamento	Razão de Polarização Paralela	RP	Realça as diferenças entre às polarizações VV e HH	Henderson e Lewis (1998)
	Razão de Polarização Cruzada	RC	Parâmetro que indica a dominância entre os retroespalhamentos nas polarizações HV	
	<i>Radar Forest Degradation Index</i>	RFDI	Índices biofísicos extraídos a partir do retroespalhamento, que se relacionam com as características da estrutura florestal.	Saatchi et al., (2010)

Fonte: adaptado de MARTINS et al. (2016).

Os últimos procedimentos da etapa do pré-processamento foram à correção geométrica dos atributos por meio da geocodificação considerando o MDE, baseado no SRTM com resolução de 30 metros. Posteriormente foi realizado o mosaico das imagens dos respectivos anos de 2015 e 2016.

3.3.2. Seleção das amostras

A seleção das amostras de referência representativas de cada classe temática foi realizada a partir do conjunto amostral coletado em campo, previamente georreferenciado (Seção 3.2.3). Com o intuito de se obter um conjunto de treinamento de melhor representação de cada classe temática, as amostras selecionadas foram bem distribuídas ao longo da área de estudo, bem também, evitou-se selecionar áreas de bordas (i.e.: áreas de transições) a fim de diminuir a sobreposição entre as distribuições de probabilidades das classes temáticas e assim, minimizar as possíveis confusões entre as mesmas.

O *software* ENVI (4.7) foi utilizado para a seleção e vetorização das Regiões de Interesse (ROI) nas imagens SAR polarimétricas dos anos 2015 e 2016, respectivamente. Uma parte do conjunto de dados amostrais foi destinada para o treinamento do algoritmo de classificação, sendo a outra parte do conjunto utilizado para a validação dos mapeamentos (Tabela 3.5).

Buscou-se seguir uma proporção de aproximadamente 40,00% dos pixels de validação para as classes, respeitando no ano investigado, os limites espaciais de cada classe identificada. Proporções menores são decorrentes da menor extensão das classes.

Tabela 3.5 – Número de pixels selecionados para treinamento e validação das classes temáticas.

Classes	Sigla	2015			2016		
		Total Pixel	Treinamento Pixel/Proporção (%)	Validação Pixel/Proporção (%)	Total Pixel	Treinamento Pixel/Proporção (%)	Validação Pixel/Proporção (%)
Área cultivada	AC	111	68 (61,26)	43 (38,74)	141	87 (61,70)	54 (38,30)
Corpo d'água	CA	104	66 (63,46)	38 (36,54)	93	73 (78,49)	20 (21,51)
Floresta Degradada	DEGRAD	81	51 (62,97)	30 (37,03)	456	296 (64,91)	160 (35,09)
Floresta Primária	FP	306	187 (61,11)	119 (38,89)	183	112 (61,20)	71 (38,80)
Pasto Limpo	PL	79	49 (62,02)	30 (37,98)	83	49 (59,03)	34 (40,97)
Pasto Sujo	OS	34	21 (61,76)	13 (38,24)	40	23 (57,50)	17 (42,50)
Solo Exposto ou Preparado	SP	117	68 (58,12)	49 (41,88)	244	145 (59,43)	99 (40,57)
Sucessão Secundária Avançada	SSA	99	69 (69,70)	30 (30,30)	46	26 (56,52)	20 (43,48)
Sucessão Secundária Intermediária	SSInt	117	77 (65,81)	40 (34,19)	51	32 (62,74)	19 (37,26)
Sucessão Secundária Inicial	SSI	30	18 (60,00)	12 (40,00)	36	21 (58,33)	15 (41,67)

3.3.3. Seleção e análise exploratória dos atributos

Após a etapa de processamento das imagens PALSAR-2, foi realizada a seleção e análise dos dados, a fim de criar grupos compostos por atributos advindos das diferentes decomposições, de Cloude-Pottier (1996), Freeman-Durden (1998) e Yamaguchi et al., (2005), das Razões de polarização Paralela e Cruzada (Richards, 2009) e do *Radar Forest Degradation Index* (Saatchi, 1997) que apresentem potenciais para discriminar as classes temáticas investigadas. Estes grupos formados por diferentes atributos foram denominados de subconjuntos ótimos.

Com o intuito de avaliar a capacidade discriminatória de cada atributo extraído foi analisada a separabilidade das classes, verificando-se a consistência entre as amostras selecionadas correspondentes às diversas classes temáticas. Nesta análise foram utilizados os gráficos do tipo *boxplot* considerando para o entendimento discriminatório das informações radiométricas das componentes extraídas para expressar a configuração das diversas classes temáticas.

Os gráficos do tipo *boxplot* tem como objetivo fornecer informações sobre a distribuição e o aspecto do conjunto de dados. Ele é formado pelo primeiro, segundo (mediana), terceiro quartil e valor máximo (i.e., valores discrepantes – *outliers*). A partir da análise dos gráficos *boxplot* foi possível eliminar as amostras e os atributos que possuía baixa ou nenhuma capacidade para discriminar as classes investigadas.

Após esta seleção preliminar, foi utilizada a técnica de seleção de atributos a fim de explorar dentre o grupo de atributos existentes, quais deles possuíam maiores potencialidades para discriminar as classes temáticas para a posterior classificação dos dados. Esta seleção foi realizada no ambiente WEKA no qual, possibilita que métodos de seleção de atributos sejam aplicados sobre uma determinada base de dados.

Diversos testes com diferentes algoritmos de avaliação e de métodos de busca foram empregados, considerando para a análise o espaço de atributos, a relevância discriminatória de cada atributo em relação as classes e também, as combinações de maior variabilidade, até formar um subconjunto ótimo aquele que apresenta a melhor solução. Neste trabalho, utilizou-se a combinação entre o atributo avaliador *InfoGainAttributeEval* (MITCHELL, 1997) e o método de busca *Ranker* (HALL et al., 2009).

O algoritmo de seleção *InfoGainAttributeEval* seleciona os atributos medindo a taxa de ganho do atributo em relação a cada classe. Este tipo de avaliador combinado com o método de busca *Ranker* possibilita ranquear e selecionar os atributos através do ganho de informação e da redução da entropia.

3.3.4. Classificação e validação dos resultados

Na etapa de classificação foram empregadas as técnicas de classificação estatística por meio do classificador pontual MaxVer integrado ao classificador contextual ICM implementado no Classificador Polarimétrico 7 (CORREIA, 1999).

Foram realizadas as classificações dos subconjuntos ótimos dos respectivos anos (2015/2016), além das classificações tendo como entrada atributos combinados de acordo com as suas naturezas.

Após os resultados obtidos nas classificações e do conjunto de amostras de referência, foi necessário analisar a acurácia dos dados para que fosse possível avaliar a efetividade dos métodos empregados. Para isto, foi considerada a Matriz de Confusão, também denominada de Matriz de Erros que descreve os erros de inclusão (erros de comissão) e erros de exclusão (erros de omissão) presentes nas classificações. Segundo Congalton e Green (2009), a Matriz de Confusão é considerada uma das formas mais eficientes de representar a exatidão de uma classificação.

A partir dos resultados da classificação e do conjunto de dados de referência dispostos na Matriz de Confusão, foi possível calcular o Coeficiente de Concordância *Kappa*, sua variância e o Índice de Exatidão Global. A análise do *Kappa* é uma técnica multivariada discreta utilizada na avaliação da exatidão com o intuito de determinar estatisticamente se uma Matriz de Confusão é significativamente diferente de outra matriz (BISHOP et al., 1975). Esta medida de concordância é baseada na diferença da Matriz de Confusão, isto é, a diferença entre a concordância da classificação e os dados de referência e as chances de concordância (CONGALTON; GREEN, 2009).

Desta forma, o Coeficiente *Kappa* permite comparar e confrontar os resultados obtidos das classificações com o conjunto de dados de referência presentes da Matriz de Confusão e analisar o grau de aleatoriedade das classificações.

Ainda que o *Kappa* seja frequentemente utilizado nas análises de exatidão de mapeamento, segundo Gaboardi (2003) e Negri (2009), não há uma fundamentação teórica que indique quais níveis mínimos do Coeficiente *Kappa* aceitáveis em uma classificação, ou seja, não há uma definição sobre os níveis do *Kappa* que permita julgar os resultados obtidos. Como alternativa, Landis e Koch (1977) propuseram uma tabela (Tabela 3.6) com critérios qualitativos associados a diferentes intervalos do Coeficiente *Kappa*.

Tabela 3.6 – Índice de concordância *Kappa*.

Estatística <i>Kappa</i>	Força de Concordância
< 0,00	Pobre (péssimo)
0,00 - 0,20	Fraco (ruim)
0,21 - 0,40	Razoável
0,41 - 0,60	Moderado
0,61 - 0,80	Substancial
0,81 - 1,00	Quase perfeito

Fonte: adaptado de Landis e Koch (1977).

Posteriormente, foi realizado o teste de hipótese Z, proposto por Congalton e Green (2009) que pressupõem uma distribuição normal dos dados. Este teste pode ser utilizado para comparar estatisticamente duas classificações, sendo

possível determinar se dois ou mais valores independentes estimados de Coeficiente *Kappa*, provenientes de duas Matrizes de Confusão são significativamente diferentes entre si (CONGALTON; GREEN, 2009).

O teste estatístico Z é adequado a esta investigação, uma vez que serão realizadas classificações distintas, avaliadas a partir de um mesmo referencial e pode ser expresso pela Equação 3.1:

$$z = \frac{|\widehat{K}_1 - \widehat{K}_2|}{\sqrt{\widehat{var}(\widehat{K}_1) + \widehat{var}(\widehat{K}_2)}} \quad 3.1$$

Sendo \widehat{k}_1 e \widehat{k}_2 denotam as estimativas estatísticas do *Kappa* para as Matrizes de Confusão 1 e 2, enquanto $\widehat{var}(\widehat{k}_1)$ e $\widehat{var}(\widehat{k}_2)$ a variância de *Kappa*.

3.3.5. Detecção de mudança e validação dos resultados

Após a etapa de validação dos mapas, foi realizada a detecção de mudanças para identificar, discriminar e quantificar as diferenças apresentadas nas classificações no intervalo de tempo em análise. Foi utilizado o *software* ENVI (4.7) para calcular estatisticamente a detecção de mudanças com o objetivo de quantificá-las. Este método permite uma comparação em nível de área, porcentagem e pixel das perdas e ganhos entre todas as classes.

Para representar espacialmente as mudanças, foi empregado à técnica de mapa de diferença, que consiste na álgebra de mapas. Este método envolve a operação de subtração a partir do resultado da classificação do ano de 2015 pela classificação do ano de 2016. Importante citar que ambos os mapas gerados foram co-registrados anteriormente. Desse processo de diferença, obteve-se, um terceiro produto, denominado de “mapa de diferença” composto pelas variações na distribuição espacial temática e em área entre duas classificações. Um ponto relevante a ser comentado é que se optou na origem da proposta considerar a análise da dinâmica nesse curto período de ano (2015/2016), decorrente do uso somente de imagens PALSAR-2 de mesmas

características radiométricas, o que poderia resultar numa baixa dinâmica de modificações na paisagem. Porém, oportuna por demonstrar o potencial desses produtos-radar de recente disponibilização no mercado de usuários e, sobretudo, na capacidade de detecção também, de pequenas modificações ocorrentes na área Amazônica, podendo ser útil nos processos de fiscalização e controle ambiental.

Como subsídio no processo das validações das classificações, foi elaborado um mapa de referência. Ressalta-se que a elaboração do mapa foi necessária devido à ausência de mapas atuais (i.e., mapas do ano de 2016 ou 2017) que abrangem a temática abordada neste trabalho. Como por exemplo, os mapas de uso e cobertura da Amazônia Legal Brasileira desenvolvidos pelo TerraClass e disponíveis até o ano de 2014, como também, o mapa de uso e cobertura do Brasil disponível entre o período de 2000 a 2014, desenvolvido pelo IBGE.

O mapa de referência foi elaborado a partir de uma imagem multiespectral do sensor OLI. A imagem possui uma resolução espacial de 30 metros, resolução radiométrica de 16 bits e nível de processamento 1T, sendo que os produtos neste nível são ortorretificados, obtido no banco de dados da USGS/NASA. Para o recobrimento da área, foi utilizada imagem de órbita 227 e ponto 62 adquirida em 29 de junho de 2016.

A etapa de elaboração do mapa de referência também foi realizada no ambiente ENVI (4.7). Foram selecionadas as amostras de referência de cada classe temática a partir das amostras coletadas em campo, previamente georreferenciadas. O conjunto de dados amostrais selecionados para a elaboração do mapa de referência pode ser observado na Tabela 3.7.

Tabela 3.7 – Conjunto amostral selecionado para elaboração do mapa de referência.

Classes	Sigla	Total Pixel	Treinamento Pixel/Proporção (%)	Validação Pixel/Proporção (%)
Área cultivada	AC	124	81 (65,32)	43 (34,68)
Corpo d'água	CA	63	37 (58,73)	26 (41,27)
Floresta Degradada	DEGRAD	439	276 (62,87)	163 (37,13)
Floresta Primária	FP	127	78 (61,42)	49 (38,58)
Pasto Limpo	PL	64	39 (60,94)	25 (39,06)
Pasto Sujo	OS	39	24 (61,54)	15 (38,46)
Solo Exposto ou Preparado	SP	72	46 (63,89)	26 (36,11)
Sucessão Secundária Avançada	SSA	37	25 (67,57)	12 (32,43)
Sucessão Secundária Intermediária	SSInt	16	10 (62,50)	06 (37,50)
Sucessão Secundária Inicial	SSI	23	14 (60,87)	09 (39,13)

No processo de classificação da imagem OLI, utilizou-se o classificador *Support Vector Machine* (SVM). Este classificador consiste no método *Machine Learning* que emprega algoritmos de otimização para localizar os limites ideais entre as classes, ou seja, o SVM visa encontrar uma maior margem para separar diferentes classes. A separação entre as classes ocorre através de um hiperplano ótimo, onde este plano é orientado para maximizar a margem (i.e. a distância entre as bordas) e pelo ponto mais próximo de cada classe (VAPNIK, 1995).

Neste método ocorre uma minimização do risco empírico e do risco estrutural que equivale à minimização do erro de generalização, no qual envolve a determinação de um limiar a fim de diminuir ao máximo a possibilidade de classificações errôneas durante a etapa de testes (SANTOS, 2002).

O método apresenta bons resultados de classificação de dados complexos e ruidosos (CHANG; LIN, 2001) e é aplicado principalmente para problemas de reconhecimento de padrão (FOODY.; MATHUR, 2004).

A etapa de validação dos resultados da detecção de mudanças foi baseada no procedimento metodológico adotado por Azevedo (2013) que analisou imagens


multitemporais do sensor Cosmo-SkyMed para o mapeamento do uso e cobertura da terra no município de Humaitá, sul do estado do Amazonas. No presente trabalho, utilizou-se o *software* QGIS 2.18, onde foram criados aleatoriamente 260 pontos que contemplaram todas as classes temáticas. Posteriormente, foram realizadas análises de localização de cada ponto, com o intuito de que as dez classes temáticas fossem sorteadas com o maior número de pontos possível. Em seguida, foi realizada a comparação entre os pontos de validação criados e o mapa de referência associando uma classe temática a cada ponto, de acordo com a sua localização com o intuito de gerar a matriz de confusão e conseqüentemente obter o Índice *Kappa*.

4 RESULTADOS

4.1. Definição do tamanho da janela de filtragem

Através da inspeção visual (Figura 4.1), observou-se que, à medida que aumentou o tamanho da janela de filtragem, a imagem apresentou um aumento do efeito “borrado” das feições, conseqüentemente, pressupõem que houve perdas e degradações das informações espaciais, principalmente informações relacionadas à rugosidade das superfícies. Como por exemplo, na janela 9x9 pixels, que ocorreu maior suavização de algumas feições e bordas (Figura 4.2).

Figura 4.1 – Análise visual da atenuação do efeito *Speckle*.



Fonte: Produção do autor.

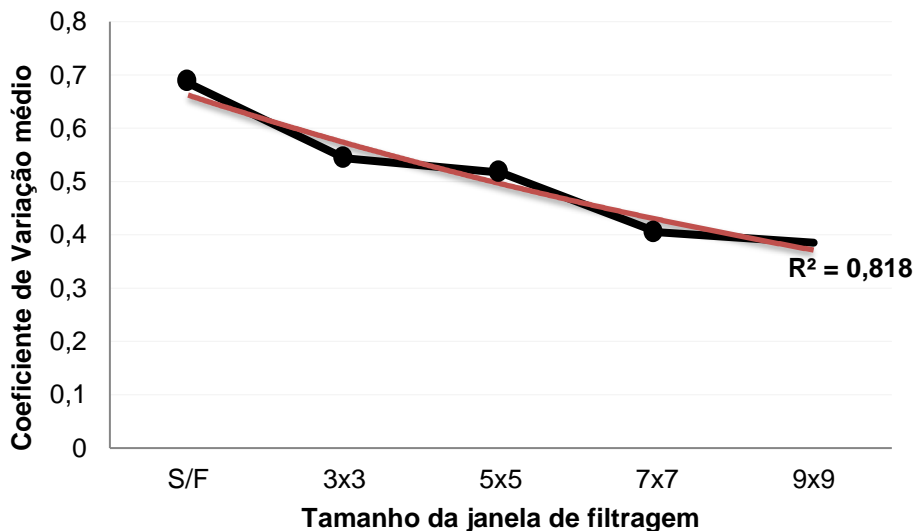
Figura 4.2 – Análise visual da suavização de bordas.



Fonte: Produção do autor.

Conforme metodologia adotada neste estudo, descrita na Seção 3.3.1, o CV médio apresentou uma redução de 0,6849 para 0,3908 da imagem sem filtro para uma janela de tamanho 9x9 pixels respectivamente, representando uma redução de 42,94% (Figura 4.3). Observou-se que 40,37% da redução do CV ocorreram até a janela 7x7. A janela de tamanho 9x9 apresentou 2,56% de redução do CV em relação à janela 7x7. A linha de tendência representada na Figura 4.3 com o coeficiente de determinação (R^2) de 0,810 pressupõe uma tendência de baixa alteração dos valores de CV para o tamanho de janela 9x9.

Figura 4.3 – Análise quantitativa da atenuação do efeito *Speckle*.



— S/F = Sem Filtragem do efeito *Speckle*.

— = Linha de tendência de Potência.


Fonte: Produção do autor.

Apesar do CV na janela 7x7 ter apresentado maior redução (40,37%) do efeito *Speckle*, foi determinado o tamanho de janela 5x5 pixels considerando que, na análise visual este tamanho de janela apresentou melhor preservação da integridade das informações espaciais representadas nas imagens SAR, principalmente nas áreas onde apresentam alta fragmentação da paisagem que compõem o recorte espacial sob investigação.

4.2. Sensibilidade dos atributos polarimétricos para discriminar as classes de uso e cobertura da terra


De acordo com a análise exploratória por meio de *boxplot* para o ano de 2015, os atributos da decomposição de Cloude-Pottier: Entropia (H) (Figura 4.4) e Ângulo Alfa (α) (Figura 4.5) não apresentaram um bom potencial discriminatório para distinguir os diferentes estádios de sucessões, havendo sobreposições das distribuições.

Figura 4.4- Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas para o ano de 2015 no atributo H da decomposição de Cloude-Pottier.




A similaridade radiométrica entre as classes de sucessões ecológicas, pode ser observada através dos valores de média de H para SSA ($H=0,95$), SSInt ($H=0,94$) e SSI ($H=0,92$). As sobreposições das distribuições das classes supracitadas, também podem ser constatadas através dos valores de média de α : 48° e 47° , respectivamente (Figura 4.5).

Figura 4.5 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo α da decomposição de Cloude-Pottier.




Destaca-se a potencialidade do atributo Anisotropia (A) (Figura 4.6), para discriminar a classe PS em relação às classes PL, AC, SP e CA, entretanto, neste atributo a separabilidade entre as classes PL e AC, e SP e CA são prejudicadas. O atributo α mostrou-se mais sensível às diferenças das classes AC, SP e CA (Figura 4.5).

Figura 4.6 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo A da decomposição de Cloude-Pottier.




No conjunto de atributos extraídos a partir da decomposição de Freeman-Durden, o atributo espalhamento volumétrico (P_v) apresentou a maior variabilidade com relação às respostas temáticas (Figura 4.7). As classes SSI, PS, PL, AC, SP e CA foram bem discriminadas por este atributo. Conforme esperado, a componente P_v obteve a maior contribuição na resposta do SAR para as classes FP e SSA, com valores de média de 111,82 e intervalo de distribuição de 109,70 a 113,68 para FP e média de 111,65 e intervalo de distribuição de 109,24 a 114,52 para SSA. Indicando assim, similaridade radiométrica entre as duas classes no atributo P_v .

Figura 4.7 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo P_v da decomposição de Freeman-Durden.




No espalhamento do tipo *double-bounce* (P_d), a classe SP apresentou uma média de 106,28, sendo este, considerado o maior valor com relação as demais classes temáticas investigadas (Figura 4.8). A classe CA exibiu o segundo maior valor, com média de 104,20. A classe AC também se apresentou bem discriminada por este atributo. Dentre as classes de diferentes estádios sucessionais analisadas, SSI obteve o maior valor, com uma média de 99,61.

Figura 4.8 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo P_d da decomposição de Freeman-Durden.




O atributo de espalhamento superficial (P_s) apresentou alto potencial para discriminar a AC das demais classes que possuem pouca e/ou sem a presença da vegetação, com um valor de média de P_s de 103,00 e com um intervalo de distribuição de 99,06 a 107,77 (Figura 4.9). Este atributo também demonstrou potencial para discriminar as classes SP e AC. Já as classes PS e PL, apresentaram, respectivamente, valores de média de 99,27 e 99,09 e intervalos de distribuições de 97,37 a 103,70 e 96,49 a 101,91, indicando, sobreposições das distribuições e conseqüentemente alta similaridade radiométrica.

Figura 4.9 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo P_s da decomposição de Freeman-Durden.




Com relação ao conjunto de atributos provenientes da decomposição de Yamaguchi, o atributo espalhamento *double-bounce* (Y_d) (Figura 4.10), apresentou um valor de média de 99,62 para a classe SSI, indicando uma maior sensibilidade de discriminação em relação as demais classes de sucessões ecológicas analisadas. As classes FP, SSA, SSInt e DEGRAD apresentaram, respectivamente, valores de média de 97,28, 97,14, 97,68 e 97,66. Estes resultados indicam que há similaridade entre as classes supracitadas. O atributo Y_d não apresentou capacidade na separabilidade entre as classes PS e PL. As classes SP e CA apresentaram os maiores valores, com média de 106,28 e 104,35, com intervalos de distribuição de 105,05 a 107,08 e 99,85 a 111,98, respectivamente. Estes resultados indicam que há similaridade entre as classes supracitadas.

Figura 4.10 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo Y_d da decomposição de Yamaguchi.




O atributo espalhamento volumétrico (Y_v) (Figura 4.11) apresentou alta capacidade na separabilidade entre as classes PS e PL. A classe AC também se apresentou bem discriminada por este atributo em relação às outras classes que em sua estrutura possuem pouca e/ou mesmo, ausência de uma cobertura vegetal. Em relação à classe Floresta Primária (FP) e aquela de Sucessão Secundária Avançada (SSA), FP apresentou um valor de média de 111,68 com intervalo de distribuição de 109,47 a 113,59 e para SSA com média de 111,53 e intervalo de 109,15 a 114,13, indicando, um baixo potencial deste atributo na separação entre as classes supracitadas. Provavelmente as classes FP e SSA possuem similaridade em suas respectivas características fisionômico-estruturais pelo elevado nível de desenvolvimento regenerativo que causou a semelhança nas respostas do atributo espalhamento volumétrico (Y_v).

Figura 4.11 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo Y_v da decomposição de Yamaguchi.




O atributo Y_s não exibiu capacidade para discriminar as classes em diferentes estádios sucessionais (Figura 4.12). Os valores de média de Y_s para FP (98,92), SSA (97,60), SSInt (97,53), SSI (101,33) e DEGRAD (95,18), com seus respectivos intervalos de distribuições de 94,25 a 103,97, 93,50 a 102,13, 93,50 a 102,11, 96,60 a 104,45 e 93,50 a 102,97, indicando sobreposições de distribuições entre as classes. Em relação às classes PS e PL, Y_s também apresentaram baixo potencial na separabilidade entre as classes supracitadas. As classes SP e CA apresentaram-se melhor discriminadas por este atributo em comparação com as demais classes.

Figura 4.12- Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo Y_s da decomposição de Yamaguchi.




O atributo do espalhamento do tipo em hélice (Y_H) específico da decomposição de Yamaguchi exibiu os maiores valores para as classes DEGRAD e FP (Figura 4.13) enquanto os menores valores estão associados às classes PS, PL e AC. Dentre as classes temáticas que apresentam pouca e/ou sem a presença da vegetação, a classe SP apresentou-se bem discriminado por este atributo.

Figura 4.13 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo Y_H da decomposição de Yamaguchi.




O atributo Razão de Polarização Cruzada (RC), extraído a partir do coeficiente de retroespalhamento (Figura 4.14), apresentou uma média de valores para PS (0,27), PL (0,26), AC (0,19), SP (0,16) e CA (0,13), denotando assim, uma pequena variação de valores médios, e conseqüentemente, uma baixa diferença radiométrica entre classes supracitadas. As classes de sucessões ecológicas, também apresentaram alta similaridade radiométrica, com uma média de 0,43 para FP, 0,41 para SSI e 0,45 para DEGRAD. Entretanto, RC apresentou maior potencial para discriminar as SSA e SSInt, com uma média de valores de 0,91 e 0,54 respectivamente.

Figura 4.14 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo RC.




A Razão de Polarização Paralela (RP) (Figura 4.15) exibiu os maiores valores de média para os diferentes estádios sucessionais, principalmente para as classes FP com média 2,19 e intervalo de distribuição de 0,162 a 5,613, SSA com média 2,09 e distribuição de 0,179 a 4,555 e SSInt com média de 2,49 e com um intervalo de 0,228 a 4,957. Os resultados demonstram que há uma sobreposição de distribuição, conseqüentemente, uma menor sensibilidade do atributo RC em separar a classe FP da classe SSA. Por sua vez, RC exibiu a maior capacidade para discriminar a classe CA das demais classes que apresentam pouca presença da vegetação.

Figura 4.15 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo RP.



Com relação para o atributo RFDI, os maiores valores obtidos (i.e., os valores de média acima de 0,6) estão relacionadas às áreas sem e/ou com pouca cobertura florestal (Figura 4.16). As diferentes classes ecológicas obtiveram os menores valores de média (abaixo de 0,5), sendo que, estas classes apresentaram uma baixa variação de valores médios, exceto a classe DEGRAD que obteve maior separabilidade no espaço de atributos que a define.

Figura 4.16 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2015 no atributo RFDI.



De acordo com os gráficos *boxplot* dos atributos da decomposição de Cloude-Pottier do ano de 2016, os atributos desta decomposição apresentaram boa capacidade para discriminar as classes de estádios ecológicos das classes sem e/ou com pouca presença da vegetação. Exibindo ainda, baixo potencial para separar as classes de diferentes sucessões florestais, principalmente nos atributos H e α , (Figuras 4.17 e 4.18).

Figura 4.17 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo H da decomposição de Cloude-Pottier.






Figura 4.18 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo α da decomposição de Cloude-Pottier.



Os altos valores de média de H para as classes FP ($H= 0,945$), SSA ($H=0,942$), SSInt ($H=0,945$), e SSI ($H=0,926$), denota, portanto, uma similaridade radiométrica entre as classes. Através do atributo Ângulo Alfa (α), também se constata as sobreposições de distribuições. Os valores de média de α para as classes FP, SSA, SSInt e SSI foram respectivamente $47,2^\circ$, $46,9^\circ$, $48,7^\circ$ e $48,1^\circ$. As classes SP e CA também apresentaram altos valores de α , com médias de $57,0^\circ$ e $55,0^\circ$, respectivamente.


O atributo A exibiu a maior sensibilidade aos diferentes estádios de sucessão (Figura 4.19), apresentando respectivamente valores de média para as classes FP, SSA, SSInt, SSI e DEGRAD de 0,10, 0,09, 0,17, 0,21, 0,14, indicando uma maior variabilidade de respostas radiométricas das classes supracitadas quando comparado com os atributos H e α . O atributo A , mostrou-se ainda mais sensível que os demais atributos para discriminar as classes DEGRAD, PS, PL, AC, SP e CA.

Figura 4.19 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo A da decomposição de Cloude-Pottier.



O atributo P_v exibiu maior variabilidade de resposta radiométrica para as classes SSI, PS, PL, AC, SP e CA (Figura 4.20). Destaca-se a sensibilidade às diferenças entre as classes PS e PL. As classes FP e SSA apresentaram respostas radiométricas similares, o que dificulta a diferenciação e separabilidade das mesmas. Contudo, FP e SSA apresentaram os maiores valores, no qual possibilitou distingui-las em relação às classes SSInt e SSI com uma média de valor para FP (111,18), SSA (111,12), SSInt (110,48) e SSI (109,15).


Figura 4.20 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo P_v da decomposição de Freeman-Durden.



Na componente P_d , as classes SP e CA apresentaram os maiores valores em relação as demais tipologias analisadas, com média de 107,96 e 107,25 respectivamente (Figura 4.21). De acordo com a análise das classes com diferentes estádios sucessionais, a classe SSI apresentou maior valor, com uma média de 102,29, seguida pela classe SSInt com 98,98. As classes PS e PL não foram bem discriminadas por este atributo, apresentando uma média de


valor para PS de 100,08 com intervalo de distribuição de 97,63 a 102,97, e para PL uma média de 99,37 com distribuição de 97,14 a 101,20.

Figura 4.21 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo P_d da decomposição de Freeman-Durden.



O atributo P_s obteve maior separabilidade entre as classes SSInt, SSI e DEGRAD, com destaque para a classe SSI que apresentou maior valor em relação as diferentes classes de sucessão (Figura 4.22). Os maiores valores foram obtidos para as classes que apresentam pouca e/ou sem a presença da vegetação, exibindo potencial para discriminação entre as classes PS e PL e a classe CA das demais classes sem a presença da vegetação. O atributo P_s apresentou baixa capacidade na separabilidade entre as classes AC e SP, exibindo respectivamente uma média de valores de 103,84 e 104,12.


Figura 4.22 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo P_s da decomposição de Freeman-Durden.



O atributo Y_v , (Figura 4.23) apresentou baixo potencial para discriminar a classe FP em relação a classe SSA, como pode ser observado pelos valores de média de 110,89 e intervalo de distribuição de 109,82 a 112,13 para FP e média de 111,01 e distribuição de 109,28 a 112,20 para SSA, indicando assim, a sobreposição entre as classes. Já as classes SSInt e SSI apresentaram-se melhor discriminadas, quando comparadas com as classes FP e SSA. A classe SSInt obteve média de 110,21 e distribuição num intervalo de 109,20 a 111,18 e SSI média de 108,46 e distribuição de 107,97 a 110,50.


As classes com menor e/ou sem presença da vegetação obtiveram boa separabilidade pelo atributo Y_v , indicando que este atributo apresenta capacidade para discriminar principalmente as classes PS, PL, AC, SP e CA.

Figura 4.23 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo Y_v da decomposição de Yamaguchi.




O atributo Y_d (Figura 4.24), não apresentou potencial na separabilidade das classes FP e SSA, indicando uma similaridade radiométrica entre as classes, como pode ser observado pelos valores de média e distribuição de ambas as classes. Sendo que, FP obteve uma média de 96,97 e distribuição de 92,35 a 101,09 e para SSA uma média de 97,46 e distribuição de 93,95 a 101,89. Dentre as classes de sucessão ecológica investigadas, SSI apresentou o maior valor, com média de 101,04, seguida por SSInt com média de 99,74 e por DEGRAD com média de 98,03. O atributo, não obteve bom desempenho na diferenciação das classes PS, PL e AC. As classes SP e CA foram melhor discriminadas, apresentando os maiores valores em relação as demais tipologias analisadas. SP apresentou um intervalo de distribuição de 100, 50 a 115,41 e média de 108,01 e CA com distribuição de 105, 00 a 109,91 e média de 107,10.

Figura 4.24 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo Y_d da decomposição de Yamaguchi.




A componente P_s apresentou baixa variabilidade das respostas radiométricas para as diferentes classes de sucessão ecológica, exibindo baixo potencial para discriminá-las, conforme pode ser observado na Figura 4.25. Os maiores valores foram exibidos pelas classes que apresentam menor presença da vegetação. A classe CA apresentou-se bem discriminada pelo atributo Y_s , entretanto, este mesmo atributo não exibiu sensibilidade na separabilidade entre as classes PS, PL e AC, obtendo respectivamente um valor de média de 102,00, 102,85 e 103,92.

Figura 4.25 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo Y_s da decomposição de Yamaguchi.




O espalhamento em Hélice apresentou sobreposições de distribuições para as diferentes classes de sucessões ecológicas (Figura 4.26), principalmente com relação às classes FP, SSA e DEGRAD, com média de 95,58, 95,54 e 95,71, respectivamente. As classes com pouca e/ou sem a presença da vegetação também não se apresentaram bem discriminadas por este atributo.

Figura 4.26 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo Y_H da decomposição de Yamaguchi.




O atributo RC apresentou alta similaridade radiométrica para as classes AC, SP e CA, com uma média de 0,13, 0,12 e 0,14 respectivamente (Figura 4.27). As classes de diferentes estádios de sucessão ecológica apresentaram uma média de valores para SSA de 0,44, e intervalo de distribuição de 0,32 a 0,77, SSInt com média de 0,30 e distribuição entre o intervalo de 0,18 a 0,56 e SSI com média de 0,25 e intervalo de 0,19 a 0,39, denotando assim, uma maior separabilidade destas classes para os diferentes estádios de sucessão.

Figura 4.27 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo RC.




Com relação à RP (Figura 4.28), os maiores valores de retroespalhamento obtidos para as classes temáticas de diferentes estádios sucessionais estão relacionadas com FP e SSA, com média de valores de 2,66 e 2,53 respectivamente. Os menores valores foram obtidos pelas classes SSInt e SSI, com média de 1,26 e 0,98 respectivamente. As classes PS e PL apresentaram alta similaridade radiométrica, não sendo possível diferenciá-las a partir do atributo. Já as classes AC, SP e CA apresentaram-se bem discriminadas por este atributo.

Figura 4.28 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo RP.



O RFDI exibiu os menores valores para às classes FP, SSA, SSInt e DEGRAD, com uma média de valores de, 0,48, 0,46, 0,56 e 0,49, respectivamente, (Figura 4.29). Os valores acima de 0,56 são exibidos pelas classes SSI, PS, PL, AC, SP e CA. Observa-se na análise do gráfico *boxplot* que o atributo RFDI apresenta baixa capacidade para diferenciação discriminatória entre as classes AC, SP e CA, como também entre as classes PS e PL.


Figura 4.29 - Gráfico *boxplot* representando o quartil inferior, superior e mediana das distribuições das classes temáticas em 2016 no atributo RFDI.



4.3. Seleção do subconjunto ótimo

Na seleção dos subconjuntos ótimos de atributos dos anos de 2015 e 2016, considerou-se o ordenamento dos atributos representados pelo *ranking* de importância, conforme apresentados nas Figuras 4.30 e 4.31.

Figura 4.30 - *Ranking* segundo a importância dos atributos em relação a todas as classes do ano 2015.




O atributo que apresentou maior importância no *ranking* do ano de 2015 foi a Entropia (H), seguindo sequencialmente pelas referências de maiores posições no *ranking* a anisotropia (A), ângulo alfa (α), espalhamento volumétrico de Freeman-Durden (P_v), espalhamento volumétrico de Yamaguchi (Y_v) e o *Radar Forest Degradation Index* (RFDI) (Figura 4.30). Observa-se um decaimento de 25% da medida de importância entre os atributos RFDI e o espalhamento *double-bounce* de Yamaguchi (Y_d). Assim, preliminarmente foram excluídos os atributos que apresentaram baixa ou nenhuma sensibilidade às classes temáticas, segundo o *ranking* de medida de importância. Os atributos excluídos foram: espalhamento *double-bounce* de Yamaguchi (Y_d), espalhamento *double-bounce* de Freeman-Durden (P_d), razão de polarização cruzada (RC), espalhamento superficial (Y_s) e em hélice de Yamaguchi (Y_h), espalhamento superficial de Freeman-Durden (P_s) e a razão de polarização

De acordo com o *ranking* de importância dos atributos referente ao ano de 2016 (Figura 4.31), o atributo que apresentou maior relevância foi o espalhamento volumétrico de Freeman-Durden (P_v), seguido pelos atributos do

ranking de maiores posições a anisotropia (A), entropia (H), ângulo alfa (α) e o RFDI. Pode-se observar um decaimento de aproximadamente 12% entre os atributos RFDI e o espalhamento *double-bounce* de Freeman-Durden (P_d), sendo assim, no ano de 2016, também foram excluídos os atributos que apresentaram baixa ou nenhuma capacidade discriminatória. Os atributos excluídos preliminarmente foram o espalhamento *double-bounce* de Freeman-Durden (P_d), razão de polarização cruzada (RC), espalhamento *double-bounce* de Yamaguchi (Y_d), espalhamento superficial de Freeman-Durden (P_s), espalhamento em hélice e superficial de Yamaguchi (Y_H) e razão de polarização paralela (RP).

Figura 4.31 - *Ranking* segundo a importância dos atributos em relação a todas as classes do ano 2016.



Ainda que, utilizado um minerador de dados para selecionar os atributos que apresentam um maior potencial discriminatório considerando a redução da correlação entre os mesmos, observa-se na Figura 4.31 que os atributos espalhamento volumétrico de Freeman-Durden (P_v) e espalhamento volumétrico de Yamaguchi (Y_v) exibiram alta correlação entre si. Segundo a medida de importância, os valores apresentados por estes atributos são de

1,924 e 1,893, respectivamente, o que corresponde uma diferença de aproximadamente 1,6%. Considerando a alta correlação entre estes atributos, foi excluído o atributo Y_v .

A partir da análise preliminar das medidas de importância dos atributos, foram realizadas as melhores combinações dos mesmos, considerando o potencial discriminatório das classes temáticas, a variabilidade dos subconjuntos e os Índices *Kappa* obtidos a partir dos resultados das classificações dos anos 2015 e 2016, como podem ser observados na Tabela 4.1.

Tabela 4.1 – Valores de *Kappa* obtidos a partir das classificações dos Subconjuntos Ótimos de 2015 e 2016.

2015			2016		
Subconjuntos	Número de atributos	<i>Kappa</i>	Subconjuntos	Número de atributos	<i>Kappa</i>
H, A, α, P_v	4	0,75	H, A, α, P_v	4	0,74
H, A, α, P_v, Y_v	5	0,75	H, A, α, P_v, Y_v	5	0,74
$H, A, \alpha, P_v, Y_v, RFDI$	6	0,73	$H, A, \alpha, P_v, Y_v, RFDI$	6	0,79

Nos subconjuntos do ano de 2015, observa-se uma pequena variação do Índice *Kappa* conforme o acréscimo de atributos. Já no ano de 2016, no subconjunto com seis atributos, pode-se constatar um maior aumento no Índice *Kappa* (0,79) em relação aos demais subconjuntos do respectivo ano, e também, em comparação ao grupo de seis atributos do ano de 2015 (Tabela 4.1). Para selecionar o subconjunto ótimo para as análises realizadas na Seção 4.4 foram considerados a similaridade dos valores entre os Índices *Kappa*, a combinação dos mesmos atributos, bem como, a igualdade do número destes atributos nos respectivos anos de 2015 e 2016. Assim, o melhor subconjunto ótimo selecionado para os respectivos anos foram constituídos por quatro atributos: H, A, α, P_v .

4.4. Classificações

Conforme pode ser observado na Tabela 4.2, os melhores conjuntos de dados classificados foram obtidos a partir da decomposição de Cloude-Pottier que apresentou valores de *Kappa* de 0,78 e 0,75 nos anos de 2015 e 2016 respectivamente. E o segundo melhor resultado foi obtido pelo grupo de atributos do subconjunto ótimo, com valores *Kappa* de 0,75 para o ano de 2015 e de 0,74 no ano de 2016.

Tabela 4.2 – Valores de *Kappa* obtidos a partir das classificações de 2015 e 2016.

Atributos polarimétricos	<i>Kappa</i>	
	2015	2016
Cloude-Pottier	0,78	0,75
Freeman-Durden	0,56	0,56
Yamaguchi	0,58	0,61
Razão Pol. Cruzada (RC)	0,23	0,20
Razão Pol. Paralela (RP)	0,14	0,13
<i>Radar Forest Degradation Index</i> (RFDI)	0,28	0,23
Subconjunto ótimo	0,75	0,74

Ainda, de acordo com os valores *Kappa*, os melhores resultados obtidos a partir das classificações foram das decomposições de Cloude-Pottier, Freeman-Durden, Yamaguchi e do subconjunto ótimo em ambos os anos. As classificações a partir das razões RC e RP, e do RFDI apresentaram desempenhos inferiores. Constatando-se assim, que para este estudo, as classificações a partir dos dados complexos demonstraram desempenho superior às classificações a partir dos dados em amplitude.

A diferença estatística entre a classificação a partir da decomposição de Cloude-Pottier e RC foi de 15,63 e 17,64, e de 18,79 e 21,42 em relação à RP nos anos de 2015 e 2016 respectivamente. Ainda, comparando a classificação de Cloude-Pottier com o RFDI, a diferença estatística foi de 14,31 no ano de 2015 e 16,53 em 2016 (Tabela 4.3).

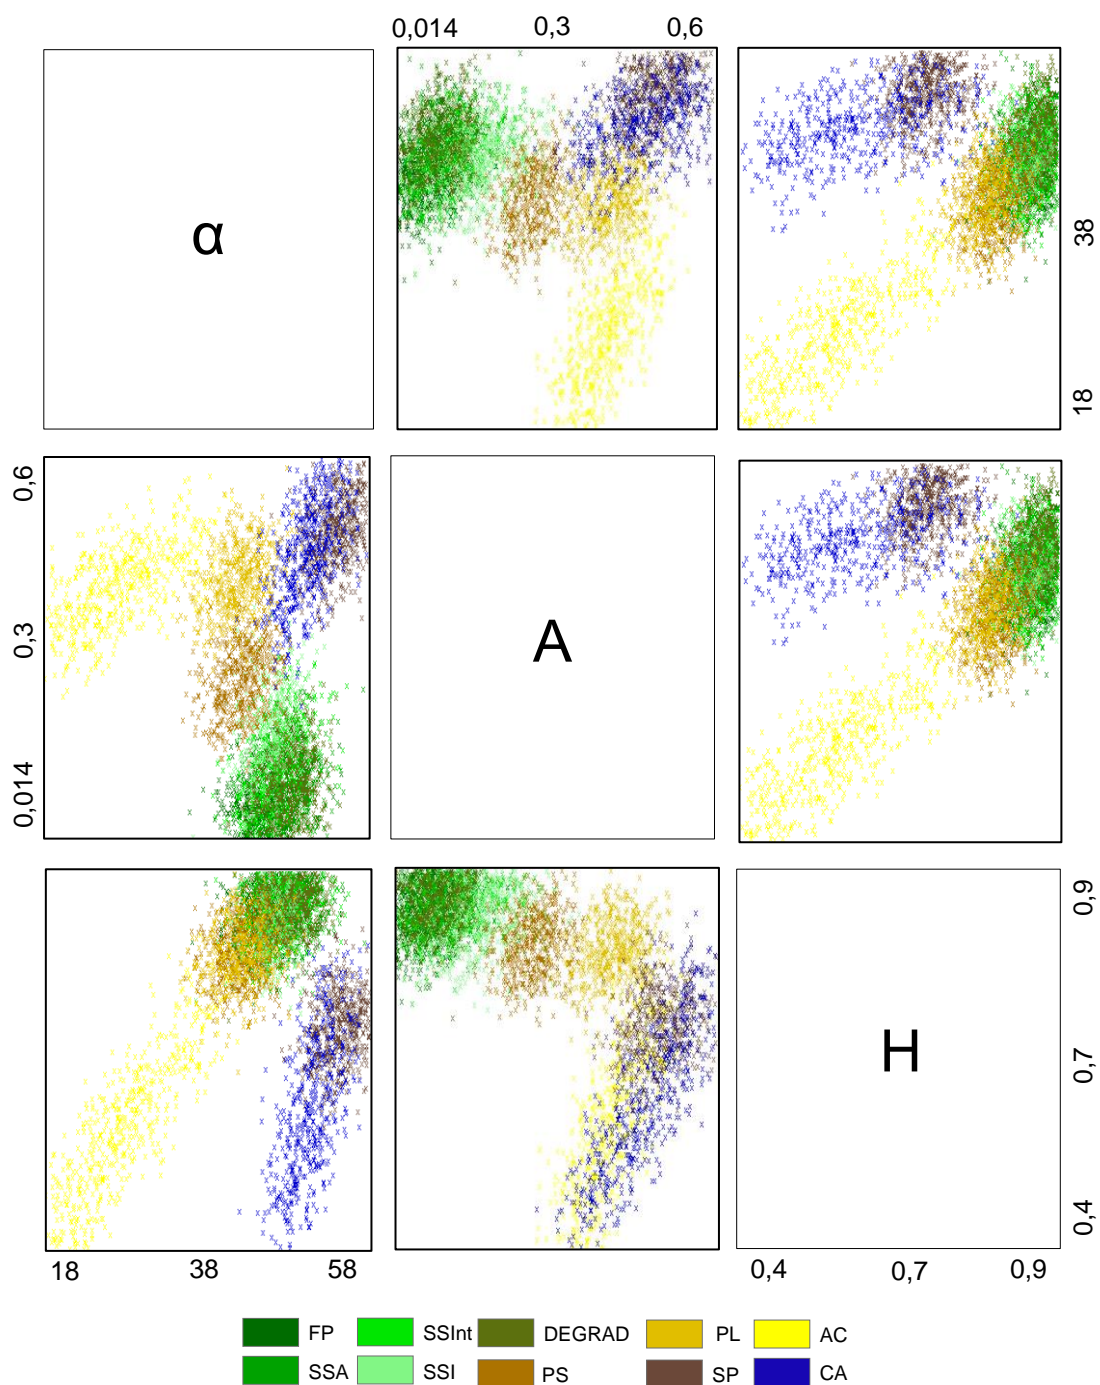
Tabela 4.3 - Teste Z aplicado aos valores Kappa das classificações realizadas para os anos de 2015 e 2016.

	Cloude Pottier	Freeman Durden	Yamaguchi	RC	RP	RFDI	Sub-conjunto ótimo
2015							
Cloude-Pottier	0,00						
Freeman Durden	6,27	0,00					
Yamaguchi	5,69	-0,52*	0,00				
RC	15,63	8,58	9,08	0,00			
RP	18,79	11,23	11,73	2,40	0,00		
RFDI	14,31	7,33	7,83	-1,30*	-3,75	0,00	
Subconjunto ótimo	0,93*	-5,31	-4,74	-14,50	-17,55	-13,19	0,00
2016							
Cloude Pottier	0,00						
Freeman Durden	5,92	0,00					
Yamaguchi	4,39	-1,47*	0,00				
RC	17,64	10,81	12,40	0,00			
RP	21,42	14,14	15,79	3,16	0,00		
RFDI	16,53	9,83	11,40	-0,92*	-4,07	0,00	
Subconjunto ótimo	0,33*	-5,55	-4,04	-14,50	-17,15	-16,05	0,00

*Diferença não significativa no intervalo de 95% de confiança

Ao analisar o espaço bidimensional dos atributos da decomposição de Cloude-Pottier para o ano de 2015 (Figura 4.32), observa-se que a combinação entre os atributos α e A , favorece a discriminação das classes PS, PL e AC. A matriz de confusão (Tabela 4.4) evidencia a assertividade de 100% das classes supracitadas. Já a combinação entre H e A , demonstra bom desempenho para discriminar a classe CA, não ultrapassando 11,00% de confusão entre as classes CA e AC (Tabela 4.4).

Figura 4.32 – Espaço de atributos de acordo com a decomposição de Cloude-Pottier do ano de 2015 para as classes de uso e cobertura da terra.



Ainda, de acordo com a análise do espaço bidimensional, todas as combinações de pares de atributos apresentam baixa capacidade em distinguir os diferentes estádios de sucessão ecológica, principalmente entre as classes

SSA, SSInt, SSI e DEGRAD. Como pode ser observado na matriz de confusão da Tabela 4.4, o percentual de acerto de SSA é de 63,33%, SSInt de 20,00%, SSI de 50,00% e DEGRAD de 46,67%. Assim, constata-se que o menor desempenho classificatório dos atributos extraídos da decomposição de Cloude-Pottier é da classe SSInt e os melhores desempenhos são das classes PS, PL e AC.

Tabela 4.4 - Matriz de confusão da classificação da Decomposição de Cloude-Pottier do ano de 2015.

		REFERÊNCIA (%)									
		FP	SSA	SSInt	SSI	DEGRAD	PS	PL	AC	SP	CA
CLASSIFICAÇÃO (%)	FP	82,36	26,67	10,00	0,00	3,33	0,00	0,00	0,00	0,00	0,00
	SSA	14,28	63,33	35,00	0,00	50,00	0,00	0,00	0,00	0,00	0,00
	SSInt	0,84	10,00	20,00	50,00	0,00	0,00	0,00	0,00	0,00	0,00
	SSI	0,00	0,00	0,00	50,00	0,00	0,00	0,00	0,00	0,00	0,00
	DEGRAD	2,52	0,00	35,00	0,00	46,67	0,00	0,00	0,00	0,00	0,00
	OS	0,00	0,00	0,00	0,00	0,00	100,00	0,00	0,00	0,00	0,00
	PL	0,00	0,00	0,00	0,00	0,00	0,00	100,00	0,00	0,00	0,00
	AC	0,00	0,00	0,00	0,00	0,00	0,00	0,00	100,00	0,00	0,00
	SP	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	100,00	10,50
	CA	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	89,50

O grupo de atributos classificados a partir do subconjunto ótimo do ano de 2015 apresentou um valor *Kappa* de 0,75. De acordo com a matriz de confusão (Tabela 4.5), os melhores resultados obtidos com percentual de acerto acima de 80,00%, foram para as classes FP, PL, AC, SP e CA.

Tabela 4.5 - Matriz de confusão da classificação do subconjunto ótimo do ano de 2015.

		REFERÊNCIA									
		FP	SSA	SSInt	SSI	DEGRAD	PS	PL	AC	SP	CA
CLASSIFICAÇÃO (%)	FP	83,19	26,67	5,00	8,33	13,33	0,00	0,00	0,00	0,00	0,00
	SSA	15,13	43,33	45,00	0,00	23,33	0,00	0,00	0,00	0,00	0,00
	SSInt	0,84	20,00	25,00	75,00	0,00	0,00	0,00	0,00	0,00	0,00
	SSI	0,00	0,00	0,00	16,67	0,00	0,00	0,00	0,00	0,00	0,00
	DEGRAD	0,84	10,00	25,00	0,00	63,34	0,00	0,00	0,00	0,00	0,00
	OS	0,00	0,00	0,00	0,00	0,00	30,77	0,00	0,00	0,00	0,00
	PL	0,00	0,00	0,00	0,00	0,00	69,23	100,00	6,98	0,00	0,00
	AC	0,00	0,00	0,00	0,00	0,00	0,00	0,00	93,02	0,00	0,00
	SP	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	100,00	0,00
	CA	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	100,00

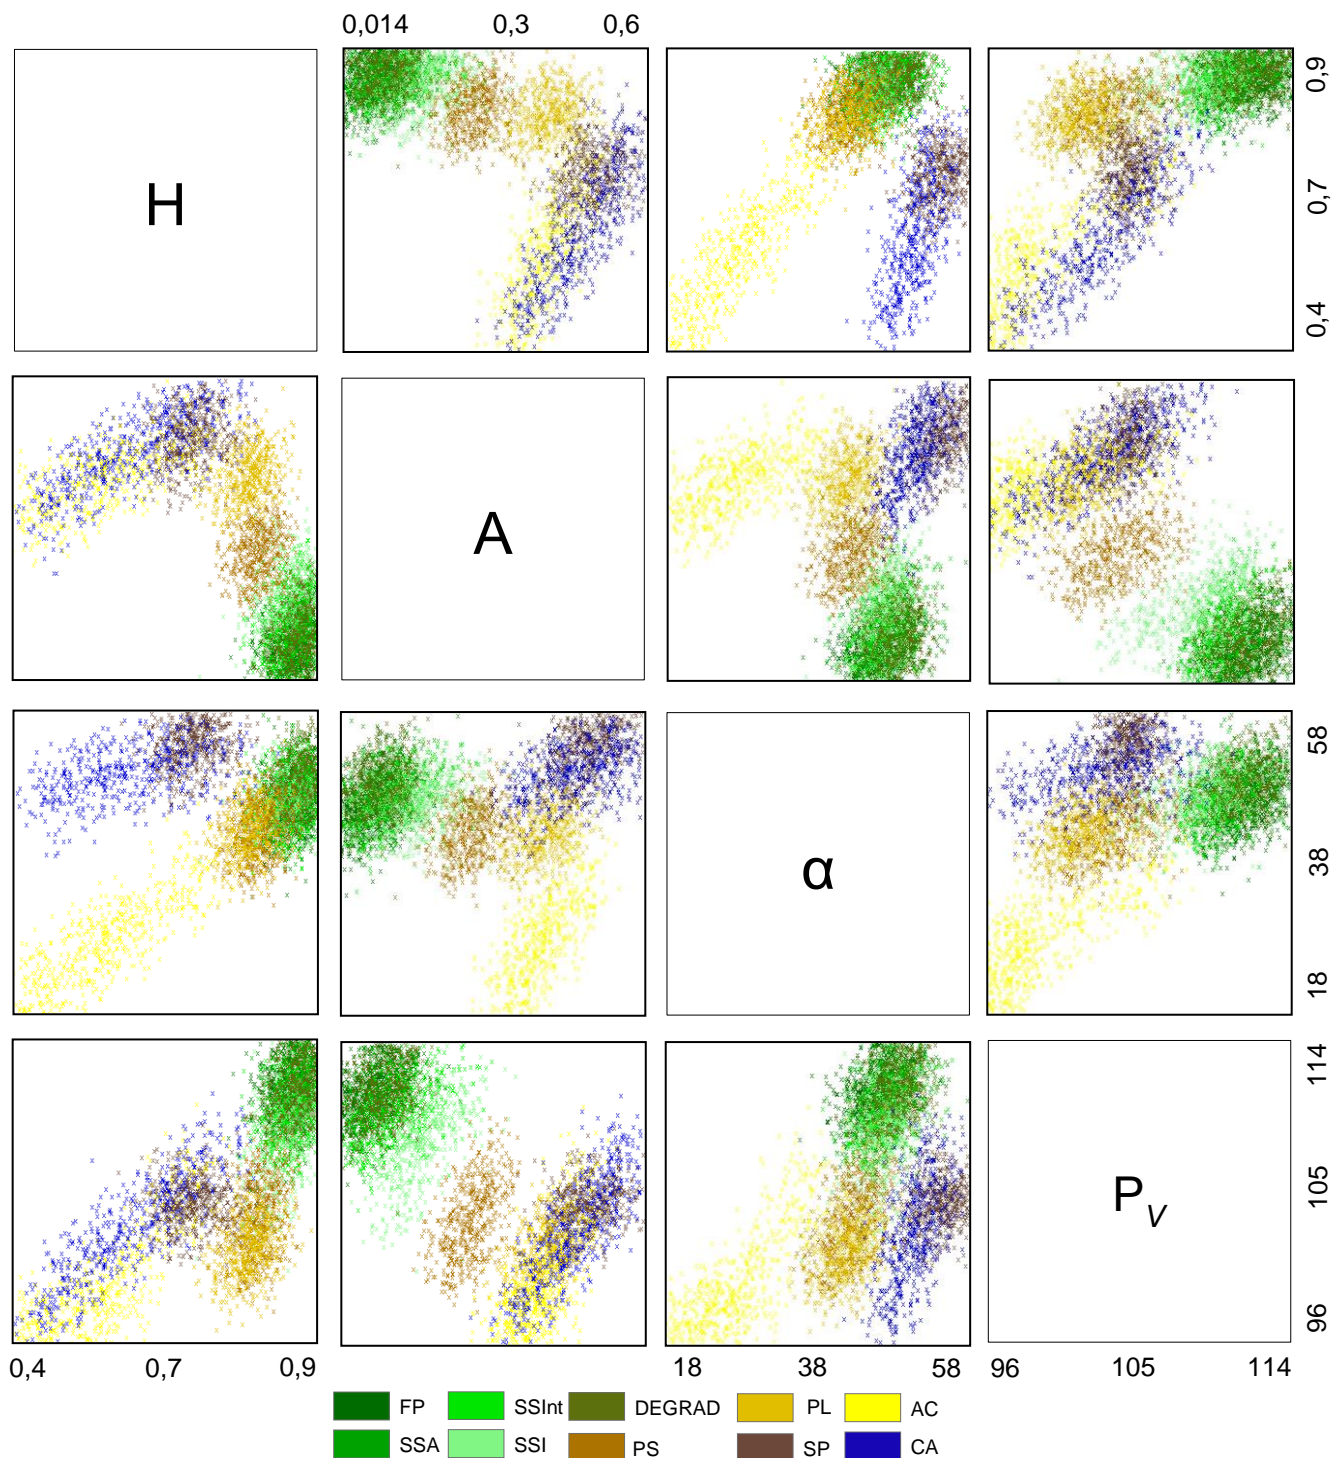
Os resultados da classificação a partir do grupo de atributos do subconjunto ótimo corroboram com alguns resultados obtidos a partir da análise visual dos espaços de atributos (Figura 4.33). O par de atributos H e A exibiu alto potencial discriminatório para a classe PL. A classe AC apresentou-se bem discriminada nos pares de atributos H e α , A e α , e também nos pares P_v e α , indicando assim, a alta contribuição do atributo α para discriminar esta classe. Já a classe CA foi melhor discriminada principalmente pelo par de atributos H e α .

Dentre as classes que apresentaram um resultado classificatório com percentual de acerto acima de 80,00% (Tabela 4,5), conforme supracitado, apenas as classes FP e SP ao serem analisadas em todas as combinações de pares de atributos, exibiram espaços de atributos com baixa separabilidade.

A Matriz de confusão da Figura 4.5, evidencia o baixo desempenho classificatório das classes de diferentes estádios sucessionais. A classe SSA apresentou percentual de 43,33% de acerto, sendo que 26,67% das amostras foram erroneamente classificadas como FP, 20,00% como SSInt e 10,00%

como DEGRAD. A classe SSInt teve 75,00% das suas amostras classificadas erroneamente como FP, SSA e DEGRAD. A classe SSI apresentou o mais baixo percentual de acerto, 16,67%, sendo, 75,00% das amostras classificadas erroneamente como SSInt e 8,33% como FP.


Figura 4.33 – Espaço de atributos de acordo com o subconjunto ótimo do ano de 2015 para as classes de uso e cobertura da terra.



O par de atributos A e P_v exibiu espaços de atributos com alta separabilidade da classe PS, porém, na matriz de confusão (Tabela 4.5), pode-se observar que esta classe não apresentou bom desempenho classificatório, tendo 69,23% das suas amostras classificadas erroneamente como PL.

A partir das análises realizadas, foi elaborado o mapa de uso e cobertura da terra do ano de 2015 utilizando o grupo de atributos do subconjunto ótimo (H , A, α e P_v), conforme representado pela Figura 4.34.

Figura 4.34 – Mapa de uso e cobertura da terra 2015 da área de estudo elaborada a partir da classificação do subconjunto ótimo.



Segundo a análise do espaço bidimensional dos atributos da decomposição de Cloude-Pottier do ano de 2016 (Figura 4.35), as combinações entre os atributos α e A , como também, entre α e H , favorecem a discriminação da classe AC. Como pode ser observado na matriz (Tabela 4.6), houve a assertividade de 88,89% da classe supracitada. As combinações entre os atributos A e α , e, H e A apresentam alta capacidade para discriminar a classe PL. A matriz (Tabela 4.6) evidencia que não houve confusão, evidenciando 100,00% de acerto desta classe durante o processo de classificação.

A combinação entre os atributos α e A , demonstra a alta capacidade para discriminar às classes PS e SP. De acordo com a matriz de confusão (Tabela 4.6) a classe PS apresenta 94,12% de acerto na classificação, havendo uma confusão de 5,88% com a classe SSInt. Já a classe SP apresenta 100,00% de assertividade.

Ainda conforme pode ser observado do espaço bidimensional de atributos, todas as combinações de pares de atributos obtiveram baixa capacidade para diferenciar as classes FP, SSA, SSInt, SSI e DEGRAD. Na matriz de confusão (Tabela 4.6) é possível averiguar as confusões geradas entre as classes supracitadas durante o processo de classificação. Sendo o percentual de acerto das classes de FP, SSA, SSInt, SSI e DEGRAD de 40,84%, 65,00%, 31,58%, 53,34% e 64,37% respectivamente. O menor desempenho da classificação neste grupo de atributos é da classe SSInt e os maiores são das PL e AC.

Figura 4.35 – Espaço de atributos de acordo com a decomposição de Cloude-Pottier do ano de 2016 para as classes de uso e cobertura da terra.

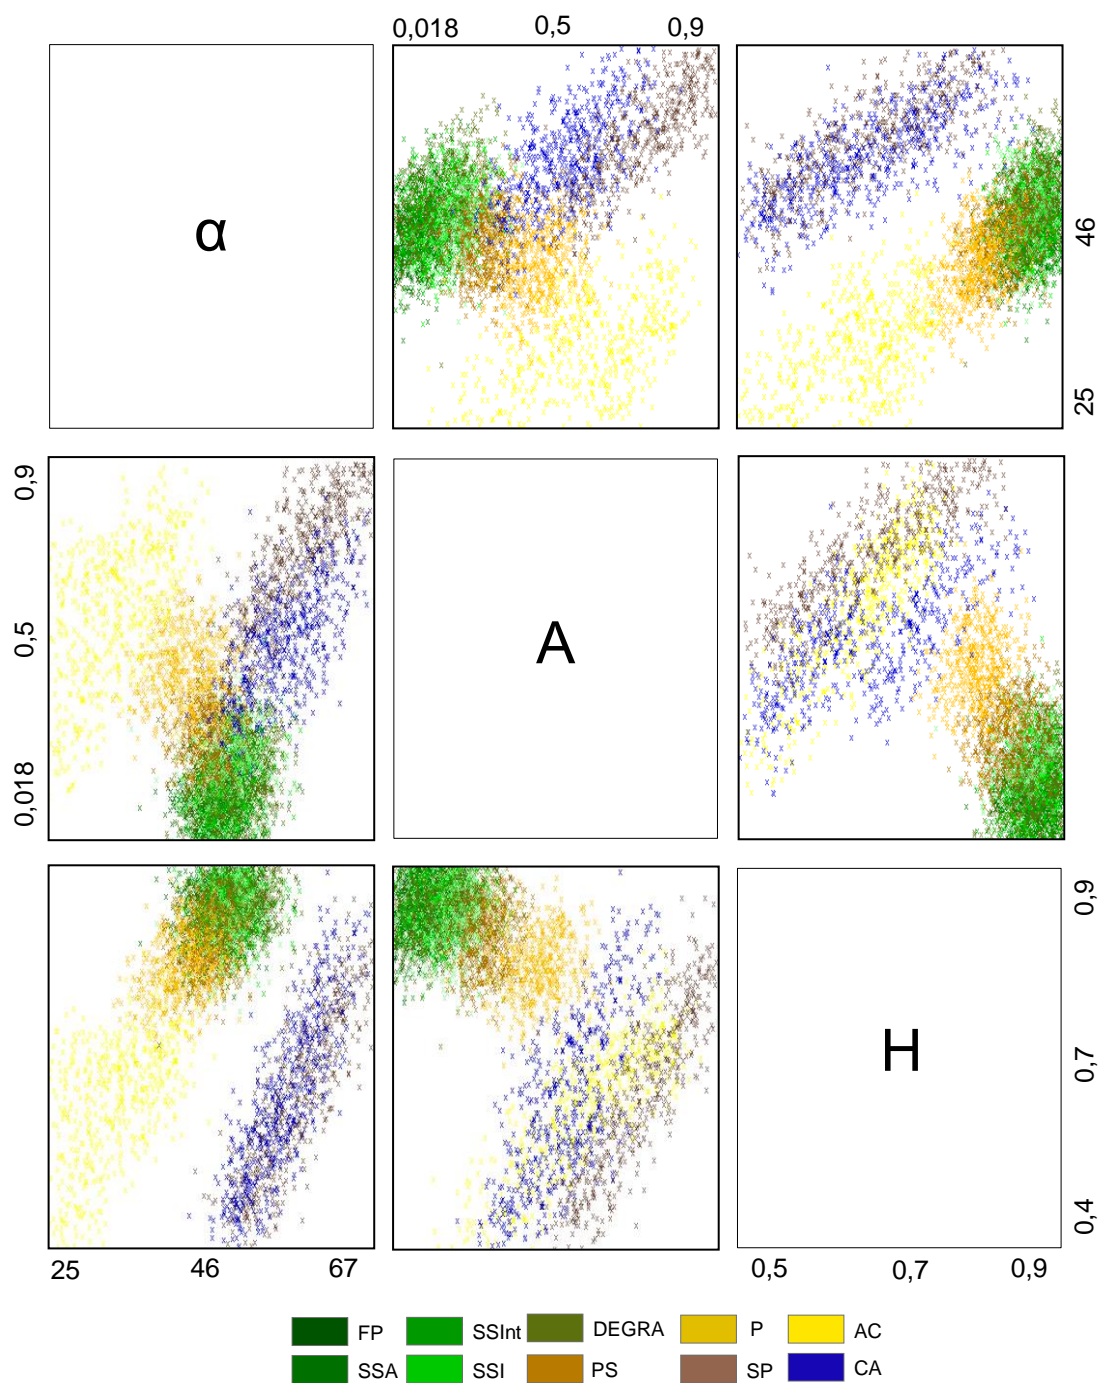


Tabela 4.6 - Matriz de confusão da classificação da Decomposição de Cloude-Pottier do ano de 2016.

		REFERÊNCIA (%)									
		FP	SSA	SSInt	SSI	DEGRAD	PS	PL	AC	SP	CA
CLASSIFICAÇÃO (%)	FP	40,84	25,00	10,53	0,00	13,12	0,00	0,00	0,00	0,00	0,00
	SSA	39,44	65,00	0,00	0,00	3,75	0,00	0,00	0,00	0,00	0,00
	SSInt	11,27	10,00	31,58	0,00	15,62	5,88	0,00	0,00	0,00	0,00
	SSI	0,00	0,00	5,26	53,34	2,50	0,00	0,00	0,00	0,00	0,00
	DEGRAD	8,45	0,00	52,63	33,33	64,37	0,00	0,00	0,00	0,00	0,00
	PS	0,00	0,00	0,00	13,33	0,00	94,12	0,00	0,00	0,00	0,00
	PL	0,00	0,00	0,00	0,00	0,00	0,00	100,00	11,11	0,00	0,00
	AC	0,00	0,00	0,00	0,00	0,00	0,00	0,00	88,89	0,00	0,00
	SP	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	100,00	35,00
	CA	0,00	0,00	0,00	0,00	0,64	0,00	0,00	0,00	0,00	65,00

De acordo com o resultado da classificação do grupo de atributos do subconjunto ótimo de 2016, o valor *Kappa* obtido para esta classificação é de 0,74. A matriz de confusão (Tabela 4.7) evidencia o alto potencial deste grupo de atributos para discriminar principalmente, alvos com pouca e/ou sem a presença da vegetação. Assim, observa-se que as classes que apresentam os melhores desempenhos classificatórios são PS, PL, AC, SP e CA, com um percentual de acerto acima de 84,00%.

Os resultados classificatórios também vão ao encontro da separabilidade das classes investigadas, representadas no espaço bidimensional de atributos (Figura 4.36). O par de atributos A e P_v exibiu o mais alto potencial para discriminar a classe PS, que obteve um percentual de 5,88% das suas amostras classificadas erroneamente como SSInt. A classe PL obteve a melhor separabilidade com o par de atributos H e A . Os pares de atributos H e α , A e α , e P_v e α apresentaram os mais altos potenciais discriminatórios, sugerindo assim, uma alta contribuição do atributo α para discriminar a classe AC. Já a classe foi bem discriminada pelo par de atributos P_v e α .

Tabela 4.7 - Matriz de confusão da classificação do subconjunto ótimo do ano de 2016.

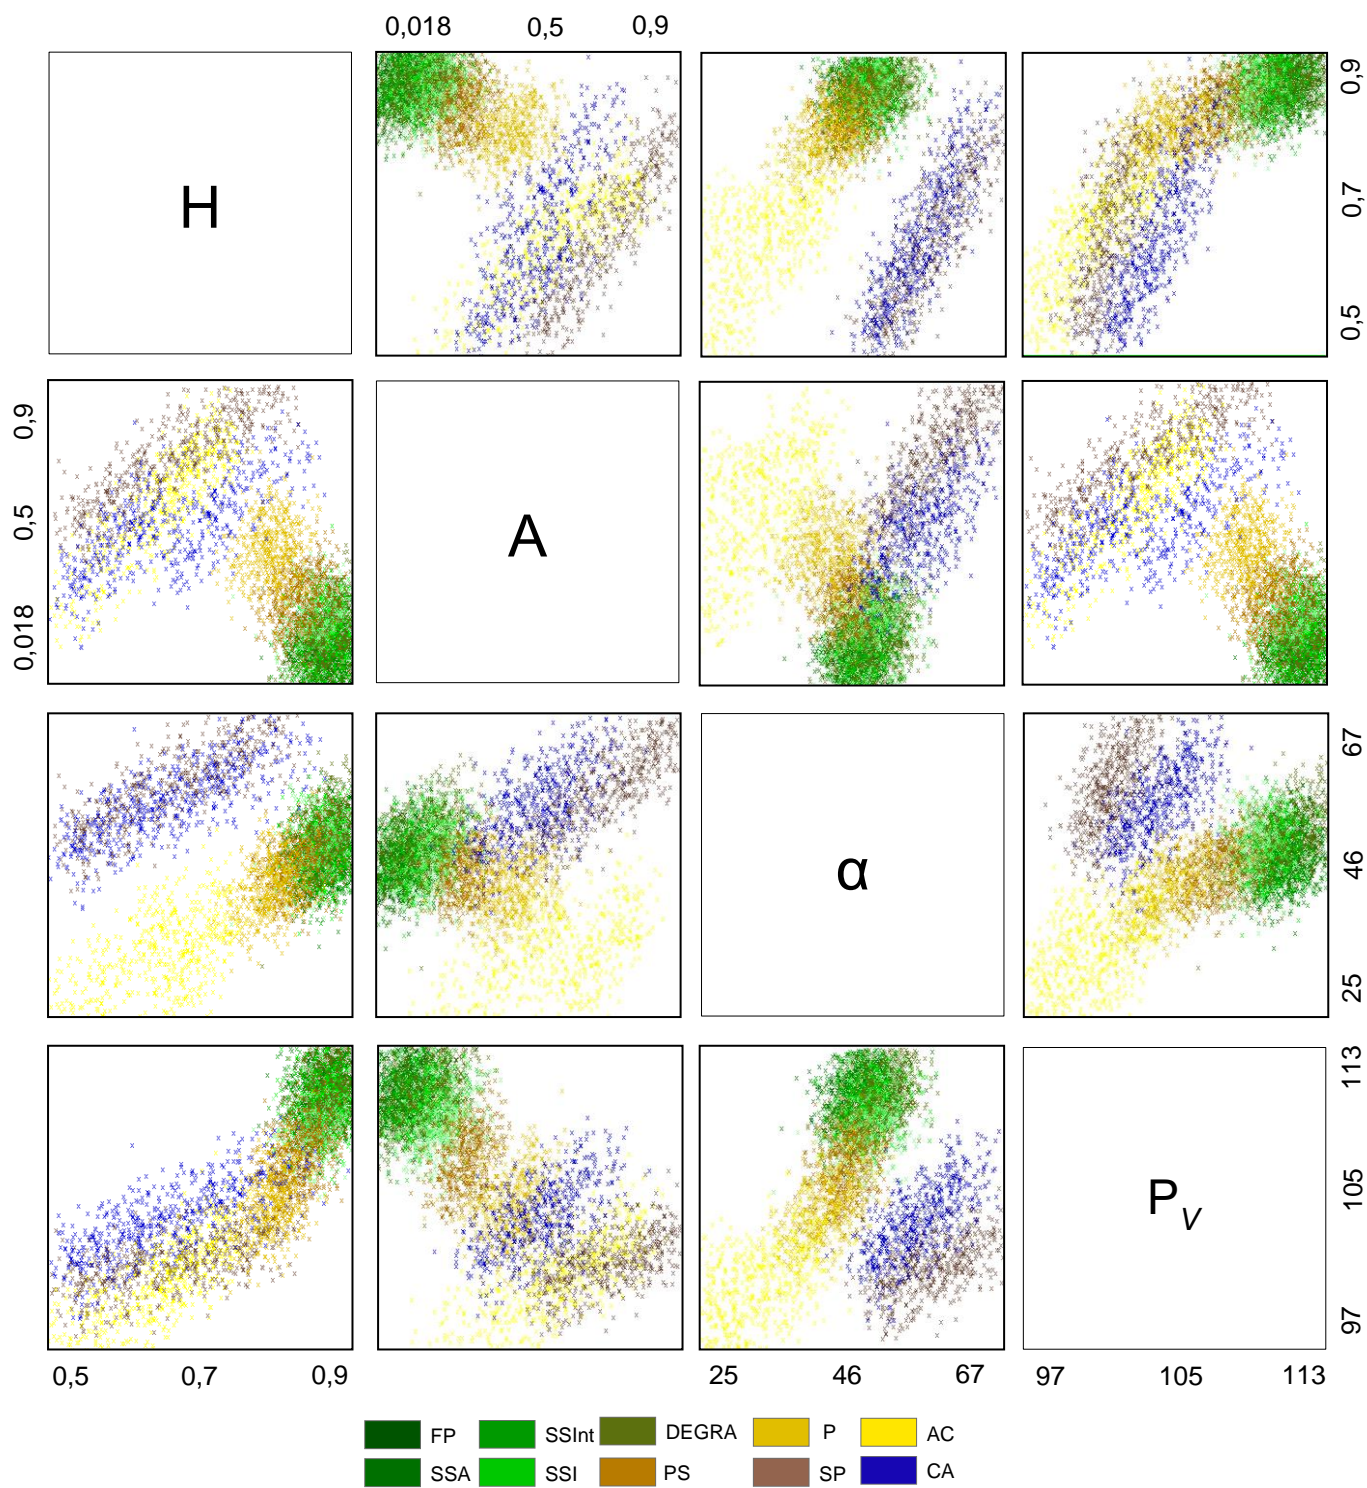
		REFERÊNCIA									
		FP	SSA	SSInt	SSI	DEGRAD	PS	PL	AC	SP	CA
CLASSIFICAÇÃO (%)	FP	45,07	35,00	15,79	0,00	11,88	0,00	0,00	0,00	0,00	0,00
	SSA	38,03	50,00	0,00	0,00	3,12	0,00	0,00	0,00	0,00	0,00
	SSInt	9,86	15,00	36,84	0,00	22,50	0,00	0,00	0,00	0,00	0,00
	SSI	0,00	0,00	0,00	53,33	1,87	5,88	0,00	0,00	0,00	0,00
	DEGRAD	7,04	0,00	47,37	20,00	60,63	0,00	0,00	0,00	0,00	0,00
	PS	0,00	0,00	0,00	26,67	0,00	88,24	0,00	0,00	0,0	0,00
	PL	0,00	0,00	0,00	0,00	0,00	5,88	100,00	0,00	0,00	0,00
	AC	0,00	0,00	0,00	0,00	0,00	0,00	0,00	100,00	0,00	0,00
	SP	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	98,00	15,00
	CA	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	2,00	85,00

A classe CA apresentou um percentual de acerto de 85,00% de acerto, sendo que 15,00% das amostras foram erroneamente classificadas como SP. No espaço bidimensional de atributos, pode-se observar que as combinações entre os atributos H e P_v e P_v e α , favorecem a discriminação da classe CA, embora, também pode-se constatar certa confusão desta classe com a classe SP. A análise do resultado a partir das combinações dos atributos supracitados, possivelmente indica o alto potencial do atributo P_v para discriminar a classe CA.

A classe FP apresentou percentual de acerto de 45,07%, sendo 38,03% das amostras classificadas erroneamente como SSA, 9,86% como SSInt e 7,04% como DEGRAD. A classe SSA obteve 35,00% das suas amostras classificadas como sendo FP e 15,00% como SSInt. A classe SSInt apresentou o menor percentual de acerto (36,84%), sendo 15,79% das amostras classificadas como FP e 47,37% como DEGRAD. A classe SSI apresentou 53,33% de acerto, sendo que 20,00% das amostras foram classificadas como sendo DEGRAD e 26,67% das amostras como PS. Os resultados classificatórios supracitados

corroboram com o baixo potencial discriminatório exibido em todas as combinações de pares de atributos (Figura 4.36).

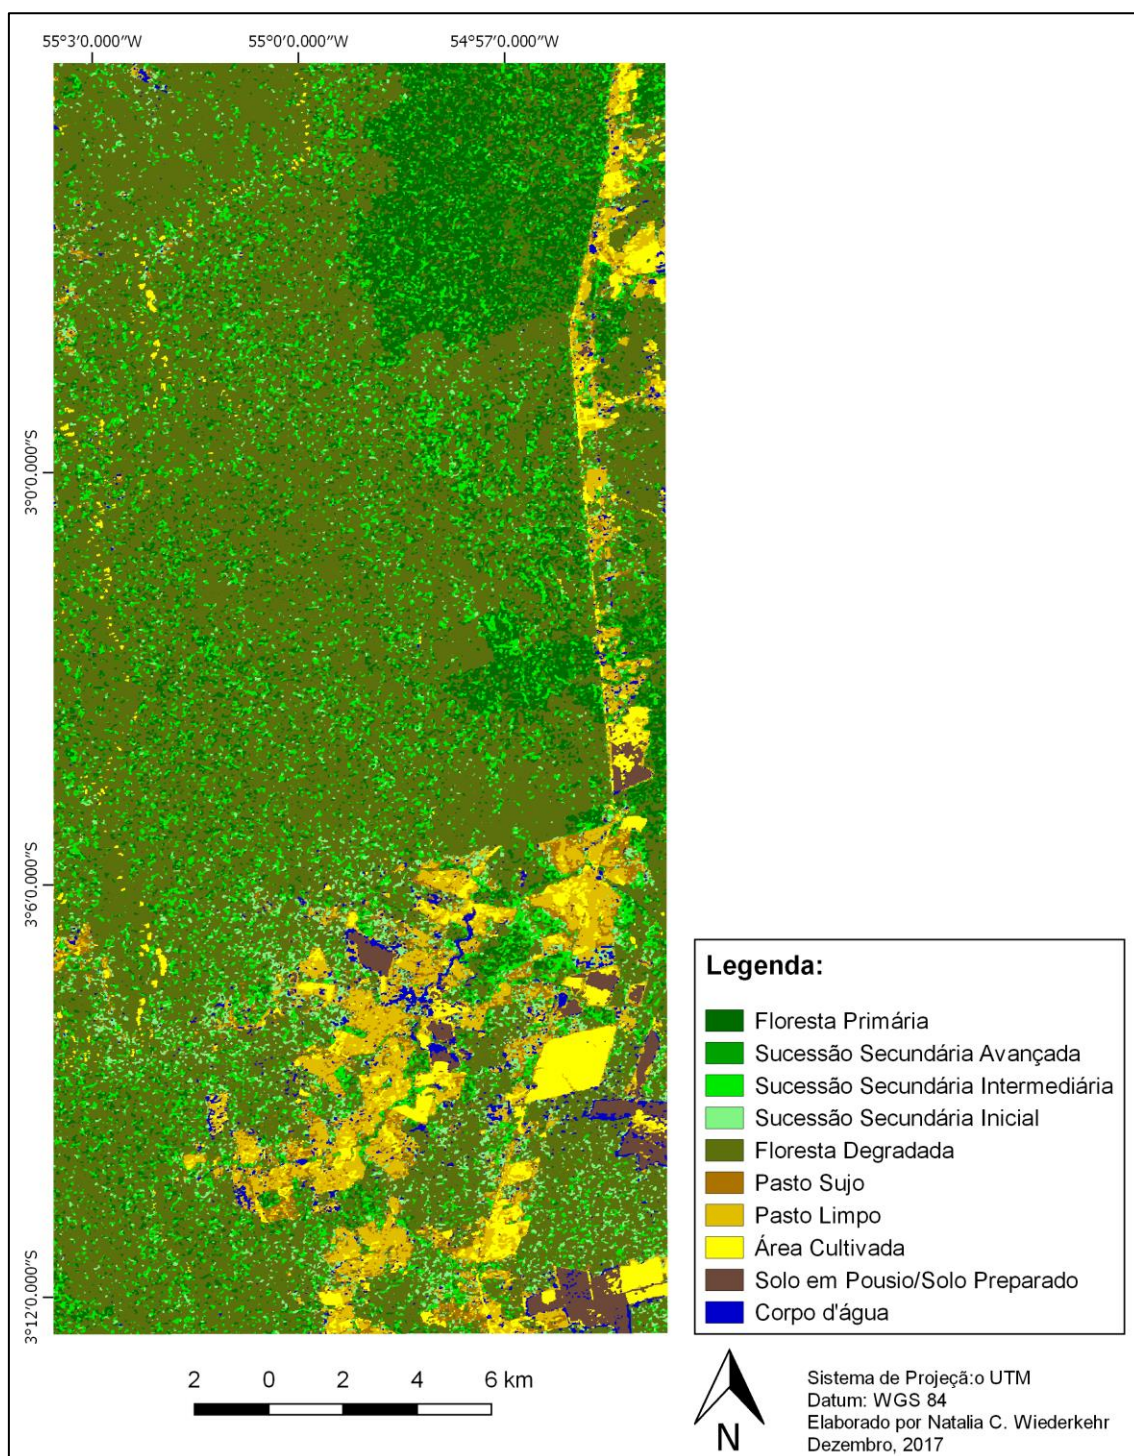
Figura 4.36 – Espaço de atributos de acordo com o subconjunto ótimo do ano de 2016 para as classes de uso e cobertura da terra.



Por sua vez, a classe DEGRAD obteve 60,63% de acerto. Esta classe, apresentou confusão com todas as classes de sucessão ecológica, sendo 11,87% das amostras classificadas erroneamente como FP, 3,12% como SSA, 22,50% como SSInt e 1,87% como SSI.

O mapa de uso e cobertura da terra de 2016 foi elaborado a partir do grupo de atributos do subconjunto ótimo, conforme pode ser observado na Figura 4.37.

Figura 4.37 – Mapa de uso e cobertura da terra 2016 da área de estudo elaborada a partir da classificação do subconjunto ótimo.



4.5. Resultados da classificação do mapa de referência

Para a elaboração do mapa de referência, foi utilizado o algoritmo classificador SVM. O resultado da classificação exibiu um valor de *Kappa* de 0,91. A diferença estatística apresentada entre a classificação a partir do subconjunto ótimo do ano de 2016 e a classificação do mapa de referência foi de 6,20 em um intervalo de confiança de 95% para todo o conjunto de classes.

De acordo com a matriz de confusão (Tabela 4.8) obtida a partir dos resultados classificatórios, constata-se que em suma, as classes com pouca e/ou sem a presença da vegetação, foram bem discriminadas. Exemplos disso são as classes PS, AC e CA que exibiram 100,00% de acerto. A classe SP apresentou 76,92% de assertividade, sendo que, a única confusão que houve na classe SP foi em relação à classe AC, onde, 23,08% das amostras de SP foram erroneamente classificadas como AC. A confusão que ocorreu entre estas classes pode indicar que determinadas culturas encontravam-se em um desenvolvimento em estágio inicial. Por sua vez, a classe PL exibiu 56,00% de acerto, sendo que 16,00% das amostras foram erroneamente classificadas como SSA e SSI, 8,00% como PS e 4,00% como SSInt.

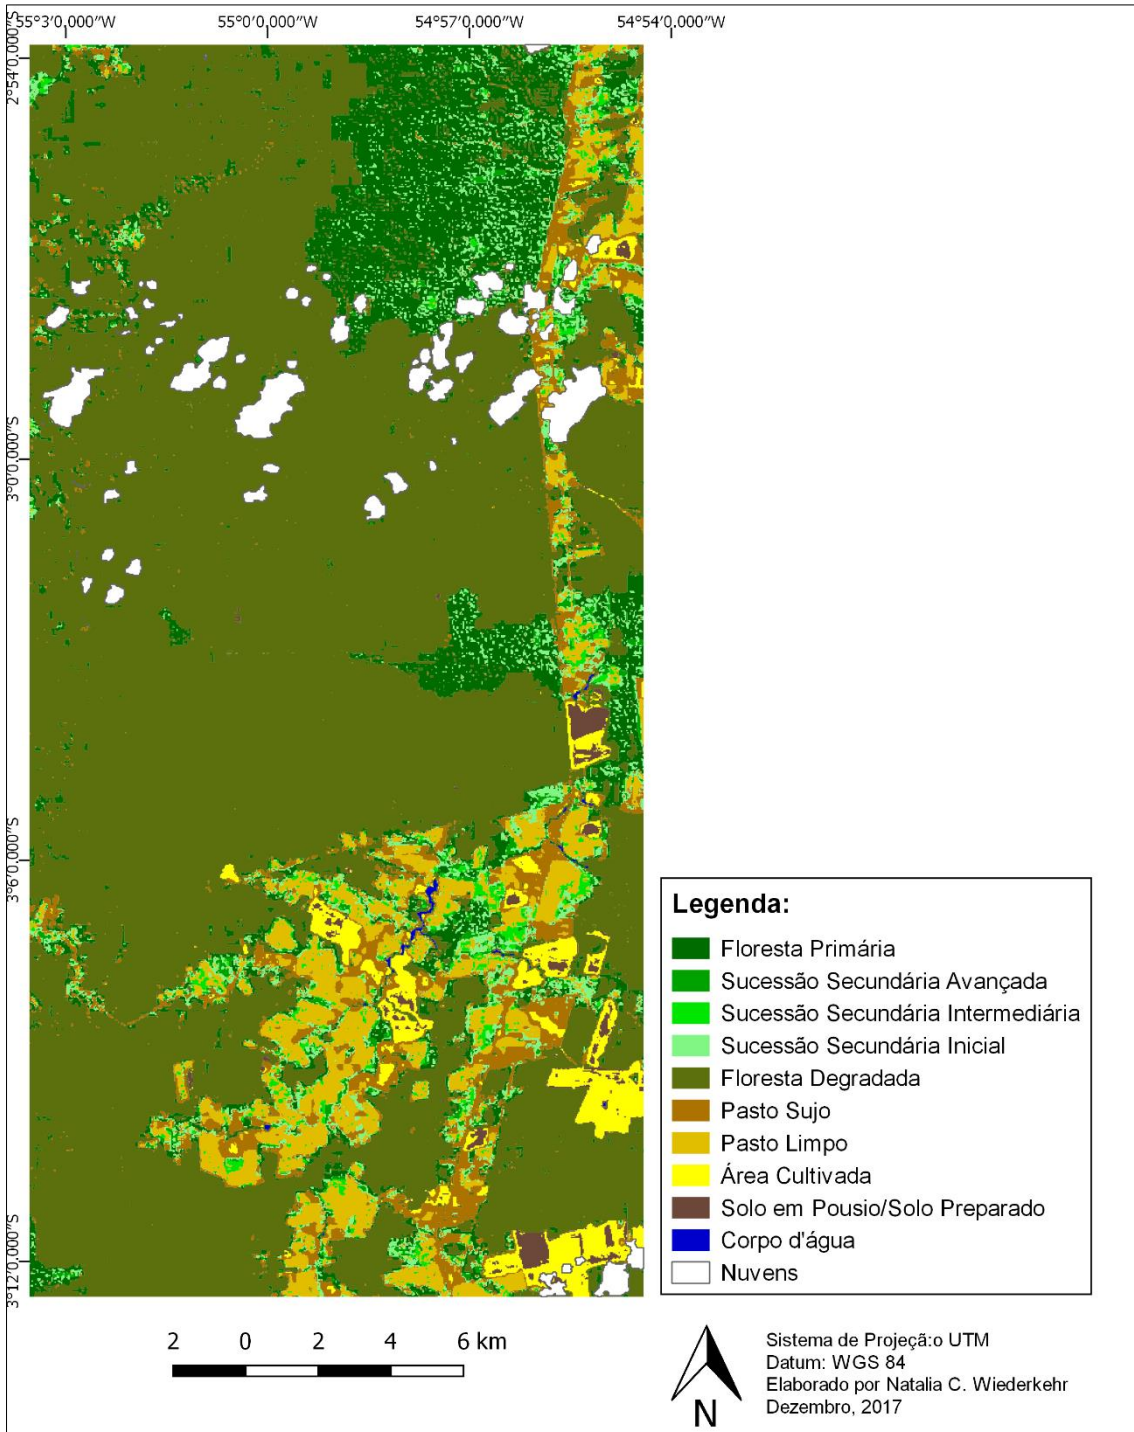
Tabela 4.8 - Matriz de confusão da classificação do mapa de referência.

		REFERÊNCIA (%)									
		FP	SSA	SSInt	SSI	DEGRAD	PS	PL	AC	SP	CA
CLASSIFICAÇÃO (%)	FP	100,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
	SSA	0,00	100,00	16,67	0,00	0,00	0,00	16,00	0,00	0,00	0,00
	SSInt	0,00	0,00	83,33	0,00	0,00	0,00	4,00	0,00	0,00	0,00
	SSI	0,00	0,00	0,00	22,23	0,00	0,00	16,00	0,00	0,00	0,00
	DEGRAD	0,00	0,00	0,00	0,00	100,00	0,00	0,00	0,00	0,00	0,00
	PS	0,00	0,00	0,00	33,33	0,00	100,00	8,00	0,00	0,00	0,00
	PL	0,00	0,00	0,00	44,44	0,00	0,00	56,00	0,00	0,00	0,00
	AC	0,00	0,00	0,00	0,00	0,00	0,00	0,00	100,00	23,08	0,00
	SP	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	76,92	0,00
	CA	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	100,00

Em relação às classes associadas com a cobertura vegetal, FP, SSA e DEGRAD exibiram os maiores percentuais de acerto com 100,00%, seguido pela classe SSInt com 83,33% de assertividade, sendo que 16,67% das amostras de SSInt foram erroneamente classificadas como SSA. As confusões que ocorreram entre as classes SSInt e SSA pode estar associado com a similaridade das respostas radiométricas das respectivas classes, devido similaridade em suas características fisionômico-estruturais. A classe SSI apresentou 22,23% de assertividade, sendo esse o menor percentual de assertividade entre as classes investigadas. As maiores confusões foram em relação à classe PL (44,44%) e PS (33,33%). A baixa separabilidade da classe SSI em relação às classes PL e PS podem ser em virtude de SSI apresentar uma composição de estrutura física de pequeno porte, com indivíduos arbustivo-arbóreos não formando um dossel ainda totalmente uniforme, com o material vegetativo (gramíneas e arvoretas) do sub-bosque em plena competição por luz.

O mapa de uso e cobertura da terra que será utilizado como referência para este estudo foi elaborado a partir de uma imagem multiespectral do ano de 2016 do sensor OLI e pode ser observado na Figura 4.38.

Figura 4.38 – Mapa de referência de uso e cobertura da terra do ano 2016 utilizado na etapa de validação.



4.6. Resultados da validação da detecção de mudança

A validação da detecção de mudança foi realizada na comparação do mapa de referência com o mapa classificado, ambos gerados para o ano de 2016, através da tabulação cruzada dos dados. Obteve-se como resultado da validação um valor de *Kappa* de 0,60, mostrando-se moderado, ao compará-lo com os valores de referência recomendados por Landis e Koch (1977) (Tabela 3.6 – Seção 3.3.3). Dentre os resultados de detecção apresentados para cada classe em ambos os anos analisados, ressalta-se a necessidade de considerar os erros de classificação contidos nas Tabelas 4.5 e 4.7 (Seção 4.4).

As classes associadas à cobertura vegetal apresentaram um percentual de acerto igual e/ou superior a 60,00%, exceto a classe SSI, conforme pode ser observado na Tabela 4.9. A classe FP, apresentou 70,00% de assertividade, a maior confusão exibida para esta classe foi em relação à classe SSA, sendo 20,00% das amostras de FP classificadas erroneamente como SSA. As classes SSA e SSInt apresentaram, respectivamente, 62,50% e 60,00% de acerto, sendo que as maiores confusões que ocorreram, estão relacionadas com as demais classes de sucessão ecológica, exceto com SSI. A classe SSA exibiu 18,75% de confusão com a classe FP, 12,50% como SSInt e 6,25% como DEGRAD. Na classe SSInt, 6,67% de suas amostras foram classificadas erroneamente como FP, 20,00% como SSA e 13,33% como DEGRAD. A classe SSI obteve o menor percentual de acerto dentre as classes investigadas, com 19,39% de assertividade, sendo que, 3,22% de suas amostras foram classificadas como FP, 9,67%, 9,67% como SSInt, 9,67% como DEGRAD, 25,80% como PS e 32,25% como sendo PL. Por sua vez, a classe DEGRAD exibiu 60,00% de acerto, as maiores dificuldades na discriminação desta classe estão relacionadas com as confusões que ocorreram com às classes FP (4,00%), SSA (18,00%), SSInt (16,00%) e SSI (2,00%).

Em relação às classes de uso da terra, a classe PS obteve um percentual de 63,64% de suas amostras classificadas corretamente. A principal confusão que ocorreu nesta classe foi em relação à classe PL, sendo que, 27,27% de suas amostras classificadas erroneamente como sendo PL. Já a classe PL exibiu um percentual de acerto de 61,92%. As maiores confusões de classificação de PL foram em relação às classes SSInt com percentual de 19,04% de erro classificatório e SSI, com 14,28%. A classe AC apresentou 82,35% de acerto, sendo que 14,70% de suas amostras foram confundidas com a classe SP e 2,95% com PL. A classe SP apresentou 26,67% de confusão com a classe AC, obtendo uma assertividade de 82,35%. Por sua vez, a classe CA apresentou o maior percentual de acerto dentre as classes, com 84,00% de acerto.

Tabela 4.9 - Matriz de confusão da classificação de detecção de mudança.

		REFERÊNCIA									
		FP	SSA	SSInt	SSI	DEGRAD	PS	PL	AC	SP	CA
CLASSIFICAÇÃO (%)	FP	70,00	18,75	6,67	3,22	4,00	0,00	0,00	0,00	0,00	0,00
	SSA	20,00	62,50	20,00	0,00	18,00	0,00	0,00	0,00	0,00	0,00
	SSInt	5,00	12,50	60,00	9,67	16,00	0,00	19,04	0,00	0,00	0,00
	SSI	0,00	0,00	0,00	19,39	2,00	9,09	14,28	0,00	0,00	0,00
	DEGRAD	5,00	6,25	13,33	9,67	60,00	0,00	0,00	0,00	0,00	0,00
	OS	0,00	0,00	0,00	25,80	0,00	63,64	4,76	0,00	0,00	0,00
	PL	0,00	0,00	0,00	32,25	0,00	27,27	61,92	2,95	0,00	0,00
	AC	0,00	0,00	0,00	0,00	0,00	0,00	0,00	82,35	26,67	8,00
	SP	0,00	0,00	0,00	0,00	0,00	0,00	0,00	14,70	73,33	8,00
	CA	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	84,00


4.7. Resultados de detecção de mudança

A partir da Tabela de detecção de mudanças de uso e cobertura da terra (Tabela 4.10) foi possível analisar o resultado das mudanças detectadas entre as imagens classificadas nos anos de 2015 e 2016, por unidade de área (km²) e percentual (%). Através desta Tabela 4.10, foi possível analisar a diferença

das classificações de classe para classe, a análise se concentrou principalmente nas mudanças de classificação de estado inicial (i.e., no ano de 2015) e compararam-se quais foram às mudanças que ocorreram em cada classe a partir do seu estado final (ano de 2016).

De acordo com os resultados obtidos a partir da detecção de mudanças de uso e cobertura da terra entre os anos de 2015 e 2016, a cobertura florestal: FP (11,69 km²), SSA (4,66 km²), SSInt (19,29 km²), SSI (7,71km²) e DEGRAD (88,95 km²) representa uma área total de 126,14 km², o que equivale a um total de 88,31% da área de estudo (Tabela 4.10). A classe DEGRAD constituída por áreas florestais afetadas pelo fogo, somada com as áreas florestais onde a exploração madeireira não respeitou um regime de exploração sustentável, exibiu a maior representatividade dentre as classes supracitadas, ocupando 64,30% da área total (88,95 km²). Para o uso da terra as classes PS (1,64 km²), PL (9,22 km²), AC (4,98 km²) e SP (0,38 km²), obtiveram uma representatividade de área total de 16,22 km² (127,57%), já a classe corpos d'água exibiu uma área total de 0,48 km² (0,34%) (Figura 4.39).

Figura 4.39 – Representação das classes temáticas em área (Km²) e percentual (%).



No que concerne às classes associadas à cobertura da terra, a classe FP apresentou uma área total de aproximadamente, 11,69 km² (14,80%). Entre os anos de 2015 e 2016, aproximadamente 68,26 km² da classe FP apresentou alterações, conforme pode ser observado na Tabela 4.10. Dentre este valor apresentado, é muito importante considerar, que a classe FP abrange a tipologia de vegetação primária, bem como, inclui áreas de floresta com exploração manejada. Ainda, destaca-se a importância de considerar que os resultados apresentados contêm uma somatória de erros, provenientes de erros das classificações apresentados nas Tabelas 4.5 e 4.7, erros de classificação do mapa de referência (Tabela 4.8), e os erros da validação da detecção de mudança (Tabela 4.9).

A classe SSA ocupa atualmente uma área total de 4,66 km². Entre o ano de 2015 para 2016, houve uma redução de 115,70 km² da área total desta classe. Ressalta-se que dentre o valor apresentado pela classe SSA, é necessário também considerar os percentuais de erros classificatórios principalmente em relação à classe FP, nos anos de 2015, 2016 e das detecções de mudanças. A classe SSInt, apresenta uma área total de 19,29 km², exibindo um total de mudanças na classe durante os anos analisados, de aproximadamente 103,24 km². Por sua vez, a classe SSI ocupa uma área total de 1,55 km² (6,50%) e apresentou uma redução da área da classe de aproximadamente 7,60%, como pode ser observado na Tabela 4.10. Os resultados apresentados acima sugerem que houve reduções da cobertura vegetal natural e indicam possíveis mudanças e conversões para outras classes de uso e cobertura, sobretudo as relacionadas com a classe DEGRAD. Considerando, que houve perdas de densidade da vegetação nos diferentes estádios ecológicos principalmente devido às queimadas que ocorreram no ano de 2016. Salienta-se ainda, que os resultados apresentados nas classes supracitadas, apresentam erros classificatórios e de validação de detecções que precisam ser considerados.

Em relação às classes de uso da terra, a classe PS exibiu um aumento de 9,29 km² de sua área total. As principais modificações que ocorreram na área desta

classe, estão associadas principalmente com as classes PL que representou cerca de 2,97 km² das modificações, DEGRAD 2,08 km² e AC 1,06 km². Já em relação à classe PL, as principais mudanças exibidas estão relacionadas com as classes DEGRAD, PS, e AC, sendo que, aproximadamente 3,72 km² da área total da classe PL foi alterada para PS, 2,96 km² da área total foi modificada para DEGRAD, e 2,90 km² da área total para AC. Aproximadamente 9,22 km² (39,10%) da área total permaneceu como PL.

As principais alterações que ocorreram nas áreas de uso pela classe AC foram principalmente em relação às classes PL e SP. Aproximadamente 4,60 km² da área total de AC foi alterada para PL e 4,40 km² da área total alterada para SP. A principal mudança que ocorreu na classe SP está associada com a classe AC. Aproximadamente 40,20% (0,36 km²) da classe SP foi alterado para AC. Cerca de 48,00%, equivalente a 0,38 km² da área total permaneceu com a finalidade de uso de SP. A classe CA exibiu uma diferença entre as classificações de 2015 e 2016 de aproximadamente -1,55 km², denotando uma redução da área total. Ainda de acordo com os resultados obtidos, a mudança que ocorreu nesta classe foi em torno de 8,50 km², tais mudanças ocorreram principalmente com relação às classes PL (25,5%), DEGRAD (19,5%) e PS (16,3%). Considera-se ainda, como parte dos resultados de detecção de mudanças apresentados pelas classes de uso da terra, a somatória dos erros contidos nas classificações dos respectivos anos investigados, os erros contidos no mapa de referência e também, os erros das validações de detecções de mudanças.

Tabela 4.10 – Detecção de mudanças de uso e cobertura da terra entre os anos de 2015 e 2016.

Estado inicial das classes temáticas - Área (Km ²) / Proporção (%)										
DE ¹ PARA ²	FP	SSA	SSInt	SSI	DEGRAD	PS	PL	AC	SP	CA
FP	11,69 (14,8%)	24,90 (19,4%)	9,12 (7,4%)	2,06 (8,4%)	13,86 (10,0%)	0,32 (3,0%)	0,49 (2,1%)	0,11 (0,5%)	0,00 (0,0%)	0,33 (3,7%)
SSA	2,30 (2,9%)	4,66 (3,6%)	1,92 (1,6%)	0,42 (1,7%)	2,69 (1,9%)	0,10 (0,9%)	0,17 (0,7%)	0,05 (0,2%)	0,00 (0,0%)	0,09 (1,0%)
SSInt	11,47 (14,3%)	18,10 (14,13%)	19,29 (15,8%)	3,03 (12,4%)	19,69 (14,2%)	0,81 (7,8%)	1,28 (5,4%)	0,59 (2,9%)	0,00 (0,0%)	0,63 (7,0%)
SSI	1,83 (2,3%)	2,96 (2,3%)	7,71 (6,3%)	1,55 (6,5%)	4,64 (3,3%)	0,87 (8,3%)	1,50 (6,3%)	0,76 (3,7%)	0,00 (0,0%)	0,74 (8,2%)
DEGRAD	48,64 (60,8%)	72,12 (56,3%)	69,46 (56,7%)	10,86 (44,4%)	88,95 (64,3%)	2,08 (20,0%)	2,96 (12,5%)	2,07 (10,3%)	0,00 (0,0%)	1,46 (19,5%)
PS	0,99 (1,2%)	1,46 (1,1%)	4,46 (3,6%)	1,93 (7,9%)	2,61 (1,9%)	1,64 (15,7%)	3,72 (15,7%)	1,46 (7,3%)	0,00 (0,0%)	1,75 (16,3%)
PL	1,36 (1,7%)	1,83 (1,4%)	5,39 (4,4%)	2,84 (11,6%)	2,76 (2,0%)	2,97 (28,4%)	9,22 (39,10%)	4,41 (22,0%)	0,10 (10,7%)	2,29 (25,5%)
AC	1,10 (1,4%)	1,13 (0,9%)	2,41 (2,0%)	0,91 (3,7%)	1,76 (1,2%)	1,06 (10,1%)	2,90 (12,3%)	4,98 (24,77%)	0,36 (40,2%)	0,83 (9,3%)
SP	0,20 (0,2%)	0,29 (0,2%)	1,04 (0,8%)	0,20 (0,8%)	0,39 (0,3%)	0,15 (1,5%)	0,40 (1,7%)	4,62 (23,0%)	0,38 (48,0%)	0,38 (4,2%)
CA	0,37 (0,4%)	0,66 (0,5%)	1,74 (1,4%)	0,64 (2,6%)	1,03 (0,7%)	0,45 (4,3%)	0,99 (4,2%)	1,07 (5,33%)	0,01 (1,1%)	0,48 (5,3%)
Total da Classe	79,95 (100%)	128,11 (100%)	122,54 (100%)	24,44 (100%)	138,38 (100%)	10,45 (100%)	23,63 (100%)	20,12 (100%)	0,85 (100%)	8,98 (100%)
Mudança de classe	68,26 (85,38%)	123,43 (96,36%)	103,24 (84,26%)	22,89 (93,67%)	49,43 (35,72%)	8,80 (84,27%)	14,39 (60,95%)	15,14 (75,24%)	0,39 (57,82%)	8,50 (94,69%)
Diferença das Classificações	-17,08 (-21,37%)	-115,70 (-90,33%)	-47,64 (-38,87%)	0,30 (-7,60%)	160,52 (116,00%)	9,29 (88,92%)	9,55 (40,46%)	-2,70 (-13,41%)	6,96 (799,47%)	-1,55 (-17,22%)

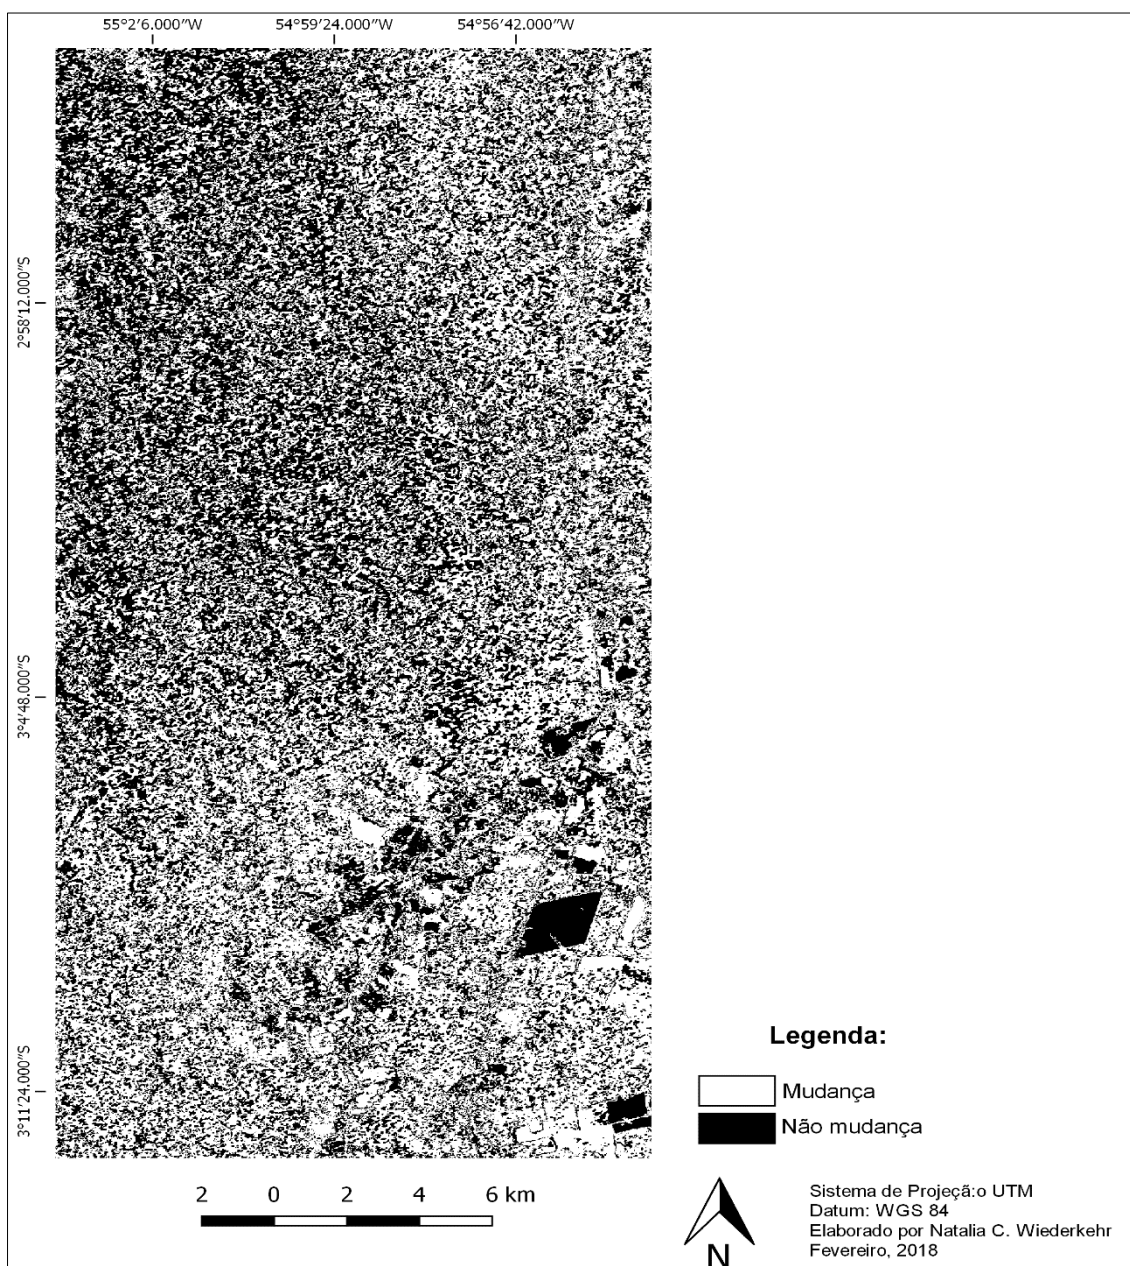
¹ Classes iniciais localizadas nas linhas. ² Classes finais localizadas nas colunas.

Valores com sinal negativo (-) apresentaram diminuição de área/proporção;

Valores com sinal positivos (+) apresentaram aumento de área/proporção.

Com o intuito de representar espacialmente a detecção de mudanças de uso e cobertura da terra no período analisado, foi elaborado um mapa de diferença (Figura 4.40), onde foi possível observar as áreas que apresentaram ou não mudanças de uso e cobertura da terra.

Figura 4.40 – Mapa de diferença na detecção de mudanças de uso e cobertura da terra entre os anos de 2015 e 2016



5 DISCUSSÃO DOS RESULTADOS

5.1. Decomposição de Cloude-Pottier frente às classes temáticas abordadas neste estudo para os anos de 2015 e 2016

Segundo as análises exploratórias por meio do *boxplot*, os atributos extraídos das decomposições de Cloude-Pottier nos anos de 2015 e 2016 exibiram boa capacidade para discriminar as classes de sucessões ecológicas das classes com pouca presença da vegetação (i.e., classes como: Solo Exposto/Pousio, Área de Cultivo, Corpo d'água). Porém, não exibiram potencial para separar às classes de diferentes sucessões ecológicas, mais especificadamente os atributos H e α nos respectivos anos analisados.

Os resultados de altos valores de média apresentados pelo atributo H para as diferentes classes de sucessões ecológicas nos anos de 2015 e 2016 evidenciam que os diferentes mecanismos de espalhamento contribuíram de modo equivalente para o sinal retornado ao sensor. Estes resultados, vão ao encontro com os resultados apresentados por Pôssa (2016), que avaliou o potencial dos dados polarimétricos do PALSAR-1 para discriminação de classes de uso e cobertura da terra em uma porção da FNT.

Ainda, os altos valores de H ($\sim 0,8$) apresentados pelas áreas cobertas por pastos (sujos e limpos) em ambos os anos analisados, podem estar associados com a alta quantidade de biomassa produzida principalmente pela presença de inajás e babaçus. Os resultados de altos valores de H obtidos pelas classes citadas acima são suportados pela literatura, conforme GlobeSAR (1997) e Pôssa (2016).

A classe SP apresentou valores medianos para o atributo α para os anos de 2015 e 2016. O efeito dos diferentes tipos de preparo do solo pode influenciar diretamente no retroespalhamento. Por exemplo, as áreas preparadas por grade de discos (áreas gradeadas) podem produzir superfícies mais rugosas quando comparadas com parcelas sem a mecanização (BRISCO et al., 1991) e

consequentemente, produzir um retroespalhamento de maior intensidade, aumentando a contribuição no atributo α .

Dentre os atributos da decomposição de Cloude-Pottier analisados nos dois anos, o atributo A exibiu a maior sensibilidade para discriminar as classes temáticas de estádios de sucessão, apresentando uma maior variabilidade de respostas radiométricas quando comparado com os atributos H e α .

5.2. Decomposições de Freeman-Durden e Yamaguchi frente às classes temáticas abordadas neste estudo para os anos de 2015 e 2016

Com relação ao grupo de atributos da decomposição de Freeman-Durden, o atributo P_v nos anos de 2015 e 2016, apresentou altos valores para as classes FP e SSA, assim como, baixa separabilidade entre ambas as classes, indicando sobreposição entre as classes. Apesar de que houve sobreposição entre as classes, FP e SSA apresentaram maiores distinções de valores de média em relação às classes SSInt e SSI. Os altos valores de média exibidos pelo atributo P_v para as classes de sucessões ecológicas também foram encontrados por Pôssa (2016). Este tipo de resposta é esperado, principalmente para as classes FP e SSA em virtude da densa cobertura florestal (i.e., estruturas mais complexas), que apresentam um maior número de estratos, possibilitando assim, a ocorrência do espalhamento volumétrico.

O estudo apresentado por Narvaes (2010) para modelar e estimar biomassa florestal a partir dos dados polarimétricos do PALSAR-1 em uma porção da FNT, também indicaram significativa contribuição do atributo P_v na resposta dos dados SAR para as classes de floresta primária e secundária.

De acordo com os resultados apresentados no estudo de Kuplich et al. (2009), ao analisar os atributos extraídos da decomposição de Freeman-Durden, a componente P_v também apresentou maior contribuição para discriminar classes de uso e cobertura da terra na FNT e áreas adjacentes.

O atributo P_d apresentou alto valor de média para a classe CA nos respectivos anos analisados. Este resultado indica que a possível interação entre a superfície do corpo d'água com seu entorno condiciona esta resposta uma vez que a área de investigação é constituída por canais fluviais de ordem inferior e que apresenta algumas vegetações aquáticas e/ou vegetações arbustivo-arbórea ciliar alagável. Dentre as classes de diferentes sucessões ecológicas, SSI exibiu a maior média de valores, sugerindo que há um crescimento regular de espécies pioneiras com a predominância de apenas um estrato superior homogêneo e de um estrato inferior. Este estrato possivelmente é composto por regenerações em estágio de sucessão inicial que se encontram dispostos de maneira irregular e disperso no ambiente, no qual germinaram e iniciaram um processo de sucessão mais tardia e são influenciados principalmente pelas sombras das espécies pioneiras. Os resultados obtidos pelo atributo P_d para as classes CA e SSI estão de acordo com os resultados apresentados por Pôssa (2016), e Narvaes (2010) referente à classe SSI.

Conforme análise do atributo P_s por meio do gráfico *boxplot*, no ano de 2015, a classe AC exibiu o maior valor de média. Este resultado indica que as maiores reflexões especulares possivelmente ocorreram em culturas de desenvolvimento em estágio inicial. A classe SSI também foi melhor discriminada por este atributo em relação as diferentes classes de sucessão ecológica. Isto ocorre em virtude da composição da estrutura física da classe SSI apresentar-se aleatoriamente dispostos com tamanhos menores de diâmetro e altura de troncos quando comparados, por exemplo, com indivíduos arbóreos mais desenvolvidos em um ambiente florestal mais estruturado.

Observou-se também que o atributo P_s apresentou diferentes respostas em relação as classes investigadas. Por exemplo, as classes AC e SP apresentaram-se bem discriminadas no ano de 2015 e, no entanto, em 2016, houve uma menor diferenciação entre as mesmas, assim como as classes PS e PL exibiram maior separabilidade entre si no ano de 2016.

Ao comparar os conjuntos de atributos provenientes das decomposições de Freeman-Durden e Yamaguchi nos anos de 2015 e 2016, os resultados obtidos para as classes temáticas analisadas demonstraram que os atributos Y_d e Y_v apresentaram, respectivamente, maior similaridade com os atributos P_d e P_v . Isto indica que os atributos das decomposições relacionadas acima estabeleceram, as mesmas potencialidades de discriminação. O atributo Y_s , em comparação com o atributo P_s , exibiu maior diferenciação nos resultados das respostas radiométricas entre as diferentes classes analisadas para o ano de 2015. As classes SSI, DEGRAD, AC e CA foram melhores discriminadas no atributo P_s do que no atributo Y_s . Estes resultados obtidos de alta similaridade entre os atributos da decomposição de Freeman-Durden e Yamaguchi estão em consonância com os resultados apresentados por Pôssa (2016).

O atributo Y_H , específico da decomposição de Yamaguchi, não apresentou potencial discriminatório para diferenciação das diferentes sucessões ecológicas em ambos os anos.

5.3. Atributos extraídos a partir do coeficiente de retroespalhamento: RC, RP e RFDI frente às classes temáticas abordadas neste estudo para os anos de 2015 e 2016

A RC apresentou resultados bem distintos nos anos de 2015 e 2016. Em 2015, este atributo exibiu, de uma maneira geral, baixo desempenho para separar as diferentes classes temáticas em análise, principalmente, as classes que contém pouca ou nenhuma presença de vegetação arbórea (PS, PL, AC e SP). A componente RC também não apresentou potencial para discriminar as diferentes classes de sucessões ecológicas, com exceção para as classes SSA e SSInt que foram melhor discriminadas em relação às demais classes ecológicas. Estes resultados são suportados pela literatura: de acordo com Evans et al. (1986), a vegetação geralmente apresenta uma alta componente de polarização cruzada e conseqüentemente, gera um espalhamento de menor intensidade, principalmente em superfícies levemente rugosas.

Os resultados obtidos no ano de 2016 demonstraram que RC exibiu bom desempenho na separabilidade entre as classes de diferentes estádios sucessionais. RC também apresentou o maior potencial para discriminar as classes AC e SP em relação com às demais classes temáticas analisadas. As classes PS e PL não apresentaram boa separabilidade entre si nos respectivos anos, assim como as classes FP e SSA.

Com relação ao atributo RP para ambos os anos, os maiores valores de retroespalhamento exibidos por este atributo estão relacionados às classes de diferentes estádios de sucessão ecológica, principalmente com FP, SSA e SSInt. Os valores obtidos para as classes supracitadas são resultantes dos tipos de estruturas formadoras dos dosséis nos diferentes tipos de estádios regenerativos, sendo que as sucessões em estágio inicial e/ou intermediária geralmente apresentam menor porte e densidade em relação àquelas de categoria avançada, que possuem maior densidade de elementos dispersores.

Como esperado, os mais baixos valores de RP estão associados aos alvos que apresentam pouca presença da vegetação, atribuindo assim, a maior contribuição do mecanismo de espalhamento na polarização HH, que é sensível ao espalhamento do tipo superficial, no qual contribuiu para a identificação e discriminação dos alvos supracitados. Este atributo exibiu maior capacidade principalmente para discriminar a classe CA das demais classes que apresentam pouca presença da vegetação nos anos de 2015 e 2016.

O atributo RFDI apresentou resultados similares para os anos de 2015 e 2016 respectivamente, corroborando com os resultados esperados pela literatura (SAATCHI, 2007). Os maiores valores exibidos por este Índice (i.e., valores próximos de 1,0) foram associados com as classes temáticas que apresentam menor presença de cobertura florestal. Destaca-se a contribuição da polarização HH no qual exibiu maior sensibilidade, principalmente para discriminar alvos na superfície que são representados no plano horizontal.

Como também esperado pela literatura, os menores valores de RFDI (i.e., valores próximos de 0,0) estão relacionados com as classes com maior porte e densidade da vegetação. Assim como esperado para as diferentes classes ecológicas que obtiveram os menores valores de média, indicando a contribuição do retroespalhamento no canal HV que se mostra mais sensível ao retroespalhamento volumétrico para os diferentes estádios de sucessões.

O Índice apresentou baixa capacidade para discriminação entre as classes AC, SP e CA e também, entre PS e PL em ambos os anos investigados.

5.4. Classificações a partir: das decomposições, dos subconjuntos ótimos e dos coeficientes de retroespalhamento para os anos de 2015 e 2016

A partir das análises das matrizes de confusão das classificações de Cloude-Pottier e do subconjunto ótimo (H , A , α , P_v) no ano de 2015, evidenciou-se a alta capacidade dos dois grupos de atributos supracitados para discriminar as classes com pouca e/ou sem presença de vegetação. No entanto, observa-se que houve confusões geradas entre as classes de diferentes sucessões ecológicas durante o processo de classificação, demonstrando o baixo potencial de ambos os atributos para discriminar estas classes.

As classes FP e SP apresentaram alto percentual de acerto classificatório a partir dos grupos de atributos da decomposição de Cloude-Pottier e do subconjunto ótimo para o ano de 2015. Ao analisar as diferentes combinações de pares de atributos no espaço bidimensional, estas classes exibiram baixa separabilidade; sugerindo assim, que, possivelmente apenas um atributo apresenta alto potencial discriminatório e que, ao interseccioná-lo, ocorra confusões entre diferentes classes, principalmente entre as classes SP, CA e AC e também, entre as classes FP, SSA, SSInt, SSI e DEGRAD.

Ao analisar os gráficos *boxplot*, observou-se que o grupo de atributos que compõem o subconjunto ótimo selecionado, apresentou capacidade para

discriminar a classe SP, como também, para discriminar a classe FP, exceto o atributo *H* que não apresentou potencial de separabilidade da classe FP em relação às demais classes ecológicas.

Como pode ser observado na Tabela 5.1, os atributos extraídos a partir da RC exibiram maior capacidade para discriminar as classes SP e CA, com percentual de acerto de 81,63% e 78,95%, respectivamente; as demais classes apresentaram resultados classificatórios inferiores a 30,00% de acerto para as classes de sucessão ecológica.

Tabela 5.1 – Porcentagem de acertos das classes temáticas em seus respectivos conjuntos de atributos do ano de 2015.

	FP	SSA	SSInt	SSI	DEGR	PS	PL	AC	SP	CA
Cloude-Pottier	82,36	63,33	20,00	50,00	46,67	100,00	100,00	100,00	100,00	89,50
Freeman-Durden	52,94	50,00	25,00	16,67	16,67	92,31	73,33	69,77	100,00	94,74
Yamaguchi	66,39	20,00	30,00	16,67	13,33	30,77	70,00	83,72	100,00	100,00
RC	19,33	10,00	0,00	50,00	26,67	46,15	20,00	0,00	81,63	78,95
RP	0,00	0,00	7,50	58,33	20,00	7,69	0,00	69,77	6,12	97,37
RFDI	29,89	0,00	5,00	75,00	36,67	0,00	73,33	25,58	75,51	55,26
Subconjunto ótimo	83,19	43,33	25,00	16,67	63,34	30,77	100,00	93,03	100,00	100,00

A RP também não exibiu bom desempenho para discriminar as classes de estádios de sucessão ecológica, bem como, para algumas classes que apresentam pouca presença da vegetação. Esta Razão também não apresentou capacidade para discriminar as classes FP, SSA e PL, ambas com 0,00% de acerto. As classes SSInt, PS e SP apresentaram um percentual de acerto inferior a 8,00% em ambas as classes e 20,00% de acerto para a classe DEGRAD. No entanto, esta Razão exibiu um bom desempenho discriminatório para a classe CA, com 97,37% de acerto da classificação (Tabela 5.1).

O índice biofísico RFDI obteve bom desempenho para discriminar as classes SSI, PL e SP, com 75,00%, 73,33% e 75,51% de acerto, respectivamente. As demais classes (FP, SSA, SSInt, DEGRAD, PS e AC) não foram bem discriminadas através deste Índice, apresentando um percentual de acerto na classificação inferior a 40,00%.

Conclui-se que, para este estudo, os atributos RC, RP e RFDI referentes ao ano de 2015 apresentaram potencial para discriminar a classe CA, exibindo assertividade de 78,95%, 97,37% e 55,26%, respectivamente. Porém, de um modo geral, exibiram baixo desempenho para discriminar as classes de sucessões ecológicas (FP, SSA, SSInt e DEGRAD), exceto para a classe SSI. Os três atributos, apresentaram maior capacidade em discriminar SSI em relação às demais classes de diferentes estádios sucessionais, sendo que RC exibiu assertividade de 50,00%, RP de 58,33% e RFDI com 75,00% de acerto, sendo estes os melhores resultados classificatórios obtidos para a classe SSI.

Os atributos RC e RFDI apresentaram alto desempenho na discriminação da classe SP, com resultados classificatórios acima de 75,00% de acerto em ambos os atributos. Os resultados classificatórios obtidos pela classe SSI sugerem uma possível maior contribuição do retroespalhamento na polarização HH que é sensível ao espalhamento do tipo superficial, que por sua vez, favorece principalmente a discriminação dos alvos com pouca ou sem a presença da vegetação.

Através da análise comparativa dos resultados classificatórios dos grupos de atributos em relação a cada classe temática investigada (Tabela 5.1), as classes SSA, PS, PL, AC e SP apresentaram as melhores discriminações no grupo de atributos de Cloude-Pottier. As classes PL e SP obtiveram os mesmos desempenhos classificatórios no grupo de atributos do subconjunto ótimo, com 100,00% de assertividade em ambas as classificações. A classe AC além de apresentar alta capacidade de discriminação no grupo de atributos de Cloude-Pottier, também apresentou alto desempenho classificatório no grupo

do subconjunto ótimo, com 93,03% de assertividade. As classes FP, DEGRAD e CA apresentaram os melhores desempenhos classificatórios no grupo de atributos do subconjunto ótimo. Já as classes SSInt e SSI apresentaram os maiores percentuais de acerto nos processos de classificações nos grupos de atributos de Yamaguchi e no RFDI, respectivamente.

Em uma análise comparativa das matrizes de confusão das classificações de Cloude-Pottier e do subconjunto ótimo para o ano de 2016, evidenciou-se o alto potencial de ambos os grupos de atributos para discriminar os alvos que possuem pouca ou nenhuma vegetação. Os melhores resultados classificatórios do subconjunto foram para as classes PL, AC, SP e CA. Também se observa que os grupos de atributos apresentaram menor desempenho classificatório para discriminar e distinguir as classes de sucessões ecológicas.

De acordo com os resultados apresentados na Tabela 5.2, a RC exibiu baixa capacidade para discriminar todas as classes de sucessão ecológica, obtendo o maior percentual de acerto (45,00%) classificatório para a classe SSA. Estes resultados evidenciam que, para este estudo, RC não apresentou sensibilidade ao espalhamento do tipo volumétrico. Os melhores resultados classificatórios obtidos através desta Razão foram para as classes PS e PL, com 52,94% de acerto em ambas as classes.

Tabela 5.2 – Porcentagem de acertos das classes temáticas em seus respectivos conjuntos de atributos do ano de 2016.

	FP	SSA	SSInt	SSI	DEGR	PS	PL	AC	SP	CA
Cloude-Pottier	40,84	65,00	31,58	53,33	64,37	94,12	100,00	88,89	100,00	65,00
Freeman-Durden	36,62	25,00	26,31	46,67	38,75	70,59	100,00	100,00	88,89	90,00
Yamaguchi	50,70	10,00	31,58	26,67	38,12	35,29	100,00	100,00	82,83	90,00
RC	29,58	45,00	26,31	40,00	14,37	52,94	52,94	0,00	27,27	50,00
RP	36,36	0,00	15,79	20,00	0,00	52,94	26,47	0,00	5,88	90,00
RFDI	61,97	40,00	5,26	40,00	16,25	52,94	44,12	11,11	27,27	25,00
Subconjunto ótimo	45,07	50,00	36,84	53,33	60,63	88,24	100,00	100,00	98,00	85,00

O melhor resultado classificatório obtido a partir da RP foi para a classe CA, com 90,00% de acerto na classificação (Tabela 5.2). Para as demais classes, esta Razão exibiu baixa capacidade de discriminação, com percentual de acerto inferior a 40,00%, exceto para a classe PS que obteve 52,94% de acerto na classificação.

O índice RFDI apresentou o melhor resultado classificatório dentre os grupos de atributos investigados para discriminar a classe FP (61,97% de acerto). Este resultado possivelmente indica uma maior contribuição do retroespalhamento na polarização HV, que é sensível ao espalhamento volumétrico. O resultado supracitado é suportado na literatura conforme descrito por Saatchi (2010). Porém, para as demais classes de estádios sucessionais, o RFDI não exibiu bom desempenho discriminatório, havendo muitas confusões entre as diferentes classes investigadas.

Ao comparar os resultados classificatórios dos grupos de atributos em relação às classes temáticas investigadas (Tabela 5.2), as que apresentaram melhores discriminações no grupo de atributos de Cloude-Pottier foram: SSA, DEGRAD, PS, PL, e SP. A classe SP além de apresentar alto desempenho classificatório

no grupo de atributos de Cloude-Pottier, também obteve alto desempenho no grupo do subconjunto ótimo, com 98,00% de assertividade. Ambos os grupos de atributos apresentaram 53,33% de acerto durante o processo de classificações das classes SSI.

A classe PL, além de apresentar alta capacidade de discriminação no grupo de atributos de Cloude-Pottier, também apresentou 100,00% de assertividade nos grupos de atributos do subconjunto ótimo, Freeman-Durden e Yamaguchi. A classe AC apresentou os melhores resultados no conjunto de atributos de Freeman-Durden, Yamaguchi e no subconjunto ótimo. A classe CA apresentou as mais altas capacidades de discriminação nos grupos de Freeman-Durden, Yamaguchi e RP. Por sua vez, a classe FP apresentou o melhor percentual de acerto no grupo de atributos RFDI.

5.5. Análise comparativa interanual dos resultados das classificações

Constata-se que as classificações a partir da decomposição de Cloude-Pottier e dos subconjuntos ótimos (H , A , α , P_v) em ambos os anos, apresentaram os melhores resultados classificatórios, exibindo para o subconjunto ótimo, valores *Kappa* de 0,75 e 0,74, respectivamente e para a decomposição de Cloude-Pottier, valores de *Kappa* de 0,78 para o ano de 2015 e 0,75 para o ano de 2016, sendo estes valores supracitados considerados substanciais ao compará-los com os valores de referência recomendado por Landis e Koch (1977) (Tabela 3.6 – Seção 3.3.3).

De acordo com os valores de *Kappa* supracitado, observou-se que não houve uma grande diferença entre os valores apresentados. Dentre as classes com pouca ou sem a presença da vegetação, ambos os grupos, em ambos os anos analisados, apresentaram alto potencial para discriminar as classes temáticas, exceto a classe PS no conjunto de atributos do subconjunto ótimo no ano de 2016. Porém, dentre as classes de diferente sucessão ecológica, o subconjunto ótimo apresentou melhores resultados classificatórios, principalmente para as classes FP, SSInt e DEGRAD. O conjunto de atributos provenientes da

decomposição de Cloude-Pottier apresentou os melhores resultados para discriminar principalmente as classes SSA em ambos os anos, e SSI no ano de 2016. Assim, para este trabalho, considerou-se o conjunto de atributos do subconjunto ótimo que em aspectos gerais, apresentou melhores resultados classificatórios que contemplam a maioria das classes temáticas investigadas.

Os resultados classificatórios obtidos a partir dos grupos de atributos das decomposições de Cloude-Pottier, Freeman-Durden, Yamaguchi e dos subconjuntos ótimos em ambos os anos, apresentaram desempenhos superiores às classificações a partir de σ^0 . Este resultado corrobora com o estudo apresentado por Pôssa (2016), que realizou classificações com dados *full* polarimétricos e também obteve os melhores resultados na discriminação de classes de uso e cobertura da terra com os grupos de atributos das decomposições e subconjunto ótimo. A decomposição de Cloude-Pottier apresentou valor *Kappa* de 0,70, Freeman-Durden 0,54, Yamaguchi 0,53, contra um valor de *Kappa* de 0,49, apresentado pelos Índices de coeficiente de retroespalhamento (PÔSSA, 2016).

De acordo com uma análise comparativa entre os espaços bidimensionais dos atributos dos anos de 2015 e 2016, todas as combinações de pares e atributos exibiram espaços de atributos com baixa separabilidade das classes SSA, SSInt e SSI. A baixa separabilidade entre estas classes gerou confusões nos processos de classificações, justificando os seus baixos valores de *Kappa* apresentados pelos diferentes grupos de atributos das decomposições, subconjuntos ótimos e coeficientes de retroespalhamento.

As classificações a partir da decomposição de Cloude-Pottier e dos subconjuntos ótimos evidenciaram a alta capacidade destes grupos para discriminar as classes de sucessões ecológicas das classes com pouca e/ou sem presença da vegetação. Porém, de uma maneira geral, estes mesmos grupos exibiram baixo potencial para discriminar e diferenciar as classes de sucessão ecológica.

De acordo com a análise comparativa por meio dos gráficos *boxplot*, as diferentes classes de sucessão ecológica apresentaram os altos valores de retroespalhamento nos atributos H, P_v e Y_v nos respectivos anos analisados. Segundo GlobeSar (1997), áreas com floresta natural e/ou florestas mais densas geralmente, apresentam maiores valores de retroespalhamento do que áreas abertas.

Dentre todos os grupos de atributos provenientes das decomposições de alvos, do subconjunto ótimo, dos coeficientes de retroespalhamento e Índice, a classe DEGRAD obteve o maior percentual de acerto classificatório de 63,34% no subconjunto ótimo em 2015 e 64,37% na decomposição de Cloude-Pottier em 2016.

RP exibiu alto desempenho classificatório na discriminação da classe CA em ambos os anos analisados. As demais nove classes investigadas não se apresentaram bem discriminadas por este atributo, indicando assim, a sua baixa eficiência para este estudo.

As razões RP e RC não apresentaram potencial para discriminar a classe AC. Esta classe exibiu valor *Kappa* de 0,00%, exceto para o ano de 2015, o atributo RC obteve 69,77% de assertividade. Ambas as razões também apresentaram baixa capacidade para discriminar as diferentes classes de sucessão ecológica. Assim como as razões, o índice biofísico RFDI também não apresentou bom desempenho para discriminar as diferentes classes de sucessões, exceto para a classe SSI que apresentou 75,00% de acerto no ano de 2015 e para a classe FP com 61,97% de acerto no ano de 2016.

Para as análises dos resultados obtidos neste estudo, é importante ressaltar que os ângulos de incidência de $31,10^\circ$ e $33,87^\circ$, a direção de órbita ascendente, e o teor de umidade de aproximadamente 20 a 25 mm que ocorreu na área de estudo durante a aquisição de duas das imagens utilizadas, podem ter influenciado diretamente na interação entre a radiação eletromagnética e os alvos, e conseqüentemente, nos valores de

retroespalhamento registrados pelo sensor radar. Estes fatores supracitados, podem diretamente ter influenciado nos resultados classificatórios, bem como na interpretabilidade das informações.

5.6. Análise de detecção de mudança

Ao analisar os resultados obtidos a partir da detecção de mudança de uso e cobertura que ocorreram nas e entre as classes analisadas, é essencial ponderar a inclusão dos erros das classificações dos subconjuntos ótimos dos anos de 2015 e 2016 como também, os erros associados ao mapa de referência que quando não ponderados, podem comprometer a confiabilidade dos dados, interpretabilidade e a análise dos resultados.

As maiores mudanças nas diferentes classes de sucessão estão relacionadas com a classe DEGRAD, apresentando uma diminuição da cobertura vegetal natural e um aumento das áreas florestais degradadas em função do fogo somada as áreas florestais com exploração madeireira indiscriminada. Em relação às áreas florestais degradadas pelo fogo, justifica-se principalmente pelas queimadas de grande proporção que iniciaram no final do mês de outubro de 2015, período este considerado de seca na região e que só se extinguiram em meados de janeiro, período do início das chuvas na região Amazônica. Os focos de incêndios aconteceram em diversos pontos espalhados pela FNT e áreas adjacentes, incluindo a área de estudo (Figura 5.1). Para esta análise é importante ponderar que: espectralmente essas classes apresentaram confusões entre si, principalmente por se encontrarem espacialmente próximas umas das outras; a classe FP é constituída por cobertura vegetal primária, também incluindo aquelas áreas de floresta com exploração madeireira sob regime sustentável; a classe DEGRAD é formada por florestas afetadas pelo fogo somada às áreas florestais onde houve exploração madeireira de forma indiscriminada e também, os erros de classificações que ocorreram durante os processos de classificações em ambos os anos e entre todas as classes supracitadas.

Figura 5.1 – Áreas degradadas por incêndios.



Em relação às classes de pastagem (sujo e limpo), observa-se que elas estão intimamente associadas. Uma parte desses resultados pode ser atribuída pela retirada de plantas invasoras dos pastos sujos e reformulações de pastoreio através de técnicas de melhoria por semeadura do material vegetativo ao gado, caracterizando-os assim, como áreas de pasto limpo. De outra parte, houve algum abandono do manejo adequado das pastagens, como ocorrência das invasões das “juquiras” e também, de presenças esparsas de palmas, como inajás e babaçus, decorrentes de processos de queimas da pastagem, o que favorece a germinação rápida dessas espécies na constituição desses pastos sujos. É importante ressaltar que durante o processo de classificação, a classe PS apresentou confusões com a classe PL. No ano de 2015, exibiu 69,23% de confusão com a classe PL, e no ano de 2016, 5,88% das amostras de PS foram erroneamente classificadas como sendo PL.

Os resultados obtidos para as classes PS e PL divergem dos resultados apresentados por Oliveira et al. (2010) que, ao analisarem a dinâmica de uso e cobertura da terra das regiões de integração do Araguaia e Tapajós nos anos de 2008 e 2010, constataram que houve significativos valores de conversões das classes de pastagem (pasto limpo e regeneração com pasto) para a classe de Vegetação Secundária.

Nas áreas de culturas agrícolas, houve uma diminuição de sua área entre os anos de 2015 e 2016. Cerca de 4,62 km² (23,00%) da área total da classe AC foi alterada para SP, por mais que os resultados de detecção apontem para uma perda de área desta classe para SP, é importante considerar que, a classe SP faz parte da área agrícola, denotando uma dinâmica entre elas, no qual considera um espaço de tempo onde o solo encontra-se exposto ou em pousio em fase de preparo para cultivos agrícolas.

Em relação à classe SP, houve um aumento de 6,96 km² da área total, enquanto que as áreas de cultivo agrícola apresentaram uma diminuição da área total de 2,70 km² no período analisado, conforme mencionado anteriormente. Este acréscimo pode estar associado com as áreas de culturas agrícolas estarem sendo colhidas, ou então, com a derrubada de capoeiras e limpeza de pastos com o intuito de preparar a terra para o plantio. Outro fator que justifica tal acréscimo das áreas de SP pode ser em função do surgimento de novas localidades ou a expansão de outras, como é o caso da Comunidade de São Jorge.

As mudanças que ocorreram entre as classes CA e SP (cerca de 4,20%) podem ser decorrentes das confusões destas duas classes durante o processo de classificação do ano de 2016, sendo que 15,00% das amostras foram erroneamente classificadas como SP. Ainda de acordo com a Tabela de detecção de mudanças, de modo geral, a classe CA exibiu as maiores alterações nos valores de áreas nas classes associadas com a maior presença da vegetação, tais como: SSInt, SSI, DEGRAD, PS e até mesmo PL. O que indica que, possivelmente as interações entre o alvo corpo d'água e os alvos próximos do seu entorno, como também, a observação da presença de plantas aquáticas durante a realização do trabalho de campo no ano de 2016, podem alterar as suas respostas, apresentando confusões durante o processo de classificação e que conseqüentemente influenciam nos resultados obtidos a partir da diferença da classificação de 2015 pela classificação de 2016.

Em síntese, a região do Tapajós é uma área de expansão da fronteira agrícola com extensas áreas. De maneira geral, os grandes proprietários de terra utilizam o solo de forma exaustiva, deixando-o por pouco tempo em fase de pousio, quando muito o deixam a fim de obter o máximo de aproveitamento possível do solo. Outra situação presente na região é o uso agrícola de pequena propriedade, constituída principalmente por áreas de pequenos cultivos de subsistência. De maneira geral, nas áreas adjacentes a FNT, a dinâmica do uso da terra nas pequenas propriedades é caracterizada pelo desmatamento de uma determinada área destinada para o cultivo agrícola e que posteriormente estas áreas serão abandonadas em virtude da diminuição da fertilidade natural do solo, e conseqüentemente o seu baixo rendimento. Estas áreas abandonadas geralmente são invadidas por capoeiras. Por sua vez, o agricultor realiza a limpeza de uma nova área para estabelecer outro plantio, até que a fertilidade do solo anteriormente utilizado tenha sido naturalmente restaurado/renovado.

Venturieri et al. (2005), em uma avaliação da mudança do uso e cobertura da terra no município de Paragominas/Pará, também sinalizou para uma substituição da vegetação para as atividades produtivas em expansão em toda região da Amazônia. Isto denota que as pressões nos recursos naturais também são alteradas, sendo necessário estudar as diferentes dinâmicas do uso e cobertura da terra na região.

6 CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES

A análise exploratória a partir dos dados do PALSAR-2 indicou que as maiores diferenças entre as respostas das sucessões florestais (SSA, SSInt, SSI e DEGRAD) foram encontradas nos atributos A , P_v , Y_v para os respectivos anos de 2015 e 2016, acrescido do atributo RC para o ano de 2016. Os coeficientes de retroespalhamento e o Índice RFDI apresentaram menor contribuição para discriminar as classes investigadas neste estudo. As maiores diferenças entre as respostas das sucessões florestais (SSA, SSInt, SSI e DEGRAD) foram encontradas nos atributos A , P_v , Y_v para os respectivos anos de 2015 e 2016, acrescido do atributo RC para o ano de 2016.

O atributo A exibiu o maior potencial dentre os atributos investigados para discriminar a classe DEGRAD, principalmente no que concerne às áreas florestais afetadas pelas queimadas que ocorreram no ano de 2016.

Com o intuito de contemplar as classes temáticas investigadas, os resultados classificatórios a partir do grupo de atributos do subconjunto ótimo, em aspectos gerais, exibiram os melhores resultados dentre os grupos analisados. Por sua vez, observou-se que as classes SSA, SSI e PS mostraram-se melhor discriminadas pelo grupo de atributos da decomposição de Cloude-Pottier. Sendo assim, dependendo do objetivo, a decomposição de Cloude-Pottier pode ser uma solução razoável, principalmente com ganhos em relação às classes SSA, SSI e PS.

Constatou-se que os resultados classificatórios obtidos a partir dos grupos de atributos das decomposições de Cloude-Pottier, Freeman-Durden e Yamaguchi para sensor PALSAR-2 (banda L) apresentaram valores de *Kappa* mais altos e estatisticamente diferentes quando comparados aos valores de *Kappa* obtidos pelos grupos de coeficientes de retroespalhamento. Tais resultados sugerem um desempenho classificatório superior dos dados das decomposições polarimétricas quando comparado com as classificações dos dados de amplitude, confirmando a potencialidade dos teoremas de decomposição de

alvos para classificação de uso e cobertura da terra em regiões tropicais. A análise foi realizada a um nível de confiança de 95%.

Os resultados classificatórios dos anos de 2015 e 2016 a partir do teorema de decomposição de alvos de Cloude-Pottier exibiram respectivamente um valor de *Kappa* de 0,78 no ano de 2015 e 0,75 em 2016. Pôssa (2016), ao utilizar o mesmo grupo de atributos para discriminar o uso e cobertura da terra na mesma região de investigação, a partir dos dados polarimétricos do PALSAR-1, obteve um valor de *Kappa* de 0,70. Ao comparar os valores de *Kappa* dos respectivos estudos nos quais utilizaram dados polarimétricos do sensor PALSAR-1 e 2, observa-se que houve um melhoramento na discriminação das classes analisadas.

No que concerne às mudanças que ocorreram entre 2015 e 2016, houve a diminuição das áreas florestais em relação às áreas em processo de produção. As maiores perdas ocorreram para as florestas primárias, sucessões avançadas e intermediárias. Esse fato pode estar relacionado principalmente com a degradação florestal a partir das queimadas que ocorreram na região, como também, o desmatamento nas áreas florestais. O decréscimo da área total da classe de sucessão inicial pode estar relacionado com a participação ativa que esta classe exerce enquanto áreas de pousio para as atividades agrícolas atuam como área de reserva durante o processo de recuperação das áreas de pastagem.

Assim, constatou-se que as áreas agrícolas e de pastagens continuam a avançar, suprimindo principalmente as áreas de cobertura florestal natural, tornando-se essencial para o controle de tais avanços o monitoramento contínuo das mudanças de uso e cobertura da terra.

As áreas de maior diversidade temática como observado na região da Comunidade de São Jorge, apresentaram menor precisão na confiabilidade da classificação automatizada devido à alta fragmentação do uso da terra. A fim de melhorar a exatidão dos resultados obtidos da classificação, sugere-se

utilizar o método de classificação híbrido principalmente das imagens de radar de resoluções compatíveis a escala do fenômeno.

Como pesquisa futura sugere-se explorar mais os dados do ALOS/PALSAR-2, com diferentes decomposições polarimétricas. Também, o sinergismo entre dados de sensoriamento remoto (PALSAR-2 com dados com outras frequências), pode vir a melhorar e aumentar o conteúdo de informação útil, otimizando a dimensionalidade oferecida pelos produtos do sensoriamento remoto, principalmente em relação às informações da radiometria e textura dos dados. Adicionalmente, sugere-se a utilização de conjuntos de dados temporais de radar para detectar mudanças sazonais e/ou fenológicas na vegetação, e para outros estudos de detecção de mudanças no uso e cobertura da terra.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALVES, D.S. Space-time dynamics of deforestation in Brazilian Amazonia. **International Journal of Remote Sensing**, v.23, n.14, p.2903-2908, 2002.
- ANJOS, D.S.; SANT'ANNA, S.J.S.; DUTRA, L.V. Detecção de mudanças na Floresta Nacional do Tapajós através de imagem diferença e dados RADARSAT-2. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. **Anais...**São José dos Campos: INPE, 2013. p.8374-8381.
- ASNER, G.P. Cloud cover in Landsat observations of the Brazilian Amazon. **International Journal of Remote Sensing**, v. 22, p. 3855-3862, 2001.
- AZEVEDO, A.R. **Análise das imagens dual multitemporais do Cosmo-Skymed como subsídio ao mapeamento de uso e cobertura da terra no sul do Amazonas**. 2013. 117 p. IBI: <8JMKD3MGP7W/3DBLM8L>. (sid.inpe.br/mtc-m19/2013/01.08.11.36-TDI). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3DBLM8L>>.
- BISHOP, Y.M.M.; FIENBERG, S.E., HOLLAND, P.W. **Discrete multivariate analysis: theory and practice**. Cambridge: MIT Press, 1975. 557 p.
- BISPO, P.C. **Efeitos de geomorfometria na caracterização florístico-estrutural da floresta tropical na região de tapajós com dados SRTM e PALSAR**. 2012. 147 p. IBI: <8JMKD3MGP7W/3C34QC8>. (sid.inpe.br/mtc-m19/2012/06.03.13.58-TDI). Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2012. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3C34QC8>>.
- BLASCHKE, T.; JOHANSEN, K.; TIEDE, D. Object-based image analysis for vegetation mapping and monitoring. In: WENG, Q. (Ed.). **Advances in environmental remote sensing: sensors, algorithms, and applications**. Boca Raton: CRC Press, Taylor and Francis, 2011.
- BOERNER, W.M.; MOTT, H.; LUNEBURG, E.; LIVINGSTONE, C.; BRISCO, B.; BROWN, R.J.; PATERSON, J.S.; CLOUDE, S.R.; KROGAGER, E.; LEE, J.S.; SCHULER, D.L.; VAN ZYL, J.J.; RANDALL, D.; BUDKEWITSCH, R.P.; POTTIER, E. Polarimetry in radar remote sensing: basic and applied concepts. In: LEWIS, A.J.; HENDERSON, F.M.; RYERSON, R.A. (Eds.). **Principles and applications of imaging radar: manual of remote sensing**. 3.ed. New York: John Wiley & Sons, Inc, 1998. v.2, cap.5, p.271-356.

BRASIL. **Decreto-lei no 1.106, de 16.06.1970**. Cria o Programa de Integração Nacional, altera a legislação do imposto de renda das pessoas jurídicas na parte referente a incentivos fiscais e dá outras providências. Jus Brasil, Legislação, 1970. Disponível em: http://www.planalto.gov.br/ccivill_03decreto-lei/1965-1988/Del1106.htm. Acesso em: 30 jan. 2017.

BRISCO, B.; BROWN, R. J.; SNIDER, G. J.; SOFKO, J. A.; KOEHLER, J. A.; WACKER, A. G. Tillage effects on the radar backscattering coefficient of grain stubble fields. **International Journal of Remote Sensing**, London, v. 12, n. 11, p. 2283-2298, 1991.

CHANG, C.C; LIN, C.J. **LIBSVM**: a library for support vector machines. Taipei, Taiwan: Department of Computer Science National Taiwan University, 2001. Disponível em: <http://www.csie.ntu.edu.tw/~cjlin/papers/libsvm.pdf>. Acesso em: 20 ago. 2017.

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, Mar.1996.

CONGALTON, R.G.; GREEN, K. **Assessing the accuracy of remotely sensed data**: principles and practices. 2.ed. New York: Lewis Publishers, 2009. 183 p.

CORAZZA, R.; CASSOL, H.L.G.; KUPLICH, T.M. Uso e cobertura da terra na região da Floresta Nacional do Tapajós (PA) com suporte de imagens LISS III. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011. p. 2989-2996. ISBN 978-85-17-00056-0 (Internet), 978-85-17-00057-7 (DVD). IBI: <3ERPFQRTRW/3A3U23B>. Disponível em: <<http://urlib.net/3ERPFQRTRW/3A3U23B>>.

CORREIA, A.H. **Método automático para calibração polarimétrica de imagens SAR**. 2009. 307 p. IBI: <8JMKD3MGP8W/35DKDSP>. (INPE-16349-TDI/1557). Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009. Disponível em: <<http://urlib.net/8JMKD3MGP8W/35DKDSP>>.

CORREIA, A.H. **Projeto, desenvolvimento e avaliação de classificadores estatísticos pontuais e contextuais para imagens SAR polarimétricas**. 1998. 273 p. IBI: <6qtX3pFwXQZ4PKzA/isJ7N>. (INPE-7178-TDI/679). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1998. Disponível em: <<http://urlib.net/6qtX3pFwXQZ4PKzA/isJ7N>>.

CRÓSTA, A.P. **Processamento digital de imagens de sensoriamento remoto**. Campinas, SP: IG/UNICAMP, 1992. 170p.

DUTRA, L.V.; SCOFIELD, G.B.; NETA, S.A.R.; NEGRI, R.G.; FREITAS C.C.; ANDRADE, D. Land cover classification in Amazon using Alos Palsar Full Polarimetric Data. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 7259-7264. DVD, On-line. ISBN 978-85-17-00044-7. (INPE-15865-PRE/10475). Disponível em: <<http://urlib.net/dpi.inpe.br/sbsr@80/2008/11.17.18.24>>.

EVANS, D.L.; FARR, T.G.; VAN ZYL, J.J.; ZEBKER, H.A. Radar polarimetry: analysis tools and applications. **IEEE Transactions on Geoscience and Remote Sensing**, v.26, n.6, p.774–789, Nov. 1988.

FOLEY, J.A.; DEFRIES, R.; ASNER, G.P.; BARFORD, C.; BONAN, G.; CARPENTER, S.R.; CHAPIN, F.S.; COE, M.T.; DAILY, G.C.; GIBBS, H.K.; HELKOWSKI, J.H.; HOLLOWAY, T.; HOWARD, E.A.; KUCHARIK, C.J.; MONFREDA, C.; PATZ, J.A.; PRENTICE, I.C.; RAMANKUTTY, N.; SNYDER, P.K. Global consequences of land use. **Science**, v. 309, p. 570–574, 2005.

FOODY, G.M.; MATHUR, A.A. Relative evaluation of multiclass image classification by support vector machines. **IEEE Transactions on Geoscience and Remote Sensing**, v.42, n.6, 2004.

FREEMAN, A.; DURDEN, S.L. A three-component scattering model for polarimetric SAR Data. **IEEE Transactions on Geoscience and Remote Sensing**, v.36, n. 3, p.963-973, maio1998.

FREITAS, C. C.; SANT´ANNA, S. J. S.; RENNO, C. D.; CORREIA, A. H. **Utilização de imagens de radar de abertura sintética na classificação de uso e ocupação do solo**. São José dos Campos: INPE, 2007. Disponível em: < <http://www.dpi.inpe.br/ofigeo.PDF>>. Acesso em: 09 fev. 2017.

GABOARDI, C. **Utilização de imagem de coerência SAR para classificação do uso da terra: Floresta Nacional do Tapajós**. 2002. 137 p. IBI: <6qtX3pFwXQZsFDuKxG/xHomg>. (INPE-9612-TDI/842) Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2003. Disponível em: <<http://urlib.net/6qtX3pFwXQZsFDuKxG/xHomg>>.

GLOBESAR-2. **Recursos educacionais para sensoriamento remoto: aplicações em florestas**, CCRS, 1997. Disponível em: http://ftp.ccrs.nrcan.gc.ca/ftp/ad/MAS/globesar/por/intro_p.pdf. Acesso em: 15 ago. 2016.

GUERRA, J.B.; MURA J.C.; FREITAS, C.C. Discriminação de incrementos de desflorestamento na Amazônia com dados SAR R99B em banda L. **Acta Amazônica**, v. 40, n. 3, p. 557-566, 2010.

HALL, M. et al. The weka data mining software: an update. **ACM SIGKDD Explorations Newsletter**, v. 11, n.1, p. 10–18, nov. 2009. ISSN 1931-0145.

HELLMANN M. P. **SAR polarimetry tutorial**. Rennes, France: University of Rennes, 2001. 109p. Disponível em: <<http://epsilon.nought.de/>>. Acesso em: 31 jan.2017.

HENDERSON, F.M.; LEWIS, A.J. **Manual of remote sensing: principles and applications of imaging radars**. 3. ed. New York, NY: John Wiley & Sons, 1998. 866p.

INSTITUTO NACIONAL DE METEOROLOGIA (INMET). **Chuva acumulada 24h**. Brasília, 2017. Disponível em: http://www.inmet.gov.br/sim/abre_graficos.php. Acesso em: 28 jan. 2017.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Taxas anuais de desmatamento na Amazônia Legal Brasileira (AMZ)**. 2016. Disponível em: <<http://www.obt.inpe.br/prodes/dashboard/prodes-rates.html>>. Acesso em: 17 fev.2017.

JAPAN AEROSPACE EXPLORATION AGENCY (JAXA). **ALOS-2 Project: PALSAR-2**. 2014. Disponível em: <http://www.eorc.jaxa.jp/ALOS-2/en/about/palsar2.htm>. Acesso em: 28 jan. 2017.

JAPAN AEROSPACE EXPLORATION AGENCY (JAXA). **ALOS Observation Strategy: PALSAR**. 2011. Disponível em: <http://www.eorc.jaxa.jp/ALOS/em/obs/palsarstrat.htm>. Acesso em: 28 jan. 2017.

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

JOHNSON, R.; KASISCHKE, E. Change vector analysis: a technique for the multispectral monitoring of land cover and condition. **International Journal of Remote Sensing**, v. 19, n. 3, p. 411–426, 1998.

KASISCHKE, E.S.; MELACK, J.M.; DOBSON, M.C. The use of imaging radars for ecological applications: a review. **Remote Sensing of Environment**, v. 57, n. 2, p. 141-156, 1997.

KUPLICH, T.H.; SHIMABUKURO, Y.E.; SERVELLO, E.; SANO, E. Polarimetric signatures and classification of tropical land covers. In: IEEE INTERNATIONAL

GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, (IGARS 2009), 2009, Cape Town. **Proceedings...** IEEE, 2009, p.118-121.

LANDIS, J.R.; KOCH, G.G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159-174, Mar. 1977.

LAVALLE, M.; WRIGHT, T. **Absolute radiometric and polarimetric calibration of ALOS PALSAR products**. 2009. Disponível em: https://erth.esa.int/documents/700255/709910/Calibration_palsar_products_v13.pdf. Acesso em: 29 jan. 2017.

LEE, J. S.; GRUNES, M. R.; DE GRANDI, G. Polarimetric SAR speckle filtering and its implication for classification. **IEEE Transactions on Geoscience and Remote Sensing**, v.37, n.5, p.2363 - 2373, 1999.

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

LEMOS, A.L.F.; SILVA, J.A. Desmatamento na Amazônia Legal: evolução, causas, monitoramento e possibilidades de mitigação através do Fundo Amazônia. **Revista Floresta e Ambiente**, v.8, n.1, p.98-108, 2011.

LEWIS, A.J.; HENDERSON, F.M; HOLCOMB, D.W. Radar fundamentals: the geoscience perspective. In HENDERSON, F.M; LEWIS, A.J. **Manual of remote sensing: principles and applications of imaging radars**. 3. ed. New York, NY: John Wiley & Sons, 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. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 70, p.26-38, 2012.

LORENA, R.B. **Evolução do uso da terra em porção da Amazônia Ocidental (Acre), com uso de técnicas de detecção de mudanças**. 2001. 116 p. (INPE-9650-TDI/846). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2001. Disponível em: <<http://urlib.net/sid.inpe.br/jeferson/2003/04.22.14.15>>. 116p.

LU, D.; MAUSEL, P.; BRONDÍZIO, E.; MORAN, E. Change detection techniques. **International Journal of Remote Sensing**, v. 25 n. 12, p.2365-2407, 2003.

LU, D.; MAUSEL, P.; BATISTELLA, M.; MORAN, E. Land-cover binary change detection methods for use in the moist tropical region of the Amazon: a

comparative study. **International Journal of Remote Sensing**. v. 26, n.1, p. 101-114, 2005.

LU, D.; LI, G.; MORAN, E. Current situation and needs of change detection techniques. **International Journal of Image and Data Fusion**, v. 5, n. 1, p.13–38, 2014.

MARTINS, F.S.R.V.; SANTOS, J.R.; GALVÃO, L.S.; XAUD, H.A.M. Sensitivity of ALOS/PALSAR imagery to forest degradation by fire innorthern Amazon. **International Journal of Applied Earth Observation and Geoinformation**, p.163-174, 2016.

MITCHARD E. T., SAATCHI S. S., LEWIS S. L., FELDPAUSCH T. R., WOODHOUSE I. H., SONKÉ B., MEIR P. Measuring biomass changes due to woody encroachment and deforestation/degradation in a forest–savanna boundary region of central Africa using multi-temporal L-band radar backscatter. **Remote Sensing of Environment**, v.115, p.2861–2873, 2011.

MITCHELL, T.M. **Machine learning**. [S.l.]: McGraw-Hill, 1997. (McGraw Hill Series in Computer Science). ISBN 978-0-07-042807-2.

MINISTÉRIO DO MEIO AMBIENTE: **Plano de manejo da Floresta Nacional do Tapajós**. Brasília: MMA, 2004. Disponível em: <http://www.icmbio.gov.br/portal/images/stories/imgs-unidades-conservacao/FNT_tapajos.pdf>. Acesso em: 30 jan. 2017.

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

NEGRI, R.G. **Avaliação de dados polarimétricos do sensor ALOS PALSAR para classificação da cobertura da terra da Amazônia**. 2009. 170 p. IBI: <8JMKD3MGP8W/35AKRR5>. (INPE-16220-TDI/1541). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009. Disponível em: <<http://urlib.net/8JMKD3MGP8W/35AKRR5>>.

OLIVEIRA, R.R.S.; VENTURIERI, A.; SAMPAIO, S.M.V.; LIMA, A.M.M.; ROCHA, E.J.P. Dinâmica de uso e cobertura da terra das regiões de integração do Araguaia e Tapajós/PA, para os anos de 2008 e 2010. **Revista Brasileira de Cartografia**, v.68, n.7, p.1411-1424, 2015. Disponível em: <http://www.lsie.unb.br/rbc/index.php/rbc/article/viewFile/1061/1019>. Acesso em: 05 jan. 2017.

PENNA, P.A.L. **Filtragem de ruído Speckle em imagens de Radar de Abertura Sintética por filtros de média não local com transformação homomórfica e distâncias estocásticas**. Dissertação (Mestrado em Ciência da Computação) - Universidade Federal de São Carlos. São Carlos: UFSCar, 2014. 170p.

PEREIRA, L.O.; SILVA, A.E.P.; NEGRI, R.G.; SANT'ANNA, J.S.; DUTRA, L.V.; FREITAS, C.C.; ERTHAL, G.J. Análise comparativa dos métodos de classificação SVM e Maxver-ICM Polarimétrico em imagem de radar ALOS PALSAR. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 15., 2011, Curitiba, PR, maio de 2011. **Anais...** São José dos Campos: INPE, 2011. Disponível em: <<http://www.dsr.inpe.br/sbsr2011/files/p0975.pdf>> Acesso em: 20 fev. 2017.

PEREIRA, L. O.; FREITAS, C. C.; SANT'ANNA, J. S.; REIS, M.S. ALOS/PALSAR data evaluation for land use and land cover mapping in the Amazon region. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v.9, n.12, p. 5413-5423, dez. 2016.

PIELKE, R.A. Land use and climate change, **Science**, v. 310, n. 5754, p. 1625-1626, 2005.

PÔSSA, E.M. **Discriminação de uso e cobertura da terra na região amazônica a partir de informação polarimétrica ALOS/PALSAR e coerência interferométrica da missão TANDEM-X**. 2016. 123 p. IBI: <8JMKD3MGP3W34P/3L65BH8>. (sid.inpe.br/mtc-m21b/2016/02.10.18.10-TDI). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016. Disponível em: <<http://urlib.net/8JMKD3MGP3W34P/3L65BH8>>.

RADAMBRASIL. **Folha AS,21- Santarém**: geologia, geomorfologia, pedologia, vegetação, uso potencial da terra. Rio de Janeiro: Ministério das Minas e Energia, 1976. Disponível em: <<http://biblioteca.ibge.gov.br/visualizacao/livros/liv24027.pdf>>. Acesso em: 30 jan. 2017.

RANEY, R.K. Radar fundamentals: technical perspective. In: HERDERSON, F.M.; LEWIS, A.J. (Eds.). **Manual of remote sensing: principles and applications of imaging radars**. 3. ed. New York, NY: John Wiley & Sons, 1998.

REIS, S.M. **Detecção de mudanças de uso e cobertura da terra utilizando dados óticos e de micro-ondas em região da Amazônia brasileira**. 2014. 331 p. IBI: <8JMKD3MGP5W34M/3GJ7LFB>. (sid.inpe.br/mtc-m21b/2014/06.30.19.09-TDI). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais. São José dos Campos: INPE, 2014. Disponível em: <<http://urlib.net/8JMKD3MGP5W34M/3GJ7LFB>>.

RICHARDS, J.A. **Remote sensing with imaging radar**. Berlim: Springer, 2009. 361p.

ROSA, R.G.S. **Filtragem de ruído speckle em imagens clínicas de ecografia**. 2012. 99p. Dissertação (Mestrado em Tecnologia Biomédica) – Instituto Politécnico de Bragança, Escola Superior de Tecnologia e Gestão, 2012.

SAATCHI, S.S.; DUBAYAH, R.; CLARK, D.; CHAZDON, R.; HOLLINGER, D. Estimation of forest biomass change from fusion of radar and lidar measurements. In: SEMINÁRIO DE ATUALIZAÇÃO EM SENSORIAMENTO REMOTO E SISTEMAS DE INFORMAÇÕES GEOGRÁFICAS APLICADOS À ENGENHARIA FLORESTAL, 9. 2010, Curitiba. **Apresentação...** Disponível em: <<http://www.slideshare.net/grassieee/estimation-of-forest-biomass>>. Acesso em: 08 fev. 2017.

SANTOS, E.M. **Teoria e aplicação de support vector machines à aprendizagem e reconhecimento de objetos baseado na aparência**. 2002. 111p. Dissertação (Mestrado em Informática) - Universidade Federal da Paraíba, João Pessoa, 2002.

SANTOS, J.R.; FREITAS, C.C.; ARAÚJO, L.S.; DUTRA, L.V.; MURA, J.C.; GAMA, F.F.; SOLER, L.S.; SANT'ANNA, S.J.S. Airborne P-band SAR applied to the above ground biomass studies in the Brazilian tropical rainforest. **Remote Sensing of Environment**, v. 87, n. 4, p. 482-493, 2003.

SHIMADA, M.; TADONO, T.; WATANABE, M. Determination of polarimetric calibration parameters of L band SAR using uniform forest data. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS 2004), 2004, Anchorage, AK. **Proceedings...** IEEE, 2004. p. 699 - 702.

SHIMADA, M.; ISOGUCHI, O.; TADONO, T.; ISONO, K. PALSAR Radiometric and geometric calibration. **IEEE Transactions on Geoscience Remote Sensing**, v.47, n.12, p. 3915-3932, dez. 2009.

SILVA, C.V.J. **Caracterização florístico-estrutural e modelagem de biomassa na floresta amazônica a partir de dados ALOS/PALSAR e TERRASAR/TANDEM-X**. 2014. 157 p. IBI: <8JMKD3MGP5W34M/3G66UN5>. (sid.inpe.br/mtc-m21b/2014/04.17.19.53-TDI). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2014. Disponível em: <<http://urlib.net/8JMKD3MGP5W34M/3G66UN5>>.

SINGH, A. Digital change detection techniques using remotely-sensed data. **International Journal of Remote Sensing**, v. 10, n. 6, p. 989-1003, 1989.

TRIBUNAL DE CONTAS DA UNIÃO. **Relatório de auditoria**. Brasília, 2008. Disponível em: <<http://contas.tcu.gov.br/juris/>>. Acesso em: 30 jan. 2017.

ULABY, F.T.; ELACHI, C. **Radar polarimetry for geoscience applications**. Norwood: Artech House, 1990. 364p.

VAPNIK, V. **The nature of statistical learning theory**. New York: Springer-Verlag, 1995.

VAN DER SANDEN, J.J **Radar remote sensing to support tropical forest management**. 1997. 330p. Thesis (Doctoral in Agricultural) – Wageningen Agricultural University, The Netherlands, 1997. Disponível em <<http://www.tropenbos.org/publications/>>. Acesso em: 04 fev. 2017.

VENTURIERI, A.; FIGUEIREDO, R.O.; WATRIN, O.S.; MARKEWITZ, D. Utilização de imagens Landsat e CBERS na avaliação da mudança do uso e cobertura da terra e seus reflexos na qualidade da água em microbacia hidrográfica do município de Paragominas, Pará. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 12., 2005, Goiânia, GO, abril de 2005. **Anais...** São José dos Campos: INPE, 2005. Disponível em: < <http://marte.sid.inpe.br/rep/ltid.inpe.br/sbsr/2004/>>. Acesso em: 03 jan. 2018.

WOODHOUSE, I.H. **Introduction to microwave remote sensing**. Boca Raton: Taylor & Francis Group CRC Press, 2006. 370p.

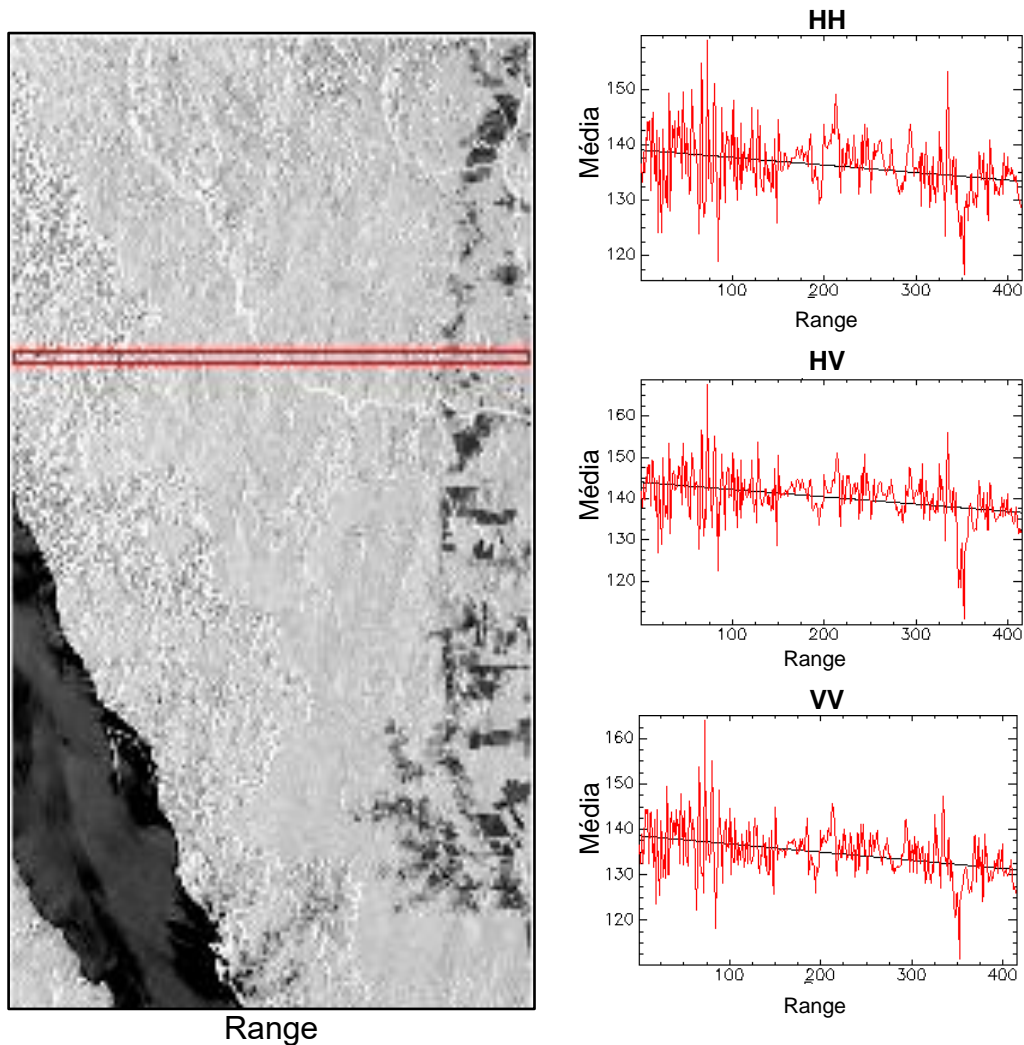
YAMAGUCHI, Y. Four-component scattering model for polarimetric SAR image decomposition. **IEEE Transactions on Geoscience Remote Sensing**, v.43, n.8, p. 1699-1706, ago. 2005.


YANASSE, C.DAC.F.; SANT´ANNA, S. J. S. ; FRERY, A. C. ; RENNO, C. D. ; SOARES, J. V. ; LUCKMAN, A. J. Exploratory study of the relationship between tropical forest regeneration stages and SIR-C L and C data. **Remote Sensing of Environment**, v. 59, n.2, p. 180-190, 1997.

APÊNDICE A – VERIFICAÇÃO DO PADRÃO DA ANTENA

Abaixo são apresentadas as figuras referentes às verificações do comportamento da antena das cenas utilizadas neste trabalho.

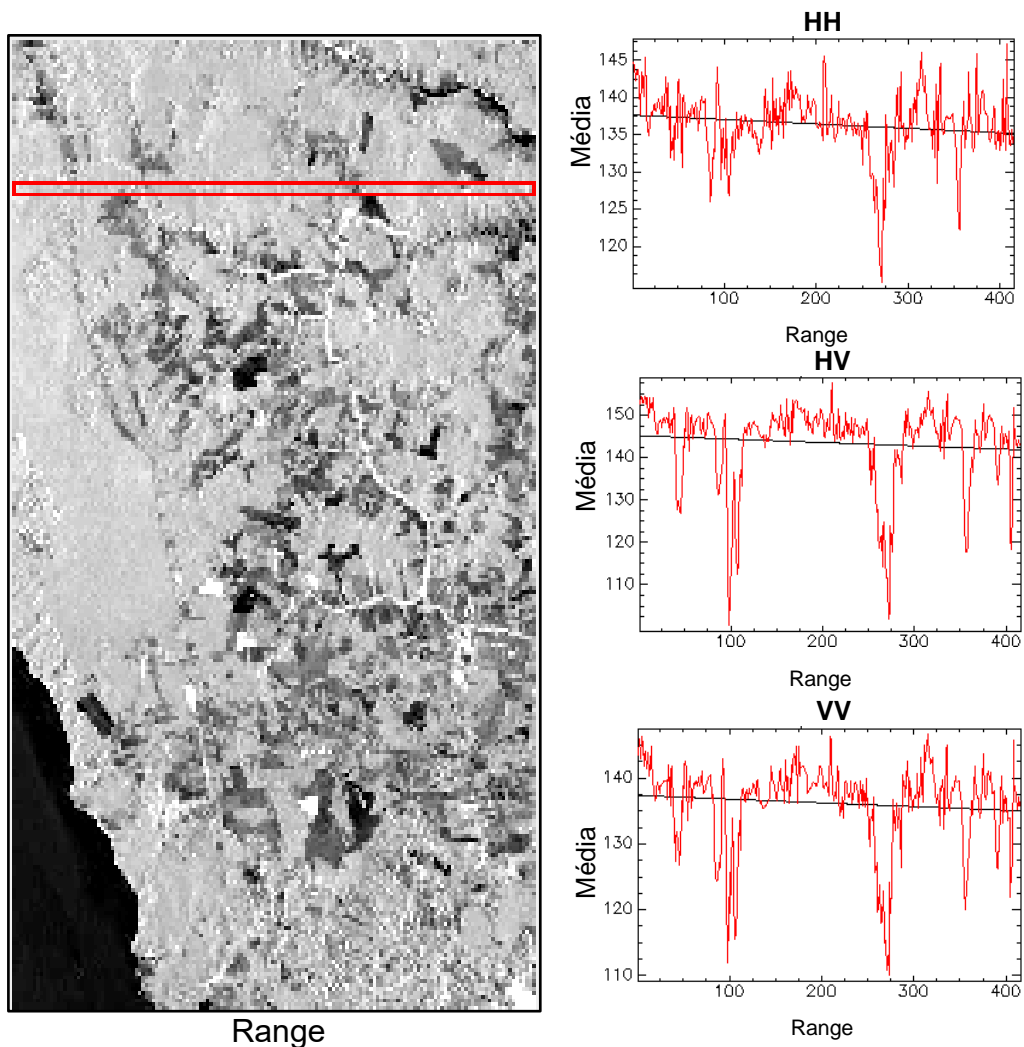
Figura A.1 – Cena 2032237120 de 28/12/2014.




 Faixa homogênea selecionada

Fonte: Produção do autor.


Figura A.2 – Cena 2048797130 de 19/04/2015.






 Faixa homogênea selecionada


Fonte: Produção do autor.

Figura A.3 – Cena 2050867130 de 03/05/2015.




Range



 Faixa homogênea selecionada

Fonte: Produção do autor.

Figura A.4 – Cena 2102617130 de 17/04/2016.






 Faixa homogênea selecionada
Fonte: Produção do autor.

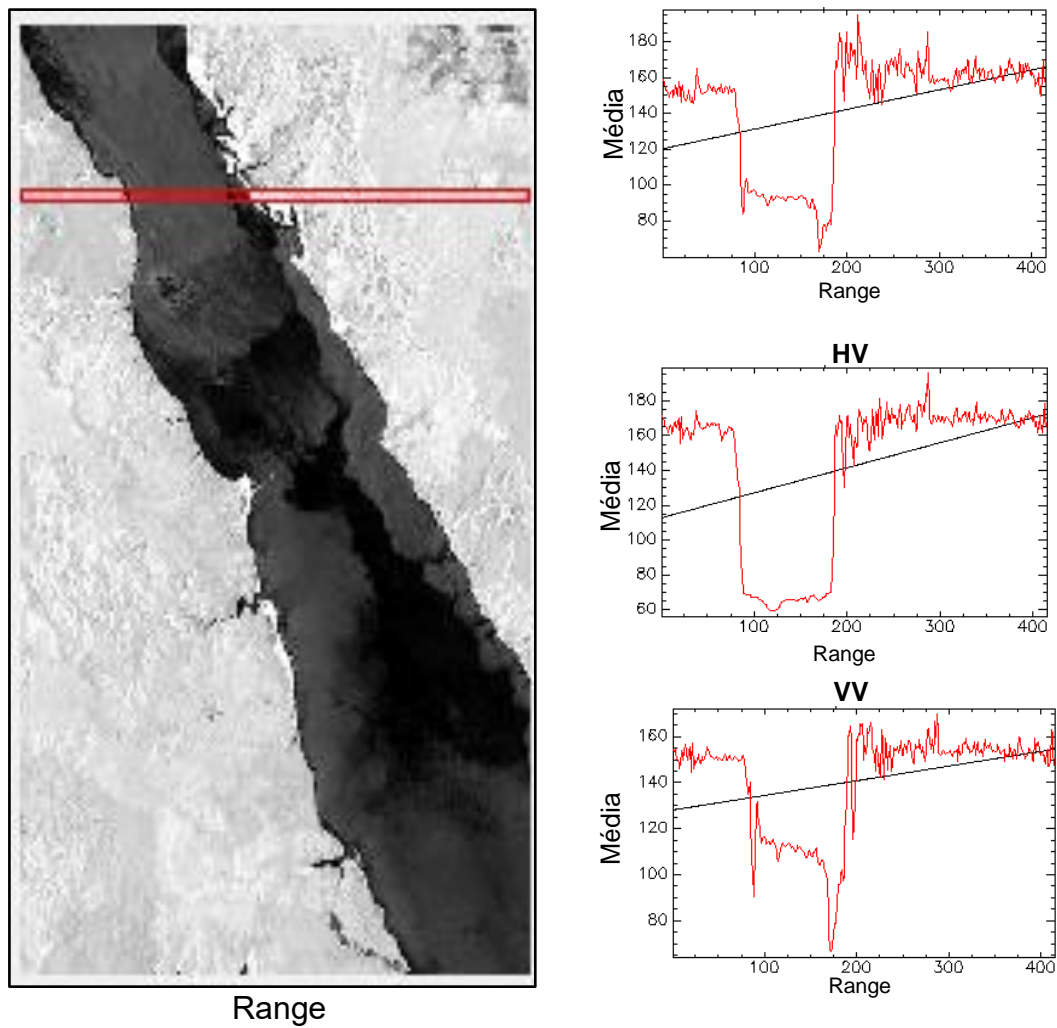
Figura A.5 – Cena 2104687120 de 01/05/2016.




 Faixa homogênea selecionada

Fonte: Produção do autor.

Figura A.6 – Cena 2104687130 de 01/05/2016.



 Faixa homogênea selecionada

Fonte: Produção do autor.

