



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

sid.inpe.br/mtc-m21c/2019/10.08.12.22-TDI

DETECÇÃO DE MUDANÇA DA COBERTURA DA TERRA USANDO DADOS POLARIZADOS MULTIFREQUÊNCIA NA AMAZÔNIA BRASILEIRA

Rebeca Suely Gabriella Soares Carneiro

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Sidnei João Siqueira
Sant'Anna, e Claudio Aparecido
de Almeida, aprovada em 20 de
agosto de 2019.

URL do documento original:

<http://urlib.net/8JMKD3MGP3W34R/3U79NKS>

INPE
São José dos Campos
2019

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GBDIR)

Serviço de Informação e Documentação (SESID)

CEP 12.227-010

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/7348

E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELECTUAL DO INPE - CEPPII (PORTARIA N° 176/2018/SEI-INPE):

Presidente:

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

Membros:

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

Dr. Alisson Dal Lago - Coordenação-Geral de Ciências Espaciais e Atmosféricas (CGCEA)

Dr. Evandro Albiach Branco - Centro de Ciência do Sistema Terrestre (COCST)

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

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

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação - (CPG)

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 Ducca Barbedo - Serviço de Informação e Documentação (SESID)

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

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Serviço de Informação e Documentação (SESID)

Cauê Silva Fróes - Serviço de Informação e Documentação (SESID)



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

sid.inpe.br/mtc-m21c/2019/10.08.12.22-TDI

DETECÇÃO DE MUDANÇA DA COBERTURA DA TERRA USANDO DADOS POLARIZADOS MULTIFREQUÊNCIA NA AMAZÔNIA BRASILEIRA

Rebeca Suely Gabriella Soares Carneiro

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Sidnei João Siqueira
Sant'Anna, e Claudio Aparecido
de Almeida, aprovada em 20 de
agosto de 2019.

URL do documento original:

<http://urlib.net/8JMKD3MGP3W34R/3U79NKS>

INPE
São José dos Campos
2019

Dados Internacionais de Catalogação na Publicação (CIP)

Carneiro, Rebeca Suely Gabriella Soares.

C215d Detecção de mudança da cobertura da terra usando dados polarizados multifrequência na Amazônia brasileira / Rebeca Suely Gabriella Soares Carneiro. – São José dos Campos : INPE, 2019.

xxx + 147 p. ; (sid.inpe.br/mtc-m21c/2019/10.08.12.22-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2019.

Orientadores : Drs. Sidnei João Siqueira Sant’Anna, e Claudio Aparecido de Almeida.

1. Radar de Abertura Sintética. 2. Banda L. 3. Banda C. 4. Floresta Nacional de Tapajós. 5. Sensoriamento Remoto. I.Título.

CDU 528.8:332.3(81)



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

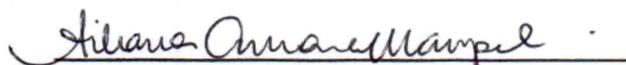
This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): **Rebeca Suelly Gabriella Soares Carneiro**

Título: "DETECÇÃO DE MUDANÇA DA COBERTURA DA TERRA USANDO DADOS POLARIZADOS MULTIFREQUÊNCIA NA AMAZÔNIA BRASILEIRA"

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

Dra. Silvana Amaral Kampel



Presidente / INPE / SJCampos - SP

Participação por Video - Conferência

Aprovado Reprovado

Dr. Sidnei João Siqueira Sant'Anna



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

Participação por Video - Conferência

Aprovado Reprovado

Dr. Claudio Aparecido de Almeida



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

Participação por Video - Conferência

Aprovado Reprovado

Dr. José Claudio Mura

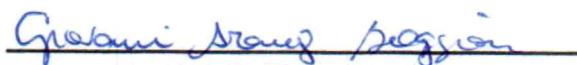


Membro da Banca / INPE / São José dos Campos - SP

Participação por Video - Conferência

Aprovado Reprovado

Dr. Giovanni de Araujo Boggione



Convidado(a) / IFG / Goiás - GO

Participação por Video - Conferência

Aprovado Reprovado

Este trabalho foi aprovado por:

maioria simples

unanimidade

São José dos Campos, 20 de agosto de 2019

A FÊNIX

*"Esgote o meu tempo e veja o relógio voltar
Me dê por vencido e eu voltarei a voar
Não temo a chama a me incendiar
A morte é apenas um passar*

*O fogo que me envolve me consome
E renova o meu ser
Sempre há vida em mim
Em meio às minhas cinzas eu desperto
E do chão do deserto
Nasce uma rosa outra vez!*

*Provoque a mudança e eu continuarei a viver
Destrua a esperança e eu a farei renascer
No árido chão vou florescer*

*Apague o meu nome e eu voltarei a escrever
Esqueça que existo e eu te farei perceber
E quando disser que eu não posso ser
Olhe ao seu redor, e vai me ver!"*

Bruno Faglioni

A meus pais, Carlos e Elizabeth.

AGRADECIMENTOS

A meus pais, pelo amor, carinho e, principalmente, por me permitirem sonhar e alcançar meus objetivos. Aos meus irmãos Henrique, Denise e Guilherme, pelo apoio e auxílio que me deram em todos esses anos de vida. À minha cunhada, Lisão, por todos os momentos que passamos juntas, e à minha futura sobrinha Bia. À minha gata, Neném, pela felicidade que me proporcionou em todos esses anos.

Aos meus orientadores, Dr. Sidnei Sant'ANNA e Dr. Cláudio Almeida, pelos preciosos ensinamentos, pela paciência e pelo tempo que dedicaram ao meu crescimento profissional e pessoal.

Ao Dr. Giovanni Boggione, por me ajudar desde antes do início dessa caminhada. Agradeço por acreditar em mim e me mostrar do que sou capaz.

Às minhas queridas amigas, Jessyca e Janaína, que foram os meus anjos da guarda e os presentes que Deus colocou na minha vida. Sem o apoio e suporte de vocês, eu não conseguiria.

À minha prima, Renata, e aos meus amigos, Elisa e Rafael, por ouvirem minhas preocupações, aguentarem minhas chatices, e o mais importante de tudo, por me socorrerem e me animarem sempre que eu precisava. Tenho muita sorte de ter amigos como vocês.

À minha quase orientadora, Mariane, por ter me estendido a mão e ter contribuído no desenvolvimento desse meu trabalho.

Aos meus colegas do INPE, que me ajudaram direta ou indiretamente. A meus amigos da família. Aos meus amigos da sala ASA 35, Dênis, Willian e Nildson. À minha amiga Bruna.

A Mariana Boggione pelo demasiado auxílio na parte de análise da estatística dos dados.

Ao Instituto Nacional de Pesquisas Espaciais e ao Programa de Pós-Graduação em Sensoriamento Remoto, pela oportunidade de estudo e pela concessão de suas instalações para a realização deste trabalho. A todos os funcionários e servidores do INPE, que contribuíram na minha educação durante esse processo.

Ao Instituto Federal de Goiás, por ceder seus laboratórios para a realização deste trabalho.

Ao Dr. Veraldo Liesenberg e Ms. Luciana Pereira por fornecerem as imagens SAR utilizadas nesse trabalho.

À equipe do TerraClass, pela contribuição e disponibilização dos dados do ano de 2016 na minha área de estudo e pelo apoio à minha pesquisa. Agradeço especialmente ao Dr. Cesare Neto e ao Dr. Cláudio Almeida, pela produção desses dados.

À Fundação de Ciência, Aplicações e Tecnologia Espaciais (FUNCATE), pelo apoio financeiro ao trabalho de campo. À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão da bolsa de pesquisa de pós-graduação.

Obrigada a todos que me ajudaram nesse percurso.

RESUMO

Os impactos ambientais provocados pelo desmatamento de florestas tropicais comprometem a proteção da biodiversidade e dos recursos naturais. O monitoramento constante dessas regiões é importante para a possível prevenção e controle do desmatamento, bem como para o entendimento da dinâmica do processo de mudança decorrente. A maioria dos programas de monitoramento dos biomas brasileiros utilizam dados de sensores ópticos. Entretanto, sistemas de sensores ópticos possuem limitação quanto na obtenção de dados livres de nuvens na Amazônia. Satélites imageadores que operam na faixa de frequência de micro-ondas são pouco afetados pela cobertura de nuvens, possibilitando a observação das dinâmicas da cobertura da terra e do seu monitoramento. Nesse contexto, o objetivo principal desse estudo foi avaliar o potencial do uso de dados SAR (Radar de Abertura Sintética) multifrequência provenientes dos satélites ALOS-2 e Sentinel-1A para a detecção de mudanças da cobertura da terra em uma área situada na Floresta Nacional de Tapajós e áreas próximas entre os anos de 2014 e 2016. Para este propósito as imagens SAR polarimétricas nas bandas L e C foram classificadas, separadas e em conjunto, em diferentes modelagens estatísticas pelo algoritmo de Máxima Verossimilhança associada com o algoritmo *Iteracted Conditional Modes* a fim de discriminar cinco classes de interesse. Com base nos dados polarizados univariados, bivariados e multivariados obteve-se 29 resultados de classificação para cada ano estudado. A partir de uma análise visual e observação das matrizes médias de confusão, concluiu-se que a separabilidade das classes de floresta e vegetação secundária não foi bem-sucedida, havendo necessidade de uma etapa de pós-classificação em 2014 utilizando a máscara de floresta do PRODES (Projeto de Monitoramento do Desmatamento da Floresta Amazônica Brasileira por Satélite). Os resultados foram validados utilizando amostras de validação a partir da simulação de Monte Carlo através de mil interações, onde foi feito o ranking de cada ano a partir do valor estimado do *kappa* médio de cada grupo. O ranking permitiu a exploração dos resultados classificatórios em relação aos conjuntos de canais de dados SAR pelo tipo de dado de entrada, frequências e canais utilizados. Os resultados demonstraram que o uso de dados multivariados produziu classificações de qualidade superior as demais, com *kappa* estimado da primeira posição de 0.82 para 2014 e 0.44 para 2016. A banda L (comprimento de onda de 15 a 30 cm) se destacou nos rankings de ambos os anos, produzindo resultados mais significativos comparados a banda C (comprimento de onda de 3,75 a 7,5 cm) quanto ao mapeamento da cobertura da terra. Por fim, a combinação dos canais VH e VV apresentaram melhores resultados na discriminação das classes estudadas. No que se refere a análise de mudança entre 2014 e 2016, houve modificações quanto a cobertura florestal primária (FP). Com a metodologia proposta, não foi possível identificar transições ocorridas entre FP e VS (vegetação secundária). Os cenários de mudança evidenciaram que as transições da classe de FP estão associadas ao pasto sujo, seguidas por pasto limpo e agricultura. Áreas de concordância entre polígonos de mudanças da cobertura florestal detectados com polígonos de desflorestamento do PRODES foram constatados. De modo geral, a utilização de dados SAR para o mapeamento da cobertura da terra e detecção de mudanças foi satisfatório. Este trabalho contribui para corroborar com a importância da aplicação de dados SAR para auxiliar nos programas de monitoramento existentes.

Palavras-chave: Radar de Abertura Sintética. Banda L. Banda C. Floresta Nacional de Tapajós. Sensoriamento Remoto. Classificação supervisionada. Modelagem estatística.

LAND COVER CHANGE DETECTION USING MULTI-FREQUENCY POLARIMETRIC DATA IN AMAZONIA BRASILEIRA

ABSTRACT

Environmental impacts caused by deforestation of tropical forests compromise the protection of biodiversity and natural resources. Constant monitoring of these regions is important for the possible prevention and control of deforestation, as well as for understanding the dynamics of the resulting change process. Most Brazilian biome monitoring programs use data from optical sensors. However, optical sensor systems have limitations in obtaining cloud-free data in the Amazon. Imaging satellites operating in the microwave frequency range are little affected by cloud cover, making it possible to observe the dynamics of land cover and its monitoring. In this context, the main objective of this study was to evaluate the potential of using multi-frequency SAR (Synthetic Aperture Radar) data from the ALOS-2 and Sentinel-1A satellites to detect land cover changes in an area located in the National Forest of Tapajós and nearby areas between 2014 and 2016. For this purpose polarimetric SAR images in the L and C bands were classified, separately and together, in different statistical modeling by the Maximum Likelihood algorithm associated with the Iterated Conditional Modes algorithm in order to discriminate five classes of interest. Based on univariate, bivariate and multivariate polarized data, 29 classification results were obtained for each year studied. From a visual analysis and observation of the average confusion matrices, it was concluded that the separability of forest classes and secondary vegetation was not successful, requiring a post-classification step in 2014 using the forest mask from PRODES (Brazilian Amazon Rainforest Deforestation Monitoring Project by Satellite). The results were validated using validation samples from Monte Carlo simulation through one thousand interactions, where each year was ranked from the estimated average kappa value of each group. The ranking allowed the exploration of the classification results in relation to the SAR data channel sets by the input data type, frequencies and channels used. The results showed that the use of multivariate data produced higher quality ratings than the others, with estimated first position kappa of 0.82 for 2014 and 0.44 for 2016. The L band (wavelength 15 to 30 cm) stood out in the rankings of both years, yielding more significant results compared to band C (wavelength from 3.75 to 7.5 cm) for land cover mapping. Finally, the combination of VH and VV channels presented better results in the discrimination of the studied classes. Regarding the change analysis between 2014 and 2016, there were modifications regarding the primary forest cover (PF). With the proposed methodology, it was not possible to identify transitions that occurred between PF and VS (secondary vegetation). The change scenarios showed that PF class transitions are associated with dirty pasture, followed by clean pasture and agriculture. Areas of agreement between forest cover change polygons detected with PRODES deforestation polygons were found. Overall, the use of SAR data for land cover mapping and change detection was satisfactory. This work corroborates the importance of applying SAR data to assist existing monitoring programs.

Keywords: Synthetic Aperture Radar. L-band. C-band. Tapajós National Forest. Remote Sensing. Supervised Classification. Statistical Modeling.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1- Estimativas das taxas anuais do desmatamento (1988-2017).....	10
Figura 2.2 - Exemplos de áreas que apresentam desflorestamento do tipo "corte raso".	12
Figura 2.3 - Retroespalhamento da energia de microondas nas bandas L, X e C.	15
Figura 3.1 - Mapa de localização da área de estudo.....	27
Figura 3.2 - Imagens ALOS/PALSAR-2: (a) 28/12/2014 e (b) 01/05/2016.	31
Figura 3.3 - Imagens SENTINEL-1A: (a) 19/12/2014 e (b) 19/01/2016.....	32
Figura 3.4 - Localização dos pontos coletados em campo: (a) 2014 e (b) 2016.	35
Figura 3.5 - Imagens utilizadas na confecção dos dados PRODES dos anos: (a) 2014 e (b) 2016.	37
Figura 3.6 - Dados temáticos do PRODES referentes aos anos: (a) 2014 e (b) 2016. ...	38
Figura 3.7 - Dados temáticos do TerraClass referentes aos anos: (a) 2014 e (b) 2016. .	39
Figura 3.8 - Dados pluviométricos diários na estação de Belterra (PA) do mês de dezembro (2014).....	41
Figura 3.9 - Dados pluviométricos diários na estação de Belterra (PA) do mês de janeiro (2016).	41
Figura 3.10 - Dados pluviométricos diários na estação de Belterra (PA) dos meses de abril-maio (2016).....	42
Figura 3.11 - Fluxograma metodológico.	43
Figura 3.12 - Pré-Processamento das imagens SAR.	44
Figura 3.13 - Amostras coletadas para o ano de 2014: (a) treinamento e (b) validação.	48
Figura 3.14 - Amostras coletadas para o ano de 2016: (a) treinamento e (b) validação.	49
Figura 3.15 - Gráfico <i>boxplot</i> da imagem PALSAR-2 do ano de 2014 representando o quartil inferior, superior e mediana das classes pelos valores de intensidade do sinal dos canais: (a) HH, (b) VH, (c) VV.	51
Figura 3.16 - Gráfico <i>boxplot</i> da imagem SENTINEL-1A do ano de 2014 representando o quartil inferior, superior e mediana das classes pelos valores de intensidade do sinal dos canais: (a) VH e (b) VV.	52

Figura 3.17 - Gráfico <i>boxplot</i> da imagem PALSAR-2 do ano de 2016 representando o quartil inferior, superior e mediana das classes pelos valores de intensidade do sinal dos canais: (a) HH, (b) VH, (c) VV.	53
Figura 3.18 - Gráfico <i>boxplot</i> da imagem SENTINEL-1A do ano de 2016 representando o quartil inferior, superior e mediana das classes pelos valores de intensidade do sinal dos canais: (a) VH e (b) VV.	54
Figura 4.1 - Resultado da classificação do ano de 2014 para o conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$: (a) antes e (b) depois da etapa de pós-classificação.	63
Figura 4.2 - Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ para o ano de 2014, representada graficamente.	64
Figura 4.3 - Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ para o ano de 2014M, representada graficamente.	65
Figura 4.4 - Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VH}\}$ para o ano de 2014, representada graficamente.	66
Figura 4.5 - Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VH}\}$ para o ano de 2014M, representada graficamente.	67
Figura 4.6 - Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ para o ano de 2014, representada graficamente.	68
Figura 4.7 - Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ para o ano de 2014M, representada graficamente.	69
Figura 4.8 - Matriz de confusão do conjunto $\{L_{VV}, C_{VH}\}$ para o ano de 2014M, representada graficamente.	71
Figura 4.9 - Matriz de confusão do conjunto $\{L_{VH}, C_{VV}\}$ para o ano de 2016, representada graficamente.	72
Figura 4.10 - Matriz de confusão do conjunto $\{L_{VH}\}$ para o ano de 2014M, representada graficamente.	73
Figura 4.11 - Matriz de confusão do conjunto $\{L_{VH}\}$ para o ano de 2016, representada graficamente.	74
Figura 4.12 - Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, L_{VV}\}$ para o ano de 2014M, representada graficamente.	75
Figura 4.13 - Matriz de confusão do conjunto $\{L_{VH}, C_{VH}, C_{VV}\}$ para o ano de 2016, representada graficamente.	76

Figura 4.14 - Matriz de confusão do conjunto $\{C_{VH}, C_{VV}\}$ para o ano de 2014M, representada graficamente.	77
Figura 4.15 - Matriz de confusão do conjunto $\{C_{VH}\}$ para o ano de 2016, representada graficamente.	78
Figura 4.16 - Matriz de confusão do conjunto $\{L_{HH}\}$ para o ano de 2014M, representada graficamente.	80
Figura 4.17 - Matriz de confusão do conjunto $\{L_{VV}\}$ para o ano de 2014M, representada graficamente.	81
Figura 4.18 - Matriz de confusão do conjunto $\{C_{VV}\}$ para o ano de 2014M, representada graficamente.	82
Figura 4.19 - Matriz de confusão do conjunto $\{L_{VV}\}$ para o ano de 2016, representada graficamente.	83
Figura 4.20- Matriz de confusão do conjunto $\{L_{HH}\}$ para o ano de 2016, representada graficamente.	84
Figura 4.21- Matriz de confusão do conjunto $\{C_{VV}\}$ para o ano de 2016, representada graficamente.	85
Figura 4.22 - Melhores resultados de classificação com dados multivariados referentes aos anos de: (a) 2014 e (b) 2016.	90
Figura 4.23 - Imagem temática de mudanças do cenário M1.	91
Figura 4.24 - Percentual de transições no cenário M1 da classe: (a) FP, (b) VS, (c) PS, (d) PL e (e) AG.	92
Figura 4.25 - Melhores resultados de classificação bivariada referentes aos anos de: (a) 2014 e (b) 2016.	93
Figura 4.26 - Imagem temática de mudanças do cenário M2.	94
Figura 4.27 - Percentual de transições no cenário M2 da classe: (a) FP, (b) VS, (c) PS, (d) PL e (e) AG.	95
Figura 4.28 - Melhores resultados da classificação univariada referentes aos anos de: (a) 2014 e (b) 2016.	97
Figura 4.29 - Imagem temática de mudanças do cenário M3.	98
Figura 4.30 - Percentual de transições no cenário M2 da classe: (a) FP, (b) VS, (c) PS, (d) PL e (e) AG.	99

Figura 4.31 - Melhores resultados de classificação da banda L referentes aos anos de: (a) 2014 e (b) 2016.	101
Figura 4.32 - Imagem temática de mudanças do cenário M4.....	102
Figura 4.33 - Percentual de transições no cenário M4 da classe: (a) FP, (b) VS, (c) PS, (d) PL e (e) AG.....	103
Figura 4.34 - Melhores resultados de classificação da banda C referentes aos anos de: (a) 2014 e (b) 2016.	104
Figura 4.35 - Imagem temática de mudança do cenário M5.	105
Figura 4.36 - Percentual de transições no cenário M5 da classe: (a) FP, (b) VS, (c) PS, (d) PL e (e) AG.....	106
Figura 4.37 – Polígonos de desflorestamento encontrados pelo: (a) PRODES e (b) Cenário M1.....	109
Figura 4.38 – Polígonos de desflorestamento encontrados pelo PRODES e cenário M1.	110
Figura 4.39 – Classificação da classe de vegetação secundária de uma parte da área de estudo do: (a) TerraClass 2014 e (b) conjunto {L _{VH} , L _{VV} , C _{VH} , C _{VV} } de 2014.	112
Figura 4.40 – Classificação da classe de pasto sujo de uma parte da área de estudo do: (a) TerraClass 2014 e (b) conjunto {L _{VH} , L _{VV} , C _{VH} , C _{VV} } de 2014.....	113
Figura 4.41 – Classificação da classe de pasto limpo de uma parte da área de estudo do: (a) TerraClass 2014 e (b) conjunto {L _{VH} , L _{VV} , C _{VH} , C _{VV} } de 2014.....	113
Figura 4.42 – Classificação da classe de agricultura de uma parte da área de estudo do: (a) TerraClass 2014 e (b) conjunto {L _{VH} , L _{VV} , C _{VH} , C _{VV} } de 2014.....	114
Figura 4.43 – Classificação de uma parte da área de estudo do: (a) TerraClass 2014 e (b) conjunto {L _{VH} , L _{VV} , C _{VH} , C _{VV} } de 2014.....	115

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 3.1 - Características das imagens orbitais SENTINEL-1A e ALOS-2.....	29
Tabela 3.2 - Pontos coletados nas classes de cobertura da terra.....	34
Tabela 3.3 - Descrição das classes de cobertura da terra.....	46
Tabela 3.4 - Quantidade do conjunto de amostras coletadas das classes de cobertura. .	50
Tabela 3.5 - Combinações dos canais usados nas classificações.	55
Tabela 4.1 - <i>Rankings</i> dos resultados de classificação.	60
Tabela 4.2 - Quantidade de repetições que a imagem classificada se apresentou na posição designada.	61
Tabela 4.3 - Resultado do teste estatístico de Congaton de 2014M e 2016.	86
Tabela 4.4 - Descrição dos Cenários de Mudanças.	87
Tabela 4.5 - Matriz de transição do cenário M1.....	89
Tabela 4.6 - Matriz de transição do cenário M2.....	95
Tabela 4.7 - Matriz de transição do cenário M3.....	99
Tabela 4.8 - Matriz de transição do cenário M4.....	103
Tabela 4.9 - Matriz de transição do cenário M5.....	106
Tabela A.1 - Matriz de confusão do conjunto $\{L_{HH}\}$ do ano de 2014, representada em (%)..	128
Tabela A.2 - Matriz de confusão do conjunto $\{L_{VH}\}$ do ano de 2014, representada em (%)..	128
Tabela A.3- Matriz de confusão do conjunto $\{L_{VV}\}$ do ano de 2014, representada em (%)..	129
Tabela A.4 - Matriz de confusão do conjunto $\{C_{VV}\}$ do ano de 2014, representada em (%)..	129
Tabela A.5- Matriz de confusão do conjunto $\{C_{VH}\}$ do ano de 2014, representada em (%)..	129
Tabela A.6 - Matriz de confusão do conjunto $\{L_{HH}, L_{VH}\}$ do ano de 2014, representada em (%).	130
Tabela A.7 - Matriz de confusão do conjunto $\{L_{VH}, L_{VV}\}$ do ano de 2014, representada em (%).	130

Tabela A.8- Matriz de confusão do conjunto $\{L_{HH}, L_{VV}\}$ do ano de 2014, representada em (%).	130
Tabela A.9- Matriz de confusão do conjunto $\{C_{VH}, C_{VV}\}$ do ano de 2014, representada em (%).	131
Tabela A.10- Matriz de confusão do conjunto $\{L_{HH}, C_{VH}\}$ do ano de 2014, representada em (%).	131
Tabela A.11- Matriz de confusão do conjunto $\{L_{HH}, C_{VV}\}$ do ano de 2014, representada em (%).	131
Tabela A.12- Matriz de confusão do conjunto $\{L_{VH}, C_{VH}\}$ do ano de 2014, representada em (%).	132
Tabela A.13- Matriz de confusão do conjunto $\{L_{VH}, C_{VV}\}$ do ano de 2014, representada em (%).	132
Tabela A.14- Matriz de confusão do conjunto $\{L_{VV}, C_{VH}\}$ do ano de 2014, representada em (%).	132
Tabela A.15- Matriz de confusão do conjunto $\{L_{VV}, C_{VV}\}$ do ano de 2014, representada em (%).	133
Tabela A.16- Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, L_{VV}\}$ do ano de 2014, representada em (%).	133
Tabela A.17- Matriz de confusão do conjunto $\{L_{HH}, C_{VH}, C_{VV}\}$ do ano de 2014, representada em (%).	133
Tabela A.18- Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, C_{VH}\}$ do ano de 2014, representada em (%).	134
Tabela A.19- Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, C_{VV}\}$ do ano de 2014, representada em (%).	134
Tabela A.20- Matriz de confusão do conjunto $\{L_{HH}, L_{VV}, C_{VH}\}$ do ano de 2014, representada em (%).	134
Tabela A.21- Matriz de confusão do conjunto $\{L_{HH}, L_{VV}, C_{VV}\}$ do ano de 2014, representada em (%).	135
Tabela A.22- Matriz de confusão do conjunto $\{L_{VH}, L_{VH}, C_{VV}\}$ do ano de 2014, representada em (%).	135
Tabela A.23- Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VH}\}$ do ano de 2014, representada em (%).	135

Tabela A.24- Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VV}\}$ do ano de 2014, representada em (%).	136
Tabela A.25- Matriz de confusão do conjunto $\{L_{VV}, C_{VH}, C_{VV}\}$ do ano de 2014, representada em (%).	136
Tabela A.26- Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, C_{VH}, C_{VV}\}$ do ano de 2014, representada em (%).	136
Tabela A.27- Matriz de confusão do conjunto $\{L_{HH}, L_{VV}, C_{VH}, C_{VV}\}$ do ano de 2014, representada em (%).	137
Tabela A.28- Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ do ano de 2014, representada em (%).	137
Tabela A.29- Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ do ano de 2014, representada em (%).	137
Tabela A.30 - Matriz de confusão do conjunto $\{L_{HH}\}$ do ano de 2016, representada em (%).	138
Tabela A.31 - Matriz de confusão do conjunto $\{L_{VH}\}$ do ano de 2016, representada em (%).	138
Tabela A.32 - Matriz de confusão do conjunto $\{L_{VV}\}$ do ano de 2016, representada em (%).	139
Tabela A.33 - Matriz de confusão do conjunto $\{C_{VV}\}$ do ano de 2016, representada em (%).	139
Tabela A.34 - Matriz de confusão do conjunto $\{C_{VH}\}$ do ano de 2016, representada em (%).	139
Tabela A.35 - Matriz de confusão do conjunto $\{L_{HH}, L_{VH}\}$ do ano de 2016, representada em (%).	140
Tabela A.36 - Matriz de confusão do conjunto $\{L_{VH}, L_{VV}\}$ do ano de 2016, representada em (%).	140
Tabela A.37 - Matriz de confusão do conjunto $\{L_{HH}, L_{VV}\}$ do ano de 2016, representada em (%).	140
Tabela A.38 - Matriz de confusão do conjunto $\{C_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).	141
Tabela A.39 - Matriz de confusão do conjunto $\{L_{HH}, C_{VH}\}$ do ano de 2016, representada em (%).	141

Tabela A.40 - Matriz de confusão do conjunto $\{L_{HH}, C_{VV}\}$ do ano de 2016, representada em (%).	141
Tabela A.41 - Matriz de confusão do conjunto $\{L_{VH}, C_{VH}\}$ do ano de 2016, representada em (%).	142
Tabela A.42 - Matriz de confusão do conjunto $\{L_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).	142
Tabela A.43 - Matriz de confusão do conjunto $\{L_{VV}, C_{VH}\}$ do ano de 2016, representada em (%).	142
Tabela A.44 - Matriz de confusão do conjunto $\{L_{VV}, C_{VV}\}$ do ano de 2016, representada em (%).	143
Tabela A.45 - Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, L_{VV}\}$ do ano de 2016, representada em (%).	143
Tabela A.46 - Matriz de confusão do conjunto $\{L_{HH}, C_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).	143
Tabela A.47 - Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, C_{VH}\}$ do ano de 2016, representada em (%).	144
Tabela A.48 - Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).	144
Tabela A.49 - Matriz de confusão do conjunto $\{L_{HH}, L_{VV}, C_{VH}\}$ do ano de 2016, representada em (%).	144
Tabela A.50 - Matriz de confusão do conjunto $\{L_{HH}, L_{VV}, C_{VV}\}$ do ano de 2016, representada em (%).	145
Tabela A.51 - Matriz de confusão do conjunto $\{L_{VH}, C_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).	145
Tabela A.52 - Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VH}\}$ do ano de 2016, representada em (%).	145
Tabela A.53 - Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VV}\}$ do ano de 2016, representada em (%).	146
Tabela A.54 - Matriz de confusão do conjunto $\{L_{VV}, C_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).	146
Tabela A.55 - Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, C_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).	146

Tabela A.56 - Matriz de confusão do conjunto $\{L_{HH}, L_{VV}, C_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).	147
Tabela A.57 - Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).	147
Tabela A.58 - Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).	147

LISTA DE SIGLAS E ABREVIATURAS

AC	Acurácia Global
AG	Agricultura
ARPA	Programa Áreas Protegidas da Amazônia
CBERS	Satélite Sino-Brasileiro de Recursos Terrestres
CRA	Centro Regional da Amazônia
DETER	Projeto Detecção de Desmatamento em Tempo Quase Real
DESF	Desflorestamento
DNIT	Departamento Nacional de Infraestrutura de Transportes
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
ESA	<i>European Aerospace Agency</i>
ENVI	<i>Environment for Visualizing Images</i>
FP	Floresta Primária
Flona-Tapajós	Floresta Nacional de Tapajós
GPC	<i>Ground Point Control</i>
GPS	<i>Global Positioning System</i>
GRD	<i>Ground Range Detection</i>
H	Horizontal
HBQ	<i>High Beam Quad</i>
IBAMA	Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis
IBGE	Instituto Brasileiro de Geografia e Estatística
ICMBio	Instituto Chico Mendes de Conservação da Biodiversidade
ICM	<i>Iteracted Conditional Modes</i>
IDL	<i>Interactive Data Visualization Solutions</i>
INPE	Instituto Nacional de Pesquisas Espaciais
INMET	Instituto Nacional de Meteorologia
IW	<i>Interferometric Wide Swath</i>
JAXA	<i>Japan Aerospace Exploration Agency</i>

MAXVER	Máxima Verossimilhança
MDE	Modelo Digital de Elevação
MLME	Modelo Linear de Mistura Espectral
MMA	Ministério do Meio Ambiente
MODIS	<i>Moderate-Resolution Imaging Spectroradiometer</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
PA	Pará
PolSAR	<i>Polarimetric Synthetic Aperture Radar</i>
PL	Pasto Limpo
PS	Pasto Sujo
PMV	Programa Municípios Verdes
PPCDAm	Plano de Ação para Prevenção e Controle do Desmatamento na
Amazônia	Legal
PRODES	Projeto de Monitoramento do Desmatamento da Floresta Amazônica Brasileira por Satélite
RADAR	<i>Radio Detection and Ranging</i>
RF	<i>Random Forest</i>
SAR	<i>Synthetic Aperture Radar</i>
SAR-C	<i>Synthetic Aperture Radar C-band</i>
SIRGAS	Sistema de Referência Geocêntrico para as Américas
SLC	<i>Single Look Complex</i>
SNAP	Sentinel Application Platform
SRTM	<i>Shuttle Radar Topography Mission</i>
TOPSAR	<i>Terrain Observation with Progressive Scan SAR</i>
UCs	Unidades de Conservação
UTM	<i>Universal Transversa de Mercator</i>

USGS	<i>United States Geological Survey</i>
V	Vertical
VS	Vegetação Secundária
WGS-84	<i>World Geodetic System 1984</i>

SUMÁRIO

Pág.

1	INTRODUÇÃO	1
1.1	Objetivo Geral.....	4
1.2	Objetivos Específicos	5
1.3	Organização da Dissertação	5
2	FUNDAMENTAÇÃO TEÓRICA	6
2.1	Desmatamento da Amazônia Brasileira.....	6
2.2	Programas de Monitoramento do Bioma Amazônia.....	11
2.3	Princípios Básicos de RADAR	14
2.4	Detecção de Mudanças	16
2.5	Classificação MAXVER-ICM.....	20
2.6	Distribuições Estatísticas	24
3	MATERIAIS E MÉTODOS	27
3.1	Área de Estudo.....	27
3.2	Imagens utilizadas.....	29
3.3	Dados de Campo	33
3.4	Dados auxiliares.....	36
3.4.1.	PRODES	36
3.4.2.	TerraClass	39
3.4.3.	Dados Meteorológicos.....	40
3.4.4.	<i>Softwares</i>	42
3.5	Metodologia	43
3.5.1.	Pré-Processamento	43
3.5.2.	Definição das Classes e Seleção das Amostras	45
3.5.3.	Análise Exploratória.....	50
3.5.4.	Classificação MAXVER-ICM	54
3.5.5.	Avaliação e Comparação das Imagens Classificadas.....	55
3.5.6.	Pós-Classificação	57
3.5.7.	Detecção de Mudanças.....	57

3.5.8. Análise dos Resultados.....	58
4 RESULTADOS E DISCUSSÕES	59
4.1 Análise dos resultados de classificação	59
4.1.1 Comparação entre os resultados da classificação e pós-classificação	62
4.1.2 Comparação entre os resultados de diferentes modelagens de dados	69
4.1.3 Comparação entre os resultados de diferentes frequências utilizadas.....	74
4.1.4 Comparação entre os resultados de diferentes canais utilizados	79
4.2 Análise dos resultados de mudança	86
4.2.1. Análise das matrizes de transição.....	88
5. CONCLUSÃO	117
REFERÊNCIAS BIBLIOGRÁFICAS.....	112
APÊNDICE A – MATRIZES DE CONFUSAO.....	128

1 INTRODUÇÃO

As florestas tropicais são organismos que lhes confere o fornecimento de diversos serviços ambientais, dentre eles, o condicionamento climático. A América do Sul possui florestas tropicais que estão entre os mais ricos biomas do planeta, o que gera um clima ameno em comparação aos demais continentes. No entanto, desde a colonização brasileira essas florestas vêm sendo devastadas.

De acordo com Alves (2001), o desmatamento florestal tem diversos agravantes ao meio ambiente, como o desequilíbrio do ciclo hidrológico, modificação da fertilidade do solo e alterações do ecossistema. Além disso, a falta de planejamento do crescimento urbano nessas áreas gera condições de vida precárias. Fearnside (2005) ressalta ainda o uso insustentável da floresta, a perda da sociodiversidade ao sacrificar culturas indígenas e extrativistas tradicionais, o prejuízo quanto a prestação de serviços ecossistêmicos e a intensificação do efeito estufa a nível global, causada pela emissão de gases que o desmatamento provoca, como características deste cenário.

Atualmente, pesquisas relacionadas ao desenvolvimento sustentável e à preservação ambiental são muito discutidas pela sociedade científica. Nesse contexto, a Floresta Amazônica se destaca por abrigar a maior biodiversidade do planeta, abrangendo diversos ecossistemas além da diversidade cultural humana (populações indígenas, extrativistas, agricultores etc.). Sua relevância é ainda maior, pois a Amazônia está compreendida em grande parte em território brasileiro, alcançando mais de 60% de sua extensão. Como exemplo de seu papel fundamental na manutenção climática e hídrica, Nobre (2014) argumenta que o abastecimento de água das regiões andinas depende do derretimento do gelo acumulado em suas montanhas, o qual provém principalmente da evaporação gerada pela Floresta Amazônica.

Dessa forma, estudos relacionados ao meio ambiente compreendem o entendimento de diversas forças atuantes, tanto no sentido de seu consumo (que pode levar ao seu esgotamento) quanto de sua conservação. A apropriação territorial da região amazônica foi modificada por alterações estruturais que ocorreram a partir da década de 1960. Becker (1999) destaca que há padrões novos e antigos no que tange ao uso e a cobertura da terra na Amazônia. O agronegócio se expandiu pela região a partir do final dos anos 60. Outra mudança, em âmbito econômico, ocorreu na transição do extrativismo dos

recursos naturais. Ocorreu, também, uma grande modificação no cenário demográfico, devido à forte migração e contínua expropriação da terra ao longo das rodovias, ordenando uma mobilidade espacial ligada à sua urbanização (BECKER, 2005).

A posse de terra, que era tradicionalmente empregada como reserva de valor (economicamente improdutiva), passou a ser empregada para a produção de soja, algodão e pecuária. Da área total desmatada, cerca de 60% está ocupada por atividade pecuária e menos de 5% equivale à expansão agrícola (ALMEIDA et al., 2016; TerraClass, 2008). Fearside (2005) alega que o avanço da agropecuária, principalmente o cultivo de soja, estimula a expansão de infraestruturas de transportes, provocando o aumento do desmatamento e possibilitando a migração para territórios de difícil acesso. Além do impacto do grande produtor, o autor salienta que os pequenos agricultores também causam grandes impactos em áreas nas quais se encontram concentrados, como em regiões do Pará, Amazonas, Rondônia e ao longo da rodovia Transamazônica.

Nessa conjuntura, a tecnologia dos satélites se destaca como principal fonte de dados para estudos e ações de preservação dos biomas brasileiros, principalmente nas florestas tropicais. Inclusive, foram observações realizadas por satélites as principais responsáveis pela aferição do impacto que o desmatamento amazônico exerce em escala global (BECKER, 2005). A utilização de imagens de sensores orbitais, juntamente com o avanço das geotecnologias, permitiu um mapeamento e monitoramento mais consistente e detalhado da superfície da Terra (SELCUK et al., 2003; LO e CHOI, 2004; RAWAT et al., 2014). Diante disso, o monitoramento sistemático da cobertura florestal se torna um recurso viável para o controle do desmatamento, planejamento e desenvolvimento regional.

A fiscalização do desmatamento ilegal tem sido um grande desafio nos países onde existem florestas tropicais, implicando em inúmeras discussões que sensibilizam a ação dos Governos, da comunidade científica, bem como da sociedade civil. Considerando o combate ao desmatamento ilegal, o governo e as organizações da sociedade civil brasileira estabelecem que a redução do desmatamento envolve uma série de políticas de controle e de incentivo ao desenvolvimento sustentável (ALENCAR et al., 2004). Um exemplo de plano de controle é o Plano de Ação para Prevenção e Controle do Desmatamento na Amazônia Legal (PPCDAm) que se encontra em sua 4ª fase (2016 a

2020) e que tem como objetivo auxiliar na redução do desmatamento e promover um modelo eficiente de desenvolvimento sustentável na Amazônia Legal.

Com o intuito de monitorar o desmatamento, desde 1988 o Projeto de Monitoramento do Desmatamento da Floresta Amazônica Brasileira por Satélite (PRODES) observa a cobertura florestal amazônica com imagens de satélites orbitais que operam na faixa do espectro óptico e realiza o mapeamento do desmatamento por corte raso, produzindo estimativas das taxas anuais de desmatamento na região (INPE, 2017). A estimativa da taxa de desmatamento é frequentemente utilizada para avaliar sistematicamente a pressão humana sobre a cobertura florestal na Amazônia.

Dentre as diversas técnicas de monitoramento, a detecção de mudanças de cenários por imagens de satélites é uma técnica consolidada e difundida na comunidade de sensoriamento remoto. O processo de detecção de mudanças da cobertura da terra visa identificar diferenças no estado dos alvos na superfície terrestre através da análise de dados adquiridos em momentos distintos (SINGH, 1989). Existe uma grande variedade de técnicas de sensoriamento remoto e processamento digital de imagens capazes de identificar, mapear e quantificar as mudanças ocorridas na superfície terrestre, como por exemplo, a detecção de mudanças que é comumente usada para detectar alterações ao longo do tempo e pode ser aplicada para vários propósitos, incluindo monitoramento de secas e inundações, mudanças na cobertura da terra, crescimento urbano e outras modificações.

Estudos focados no monitoramento e avaliação de causas e efeitos das mudanças na paisagem requerem uma disponibilidade constante de dados. Para dados ópticos, a presença de nuvens é um forte limitante para essa condição. Desse modo, a utilização de dados de radares de abertura sintética (SAR) para o mapeamento e monitoramento de áreas tropicais minimiza este problema por serem pouco influenciados pela cobertura de nuvens (JENSEN, 2009; HENDERSON; LEWIS, 1998).

Existem diversos sistemas de sensores que operam na faixa de micro-ondas em nível orbital, que se diferenciam em suas distintas frequências e polarizações (TEIXEIRA; PINHEIRO, 2015). Dentre os sistemas de radares imageadores existentes atualmente, os dados dos sensores que operam em Banda L (comprimento de onda de 15 a 30 cm) têm

sido utilizados essencialmente na identificação de desflorestamento nas áreas tropicais (BENEDITTI, 2010). Em contrapartida, os dados dos sensores que operam na Banda C (comprimento de onda de 3,75 a 7,5 cm) têm sido pouco utilizados para o mapeamento da cobertura da terra (SCHIMULLIUS et al., 2015). Porém, com a disponibilização de dados em 2015 do satélite SENTINEL-1A houve um aumento gradual na sua utilização em estudos relacionados quanto a sua capacidade de mapeamento em regiões tropicais (DINIZ, 2019).

Apesar de inúmeros estudos sobre o potencial da utilização das diferentes frequências dos dados SAR em estudo ambientais, há uma carência de estudos relacionados a utilização de dados SAR multifrequência. A integração de dados de diferentes frequências pode complementar e aprimorar a extração de informações para o monitoramento e mapeamento de coberturas terrestres.

Dentro desse cenário surgem algumas questões científicas, tais como:

1. A combinação de dados SAR em diferentes frequências e polarização pode melhorar a identificação/discriminação de classes de cobertura da terra?
2. A utilização conjunta dos dados de radar obtidos em frequências distintas (Bandas L e C) ajuda a discriminar melhor as mudanças ocorridas na cobertura da terra?
3. O uso conjunto de dados SAR em diferentes frequências e polarizações pode ser útil no monitoramento contínuo da região Amazônica?

Diante do exposto, o presente trabalho tem como finalidade detectar mudanças na cobertura da terra numa região da Amazônia Brasileira a partir de dados SAR polarimétricos multifrequência (Bandas L e C). Para esse objetivo, métodos de classificação e detecção de mudanças serão necessários para a discriminação das classes de cobertura da terra e identificação de mudanças dessas classes no período estudado.

1.1 Objetivo geral

O objetivo geral do trabalho é detectar mudanças nas classes de cobertura da terra (baseadas no TerraClass) na Floresta Nacional de Tapajós e áreas adjuntas utilizando imagens SAR em diferentes frequências e polarizações.

1.2 Objetivos específicos

Os objetivos específicos definidos para o desenvolvimento do trabalho estão descritos a seguir:

- Avaliar o desempenho do classificador MAXVER-ICM para dados SAR em diferentes frequências na área de estudo selecionada;
- Detectar mudanças em uma porção da região Amazônica, ocorridas entre 2014 e 2016, com dados SAR polarizados nas bandas C e L, separadas e conjuntas, por meio da análise pós-classificação;
- Detectar e analisar o desflorestamento ocorrido entre os anos de 2014 e 2016;

1.3 Organização da dissertação

A dissertação está dividida em 5 capítulos. Cada capítulo é descrito brevemente a seguir:

- Capítulo 1 (Introdução): é apresentada uma breve introdução, onde contextualiza-se o problema do desmatamento e a utilização de dados RADAR. Destaca-se a importância do tema proposto, bem como os objetivos a serem alcançados;
- Capítulo 2 (Fundamentação Teórica): está contida a revisão de literatura que trata da Amazônia Brasileira, o desmatamento, programas de monitoramento, técnicas de processamento digital de imagens e análises estatísticas;
- Capítulo 3 (Materiais e Métodos): é descrita a área de estudo na Floresta Nacional de Tapajós, as imagens satelitárias, os dados de campo e meteorológicos, bem como a metodologia executada para alcançar os objetivos propostos;
- Capítulo 4 (Resultados e Discussões): são apresentados e analisados os resultados obtidos. São avaliados neste trabalho os rankings referentes aos resultados de classificação e a análise de mudanças;
- Capítulo 5 (Conclusão): são expostas as considerações finais do trabalho e recomendações para estudos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Desmatamento da Amazônia brasileira

As florestas tropicais abrigam grande biodiversidade e desempenham um papel fundamental em processos ecológicos, climáticos e biogeoquímicos, bem como na manutenção do bem-estar humano (AMIN et al., 2019). A floresta Amazônica é uma floresta tropical, localizada na Região Centro-Norte da América do Sul, que abrange nove países: Bolívia, Brasil, Colômbia, Equador, Guiana, Guiana Francesa, Peru, Suriname e Venezuela. Entretanto, 66% da sua área total encontra-se em território brasileiro (SOUZA, 2010).

A Amazônia brasileira é caracterizada por sua biodiversidade e convivência, seja em conflito ou em harmonia, entre populações indígenas, seringueiros, colonos transferidos do sul ou nordeste do Brasil com caboclos ribeirinhos, megaempreendimentos agrícolas com uma produção familiar de subsistência e o extrativismo. Ademais, a Amazônia abriga diversos ecossistemas, do cerrado à floresta densa, em uma topografia que varia de áreas de planícies a grandes maciços rochosos. Preservar a Amazônia, maior patrimônio natural da Terra, é um grande desafio. Isso porque se trata de um bioma com grande diversidade ecológica e humana (BECKER, 1999).

A fim de planejar e promover o desenvolvimento da Amazônia, que tinha em comum a distância e o isolamento dos grandes centros mais dinâmicos da economia do Brasil, o governo federal criou, em 27 de outubro de 1966 na LEI Nº 5.173, o conceito de Amazônia Legal. Esse conceito foi pautado, essencialmente, em critérios econômicos e políticos (SOUZA, 2010). A Amazônia Legal compreende os atuais estados do Acre, do Amapá, do Amazonas, do Maranhão (a oeste de 44º), do Mato Grosso, do Pará, de Rondônia, de Roraima e do Tocantins (ALVES, 2010).

Acredita-se que a ocupação da Amazônia por descendentes europeus iniciou-se nos tempos de conquista e colonização do Brasil (SOUZA, 2010). Até o início do século XX, a floresta densa, com alta umidade, calor intenso e complexa rede fluvial formava um difícil obstáculo a ser rompido para a ocupação e exploração (SOUZA, 2010; HUERTAS, 2009). Segundo Becker (2005), nessa época havia pouca disponibilidade de recursos e população para se apropriar completamente da região amazônica, ou seja, a região carecia de integração geopolítica. Dessa forma, a posse foi garantida principalmente por políticas de controle de território. Assim, sem demanda de desmate

extensivo, a Floresta Amazônica permaneceu praticamente preservada até o início da década de 1970, quando a Rodovia Transamazônica foi inaugurada. No final do século XX, as estradas e a telecomunicação permitiram maior conectividade regional e articulação entre os atores locais, nacionais e globais, tanto de grupos que depredam quanto de grupos que buscam a conservação (BECKER, 2005).

A partir da década de 1970, o modelo tradicional de ocupação da Amazônia levou ao desmatamento de milhões de hectares de floresta da Amazônia Legal, ocasionando o aumento da especulação de terra ao longo das estradas e o crescimento desordenado das cidades, além de intensificar as atividades agropecuárias e madeireiras. Este processo de ocupação é um fenômeno complexo e não pode ser atribuído a um único fator. (ALVES, 2010; FERREIRA; VENTICINQUE; ALMEIDA, 2005; SOUZA, 2010).

Os atores e as forças que coordenam o desmatamento na Amazônia variam espaço-temporalmente. Geralmente, os grandes e médios fazendeiros respondem por grande parte do desmatamento (mais de 60%), mas os pequenos agricultores também podem impulsioná-lo nas regiões onde estão concentrados (FEARNSIDE, 2005; 2006).

O processo de desmatamento, normalmente, começa com a abertura oficial ou clandestina de estradas, que permitem a expansão humana e a ocupação irregular de terras para a exploração predatória de madeiras nobres. Posteriormente, converte-se a floresta explorada em agricultura familiar e pastagens para a criação extensiva de gado (FERREIRA; VENTICINQUE; ALMEIDA, 2005; MÜLLER-HANSEN et al., 2019). A produção pecuária, especialmente a pecuária de corte, fomenta a expansão de pastagens para a floresta tropical.

Nas últimas décadas, a abertura regional para as comunidades nacionais e mercados internacionais ocasionou mudanças nas atividades extrativistas da terra. Ademais, impulsionou o agronegócio, incluindo o desenvolvimento de uma cadeia de fornecimento para processamento de carne. Isso aumentou a demanda por terras agrícolas na bacia amazônica (MÜLLER-HANSEN et al., 2019). Na década de 1990, houve a multiplicação de unidades de conservação (UCs) e a demarcação de terras indígenas (BECKER, 2005), e nos anos 2000 foi criado o Programa Áreas Protegidas da Amazônia (ARPA) pela expansão e fortalecimento das UCs, que estabelece como maior programa de conservação de áreas florestais do mundo. As pastagens de baixa qualidade têm cedido lugar à agricultura mecanizada, especialmente para o cultivo de soja e

algodão (FERREIRA; VENTICINQUE; ALMEIDA, 2005), contribuindo com, aproximadamente, 5% de ocupação da área desmatada na Amazônia Legal (ALMEIDA et al., 2016; MÜLLER-HANSEN et al, 2019).

Com o aumento da demanda por terras agricultáveis, maior acessibilidade e acesso a tecnologias mais avançadas, a exploração madeireira predatória é sustentada em ritmo acelerado, tornando-se um coativo precedente à ocupação de terra e prescindindo da ação inicial do posseiro (BERTHA, 1999). Além de prover a ocupação, a exploração predatória representa também uma forçante de exposição ampliada da floresta ao fogo originário da renovação de pastagens vizinhas e práticas agrícolas. Em 1999, o cultivo de soja, seguido pelos cultivos de arroz e milho, já ocupava novas e significativas áreas, alcançando uma produção de 6,9 milhões de toneladas (BERTHA, 1999).

O desmatamento em grande escala traz consequências adversas, com fortes impactos negativos sobre a biodiversidade e o clima local, podendo ocasionar processo de savanização irreversível (MAHLI et al., 2007). Além disso, as regiões afetadas podem sofrer com longos períodos de seca e redução das reservas de água (LOVEJOY; NOBRE, 2018). A menor precipitação, por sua vez, afeta a produtividade agrícola e pode constituir um elemento relevante para o clima global. Outros efeitos incluem contribuições para extinções de espécies, perda de serviços ecossistêmicos e aumento da vulnerabilidade de mudanças a longo prazo na configuração da paisagem que, por sua vez, levam ao processo de fragmentação (CABRAL et al., 2018).

Métodos de corte e queima são usados para recuperar a fertilidade do solo e podem desencadear incêndios florestais não intencionais. Em muitas áreas, os solos pobres em nutrientes levam à rápida degradação da fertilidade das pastagens. Outrossim, a invasão de ervas daninhas e pragas, a compactação e a erosão do solo promovem ainda mais a degradação das pastagens. Por esse motivo, as pastagens exauridas são abandonadas e a vegetação secundária começa a crescer sobre elas. No entanto, isso força os fazendeiros a substituí-las por pastagens em áreas recém-desmatadas e avançar ainda mais a fronteira sobre a floresta preservada.

Com as mudanças estruturais, os atores políticos alteraram suas estratégias de controle do território em relação às demandas externas. Um dos fatores que concorrem para o novo cenário é o peso que o desmatamento passou a ter em âmbito global, uma vez que este exerce alterações sobre o clima e biodiversidade, atualmente considerados bens de

toda a humanidade e passíveis de acordos e regulamentações internacionais. Desde a década de 2000, tem havido esforços para reduzir o desmatamento na Amazônia brasileira. Isso inclui a aplicação de leis ambientais, o que acarreta custos consideráveis e requer monitoramento constante e aprimorado.

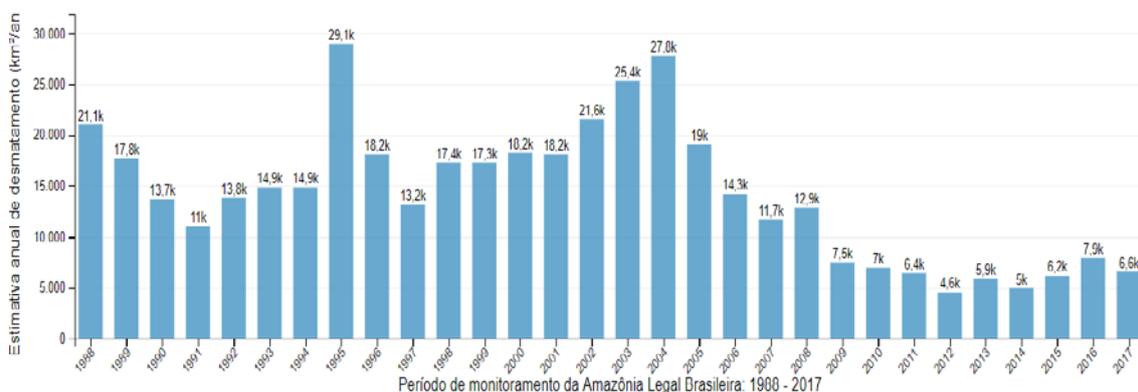
Todavia, os agentes reagem aos sistemas de monitoramento atuais, desmatando pequenos fragmentos para evitar a detecção. Além disso, a legislação ambiental atual, o Código Florestal Brasileiro (Lei 12.727/2012), permite que proprietários de terra desmatem até 20% de suas terras, no bioma Amazônia. Cortar apenas as áreas legalmente disponíveis levará a perdas na biodiversidade e quantidades consideráveis de gases de efeito estufa liberados na atmosfera (AGUIAR et al., 2016; CANO-CRESPO et al., 2015; LANDERS, 2007; LENTON et al., 2008; MÜLLER-HANSEN et al., 2019; NEPSTAD et al., 2014; OLIVEIRA et al., 2013; PERZ; SKOLE, 2003; RICHARDS et al., 2017; SOARES-FILHO et al., 2014; ZEMP et al., 2017).

Vale ressaltar que, além das alterações no funcionamento dos ecossistemas e perda de serviços ecossistêmicos, a expansão do desmatamento é acompanhada de conflitos sociais, migração desordenada e o crescimento desenfreado e desorganizado das cidades (ALVES, 2010; BECKER, 1997). Além disso, a migração e a expropriação de terras induziram a população a se concentrar nos centros urbanos, levando a Amazônia a possuir a maior taxa de crescimento urbano no Brasil nas décadas que antecedem os anos 2000 (BECKER, 2005).

Por conseguinte, o combate ao desmatamento é uma prioridade para o governo brasileiro e para as organizações internacionais. O monitoramento e a repressão são, atualmente, as estratégias principais (FEARSLIDE, 2005). A fim de monitorar e controlar o desmatamento na Amazônia, o Instituto Nacional de Pesquisas Espaciais (INPE) utiliza dados de satélite para mapear anualmente o desmatamento da Amazônia Legal desde 1988, e relata as taxas anuais de desmatamento como parte do Programa de Monitoramento do Desmatamento da Floresta Amazônica Brasileira por Satélite (PRODES) (Câmara et al., 2006; INPE, 2017). O INPE, em parceria com a EMBRAPA, também desenvolveu o projeto TerraClass, cujo objetivo é mapear o uso da terra e a distribuição espacial do uso e a cobertura do solo em áreas desmatadas identificadas pelo projeto PRODES (INPE, 2017).

Em relação às estimativas das taxas de desmatamento da Amazônia Legal, ilustrada na Figura 2.1, os índices variaram muito nos trinta anos do projeto, com acelerações nas primeiras metades dos anos 90 e 2000, com picos em 1995 (29.059 km² / ano) e 2004 (27.772 km²/ano), e então uma queda progressiva até uma baixa histórica de 4.571 km²/ano em 2012 (INPE, 2017). Esse declínio nas taxas de desmatamento na última década é corroborado por outros estudos, embora os valores absolutos tenham variado dependendo da metodologia, tipo de floresta observada e unidade de mapeamento adotada.

Figura 2.1- Estimativas das taxas anuais do desmatamento (1988-2017).



Fonte: INPE (2017).

Tradicionalmente, o mapeamento de áreas desmatadas é feito por meio da utilização e análise de imagens dos satélites Landsat. A viabilidade dessa técnica foi, inicialmente, comprovada pelos estudos realizados por Tardin et al. (1980), que utilizaram imagens do instrumento Landsat/MSS para mapear as áreas desmatadas em dois períodos da década de 1970. A possibilidade dessa visão do planeta proporcionou uma percepção mais apurada da natureza como um recurso escasso e em risco (BECKER, 2005). Essas percepções levaram à revalorização da natureza por diferentes lógicas. De um lado, há a preocupação com a conservação civilizatória e cultural da região defendida por ambientalistas. Por outro lado, o capitalismo passou também a ver a natureza como um recurso escasso, que necessita ser conservado para que seja possível uma utilização responsável ou com critérios de sustentabilidade.

Diante do exposto, é possível inferir que sistemas de monitoramento e aplicação das leis ambientais constituem parte fundamental do combate ao desmatamento da Amazônia

(ASSUNÇÃO et al. 2015; JUNG; POLASKY, 2018). O sensoriamento remoto e suas infraestruturas tornam-se importantes devido às particularidades sociais e histórica do Brasil, sem negar a relevância das possibilidades técnicas que a ele estão relacionadas. Dessas particularidades, pode-se citar a preocupação local com um território ao mesmo tempo extenso e relativamente isolado e pouco povoado, as doutrinas de segurança nacional, além da constante preocupação com a interferência internacional. As preocupações mais recentes atreladas ao desmatamento e às mudanças climáticas devem-se à atenção da agenda global com o papel da Amazônia na dinâmica climática na Terra. Além disso, ajudam a explicar a centralidade tecnológica. Portanto, o interesse em monitorar o território está ligado a diversas agendas diferentes, porém interligadas (MONTEIRO, 2015).

As políticas públicas têm um papel decisório para a conservação amazônica (BECKER, 2005). A autora defende a substituição da política de ocupação por uma política de consolidação do desenvolvimento, uma vez que a região já se encontra ocupada, dessa forma articulando os diversos interesses e atores em projetos de desenvolvimento sustentável. Outro fator determinante seria desenvolver o valor econômico da região por meio de uma revolução tecnológica que permita a apropriação da biodiversidade de maneira sustentável através de centros de tecnologia avançados, de forma que esse valor supere aquele advindo da depredação madeireira, da pecuária e do plantio de soja.

2.2 Programas de monitoramento do bioma Amazônia

Existem vários programas que monitoram as mudanças na cobertura e no uso da terra no Brasil. Desde o final dos anos 80, a crescente preocupação com o desmatamento na Amazônia levou à criação do programa de monitoramento da floresta Amazônica pelo INPE, denominado PRODES.

O programa foi uma das iniciativas mais importantes apoiada pelo governo brasileiro. O objetivo do programa é calcular a perda anual das áreas de cobertura florestal primária na Amazônia Legal. O emprego de técnicas e dados de sensoriamento remoto foi a base para mapear a dinâmica do desmatamento por corte raso (Figura 2.2) e estimar a taxa de desmatamento anual na região, com área mínima superior a 6,25ha (INPE, 2019a). Pode-se observar na Figura 2.2, áreas que sofreram a completa retirada da vegetação nativa no município de Belterra, estado do Pará.

Figura 2.2 - Exemplos de áreas que apresentam desflorestamento do tipo "corte raso".



Fonte: INPE (2019).

A maior parte dos polígonos de desmatamento mapeado pelo PRODES possui área inferior a 25 ha (INPE, 2019b). A principal fonte de dados para a execução do PRODES é proveniente das imagens de satélites do LANDSAT 5, 7 e 8, que apresentam resolução espacial nominal de 30 metros, recobrendo toda a área florestal da Amazônia brasileira com uma periodicidade de 16 dias. As imagens ópticas utilizadas são selecionadas na época da seca, geralmente entre os meses de julho a setembro, com menor recobrimento de nuvens e melhor visibilidade (CÂMARA et. al, 2006).

O Projeto Detecção de Desmatamento em Tempo Quase Real (DETER), por sua vez, surgiu da demanda apresentada pelo Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA) ao INPE quanto a necessidade de um sistema que pudesse orientar os trabalhos da fiscalização. Assim, precisava de informações sobre o que estava acontecendo em tempo quase real. O projeto DETER, de 2004 a 2014, utilizou imagens do sensor MODIS com 250 metros de resolução nominal e não era capaz de detectar este padrão de desmatamento. Pós 2014, o sistema, desenvolvido no Centro Regional da Amazônia (CRA), veio para preencher esta demanda, uma vez

que identifica e mapeia, em tempo quase real, desmatamentos e demais alterações na cobertura florestal com área mínima a 3 ha. A identificação do padrão de alteração da cobertura florestal é feita por interpretação visual com base em cinco elementos principais (cor, tonalidade, textura, forma e contexto) e utiliza a técnica de Modelo Linear de Mistura Espectral (MLME), conjuntamente com sua imagem multiespectral em composição colorida para mapear as seguintes classes: Desmatamento-alertas (desmatamento com solo exposto; desmatamento com vegetação); Degradação (Degradação; cicatriz de incêndio florestal); e Exploração Madeireira (Corte seletivo Tipo 1 – desordenado; Corte seletivo Tipo 2 – geométrico). Os dados e estatísticas resultantes desses programas podem ser acessados na plataforma Terrabrazilis (disponível em: <http://terrabrazilis.dpi.inpe.br/>) (INPEc, 2018).

Em 2010, foi iniciado o Projeto TerraClass, cujo diferencial é o empenho em qualificar o desflorestamento mapeado pelo PRODES, acrescentando informações sobre a distribuição espacial do uso e cobertura da terra na porção desmatada da Amazônia Legal Brasileira (ALMEIDA et al., 2016). O TerraClass é desenvolvido e executado pela parceria entre o INPE e a EMBRAPA. Esse projeto mapeia o uso das áreas que foram desmatadas, levando em consideração as seguintes classes: Agricultura anual; Área não observada; Área urbana; Mineração; Mosaico de ocupações; Pasto com solo exposto; Pasto limpo; Pasto sujo; Regeneração com pasto; Reflorestamento; Vegetação secundária, e Outros. Já se realizou o mapeamento de uso e cobertura da terra para os anos de 1991, 2000, 2004, 2008, 2010, 2012 e 2014 (INPE, 2019c).

A maioria dos programas brasileiros de monitoramento da Floresta Tropical da Amazônia Legal utilizam imagens de sensores que operam na faixa do espectro óptico, porém, as imagens ópticas acabam dificultando a detecção do desflorestamento na Amazônia, devido a intensa cobertura de nuvens. Sistemas ópticos possuem limitação quanto a aquisição de dados na região, onde a probabilidade de se obter dados livres de nuvens é pequena durante todo ano, mesmo no período da seca (ASNER, 2001). Uma maneira de minimizar esse problema seria a utilização de dados de radar para auxiliar o monitoramento constante da região.

2.3 Princípios básicos de RADAR

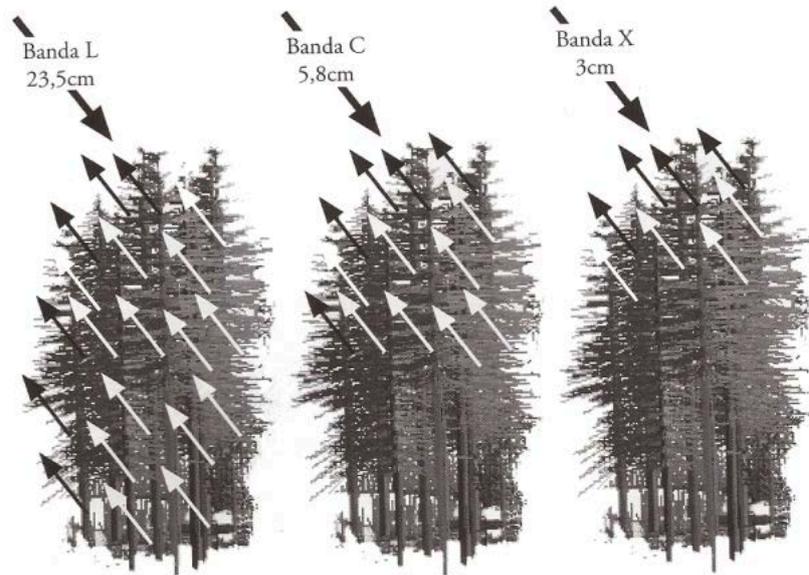
Os sistemas ativos de sensoriamento remoto independem da energia eletromagnética do Sol ou das propriedades termais da Terra, produzindo sua própria radiação (JENSEN, 2009). Isso possibilita que o imageamento da cobertura terrestre seja obtido em qualquer horário, dia ou noite.

Os radares imageadores são sistemas ativos que operam na faixa do espectro eletromagnético de micro-ondas. Os comprimentos de onda geralmente usados no sistema RADAR (*Radio Detection and Range*) variam entre 1cm a 1m. As ondas eletromagnéticas, nessa região do espectro, sofrem pouca atenuação atmosférica, permitindo a aquisição de dados mesmo com cobertura de nuvens, neblina e precipitação (NOVO, 2010).

A energia eletromagnética registrada pelos sensores ativos corresponde a energia retroespalhada dos alvos terrestres de um pulso de radiação produzida pelo próprio sensor remoto. A informação do meio (alvo) é transmitida para o sensor através das ondas eletromagnéticas (VAN ZYL; KIM, 2011). O sinal retroespalhado por um alvo na superfície terrestre pode variar de acordo com a frequência de polarização do sinal transmitido pelo radar, bem como com as características geométricas e propriedades dielétricas do alvo imageado (JENSEN, 2009; HENDERSON; LEWIS, 1998).

Em relação a interação da energia retroespalhada com a vegetação, quanto maior o comprimento de onda, maior a penetração da energia no dossel das plantas. É importante destacar que o retroespalhamento aumenta de maneira linear ao aumento da biomassa, dependendo da frequência utilizada (JENSEN, 2009). Normalmente, em menores frequências (Bandas P e L) envolvem as maiores componentes da biomassa (troncos e galhos maiores) e, à medida que as frequências aumentam (Bandas C e X), os processos de retroespalhamento são contidos na parte superior das copas das árvores (folhas e galhos menores). Na Figura 2.3 é esquematizado a penetração das ondas eletromagnéticas no dossel de uma floresta nas bandas L, X e C.

Figura 2.3 - Retroespalhamento da energia de microondas nas bandas L, X e C.



Fonte: Jensen (2009).

Os sistemas de radar enviam e recebem energia polarizada. A maioria dos radares transmite e recebe a energia eletromagnética linearmente polarizada na horizontal (H) e/ou vertical (V). A polarização pode ser sintetizada, na sua transmissão e na sua recepção, utilizando-se das componentes H e V. Com isso, o imageamento por radar é produzido a partir de polarizações paralelas (co-polarizadas) HH e VV e/ou de polarizações cruzadas HV e VH. Os diferentes tipos de energia polarizadas potencializam a obtenção das informações dos recursos naturais da Terra (JENSEN, 2009). Em relação à resposta da vegetação à energia de micro-ondas polarizada, o espalhamento superficial está ligado ao retorno do sinal com a polarização paralela e o espalhamento volumétrico relaciona-se ao sinal de retorno com polarização cruzada.

Um dos maiores problemas do uso de dados de radar é o ruído *speckle*, que é um ruído multiplicativo inerente a formação da imagem. Considerando que em uma mesma célula referente a imagem possui vários difusores distribuídos aleatoriamente, todos os elementos vão interferir uns nos outros, construtivamente e destrutivamente, produzindo variações na imagem, que se refere ao *speckle* (LILLESAND et al., 2007). Segundo os

autores, na formação da imagem de radar, cada pixel terá variações aleatórias de brilho e contraste.

O ruído proporciona um efeito de estrutura granulosa, dificultando a interpretação visual da imagem de radar. Outra consequência é que o ruído diminui a separabilidade dos alvos na cena, prejudicando os resultados da classificação. A efetividade da caracterização dos alvos pela radiometria e textura dos dados é diminuída com a presença do *speckle* (LOPES et al., 1990). Isso exige um processamento digital de imagens adequado ao tipo de dado e uma cautela na análise dos dados e informações extraídas do sistema.

2.4 Detecção de mudanças

A premissa básica na utilização de dados de sensoriamento remoto para a detecção de mudanças é que as mudanças de cobertura da terra resultam em alterações nos valores de radiância, que são maiores se comparadas a alterações de brilho causadas por outros fatores, como diferenças nas condições atmosféricas, iluminação, ângulo de visada e umidade do solo (MAS, 1999). A detecção de mudanças é útil em diversas aplicações, como análise da mudança do uso da terra, monitoramento da agricultura, avaliação do desmatamento, estudo de mudanças na fenologia da vegetação, mudanças sazonais na produção de pastagens, avaliação de danos, detecção de estresse de culturas, monitoramento de desastres, entre outros (SINGH, 1989).

O monitoramento de mudanças envolve a identificação de alterações do mesmo local em momentos diferentes, sendo importante para a aplicação de diferentes estudos, principalmente no estudo das mudanças de cobertura da terra (LIU et al., 2018a, b, c, d, e).

Segundo Beltrame et al. (2009), a forma mais simples de avaliar mudanças se dá por meio da análise visual das imagens, e ainda que válido, tal procedimento necessita de um grande esforço do analista e envolve um alto grau de subjetividade. Dentre os métodos de avaliar as mudanças, os mais comuns são a diferenciação de imagem, a diferenciação de índices de vegetação, a análise de vetor de mudanças, a análise de componentes principais, a comparação pós-classificação e a composição multitemporal seguida de classificação (ZHOU et al., 2008).

Para Pacifi et al. (2007), as técnicas de detecção de mudanças se dividem em supervisionadas e não-supervisionadas. As técnicas supervisionadas são baseadas na classificação supervisionada, na qual requer amostras para treinar o classificador. As técnicas não-supervisionadas são aquelas em que o conjunto de dados é tratado de forma a possibilitar a detecção de mudanças sem treinamento prévio. De acordo com Akbari et al. (2016), técnicas de detecção de mudanças a partir de classificações não supervisionadas estão sendo aperfeiçoadas e implementadas, como: razão de imagens, análise de coerência multitemporal, comparação pós-classificação, entre outras.

As análises de mudanças também podem se dividir em bitemporais, ou seja, onde são analisadas as diferenças entre duas imagens, sendo o principal foco analisar se houve ou não alteração; e análise de trajetória, na qual se analisa mais de duas imagens de diferentes épocas, sendo o foco classificar as mudanças (COPPIN et al., 2004; ZHOU et al., 2008). A detecção de mudanças está relacionada à utilização de dados multitemporais para identificar alterações, possibilitando uma análise quantitativa dos efeitos do fenômeno estudado (CALDEIRA et al., 2018). Na análise de detecção de mudanças é importante que os dados estejam na mesma época do ano, para que as condições climáticas e o calendário agrícola sejam semelhantes. Além disso, é imprescindível que as imagens estejam corretamente georreferenciadas e corrigidas. Pantoja et al. (2009) optaram por imagens ópticas do satélite LANDSAT/TM para avaliar as mudanças ocorridas em uma área no estado do Acre utilizando técnicas de pós-classificação em imagens NDVI (*Normalized Difference Vegetation Index*) e diferença de bandas em imagens LANDSAT/TM para detectar mudanças na cobertura do solo no período de 2000 a 2008.

A aplicação da detecção de mudanças usando imagens ópticas é comumente utilizada, existindo diversos estudos que abordam essa temática (MAS, 1999; TEIXEIRA, 2008; KENNEDY et al., 2007; QIN et al., 2006; OLIVEIRA et al., 2014). No entanto, a presença de nuvens em imagens ópticas se torna um fator limitante para detectar mudanças de forma sistemática. Desta forma, uma alternativa é a utilização de imagens SAR, as quais não apresentam limitação quanto à aquisição de dados com cobertura de nuvens e/ou incidência solar (AKBARI et al., 2016). O desenvolvimento de novos métodos de processamento de imagens SAR tem sido destinado, principalmente, para a detecção de mudanças (LIU et al., 2009).

De acordo com Rosenqvist et al. (2003), a utilização de dados SAR pode acrescentar mais informações além daquelas fornecidas pelos dados ópticos, em especial para melhorar as análises sobre detecção de mudança da cobertura vegetal e a quantificação e qualificação da estrutura do dossel. Existem diversos estudos sobre detecção de mudanças da cobertura florestal a partir de dados SAR, testando diferentes combinações de bandas e polarizações (ANJOS, 2016; REIS, 2014; HAGENSIEKER; WASKE, 2018; WIEDERKEHR, 2018).

Segundo Liu et al. (2009), a detecção de mudanças em dados PolSAR (*Polarimetric SAR*) possui quatro etapas principais: pré-processamento (filtro e correção), extração de diferenças, limiarização das mudanças ocorridas e associação das imagens. Visto que, para os autores, a extração de diferenças é o passo mais importante de todo o processo.

Uma forma de detectar mudanças é a partir da análise pós-classificação, amplamente utilizada por diversos autores tanto para dados ópticos quanto dados SAR. Nessa análise, as imagens de cada data são classificadas separadamente e posteriormente comparadas (LU et al., 2014; REIS, 2014). Uma das principais vantagens dessa análise é a minimização de erros radiométricos, e outros problemas decorrentes de efeitos atmosféricos e luminosidade (para sistemas passivos) entre as duas datas, sendo a mais indicada para a utilização de diferentes sensores. No entanto, por estar em função de eventuais erros de classificação, podem ser detectadas mudanças equivocadas na área de estudo, exigindo um conjunto de treinamento adequado para classificações supervisionadas (CANTY, 2007; LU et al., 2014; SINGH, 1989). Ainda assim, ao comparar seis técnicas de detecção de mudanças, Mas (1999) concluiu que a análise pós-classificação se destacou apresentando os melhores resultados.

Pavanelli et al. (2018) analisaram os produtos de mapeamento temático fornecidos pela integração dos dados do PALSAR-2 (Banda L), nas polarizações HH e HV, e dados do sensor OLI/LANDSAT. O objetivo foi avaliar o desempenho do modelo *Random Forest* (RF) aplicado aos conjuntos de dados ópticos e SAR para a classificação de mudanças de uso e cobertura da terra no norte da Amazônia, Brasil. Os autores concluíram que os modelos de RF usando métricas multiespectrais OLI apresentaram melhor desempenho em relação aos atributos de dupla polarização PALSAR-2 da Banda L.

Existem trabalhos que utilizam dados SAR para detectar mudanças por meio do método de pós-classificação, a exemplo de Reis (2014), Anjos (2016) e Wiederkehr (2018). Na metodologia aplicada por Reis (2014), foram utilizados dados ópticos do LANDSAT 5/TM e dados SAR do ALOS/PALSAR-1 (Banda L). O trabalho teve como objetivo avaliar as classes de mudança provenientes de dados ópticos e dados SAR separadamente e a fusão de ambos, utilizando a pós-classificação. Os resultados provenientes dos dados fusionados não foram significantes comparados aos resultados dos dados originais. A autora salienta que dados SAR apresentaram bons resultados na avaliação de mudanças, e que esses dados possuem uma certa limitação para a distinção de classes florestais. Entretanto, os resultados entre os dados SAR e ópticos se assemelham.

No estudo de detecção de mudanças na Floresta Nacional do Tapajós, Anjos (2016) concluiu que o método de classificação direta, em dados multissensor do RADARSAT-2 (Banda C) e EO-1 (*Earth Observing-1*), apresentou um desempenho superior ao comparado com o método de pós-classificação. Entretanto, a autora destaca que o método de pós-classificação possibilita ao usuário destacar classes de não-mudança e mudança, agrupando as classes de mudança em possíveis, improváveis e impossíveis para o intervalo estudado. Os dois métodos apresentaram abordagens diferentes, sendo que os dados de entrada para o método pós-classificação foram classificações dos dados SAR e dados ópticos separadamente, e o método de classificação direta utilizou dados empilhados de atributos SAR e atributos ópticos. Enquanto a detecção de mudanças por pós-classificação é dependente das classificações individuais, a classificação direta depende de uma classificação baseada em um único vetor contendo informações das duas datas.

Em Wiederkehr (2018), foram utilizados dados ALOS/PALSAR-2 na Flona de Tapajós para a detecção de mudanças do uso e cobertura entre os anos 2015 e 2016 utilizando o método de pós-classificação. O algoritmo de classificação utilizado foi o MAXVER-ICM, a partir de grupos de atributos polarimétricos extraídos dos canais das imagens PALSAR-2. Nesse trabalho concluiu-se que a maior parte das mudanças ocorridas nesse período foram atribuídas à degradação florestal a partir das queimadas. A autora também destaca que as áreas de agricultura, silvicultura e pastagem estão suprimindo as áreas florestais da Flona.

As potencialidades do uso de diferentes bandas de radar são estudadas e avaliadas para sua utilização tanto para o monitoramento da cobertura do solo, quanto para detecção de mudanças por meio de dados multitemporais (HAGENSIEKER; WARKE, 2018; LI et al., 2012; RAHMAN; SUMANTYO, 2010; FREITAS; SANT'ANNA; RENNÓ, 1999). Os estudos comparando dados de radar e ópticos separadamente e em conjunto para observação da terra também são frequentes na comunidade científica (TRICHT et al., 2018; PAVANELLI et al., 2017; PLANK et al., 2016). Entretanto, a literatura carece de pesquisas que utilizam dados multifrequência (multibanda) para estudos de análise ambiental em geral.

2.5 Classificação MAXVER-ICM

A classificação é um processo da extração de informações para reconhecimento de padrões de alvos ou regiões homogêneas em imagens digitais (CROSTA, 1992). Nesse sentido, a classificação de imagens digitais é uma ferramenta automatizada que produz uma representação aproximada da imagem original (SCHOWENGERDT, 2007). Essa técnica pode ser denotada como supervisionada e não supervisionada.

Em classificações supervisionadas considera-se que há um conhecimento a priori da cobertura da terra, a partir de trabalhos de campo, interpretação de imagens digitais, análise de mapas e experiência pessoal (JENSEN, 2005; HODGSON et. al, 2003). Esse tipo de classificador caracteriza os alvos da cena através de um conjunto de dados de treinamento selecionados pelo operador. A representação da cena dependerá de uma seleção de amostras confiáveis.

O algoritmo de classificação de Máxima Verossimilhança (MAXVER) é um método estatístico supervisionado do tipo pixel a pixel (pontual) mais comumente usado no âmbito do sensoriamento remoto para reconhecimento de padrões. Esse classificador é baseado no teorema de Bayes, onde o pixel é atribuído a uma classe, de um conjunto pré-definido, que apresentou a maior probabilidade de associação (TSO; MATHER, 2009). Assim sendo, considerando classes de cobertura denotadas por ω_i , onde $i \in \{1,2,\dots,N\}$, um pixel de vetor X pode ser classificado como (VAN ZYL, 2011):

$$X \in \omega_i, \text{ se } P(\omega_i|X) > P(\omega_j|X) \quad \text{para } i \neq j \quad (2.1)$$

A Equação (2.1) representa que o pixel descrito pelo vetor X pertence a classe ω_i pois a probabilidade é maior do que o pixel ser pertencente a classe ω_j , para todas as N classes. Entretanto, a estimativa da probabilidade utilizando verdade terrestre é muito mais

simples para $P(X|\omega_i)$ do que $P(\omega_i|X)$. Então transforma-se a Equação (2.1) usando o teorema de Bayes para (VAN ZYL, 2011):

$$X \in \omega_i, \text{ se } P(X|\omega_i) P(\omega_i) > P(X|\omega_j) P(\omega_j) \quad \text{para } i \neq j \quad (2.2)$$

A regra na Equação (2.2) não estima a probabilidade a *posteriori* $P(\omega|X)$. Pode-se usar o teorema de Bayes para expressar a probabilidade a *posteriori* em termos das funções de densidade condicional de classe de acordo com a Equação (2.3) (RICHARDS, 2009):

$$P(\omega|X) = \frac{P(X|\omega)P(\omega)}{P(X)} \quad (2.3)$$

onde $P(\omega)$ representa a probabilidade a *priori* do vetor X pertencer a uma classe ω , e $P(X)$ é a probabilidade de ocorrência do vetor X .

No entanto, este classificador não considera a dependência espacial entre as classes, fatores que são importantes quando se trata de dados SAR polarimétricos (CORREIA, 1998). Por razão da presença do ruído multiplicativo em imagens SAR, o êxito da classificação desses dados depende da redução do efeito *speckle* (RICHARDS, 2009). Outra dificuldade é encontrar amostras de treinamento suficientes para estimar os parâmetros estatísticos exigidos para a classificação de MAXVER em áreas heterogêneas (VAN ZYL, 2011).

Para superar esses obstáculos, a incorporação de informações secundárias como dados de textura, contexto e feições terrestres junto ao algoritmo MAXVER é importante para aprimorar o reconhecimento de padrões complexos da cobertura da terra (TSO; MATHER, 2009). A inclusão do contexto é importante, pois explora a capacidade das informações espaciais no seu contexto e ajuda a remover erros individuais de rotulagem de pixel que possam resultar de dados ruidosos, como no caso de dados SAR, ou de um desempenho incomum do classificador (RICHARDS; JIA, 2009).

Alguns autores implementam o classificador MAXVER junto ao classificador contextual ICM (CORREIA, 1998; VIEIRA, 1996). Desta forma, Freitas et al. (2007) explicam que o algoritmo ICM (*Iteracted Conditional Modes*) funciona como um método de refinamento do MAXVER, visto que considera a dependência espacial. O algoritmo ICM corresponde a um classificador supervisionado e contextual, que se baseia em um processo iterativo onde cada pixel é classificado de acordo com sua informação espectral e das classes associadas na vizinhança (VIEIRA, 2019).

Para o classificador MAXVER-ICM, em suma, o processo se inicia pela classificação de máxima verossimilhança, onde há a extração de um vetor de atributos, calculando-se

a probabilidade de um pixel pertencer a uma determinada classe definida na etapa de treinamento. Posteriormente, os pixels da imagem são associados à classe que apresentar maior verossimilhança (RICHARDS e JIA, 2006). Em seguida, a informação contextual dos pixels é associada à classificação MAXVER por meio do classificador ICM. Desta forma, se ocorrerem muitos pixels de uma mesma classe no contexto espacial de um único pixel que pertence uma classe diferente, este pixel poderá ser reclassificado para a classe que predominou em seu contexto espacial (CORREIA, 1998).

O algoritmo de classificação estatística por meio do classificador pontual MAXVER integrado ao classificador contextual ICM foi implementado no Classificador Polarimétrico 7.0 por Correia (1998). De acordo com McNairn et al. (2009) este classificador possui uma vantagem quanto ao baixo custo computacional. O classificador MAXVER-ICM ainda possui uma flexibilidade no que tange os dados e suas respectivas modelagens.

Freitas et al. (1999) utilizaram imagens de RADARSAT e JERS-1 para comparar o potencial dos dados em diferentes frequências para discriminar as classes de floresta primária, vegetação secundária e áreas desflorestadas através do classificador MAXVER-ICM em uma área na Floresta Nacional de Tapajós. Os autores classificaram as imagens por modelagem multivariada, parametrizando a distribuição normal para todas as classes. Os resultados apontaram que o RADARSAT obteve melhores resultados para discriminar os tipos de vegetação primária e secundária, porém os resultados do JERS-1 foram mais apropriados para identificar áreas desflorestadas.

Os estudos realizados por Guerra (2009) e Aboud Neta (2009) utilizaram o classificador MAXVER-ICM em imagens SAR multipolarimétricas para a detecção de incremento de desflorestamento na região da Amazônia. Em Guerra (2009), o classificador apresentou melhor desempenho nos dados SAR em pares de amplitude, discriminando bem a classe de incremento de desflorestamento. No entanto, no trabalho de Aboud Neta (2009) o classificador Distância de *Bhattacharyya* obteve uma acurácia melhor que o classificador MAXVER-ICM.

Aboud Neta (2009) utilizou imagens de radar do satélite ALOS, sensor PALSAR (banda L), para classificar as imagens em todas as combinações de canais: individualmente $\{L_{HH}\}$, $\{L_{HV}\}$ e $\{L_{VV}\}$; aos pares $\{L_{HH}, L_{HV}\}$, $\{L_{HV}, L_{VV}\}$ e $\{L_{HH},$

L_{VV} }; e em conjunto $\{L_{HH}, L_{HV}, L_{VV}\}$ para posterior detecção de incremento de desflorestamento em uma área na Amazônia, mais especificamente na Floresta Nacional do Tapajós. Nesse trabalho, a autora avaliou o potencial dos classificadores supervisionados pontual MAXVER-ICM e por regiões *Bhattacharyya*, para classificar classes de incremento de desflorestamento e comparou os resultados com dados PRODES do ano estudado. O classificador *Bhattacharyya* obteve resultados superiores aos comparados com MAXVER-ICM e a melhor classificação foi a bivariada da combinação $\{L_{HH}, L_{HV}\}$. A autora salienta que os dados de radar auxiliam os dados ópticos na obtenção de informações e mapeamento das coberturas do solo.

Negri (2009) aplicou os classificadores MAXVER-ICM e *K-means Wishart H/A/α* em imagens ALOS/PALSAR a fim de avaliar o desempenho de dados polarimétricos para a classificação da cobertura da terra na região da Amazônia. O autor inferiu que o classificador MAXVER-ICM foi mais eficiente em discriminar os diferentes tipos de culturas e pastagens.

Guerra et al. (2010) utilizaram o classificador MAXVER-ICM para discriminar incrementos anuais de desflorestamento na Amazônia com dados multipolarizados em banda L, em dado SAR aerotransportado. Os resultados obtidos mostraram um bom potencial do classificador, em que o índice *kappa* estimado foi de 0,68.

Rahman e Sumantyo (2010) avaliaram o potencial dos dados SAR para avaliar e mapear o desmatamento na floresta tropical localizada na região sudeste de Bangladesh. Foram utilizadas as Bandas L e C do satélite SIR-C em dupla polarização (HH e HV), e imagens da Banda L do sensor PALSAR/ALOS, nas polarizações (HH, HV, VH e VV). A classificação supervisionada MAXVER permitiu realizar o treinamento de cinco classes: floresta, arbustos/ solos de terras altas, solos de terras baixas, assentamentos e água/zonas úmidas. Também foram utilizadas imagens TM/LANDSAT e ETM+/LANDSAT para auxiliar na interpretação das imagens. Os autores ressaltam que uma classe adicional representando o crescimento da floresta poderia ser identificada apenas na imagem SIR-C. Os resultados sugerem que as polarizações utilizadas são eficientes para o mapeamento de coberturas terrestres e detecção de mudanças.

No trabalho desenvolvido por Pereira et al. (2011), os autores compararam os métodos MAXVER-ICM e SVM para classificar imagens polarimétricas do ALOS/PALSAR-1 em uma área localizada em Belterra-PA, na Amazônia. Os autores concluíram que o

MAXVER-ICM teve um melhor desempenho se comparado ao SVM, apresentando uma exatidão global de 80,24%.

Em um estudo desenvolvido por Pereira (2012), o objetivo foi avaliar as diferentes formas de integração de dados ópticos e de radar para o mapeamento de cobertura da terra em uma região na Amazônia. Foi aplicado o MAXVER-ICM em imagens SAR, nas polarizações HV/HH. Foi realizada uma combinação das segmentações feitas em imagens ALOS/PALSAR e LANDSAT/TM resultou em uma imagem final segmentada, cujo objetivo era que as amostras das classes representassem áreas homogêneas em ambas as imagens. No entanto, a autora concluiu que a combinação dos segmentos resultou em regiões menores e/ou do tamanho de um pixel, o que não era interessante em seu estudo. Já no trabalho realizado por Pereira et al. (2016), os autores avaliaram os dados ALOS/PALSAR-1 combinados com imagens ópticas para o uso e cobertura da terra em uma determinada porção da Floresta Nacional do Tapajós, utilizando o classificador MAXVER-ICM, que apresentou resultados satisfatórios para a discriminação dos alvos.

No trabalho de Wiederkehr (2018), a autora utilizou o classificador MAXVER-ICM e imagens ALOS/PALSAR nas polarizações HH, HV, VH e VV utilizando atributos polarimétricos por decomposição de alvos e comparou seus resultados com análise de mudanças geradas a partir de dados ópticos do RAPIDEYE e LANDSAT, sem a fusão dos dados. A autora concluiu que a classificação da decomposição por Cloude-Pottier e do subconjunto ótimo obtiveram melhores resultados com valores de kappa de 0,78 e 0,75 respectivamente para o ano de 2015 e 0,75 e 0,74 para 2016.

2.6 Distribuições estatísticas

As distribuições de probabilidade contínuas são bastante utilizadas em diversos trabalhos probabilísticos. De acordo com Catalunha et al. (2002), o uso de funções densidade de probabilidade está diretamente ligado à natureza dos dados a que elas se relacionam. Algumas têm boa capacidade de estimação para pequeno número de dados, enquanto outras requerem grande série de observações.

Em uma classificação, o reconhecimento de padrões de comportamento espectral de cada classe de uso e cobertura da terra é essencial para um bom treinamento. De acordo com Crosta (1992), para alguns classificadores, esse reconhecimento está relacionado à

obtenção de parâmetros estatísticos de cada classe, como média, matriz de covariância, entre outros.

Como dito anteriormente, o algoritmo MAXVER/ICM permite e flexibiliza a modelagem dos dados SAR nas distribuições que melhor representam cada classe de cobertura da terra. Dentre as distribuições inseridas no classificador polarimétrico, destaca-se três distribuições: gama, bivariada em intensidade e normal multivariada.

De acordo com Brito et al. (2017), a distribuição gama é usada em uma variedade de aplicações, incluindo modelos de *queue*, financeiros e climáticos, dentre outros. Pode ser considerada como a distribuição do tempo de espera entre eventos distribuídos de acordo com um processo de Poisson. Esta distribuição também é utilizada na modelagem de dados SAR, de áreas homogêneas e no formato de intensidade. A distribuição gama é descrita por:

$$f(x) = \frac{\beta^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\beta x}, \quad x > 0 \quad (2.4)$$

onde $\alpha > 0$ é um parâmetro de forma e $\beta > 0$ é o recíproco de um parâmetro de escala.

Considerando dados SAR polarimétricos *multi-look* a distribuição Wishart complexa é amplamente usada para modelar este tipo de dado (VAN ZYL, 2011). Sejam duas imagens em intensidade *n-looks*, a função de densidade de probabilidade do par de intensidades é dada segundo (Correia, 1998; Lee et al., 1994):

$$P_{(z_1, z_2)}(z_1, z_2) = \frac{n^{n+1} (z_1 z_2)^{\frac{(n-1)}{2}} \exp\left(-\frac{n(z_1/h_{11} + z_2/h_{22})}{1-|\rho_c|^2}\right)}{(h_{11} h_{22})^{\frac{(n+1)}{2}} \Gamma(n) (1-|\rho_c|^2) |\rho_c|^{n-1}} I_{n-1}\left(\frac{2n|\rho_c|}{1-|\rho_c|^2} \sqrt{\frac{z_1 z_2}{h_{11} h_{22}}}\right) \quad (2.5)$$

onde Z_1 e Z_2 são variáveis aleatórias; S_i e S_j são a matriz de espalhamento; $|\rho_c|$ e $|\rho_l|$ representam o módulo dos coeficientes de correlação complexa em intensidade *n-looks*; I_{n-1} representa a função modificada de Bessel; h_{11} e h_{22} são parâmetros de densidade.

Por outro lado, dados SAR multivariados (contendo mais de dois canais) processados com um alto número de looks, e no formato amplitude são melhores ajustados pela distribuição gaussiana multivariada. A sua função de densidade de probabilidade para todo vetor x é dada por (Richards, 2009; Vieira, 1996):

$$f(x|\omega) = (2\pi)^{-N/2} |\Sigma_i^{-1}| \exp\left\{-\frac{1}{2} (x - m_i)^t \Sigma_i^{-1} (x - m_i)\right\} \quad (2.6)$$

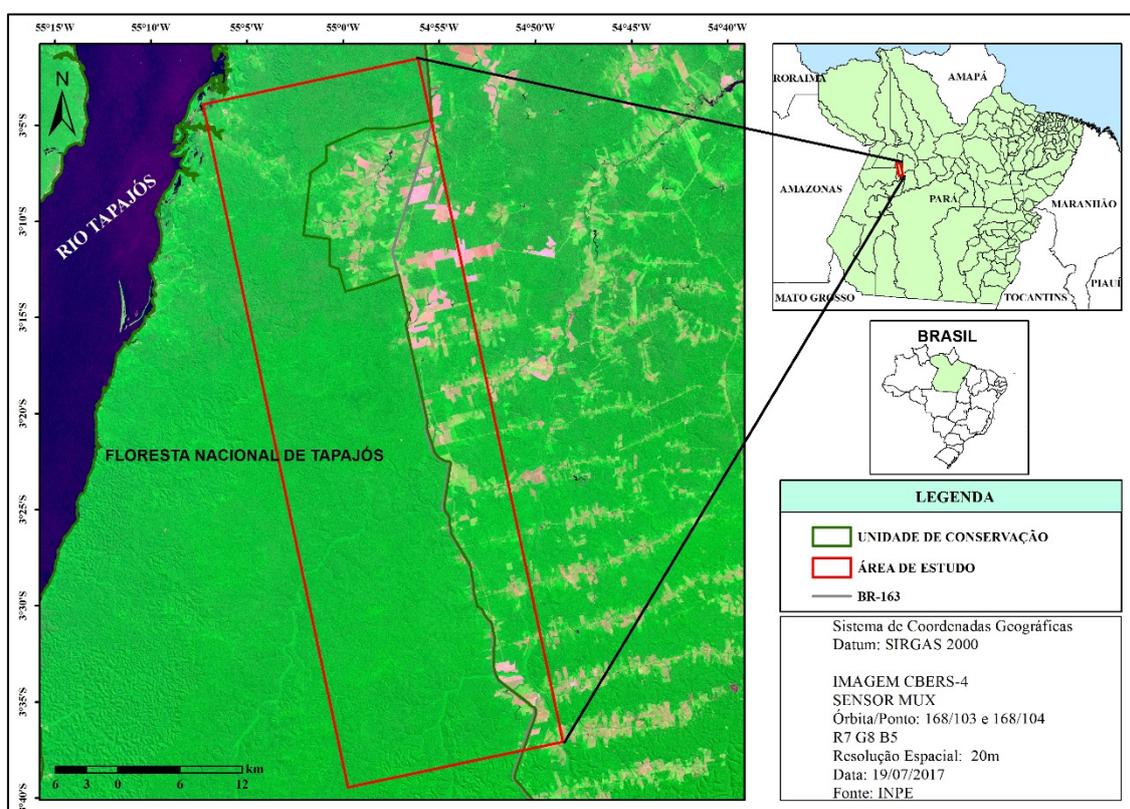
onde x é um vetor pontual bidimensional; $f(x/w)$ é a probabilidade de o pixel da classe w_i ser encontrado na posição x ; m_i é o vetor médio de x multivariado.

3 MATERIAIS E MÉTODOS

3.1 Área de estudo

A área de estudo deste trabalho está ilustrada na Figura 3.1 e tem aproximadamente 1420 km². Esta área está localizada a oeste do Estado do Pará, envolvendo os municípios de Aveiro, Belterra, Mojuí dos Campos e Placas, agregando sua maior parte no município de Belterra. A área foi selecionada de acordo com a disponibilidade de imagens, dados de campo e informações coletadas ao longo de vários anos.

Figura 3.1 - Mapa de localização da área de estudo.



Fonte: Produção da Autora.

Os municípios de Belterra, Mojuí dos Campos e Placas fazem parte da microrregião de Santarém e o município de Aveiro faz parte da microrregião de Itaituba. As duas microrregiões no total abrangem 13 municípios, na confluência do rio Amazonas e rio Tapajós, correspondendo uma área aproximada de 282.066 m² e uma população de

694.004 habitantes (IBGE, 2010). Vale ressaltar que essa região sofreu, nas últimas décadas, um aumento de suas populações acompanhado pelo encadeamento do desmembramento e a origem de novos municípios (ESCADA et al., 2009; ALVES et al., 2008).

No que se refere a essas duas microrregiões, a agricultura familiar diversificada é predominante (ALVES et. al, 2010). A agricultura familiar de até 200 ha é preponderante no sistema agrário da região com cerca de 90% dos assentamentos rurais (ALVES et. al, 2010; EMBRAPA, 2007).

A região estudada possui uma paisagem antropizada, principalmente em torno da rodovia BR-163, como pode ser observado na Figura 3.1. As áreas antrópicas da região estão relacionadas principalmente às atividades de agricultura, de pecuária, e de extração de madeira e de minério (ESCADA et al., 2009). Na atividade agrícola da região, destaca-se o cultivo de grãos como soja, milho e arroz. Escada et al. (2009) identificaram uma ou duas safras ao ano. No caso da safra anual, o calendário agrícola da região se inicia em dezembro, e o período da colheita é entorno de abril. Caso o produtor opte por duas safras anuais, o segundo plantio ocorre entre março e abril e a colheita entre julho e agosto.

A Floresta Nacional de Tapajós (Flona-Tapajós), correspondendo parte da área de estudo, margeia a oeste da BR-163 na maior parte de sua extensão. A Flona, localizada no bioma da Amazônia é uma unidade de conservação (UC) criada em 19 de fevereiro de 1974, pelo Decreto nº 73.684 (ICMBio, 2019). Segundo ICMBio (2019), órgão gestor da unidade, a UC abrange os municípios de Aveiro, Belterra, Placas e Rurópolis, possuindo uma área aproximada de 5.273 km². A Flona de Tapajós situa-se na zona de Floresta Ombrófila Densa em escala regional no sistema de classificação universal das formações vegetais da Amazônia (VELOSO et al., 1991; MMA, 2004). Essa região apresenta uma vegetação com famílias de dispersão pantropical, e predominada por fenerófitos (brotos acima de 25 cm do solo), lianas lenhosas e epífitas em abundância (IBGE, 2012).

O clima da região é tropical úmido, com variações de temperatura inferior a 5°C, com temperatura média anual de 25 °C. A precipitação média anual é de aproximadamente 1870mm, com as maiores precipitações ocorrendo nos meses entre janeiro e maio

(INMET, 2018). O regime climático é de temperaturas elevadas, com intensas precipitações distribuídas ao longo do ano (MMA, 2004).

3.2 Imagens utilizadas

Os dados selecionados para a realização deste trabalho foram imagens orbitais de micro-ondas dos satélites SENTINEL-1 (Banda C) e ALOS-2 (Banda L), cujas principais características são apresentadas na Tabela 3.1.

Tabela 3.1 - Características das imagens orbitais SENTINEL-1A e ALOS-2.

CARACTERÍSTICAS	IMAGENS	
	SENTINEL-1	ALOS -2
Órbita	Ascendente	Ascendente
Nível de Processamento	1	1.1
Modo de operação	<i>TOPSAR*</i>	<i>HBQ**</i>
Polarização	VH/VV	<i>Full (Quad)***</i>
Resolução Azimutal	22 m	4,3 m
Resolução <i>range</i>	20 m	6 m
Resolução radiométrica	32 bits	32 bits
Espaçamento entre pixel	10x10 m	2,86x3,13
Número de <i>looks</i>	5x1	1x1
Órbita/Ponto	3786/39	7120/20
Data de aquisição	19/12/2014 19/01/2016	28/12/2014 01/05/2016

Em que: **Terrain Observation with Progressive Scan SAR*; ** *High Beam Quad*; ****Full Polarimetric* (L_{HH} , L_{HV} , L_{VH} , L_{VV}).

Fonte: Adaptado de JAXA (2014) e ESA (2019).

A imagem do sensor PALSAR-2, a bordo do satélite ALOS-2, é proveniente de um sensor *SAR*, que emite ondas de rádio na frequência de Banda L (24 cm). Os produtos ALOS/PALSAR-2 utilizados nesse trabalho foram obtidos na plataforma do *Japan Aerospace Exploration Agency* (JAXA). Os dados estão no formato *Single Look Complex* (SLC) em geometria *slant range*, com número de *looks* em 1. Essas imagens foram adquiridas no modo de imageamento *Strip Map*, que opera no modo de varredura *HBQ* (*High Beam Quad*), que é um modo de operação definido pela sua resolução

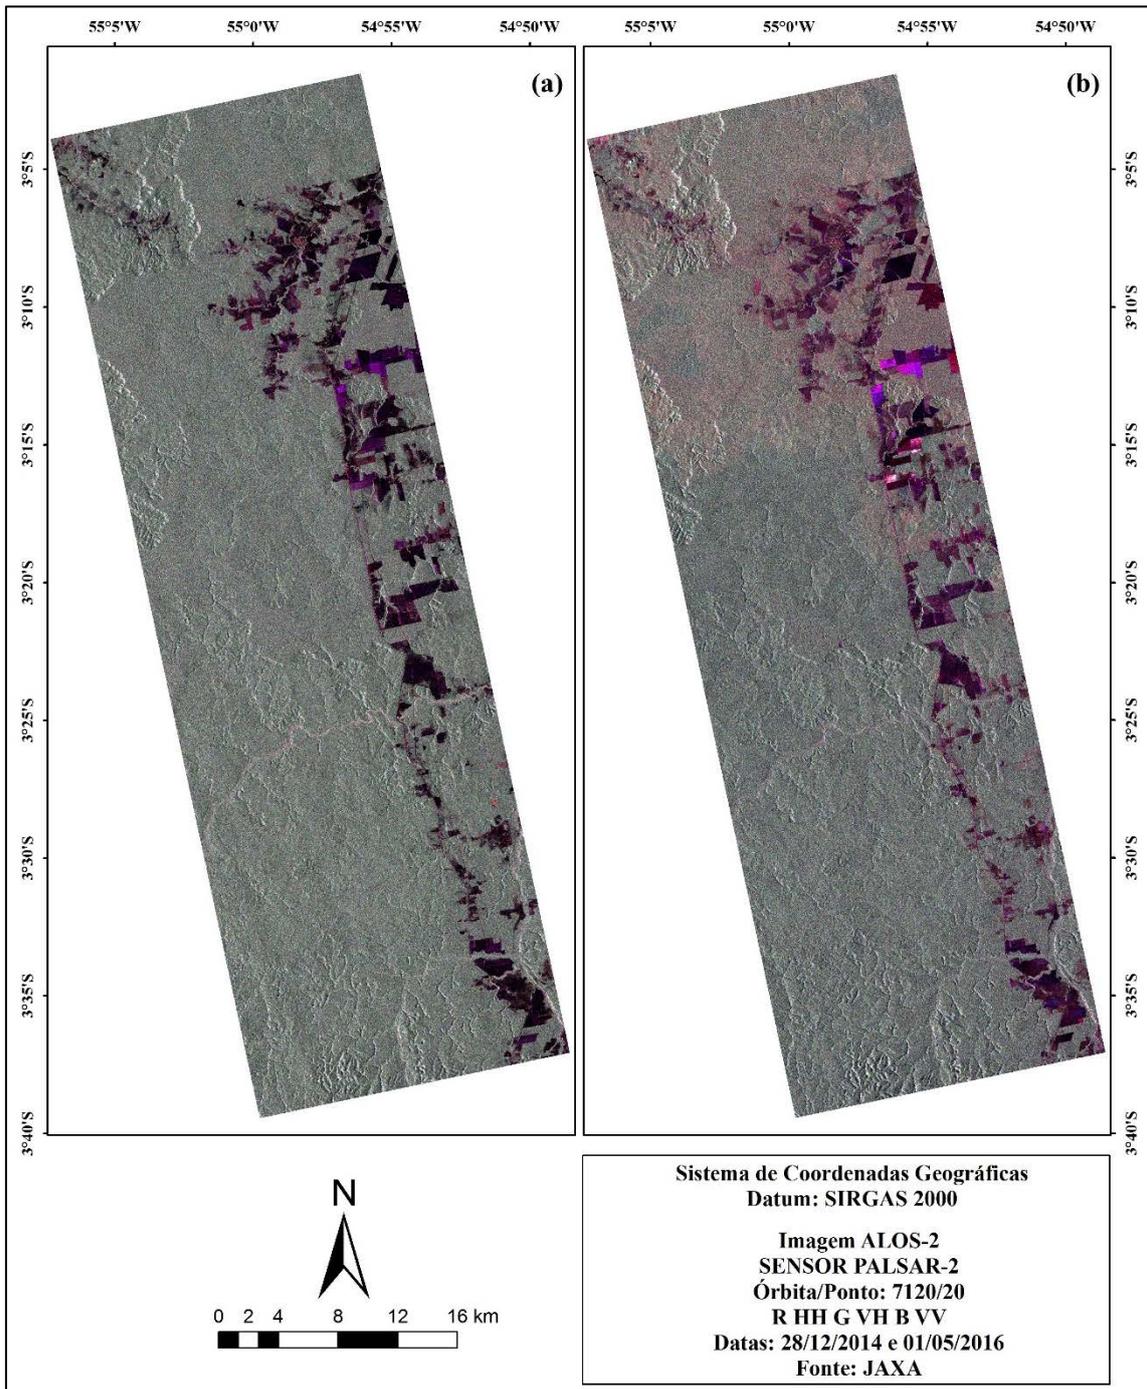
espacial de 6 metros. As imagens ALOS/PALSAR-2 são *full* polarimétricas, nos canais: HH, HV, VH, VV. Neste trabalho, baseado no princípio da reciprocidade, foi considerado a média dos canais HV e VH para a geração do canal de polarização cruzada, que será denominada como L_{VH} . As informações da fase do sinal são preservadas.

A imagem do sensor SAR-C (*Synthetic Aperture Radar C-band*), a bordo do satélite SENTINEL-1, é oriunda de um sensor SAR que emite ondas de rádio na frequência de banda C (5,5 cm). Os produtos SENTINEL-1/SAR-C utilizados foram obtidos na plataforma do *European Aerospace Agency* (ESA), que são disponibilizados gratuitamente. Os dados estão no formato *Ground Range Detected* (GRD) em geometria *ground range*, com número equivalente de looks (*ENL*) estimado em 4,4. Essas imagens foram adquiridas no modo de imageamento *Interferometric Wide Swath* (IW), que utiliza o modo de operação *Terrain Observation with Progressive Scan SAR* (TOPSAR). Essa operação tem um novo tipo de varredura do modo *ScanSAR*, que tem o princípio de reduzir o padrão da antena direcionando a antena na direção oposta do azimute (ESA, 2019). As imagens SENTINEL-1/SAR-C são *dual* polarimétricas, nos canais VH e VV. As informações da fase do sinal são perdidas.

A intersecção entre as quatro imagens adquiridas ocorreu nas coordenadas geográficas $55^{\circ}7'18,52''\text{O}$ $3^{\circ}1'32,14''\text{S}$ e $54^{\circ}48'34,39''\text{O}$ $3^{\circ}39'26,82''\text{S}$, originando a área de estudo selecionada apresentada na Figura 3.1. As imagens foram escolhidas pela disponibilidade dos dados na mesma época do ano ou datas próximas, a fim de se encontrarem no mesmo período sazonal e fenológico da vegetação.

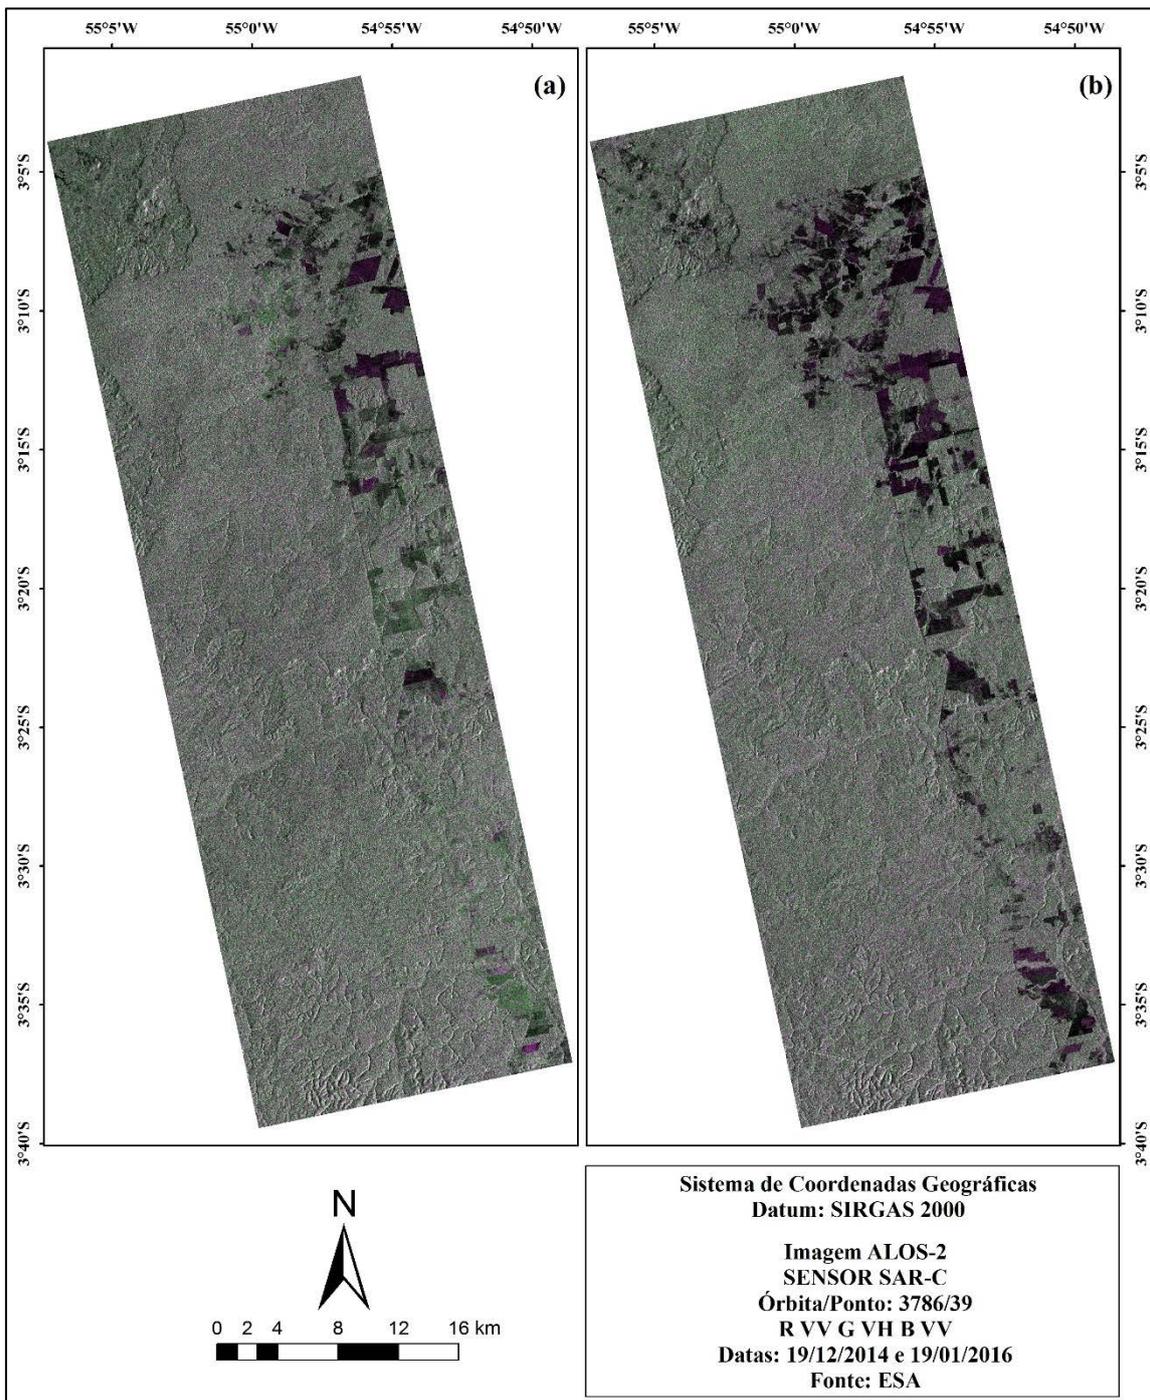
As imagens utilizadas nesse trabalho são apresentadas na Figura 3.2 e Figura 3.3 na composição colorida R-HH G-VH B-VV. As imagens disponíveis foram: ALOS/PALSAR-2 nas datas de 28 de dezembro de 2014 e 01 de maio de 2016; e SENTINEL-1/SAR-C nas datas de 19 de dezembro de 2014 e 19 de janeiro de 2016. Provavelmente, a imagem ALOS obtida em 01 de maio de 2016, por estar em época do ano diferente das demais, não esteja no mesmo estágio do calendário agrícola e fenológico da vegetação, podendo acarretar alguma discordância entre os dados auxiliares e/ou equívoco em alguma etapa de processamento de dados.

Figura 3.2 - Imagens ALOS/PALSAR-2: (a) 28/12/2014 e (b) 01/05/2016.



Fonte: Produção da Autora.

Figura 3.3 - Imagens SENTINEL-1A: (a) 19/12/2014 e (b) 19/01/2016.



Fonte: Produção da Autora.

3.3 Dados de campo

Os pesquisadores do INPE realizaram trabalhos de campo para acompanhar a dinâmica de uso e cobertura da terra no município de Belterra e região, disponibilizando uma série de dados histórica. Os dados de campo utilizados para a execução deste trabalho foram das datas de 16 a 25 de março de 2015 e 25 de agosto a 03 de setembro de 2016. Esses materiais foram selecionados por serem de datas mais próximas das imagens orbitais obtidas mencionadas anteriormente.

Nos trabalhos de campo foram coletados pontos com *Global Positioning System* (GPS), na projeção *Universal Transversa Mercator* (UTM) no Datum *World Geodetic System* 1984 (WGS-84) no fuso 21S. Pode-se observar na Figura 3.4 pelas imagens da região do satélite CBERS-4 o posicionamento dos pontos e também, na Tabela 3.2 a quantidade de pontos coletados para cada classe de cobertura em 2014 e 2016, que serão definidos posteriormente. Além dos pontos, foram feitos registros fotográficos, tomados anotações e esboçados croquis para cada ponto visitado. Particularmente, os dados do campo de 2016 dispõem de imagens dos voos de drone feitos em alguns locais de interesse. Todos os dados de campo disponíveis foram levados em consideração para a produção do trabalho.

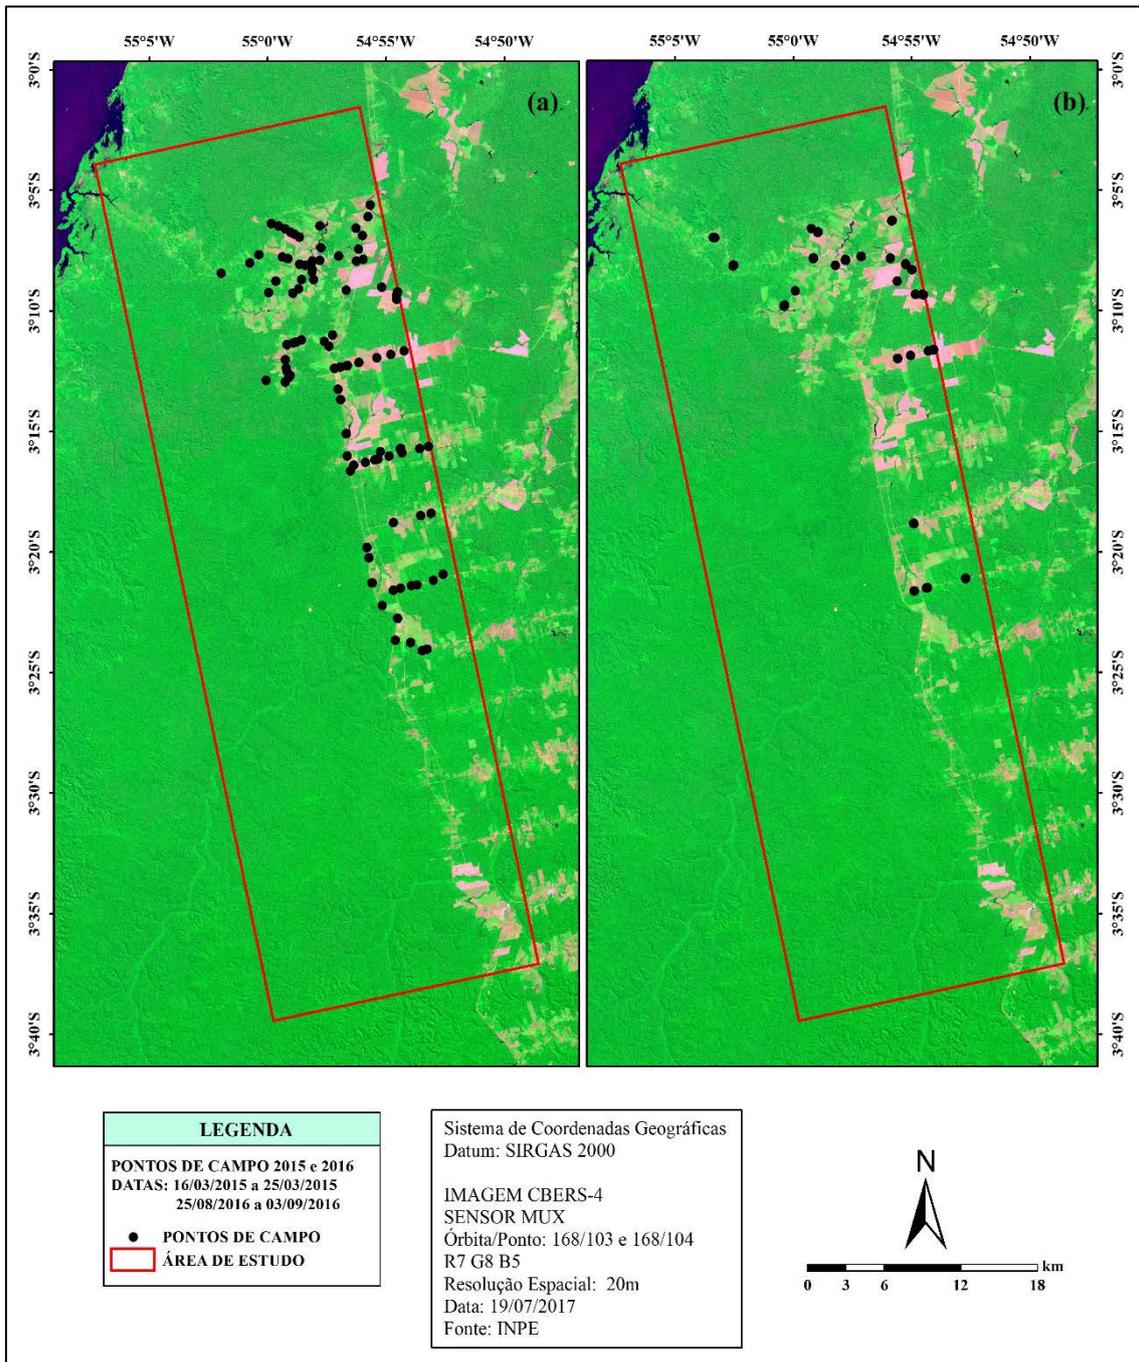
Em outra campanha, realizada em setembro de 2017, foi observada a paisagem heterogênea atual, o que permitiu a compreensão da dinâmica existente na área de estudo e uma clara percepção do cenário real. O conhecimento prévio da região foi primordial para a interpretação preliminar dos dados e uma análise crítica nos resultados obtidos.

Tabela 3.2 - Pontos coletados nas classes de cobertura da terra.

ANO	CLASSE	Nº DE PONTOS
2014	VEGETAÇÃO SECUNDÁRIA	41
	PASTO SUJO	59
	PASTO LIMPO	66
	AGRICULTURA	49
2016	VEGETAÇÃO SECUNDÁRIA	43
	PASTO SUJO	13
	PASTO LIMPO	26
	AGRICULTURA	20

Fonte: Produção da Autora.

Figura 3.4 - Localização dos pontos coletados em campo: (a) 2014 e (b) 2016.



Fonte: Produção da Autora.

3.4 Dados auxiliares

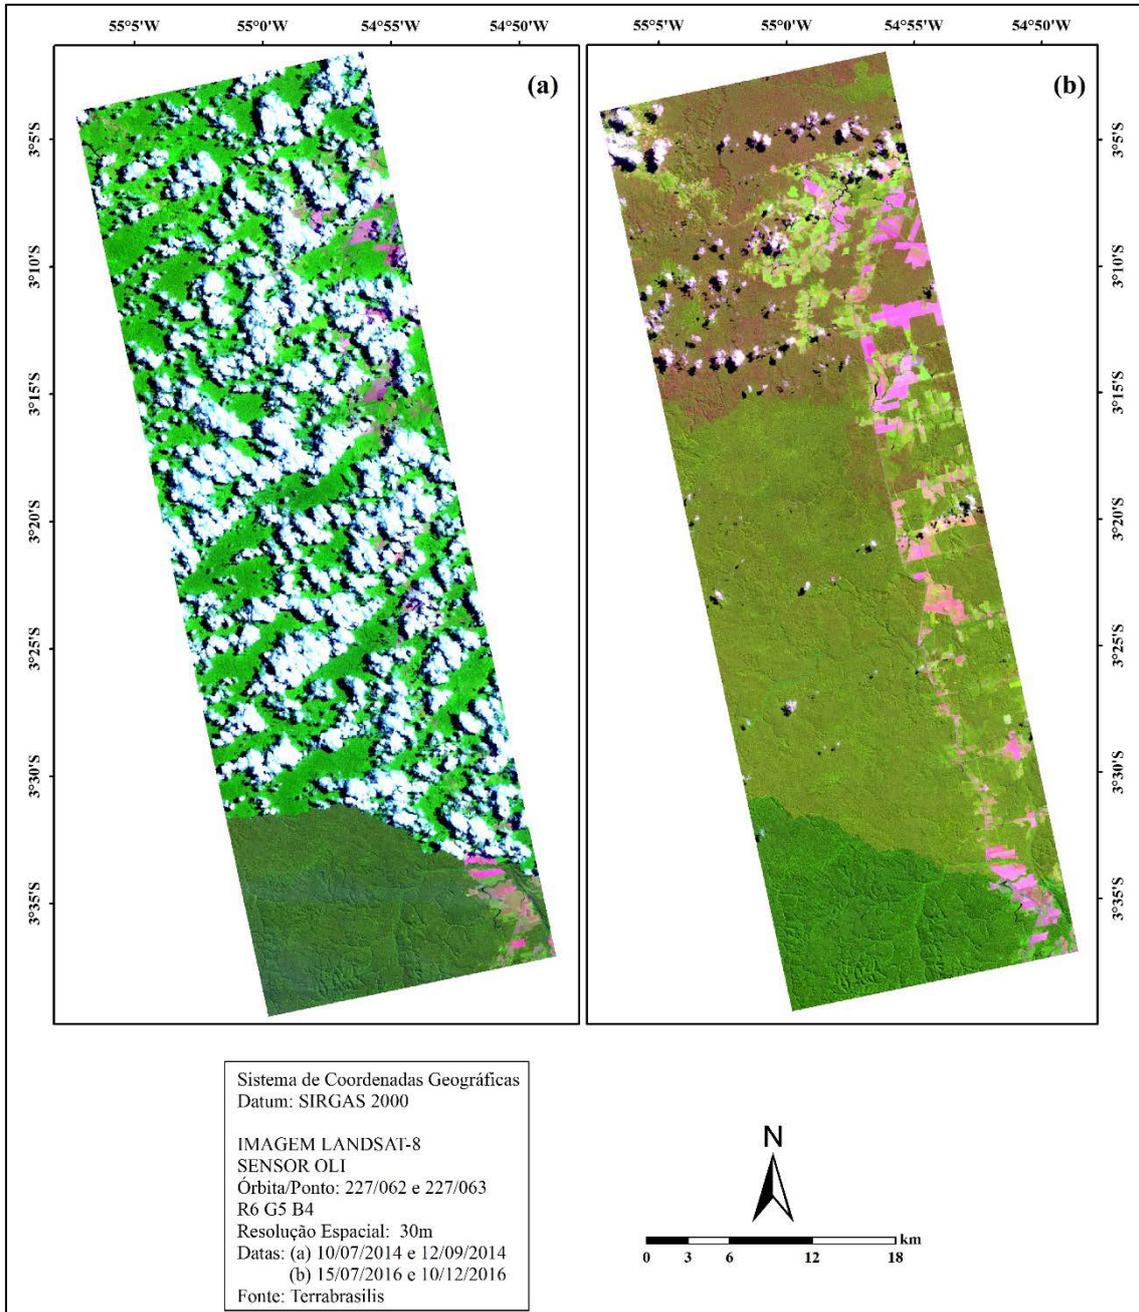
3.4.1. PRODES

O projeto PRODES foi utilizado como dado base da cobertura florestal nos anos de 2014 e 2016. Nota-se na Figura 3.5 que as imagens Landsat-8/OLI utilizadas para o mapeamento PRODES do ano de 2014 na área de estudo está praticamente coberta por nuvens em toda sua extensão, não sendo possível observar mudanças existentes nesse período em boa parte da área. Por esse motivo, foi verificado por meio do PRODES de 2015 as extensões florestais para certificar quais áreas sofreram supressão da floresta. A imagem utilizada pelo PRODES para o ano de 2016 apresenta boa visibilidade para a interpretação da área.

Segundo os dados PRODES, a extensão desmatada acumulada na área de estudo é cerca de 290 km² até o ano de 2016, correspondente a 20,4% da sua delimitação. Pode-se observar na Figura 3.6 os produtos temáticos do PRODES dos anos correspondentes derivados das imagens apresentadas da Figura 3.5. De acordo com os dados temáticos, o desflorestamento situa-se predominantemente nas margens da BR-163 (Santarém-Cuiabá) e nas margens do rio Tapajós (topo a esquerda).

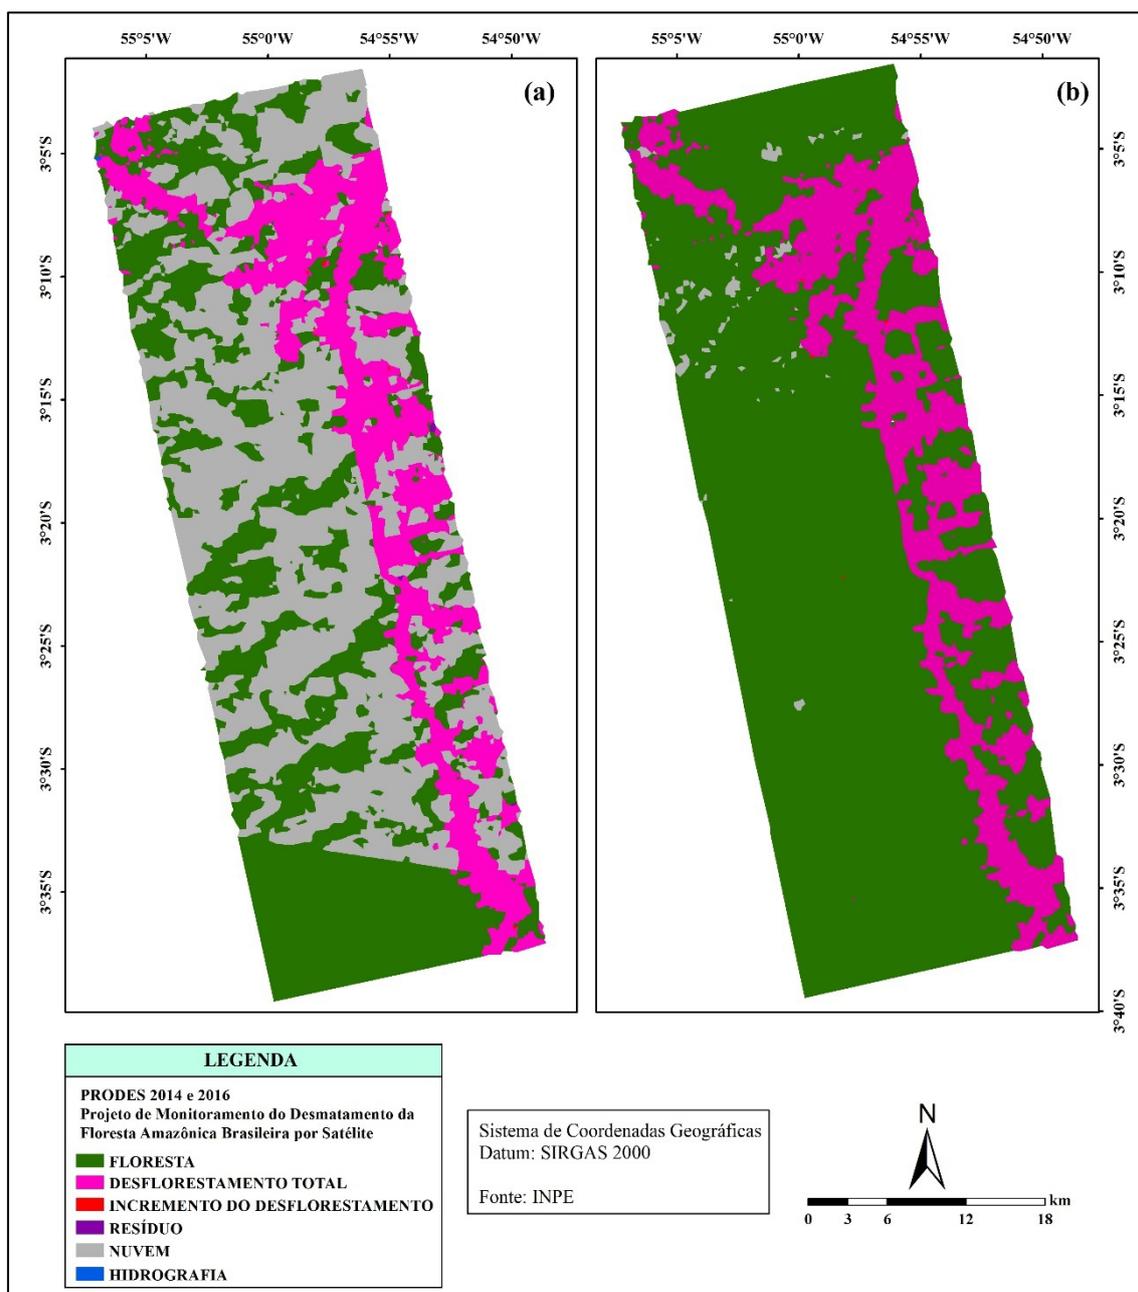
Devido a isso, é importante destacar que os municípios de Aveiro, Belterra, Mojuí dos Campos e Placas estão incluídos na política de governo do estado do Pará chamada Programa Municípios Verdes (PMV), que visa a redução da taxa de desmatamento na Amazônia seguindo quatro eixos de ação: controle e monitoramento do desmatamento; ordenamento territorial, ambiental e fundiário; produção sustentável; e gestão ambiental compartilhada.

Figura 3.5 - Imagens utilizadas na confecção dos dados PRODES dos anos: (a) 2014 e (b) 2016.



Fonte: Produção da Autora.

Figura 3.6 - Dados temáticos do PRODES referentes aos anos: (a) 2014 e (b) 2016.

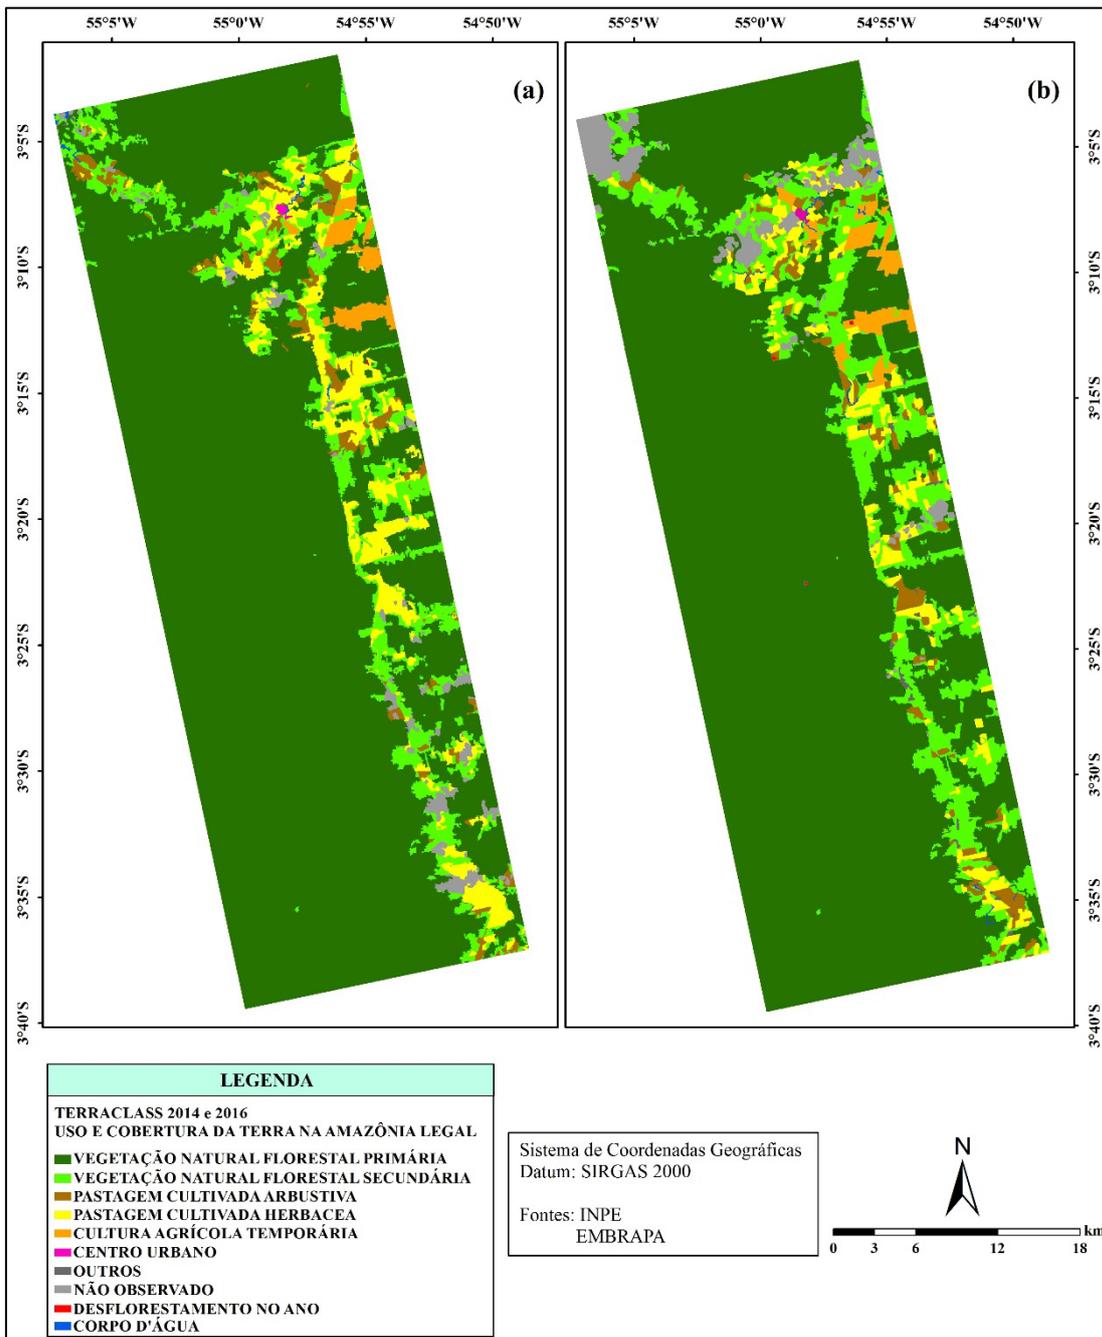


Fonte: Produção da Autora.

3.4.2. TerraClass

O projeto TerraClass dos anos de 2014 e 2016 foram usados como dado base do uso e cobertura da terra na área de estudo. Atualmente, o TerraClass do bioma Amazônia disponibiliza dados até o ano de 2014. Para fins desse trabalho, a equipe do TerraClass produziu o dado do ano de 2016. Os mapeamentos do TerraClass utilizados são ilustrados na Figura 3.7.

Figura 3.7 - Dados temáticos do TerraClass referentes aos anos: (a) 2014 e (b) 2016.



Fonte: Produção da Autora.

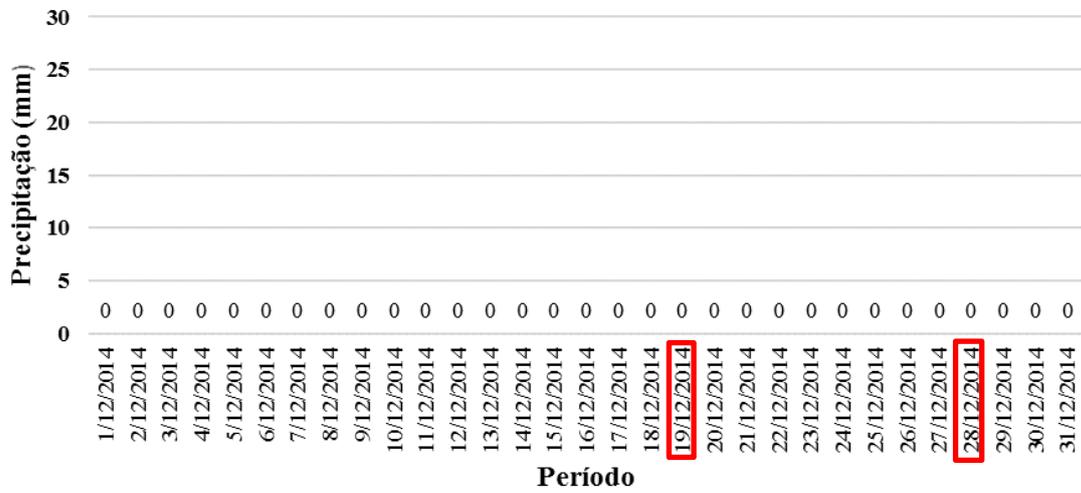
3.4.3. Dados meteorológicos

Foram utilizados dados meteorológicos de precipitação pluviométrica diária acumulada disponibilizados pelo INMET nas datas de aquisição das imagens ALOS/PALSAR-2 e SENTINEL-1. Os dados de precipitação pluviométrica utilizados foram referentes à estação 82246 localizada no município de Belterra/PA.

A umidade pode afetar a imagem de radar. O sinal retroespalhado por um alvo é influenciado pelas suas características geométricas do terreno e suas propriedades dielétricas (LEWIS; HENDERSON, 1998), porém a quantidade de umidade afeta a profundidade de penetração de energia no solo (JENSEN, 2009). Segundo Skolnik (2008), a permissividade elétrica e a atenuação do sinal retroespalhado são influenciados pela umidade relativa do solo, uma vez que, solos úmidos geralmente refletem mais energia eletromagnética do que solos secos. Sendo assim, a utilização dos dados meteorológicos é importante para o entendimento e análise de possíveis influências de fatores climáticos.

De acordo com a Figura 3.8, não foi observada a ocorrência de chuva no mês de dezembro de 2014 na estação meteorológica. Em relação à Figura 3.9, nota-se que não ocorreram precipitações significativas nas 24 horas antecedentes ao imageamento do Sentinel-1A. Na Figura 3.10, constata-se que houve precipitação ao dia anterior e no dia do imageamento da ALOS/PALSAR-2. Mesmo que a quantidade de precipitação acumulada seja considerada baixa ($< 25\text{mm}$), esse fator pode ter afetado no aumento da permissividade elétrica dos alvos e conseqüentemente, influenciando na discriminabilidade dos alvos.

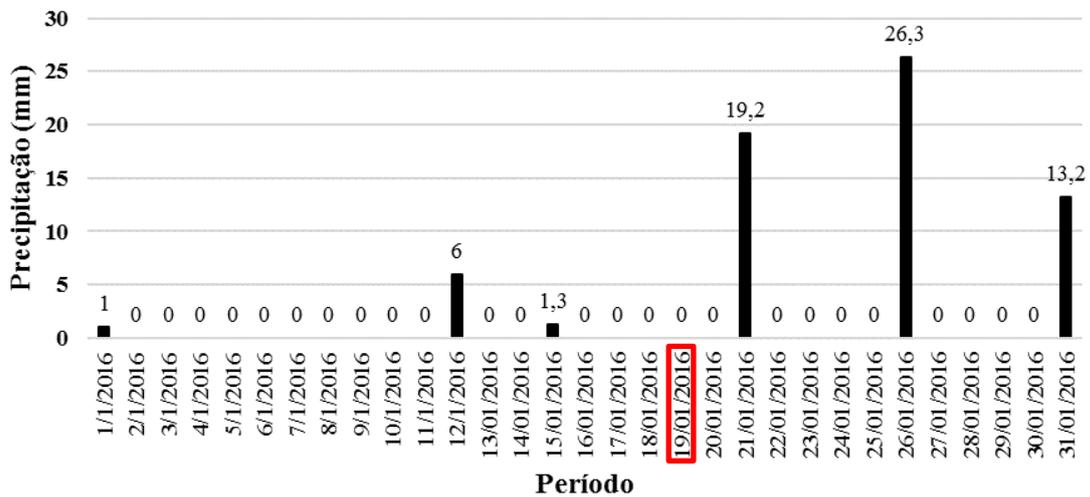
Figura 3.8 - Dados pluviométricos diários na estação de Belterra (PA) do mês de dezembro (2014).



Data de aquisição das imagens

Fonte: INMET (2019).

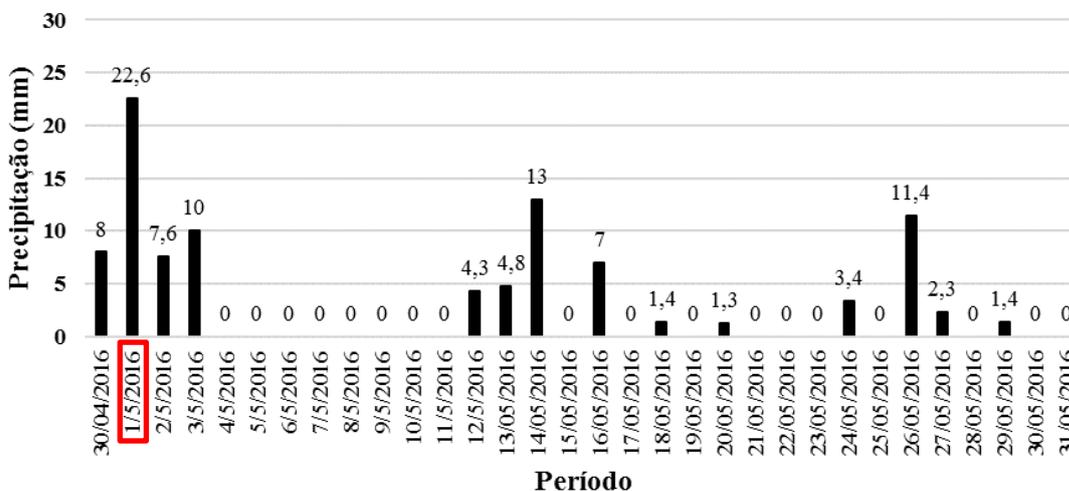
Figura 3.9 - Dados pluviométricos diários na estação de Belterra (PA) do mês de janeiro (2016).



Data de aquisição das imagens

Fonte: INMET (2019).

Figura 3.10 - Dados pluviométricos diários na estação de Belterra (PA) dos meses de abril-maio (2016).



Data de aquisição das imagens

Fonte: INMET (2019).

3.4.4. Softwares

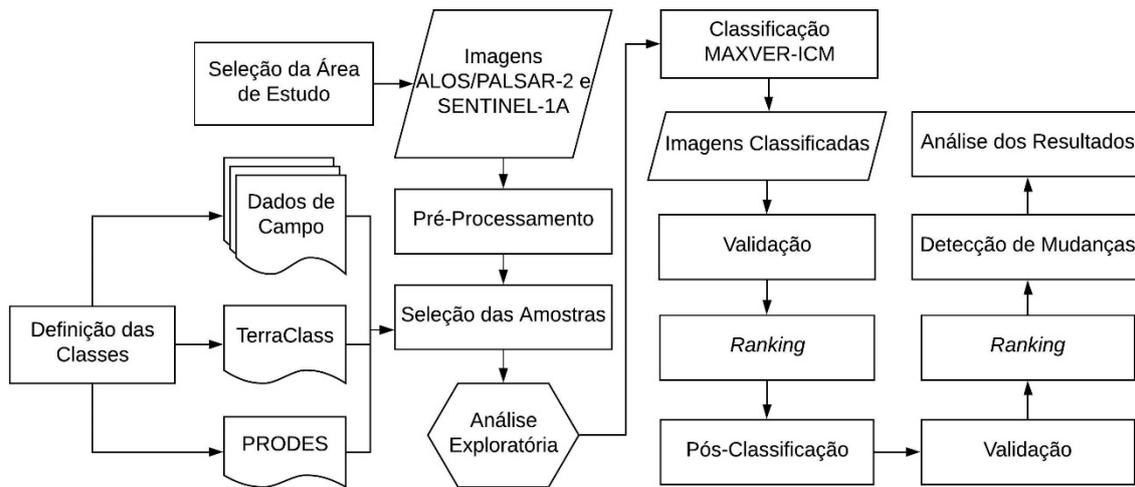
Os dados vetoriais utilizados nesse trabalho, como limites das Unidades da Federação brasileira e limites municipais do estado do Pará, rodovias federais, e delimitações das Unidades de Conservação Brasileiras, foram obtidos pelos sites do IBGE, **DNIT** e MMA, respectivamente. O modelo digital de elevação (MDE) derivado do *Shuttle Radar Topography Mission* (SRTM) manipulado neste trabalho, descrito na Seção 3.5.1, foi obtido na plataforma da **USGS**. As imagens do CBERS 4 utilizadas na produção dos mapas foram obtidas no catálogo de imagens do INPE. Para realização dos processamentos do trabalho, foram utilizados os seguintes softwares e códigos:

- SNAP 6.0;
- ArcGIS 10.3;
- ENVI 4.8;
- IDL 8.0;
- ERDAS IMAGINE 2009;
- Classificador Polarimétrico 7.0 (MAXVER-ICM);
- R versão 3.5.3;
- RStudio 1.2.

3.5 Metodologia

Considerando os objetivos do trabalho e o conjunto principal de dados (imagens SAR obtidas nos anos de 2014 e 2016 em distintas frequências), a metodologia proposta está apresentada no fluxograma da Figura 3.11. Cada etapa é descrita detalhadamente nas próximas seções.

Figura 3.11 - Fluxograma metodológico.



Fonte: Produção da Autora.

A metodologia deste trabalho foi adotada tendo em mente os seguintes pontos científicos: a) Avaliação da separabilidade das classes de cobertura da terra a partir das combinações dos canais das imagens SAR multifrequência; b) Avaliação do potencial do classificador MAXVER-ICM em mapear a cobertura da terra utilizando dados SAR polarizados em diferentes frequências; c) Detecção de mudanças na cobertura da terra em uma região da Amazônia Brasileira ocorridas entre os anos de 2014 e 2016; e d) Detecção do desmatamento, utilizando o mesmo conjunto de dados, entre os anos de 2014 e 2016.

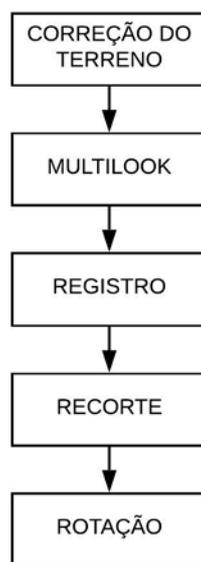
3.5.1. Pré-processamento

Após a seleção da área de estudo e aquisição das imagens orbitais, a etapa seguinte foi o pré-processamento das imagens SAR. A fase do pré-processamento tem o propósito de facilitar a manipulação e extração de informações das imagens. É importante que nessa etapa, para este trabalho, todas as imagens sejam equivalentes quanto ao tamanho do

pixel, na unidade do pixel representado, no número equivalente de *looks* e que estejam na mesma posição geográfica.

Considerando as etapas de classificação e detecção de mudanças, alguns processamentos são necessários para aprimorar a separabilidade dos alvos na cena, sobretudo, o pré-processamento foi constituído em correções geométricas e correções radiométricas, como é exemplificado na Figura 3.12.

Figura 3.12 - Pré-Processamento das imagens SAR.



Fonte: Produção da Autora.

Primeiramente, foi realizado no *software* SNAP versão 6.0 a extração da informação de intensidade e amplitude nos quatro conjuntos de dados (PALSAR-2 e SENTINEL-1A). Logo, foi feito no SNAP a ortorretificação das imagens com o algoritmo *Range Doppler Terrain Correction*, utilizando o MDE do *SRTM* de 30 metros de resolução nominal (1-arco segundo). Nessa ferramenta as distorções e degradações nos dados são reparados, de maneira que a representação da imagem seja fiel a verdade terrestre. Todas as imagens foram reamostradas para tamanho de pixel 10x10m pelo método do vizinho mais próximo na etapa de ortorretificação.

A técnica de *Multilook* foi aplicada nas imagens PALSAR-2, no SNAP, de forma que as imagens ficassem semelhantes no número de *looks* em relação as imagens do SENTINEL-1A, que tem um ENL estimado de 4,4. Assim sendo, foi aplicado 1 *look* em azimute e 5 *looks* em range. Essa etapa minimiza o efeito do ruído *speckle*, que para imagens SAR é inerente a formação das imagens e pode variar aleatoriamente os valores de cada pixel.

Em seguida, foi realizado o registro entre os conjuntos de dados no software ENVI 4.8, onde foi utilizada a imagem SENTINEL-1A de 2014 como imagem base. Nesse processo, é necessário coletar pontos de controle (*GPC- Ground Point Control*) que correspondam ao mesmo local em ambas as imagens. Após a coleta dos pontos, o método de registro utilizado foi polinomial de 3º grau.

Feitas as correções geométricas e radiométricas, as imagens foram recortadas de acordo com a área de estudo previamente definida (**Seção 3.1**) no software ERDAS IMAGINE 2009. Para seguir com a etapa de classificação, foi necessário rotacionar as imagens recortadas, de modo que o *background* não interferisse nas estatísticas do classificador. As imagens foram rotacionadas a um ângulo de 12 graus no ENVI.

Finalizado o pré-processamento das imagens, seguiu-se para a etapa de classificação.

3.5.2. Definição das classes e seleção das amostras

De acordo com os objetivos do trabalho, com o levantamento de campo e com os dados auxiliares, são apresentadas na Tabela 3.3 as classes de interesse definidas para este estudo, baseadas nas classes do TerraClass, e uma breve descrição para cada uma delas. Nessa tabela também estão ilustradas a cor adotada para cada classe de cobertura nas imagens classificadas, bem como a fotografia representativa para cada classe.

Além das classes definidas abaixo, que são tratadas na etapa de classificação, a classe de desflorestamento (DESF) será incluída na discussão dos resultados. A classe DESF está associada ao aumento da supressão da floresta que a classe de FP tenha sofrido, podendo ter sido convertida para uma das demais classes citadas na Tabela 3.3 no período estudado. Dada a não existência de informações de campo especificamente de DESF, esta classe somente será observada na etapa de análise de mudanças pela conversão referida anteriormente.

Tabela 3.3 - Descrição das classes de cobertura da terra.

Classe	Sigla	Descrição	Fotografia	Cor
Floresta Primária	FP	Vegetação natural florestal que não tenha sofrido alteração nas suas características originais		
Vegetação Secundária	VS	Vegetação natural florestal no processo de regeneração, que tenha sofrido remoção total da vegetação original		
Pasto Sujo	PS	Áreas de pastagem com predomínio de arbustos/arbóreas e herbáceas, com ou sem presença de gado		
Pasto Limpo	PL	Áreas de pastagem com predomínio de herbáceas, com ou sem presença de gado		

Continua

Tabela 3.3- Conclusão.

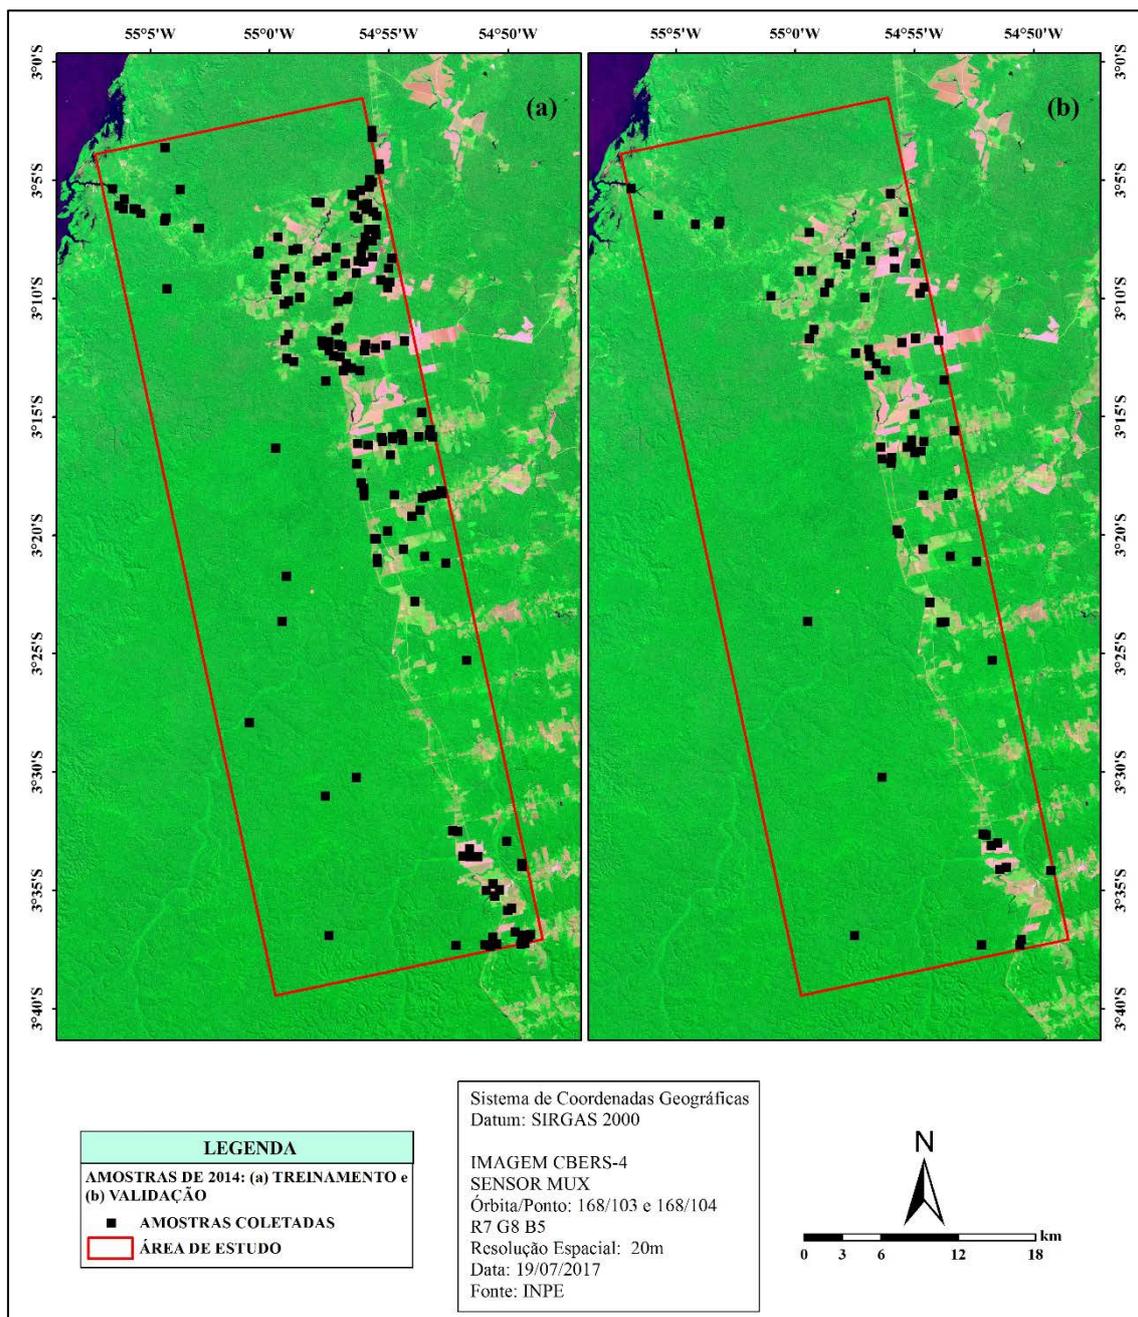
Classe	Sigla	Descrição	Fotografia	Cor
Agricultura	AG	Culturas agrícolas temporárias em diferentes coberturas vegetais e estágios de produção		

Fonte: Produção da Autora.

Definidas as classes, a próxima etapa realizada foi a coleta das amostras de treinamento e validação de cada classe das datas referentes a 2014 e 2016. Por via de regra, requer-se a cautela de não selecionar áreas de transição entre classes (bordas). Podemos observar as amostras coletadas na Figura 3.12 e Figura 3.13. Nessas figuras estão representadas apenas a localização das amostras selecionadas.

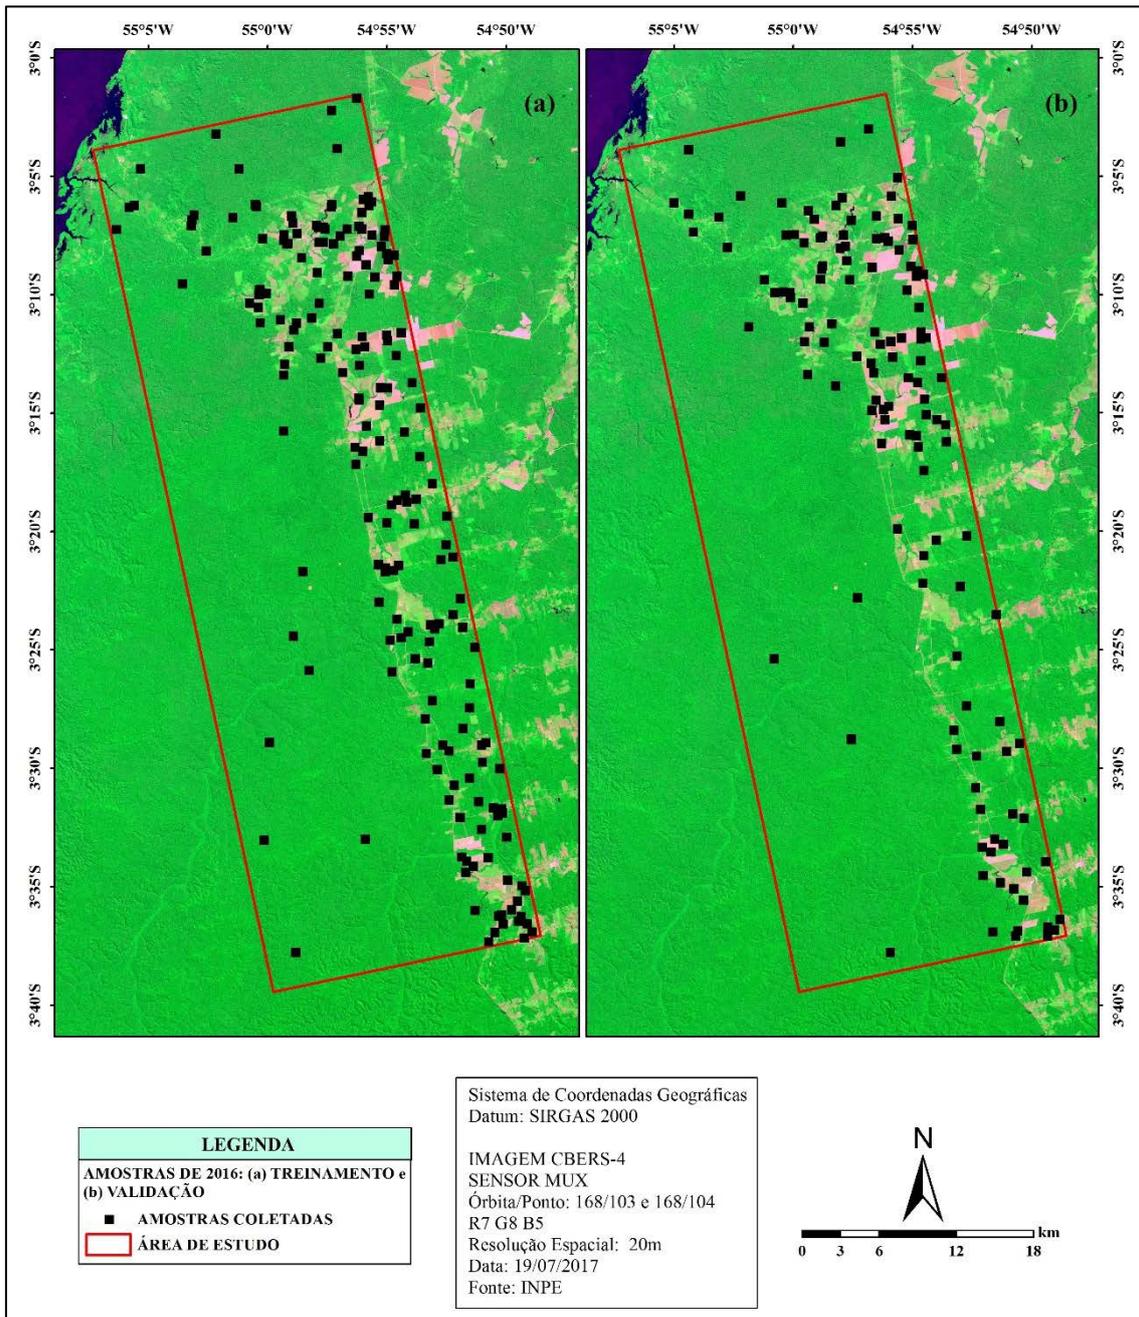
É importante destacar que do conjunto amostral, cerca de 70% das amostras foram destinadas ao treinamento do classificador supervisionado e os outros 30% restantes foram reservados para a etapa de validação das imagens temáticas. Na Tabela 3.4 está descrita a quantidade de polígonos coletados e o número de pixels totais de cada classe. Por fim, as amostras foram analisadas na etapa da análise exploratória.

Figura 3.13 - Amostras coletadas para o ano de 2014: (a) treinamento e (b) validação.



Fonte: Produção da Autora.

Figura 3.14 - Amostras coletadas para o ano de 2016: (a) treinamento e (b) validação.



Fonte: Produção da Autora.

Tabela 3.4 - Quantidade do conjunto de amostras coletadas das classes de cobertura.

Ano	Classes	Polígonos	Número de pixels
2014	FP	28	6064
	VS	69	5542
	PS	49	3922
	PL	58	5504
	AG	36	4803
2016	FP	68	5221
	VS	75	4575
	PS	66	3187
	PL	69	5091
	AG	40	4409

onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto Sujo; PL=Pasto Limpo; AG=Agricultura.

Fonte: Produção da Autora.

3.5.3. Análise exploratória

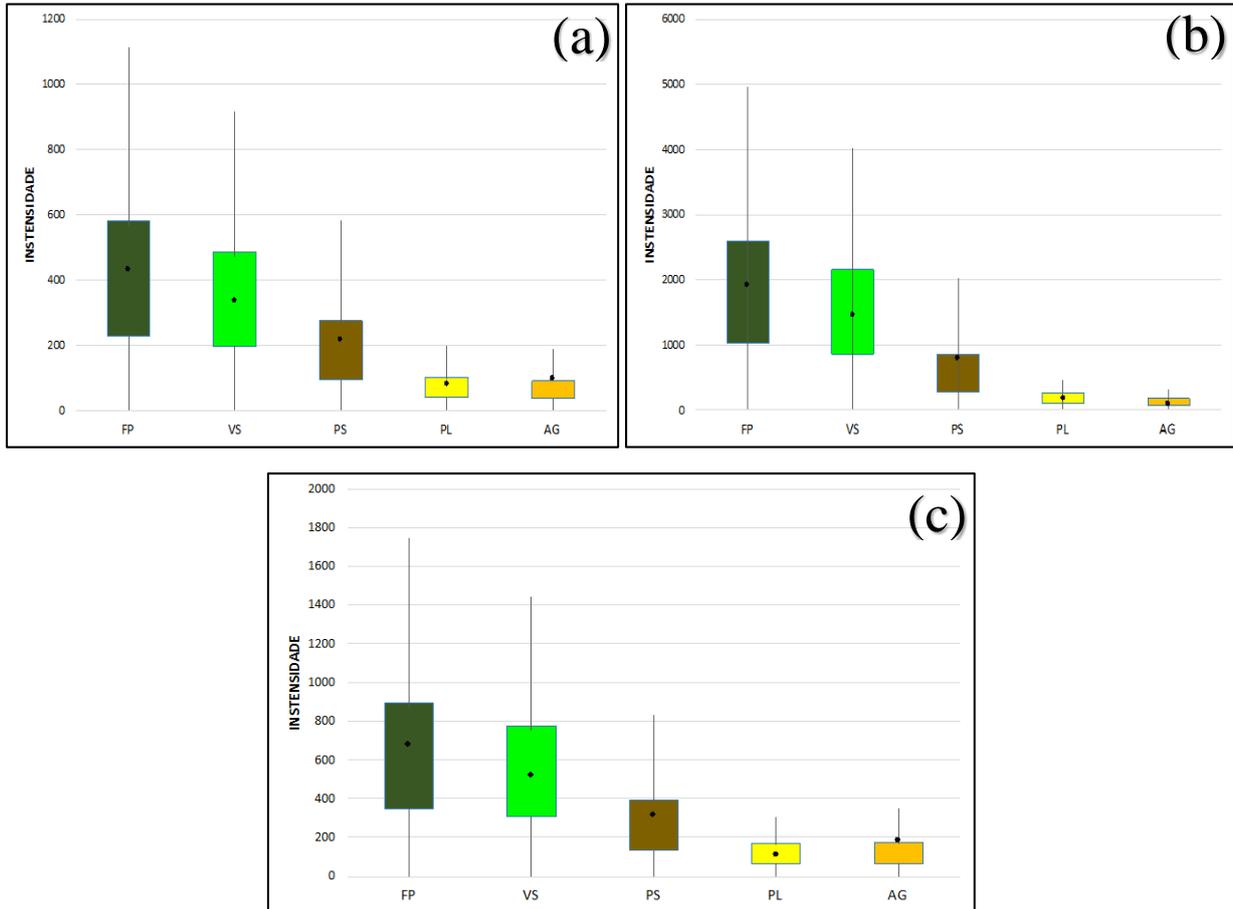
A etapa de análise exploratória tem a finalidade de caracterizar e analisar o comportamento das classes definidas baseado nas amostras selecionadas. A análise foi feita por meio da construção de gráfico *boxplot*, onde foi observado o comportamento de cada classe em cada canal dos quatro conjuntos de dados, sendo PALSAR-2 (L_{HH} , L_{VH} , L_{VV}) e SENTINEL-1A (C_{VH} , C_{VV}) de 2014 e de 2016. Os gráficos foram construídos em valores de intensidade do sinal, mostrados e comentados a seguir.

Observa-se na Figura 3.14 que as classes de FP e VS tem um comportamento semelhante em todos os canais. Nota-se também que as classes de PS e PL se distinguem bem em relação aos valores do sinal retroespalhado, e destaca-se a polarização cruzada VH na separação das dessas duas classes. As classes de PL e AG podem ter respostas semelhantes, prejudicando na separabilidade das duas. Também pode haver confusão entre as classes de VS e PS nas imagens classificadas.

Na Figura 3.15, as classes de FP e VS também tem um comportamento semelhante em todos nos dois canais. Deduz-se que a imagem SENTINEL-1A em valores de

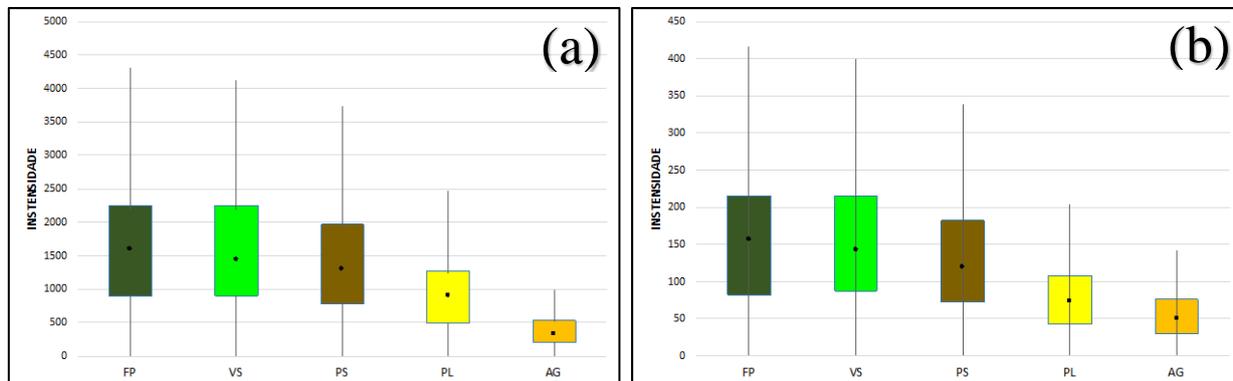
intensidade não consegue separar bem as classes de cobertura no geral, com exceção a classe AG na polarização VH.

Figura 3.15 - Gráfico *boxplot* da imagem PALSAR-2 do ano de 2014 representando o quartil inferior, superior e mediana das classes pelos valores de intensidade do sinal dos canais: (a) HH, (b) VH, (c) VV.



onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto Sujo; PL=Pasto Limpo; AG=Agricultura

Figura 3.16 - Gráfico *boxplot* da imagem SENTINEL-1A do ano de 2014 representando o quartil inferior, superior e mediana das classes pelos valores de intensidade do sinal dos canais: (a) VH e (b) VV.



onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto Sujo; PL=Pasto Limpo; AG=Agricultura.

Fonte: Produção da Autora.

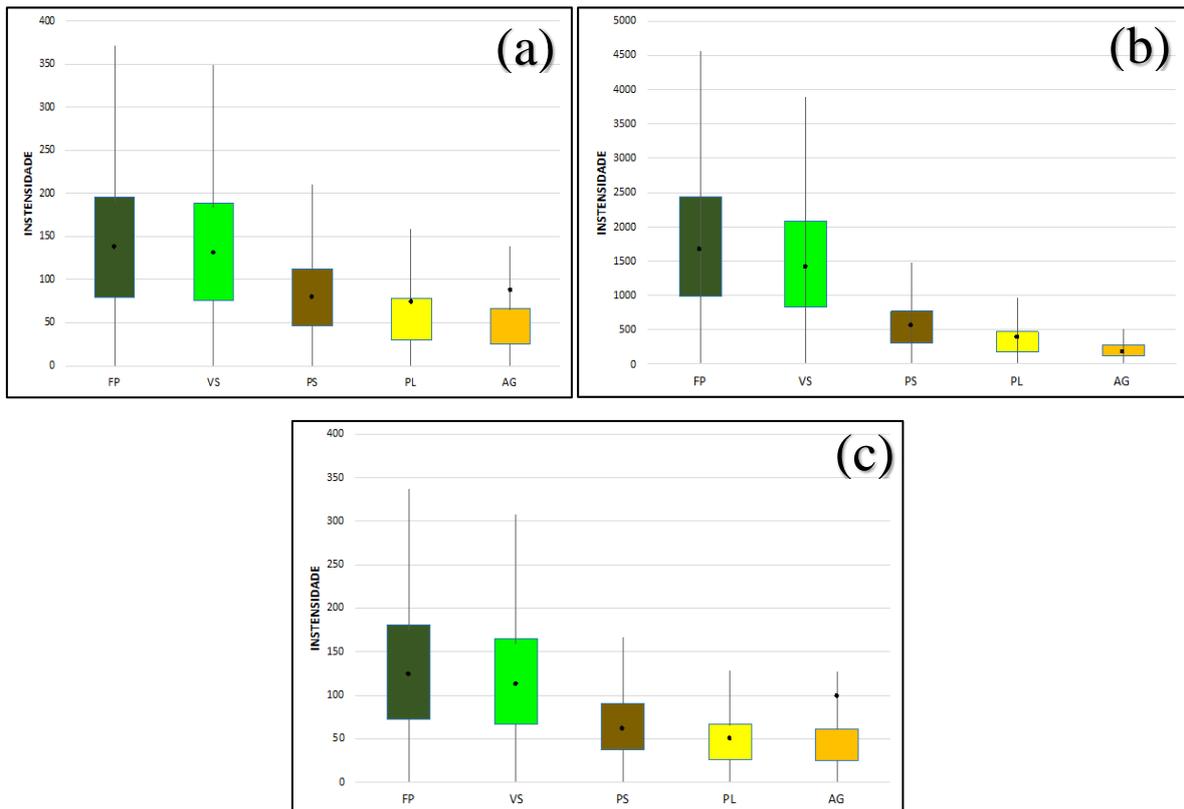
Diferentemente do observado no ano de 2014, na Figura 3.16 observa-se que na imagem PALSAR-2 de 2016 as classes de cobertura tiveram um comportamento similar. O canal VH continua se destacando em relação a separabilidade das classes, principalmente na cobertura de pastagem. As polarizações HH e VV são muito semelhantes na resposta dos sinais de retroespalhamento das classes de cobertura. Pode-se deduzir a partir dessa semelhança que a combinação dos dois canais não vai trazer uma melhoria nos resultados classificatórios. Portanto, recomenda-se a combinação de um dos dois com o canal VH do PALSAR-2 ou VH e VV do SENTINEL-1A para obter resultados satisfatórios.

As polarizações VH e VV na imagem do SENTINEL-1A também se apresentam com comportamentos muito semelhantes, como visto na Figura 3.17. Pode-se inferir que a combinação desses dois canais não trouxe resultados de classificação satisfatórios, pelo fato de não conseguirem distinguir as classes de cobertura, havendo muita confusão.

De maneira geral, observando todos os gráficos do conjunto de imagens dos anos de 2014 e 2016, pôde-se deduzir que o classificador não seria capaz de separar adequadamente as classes de cobertura vegetal (FP e VS). Também pôde-se inferir que o canal de polarização cruzada VH seja capaz de caracterizar melhor as classes de

cobertura em relação aos demais canais, principalmente na separabilidade das classes de pastagem (PS e PL). Era esperado que a classe AG obtivesse boa acurácia quanto a distinção das classes nos resultados de classificação, como pode ser observado nos gráficos mencionados.

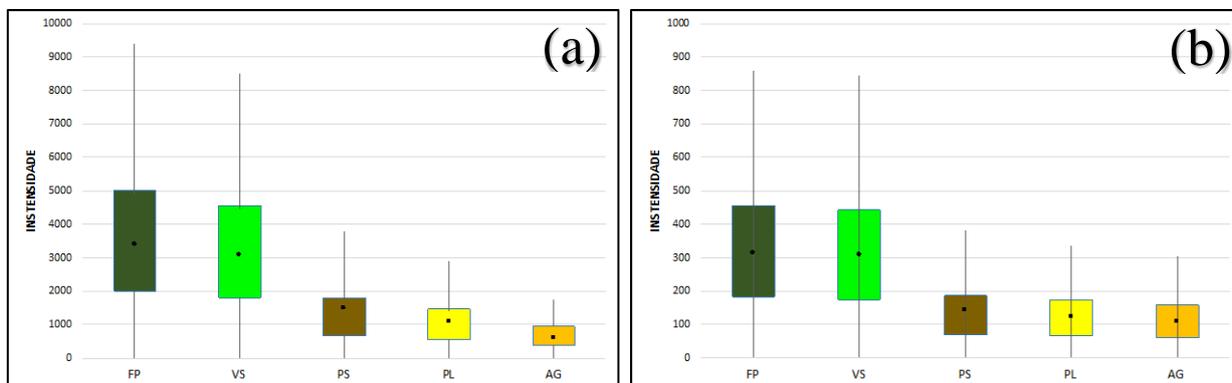
Figura 3.17 - Gráfico *boxplot* da imagem PALSAR-2 do ano de 2016 representando o quartil inferior, superior e mediana das classes pelos valores de intensidade do sinal dos canais: (a) HH, (b) VH, (c) VV.



onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto Sujo; PL=Pasto Limpo; AG=Agricultura.

Fonte: Produção da Autora.

Figura 3.18 - Gráfico *boxplot* da imagem SENTINEL-1A do ano de 2016 representando o quartil inferior, superior e mediana das classes pelos valores de intensidade do sinal dos canais: (a) VH e (b) VV.



onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto Sujo; PL=Pasto Limpo; AG=Agricultura.

Fonte: Produção da Autora.

3.5.4. Classificação MAXVER-ICM

A etapa de classificação foi realizada no Classificador Polarimétrico 7 desenvolvido por Correia (1998), que está implementado no software ENVI 4.8 em linguagem IDL. O classificador pontual MAXVER (Máxima Verossimilhança), associado ao classificador contextual ICM (*Iteracted Conditional Modes*), foi desenvolvido para atribuir as distribuições mais adequadas aos dados SAR (CORREIA, 1998). Por ser um classificador supervisionado, o algoritmo MAXVER atribui as classes em cada célula de acordo com as amostras de treinamento e posteriormente, o ICM refina a classificação considerando a sua dependência espacial.

Para cada modelagem estatística, pode-se combinar os canais disponíveis em diferentes maneiras, como exemplificado na Tabela 3.5. Observamos nesta tabela as três modelagens usadas neste trabalho, que são: univariada, bivariada e multivariada. Em cada modelagem, os dados de entrada se diferenciam quanto a quantidade de canais (mono, bi e/ou multicanal) e no valor do pixel (sinal de retorno). Para cada conjunto de canais mencionado na tabela abaixo, pode-se considerar uma classificação diferente, totalizando em 29 classificações para cada ano correspondente.

Tabela 3.5 - Combinações dos canais usados nas classificações.

Dados	Modelagem (Distribuição)	Conjunto de Canais
Univariado	Gama	$\{L_{HH}\}; \{L_{VH}\}; \{L_{VV}\}; \{C_{VH}\}; \{C_{VV}\}$
Bivariado	Par de Intensidade	$\{L_{HH}, L_{VH}\}; \{L_{HH}, L_{VV}\}; \{L_{VH}, L_{VV}\}$ $\{C_{VH}, C_{VV}\}; \{L_{HH}, C_{VH}\}; \{L_{HH}, C_{VV}\}$ $\{L_{VH}, C_{VH}\}; \{L_{VH}, C_{VV}\}; \{L_{VV}, C_{VH}\}; \{L_{VV}, C_{VV}\}$
Multivariado	Gaussiana Multivariada	$\{L_{HH}, L_{VH}, L_{VV}\}; \{L_{HH}, L_{VH}, C_{VH}\}; \{L_{HH}, L_{VH}, C_{VV}\}$ $\{L_{HH}, L_{VV}, C_{VH}\}; \{L_{HH}, L_{VV}, C_{VV}\}; \{L_{VH}, L_{VV}, C_{VH}\}$ $\{L_{VH}, L_{VV}, C_{VV}\}; \{L_{HH}, C_{VH}, C_{VV}\}; \{L_{VH}, C_{VH}, C_{VV}\}$ $\{L_{VV}, C_{VH}, C_{VV}\}; \{L_{HH}, L_{VH}, C_{VH}, C_{VV}\}; \{L_{HH}, L_{VV}, C_{VH}, C_{VV}\}$ $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}; \{L_{HH}, L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$

Fonte: Produção da Autora.

Na etapa do algoritmo MAXVER, para as modelagens uni e bivariadas, é necessário informar o valor ENL dos dados de entrada. No caso da multivariada não necessita informar este valor. O valor estimado para PALSAR-2 foi de 4,3 e para o SENTINEL-1A o valor foi de 4,4. Em relação ao algoritmo ICM, o critério de parada da classificação foi a porcentagem de mudança dos pixels em 0,5% e/ou a quantidade máxima de iterações definida em 1000 vezes, o que atingir primeiro.

3.5.5. Avaliação e comparação das imagens classificadas

Todas as imagens classificadas foram validadas e avaliadas por meio de um algoritmo baseado no método Monte Carlo. Esse algoritmo foi executado no *software* RStudio 1.2, onde os dados de entrada foram as amostras de validação e as imagens classificadas. Foram sorteados, aleatoriamente, 25% do espaço amostral de classe para a validação das imagens temáticas.

Em cada replicação do Monte Carlo, calculou-se os índices de *kappa* global, exatidão global e *kappa* condicional de cada classe. As iterações foram realizadas mil vezes para cada classificação. No final, uma matriz de confusão média de cada imagem temática foi gerada. Uma tabela foi formada para mostrar os mil resultados dos índices de cada classificação. Essa tabela foi gerada para as imagens temáticas de 2014 e 2016 separadamente.

Em relação a comparação entre os dados classificados, o índice *kappa* foi escolhido como parâmetro comparativo neste trabalho. Com a finalidade de determinar qual a combinação de canais obteve o resultado mais satisfatório, foi realizado um *ranking* das classificações, de acordo com os valores *kappa* estimados.

O *ranking* das classificações foi feito de modo a deixar a incerteza e a ocasionalidade de lado. Foram realizados dois *rankings* para se formar o vetor final. Primeiramente, ranquea-se para ordenar cada um dos mil vetores com 29 posições de acordo com os valores de *kappa* global. Então, foi identificado para cada posição do *ranking* (1° ao 29° lugar) a classificação que ocorreu com maior frequência (moda). O vetor final foi formado, onde cada posição é a moda das 1000 posições. Em caso de empate na moda em uma dada posição, o parâmetro de desempate foi o *kappa* médio (a média dos valores de *kappa* das mil repetições). É importante destacar que, uma mesma classificação não pode ocupar duas posições distintas no vetor final, caso isso ocorra, a classificação com segunda maior frequência foi escolhida. Obteve-se, então, o *ranking* final das 29 classificações para as datas de 2014 e 2016.

Com o *ranking* final de cada ano, foi feito um teste estatístico de sinal de Congaton (1999) para determinar se os valores estimados dos índices *kappa* são significativamente diferentes a um nível de significância de 95%. Esse procedimento foi realizado nos resultados de classificação, assim como para os resultados da pós-classificação (que será discutido na Seção 3.5.6).

O teste estatístico de Congaton (1999) é um teste não paramétrico que utiliza uma técnica multivariada discreta da análise *kappa*. Essa análise baseia-se na diferença da concordância dos valores das matrizes de confusão de duas classificações independentes (CONGATON, 1999). Considerando duas matrizes de confusão independentes, o teste Z pode ser expresso pela Equação 3.1 (CONGATON, 1999):

$$Z = \frac{|\hat{K}_1 - \hat{K}_2|}{\sqrt{\hat{v}\text{ar}(\hat{K}_1) + \hat{v}\text{ar}(\hat{K}_2)}}. \quad (3.1)$$

onde \hat{K}_1 e \hat{K}_2 são os valores estimados do *kappa* das matrizes de confusão; $\hat{v}\text{ar}(\hat{K}_1)$ e $\hat{v}\text{ar}(\hat{K}_2)$ são os valores estimados da variância de *kappa*; e Z é normalmente distribuído.

Dada a hipótese nula $H_0: (K_1 - K_2) = 0$ e a hipótese alternativa $H_1: (K_1 - K_2) \neq 0$, a hipótese nula é rejeitada se $Z \geq Z_{\alpha/2}$ utilizando 5% de significância.

Após a realização do teste estatístico, as combinações de canais são analisadas de acordo com o ranking final.

3.5.6. Pós-classificação

Após uma análise prévia dos resultados de classificação, verificou-se que não ocorreu separabilidade para as classes de FP e VS. Em vista disso, uma pós-classificação foi aplicada nas imagens classificadas de 2014 a fim de refiná-las, para que a etapa de detecção de mudanças não fosse afetada nessas duas classes de cobertura.

A partir da máscara da classe de floresta primária do PRODES, foi demarcada nos resultados de classificação a área referente a classe (FP) do ano de 2014. Assim, as classes que estavam dentro do limite da máscara do PRODES foram redefinidas como classe FP e a classe FP que estivesse fora das limitações foi redefinida como VS. Depois dessa fase, as classificações foram devidamente validadas, como descrito na **Seção 3.5.5**.

3.5.7. Detecção de mudanças

A técnica utilizada para detecção de mudanças neste trabalho foi a análise pós-classificação, que possui a vantagem de caracterizar/quantificar as mudanças ocorridas entre 2014 e 2016. Essa análise permite detectar transições das classes de cobertura com base nos resultados de classificação dos dois anos estudados. Essa etapa foi realizada no *software* ERDAS.

A partir do *ranking* gerado, descrito na **Seção 3.5.5**, foram analisados 5 cenários de mudanças que estão relacionados aos melhores resultados das combinações dos dados univariados, bivariados e multivariados. As matrizes de transição foram exploradas e avaliadas por meio de gráficos de porcentagem.

As mudanças nesse trabalho foram tratadas quanto à transição de uma classe para outra. No caso, a mudança da classe FP para as demais classes foi tratada como desflorestamento. Essas mudanças detectadas foram divididas em prováveis, improváveis e impossíveis, considerando a probabilidade de ocorrência da transição. A

mudança improvável considera que a probabilidade do evento acontecer é quase nula e a mudança impossível, é aquela que não pode ocorrer.

Com relação a mudanças improváveis, se os polígonos identificados como mudanças forem menores que 6,25 hectares, os mesmos foram denominados como não mudança, retornando a classe original. O tamanho de identificação do polígono de mudança foi padronizado de acordo com os dados PRODES, que somente mapeia áreas maiores que 6,25 ha.

Para mudanças impossíveis, isto é, qualquer classe que no ano de 2014 foi classificada em uma classe diferente de FP e que em 2016 foi classificada como FP, foi considerado inverossímil. Nesse caso em particular, a mudança foi redesignada para a classe VS, pelo fato de ser uma alteração mais provável.

3.5.8. Análise dos resultados

Com intuito de avaliar a potencial da classificação de dados SAR polarizados nas bandas C e L, o *ranking* foi explorado em cima dos melhores resultados das combinações de classificações univariadas, bivariadas e multivariadas. Quanto à distinção das classes definidas, foram discutidas baseadas na análise da matriz de confusão dos melhores resultados das classificações das combinações dos canais.

Para verificar a capacidade de detecção de mudanças utilizando dados SAR por meio da análise pós-classificação, os resultados de mudança entre as classes definidas, a partir das combinações univariadas, bivariadas e multivariadas, serão comparados com as mudanças ocorridas entre as classes do TerraClass 2014 e 2016. Do mesmo modo, serão comparadas as detecções de desflorestamento com os dados de incremento de desflorestamento divulgados pelo PRODES dos anos entre 2014 e 2016.

4 RESULTADOS E DISCUSSÕES

4.1 Análise dos resultados de classificação

A partir da metodologia apresentada na Seção 3.5, foram obtidos os valores dos índices estimados do *kappa* e da acurácia global (AC) gerados a partir da validação dos resultados de classificação. Então, os *rankings* dos 29 resultados de classificação dos anos de 2014 e 2016 foram produzidos em relação aos valores estimados de *kappa*, como exposto na Seção 3.5.5.

A análise dos resultados de classificação foi feita baseada no *ranking* dos dois anos, que está representado na Tabela 4.1. Nessa tabela são mostradas as posições (do melhor para o pior) dos resultados de classificação de 2014 e 2016 e os resultados de pós-classificação de 2014 (Ranking 2014M). No ranking da Tabela 4.1 pode-se notar que nos conjuntos de canais que apresentam os melhores resultados da classificação, há sempre presença de canais de diferentes frequências. Indicando assim que a combinação de dados obtidos nas bandas C e L melhoram os resultados de classificação. Da mesma forma, os canais de polarização cruzada (VH) que aparecem nas primeiras posições do ranking, desempenham papel fundamental na discriminação das classes em estudo.

Na Tabela 4.2 é mostrado a quantidade de vezes que a classificação se manifestou na posição designada. Essa informação é importante para entender e ressaltar o quanto um conjunto dos canais foi mais eficiente em relação aos demais conjuntos, no mapeamento da cobertura da terra na área de estudo. Por exemplo, os melhores resultados apareceram na primeira posição 99%, 72% e 58,2% das vezes nos *rankings* de 2014, 2014M e 2016 respectivamente. Em relação a esse conjunto de dados, nota-se mais uma vez que a combinação multifrequência apresenta resultados superiores na classificação.

A informação da Tabela 4.2, da mesma forma, pode indicar o conjunto de dados que foi menos eficiente que os demais, como por exemplo os piores resultados que manifestaram na última posição 99%, 42,9% e 100% das vezes dos respectivos *rankings* de 2014, 2014M e 2016. Nesse caso em específico, dados uni/bivariados se encontram na última posição do ranqueamento, podendo indicar que esse tipo de conjunto de dados para o mapeamento da cobertura da terra apresenta resultados inferiores.

Tabela 4.1 - *Rankings* dos resultados de classificação.

RANKING 2014		RANKING 2014M		RANKING 2016	
1°	{L _{VH} , L _{VV} , C _{VH} , C _{VV} }	1°	{L _{VH} , L _{VV} , C _{VH} , C _{VV} }	1°	{L _{VH} , C _{VH} , C _{VV} }
2°	{L _{VH} , L _{VV} , C _{VH} }	2°	{L _{VH} , L _{VV} , C _{VH} }	2°	{L _{HH} , L _{VH} , C _{VH} }
3°	{L _{HH} , L _{VH} , L _{VV} , C _{VH} , C _{VV} }	3°	{L _{HH} , L _{VH} , L _{VV} , C _{VH} , C _{VV} }	3°	{L _{HH} , L _{VH} , C _{VH} , C _{VV} }
4°	{L _{VV} , C _{VH} , C _{VV} }	4°	{L _{HH} , L _{VV} , C _{VH} }	4°	{L _{VH} , C _{VV} }
5°	{L _{VH} , C _{VH} , C _{VV} }	5°	{L _{HH} , L _{VH} , C _{VH} }	5°	{L _{VH} , L _{VV} , C _{VH} , C _{VV} }
6°	{L _{HH} , L _{VH} , C _{VH} }	6°	{L _{VH} , C _{VH} , C _{VV} }	6°	{L _{VH} , C _{VH} }
7°	{L _{HH} , L _{VV} , C _{VH} , C _{VV} }	7°	{L _{HH} , L _{VV} , C _{VH} , C _{VV} }	7°	{L _{VH} , L _{VV} , C _{VH} }
8°	{L _{HH} , L _{VV} , C _{VH} }	8°	{L _{VV} , C _{VH} , C _{VV} }	8°	{L _{VH} }
9°	{L _{HH} , L _{VH} , C _{VH} , C _{VV} }	9°	{L _{VH} , L _{VV} , C _{VV} }	9°	{L _{HH} , L _{VH} , C _{VV} }
10°	{L _{VH} , L _{VV} , C _{VV} }	10°	{L _{HH} , L _{VH} , C _{VH} , C _{VV} }	10°	{L _{HH} , L _{VH} , L _{VV} , C _{VH} , C _{VV} }
11°	{L _{HH} , C _{VH} , C _{VV} }	11°	{L _{HH} , L _{VH} , L _{VV} }	11°	{L _{VH} , L _{VV} }
12°	{L _{VH} , C _{VH} }	12°	{L _{HH} , L _{VH} , C _{VV} }	12°	{L _{VV} , C _{VH} , C _{VV} }
13°	{L _{VH} , L _{VV} }	13°	{L _{VV} , C _{VH} }	13°	{L _{HH} , C _{VH} , C _{VV} }
14°	{L _{VV} , C _{VH} }	14°	{L _{VH} , C _{VH} }	14°	{L _{VH} , L _{VV} , C _{VV} }
15°	{L _{HH} , L _{VH} , C _{VV} }	15°	{L _{HH} , L _{VH} }	15°	{L _{HH} , L _{VH} }
16°	{L _{HH} , L _{VH} }	16°	{L _{HH} , C _{VH} , C _{VV} }	16°	{L _{HH} , L _{VV} , C _{VH} , C _{VV} }
17°	{L _{HH} , L _{VH} , L _{VV} }	17°	{L _{VH} , L _{VV} }	17°	{C _{VH} }
18°	{L _{VH} }	18°	{L _{VH} }	18°	{C _{VH} , C _{VV} }
19°	{L _{HH} , L _{VV} , C _{VV} }	19°	{L _{HH} , C _{VH} }	19°	{L _{HH} , L _{VV} , C _{VH} }
20°	{L _{HH} , C _{VH} }	20°	{L _{HH} , L _{VV} , C _{VV} }	20°	{L _{HH} , L _{VH} , L _{VV} }
21°	{L _{VH} , C _{VV} }	21°	{L _{VH} , C _{VV} }	21°	{L _{VV} , C _{VV} }
22°	{L _{VV} , C _{VV} }	22°	{L _{VV} , C _{VV} }	22°	{L _{VV} , C _{VH} }
23°	{C _{VH} , C _{VV} }	23°	{C _{VH} , C _{VV} }	23°	{L _{VV} }
24°	{C _{VH} }	24°	{C _{VH} }	24°	{L _{HH} , L _{VV} , C _{VV} }
25°	{L _{HH} , C _{VV} }	25°	{L _{HH} , C _{VV} }	25°	{L _{HH} , L _{VV} }
26°	{L _{HH} , L _{VV} }	26°	{C _{VV} }	26°	{L _{HH} , C _{VH} }
27°	{L _{VV} }	27°	{L _{HH} }	27°	{L _{HH} }
28°	{L _{HH} }	28°	{L _{VV} }	28°	{C _{VV} }
29°	{C _{VV} }	29°	{L _{HH} , L _{VV} }	29°	{L _{HH} , C _{VV} }

Fonte: Produção da Autora.

Tabela 4.2 - Quantidade de repetições que a imagem classificada se apresentou na posição designada.

POSIÇÃO	RANKING EM PORCENTAGEM		
	2014	2014M	2016
1º	99,9	72,0	582
2º	74,3	65,1	51,1
3º	55,7	88,8	29,9
4º	33,4	58,4	27,3
5º	35,2	39,8	24,3
6º	36,8	33,5	22,5
7º	36,3	49,2	86,8
8º	39,2	36,2	38,8
9º	51,8	35,3	38,3
10º	59,9	37,2	36,0
11º	39,0	55,0	40,5
12º	31,2	31,3	32,9
13º	19,2	28,5	27,1
14º	32,6	38,3	43,7
15º	30,9	32,0	40,7
16º	34,2	36,1	45,4
17º	39,2	44,1	28,6
18º	52,4	43,1	29,3
19º	67,3	55,2	43,8
20º	58,5	58,7	85,2
21º	64,0	72,6	50,3
22º	82,7	62,2	34,0
23º	49,4	59,8	23,6
24º	34,9	73,1	21,4
25º	35,1	98,7	24,6
26º	94,1	43,1	17,1
27º	91,2	38,8	29,8
28º	91,1	36,3	15,8
29º	99,9	42,9	100,0

Fonte: Produção da Autora.

A partir dos resultados de ranking dos respectivos anos, primeiramente foram comparados os resultados de classificação e pós-classificação de 2014, para certificar

que houve uma melhora significativa entre os melhores resultados de classificação no *ranking*, a partir dos valores médios da matriz de confusão, do *kappa* e da AC.

Logo, o *ranking* de 2014 e 2016 foram explorados separadamente e em conjunto para avaliar os resultados de classificação sobre os diferentes tipos de modelagens de dados uni/bivariados e multivariados. Em seguida, foram consideradas as diferentes frequências utilizadas das bandas L e C dos sensores PALSAR-2 e SENTINEL-1A respectivamente. Por fim, foram exploradas as diferentes combinações dos canais e frequências empregadas.

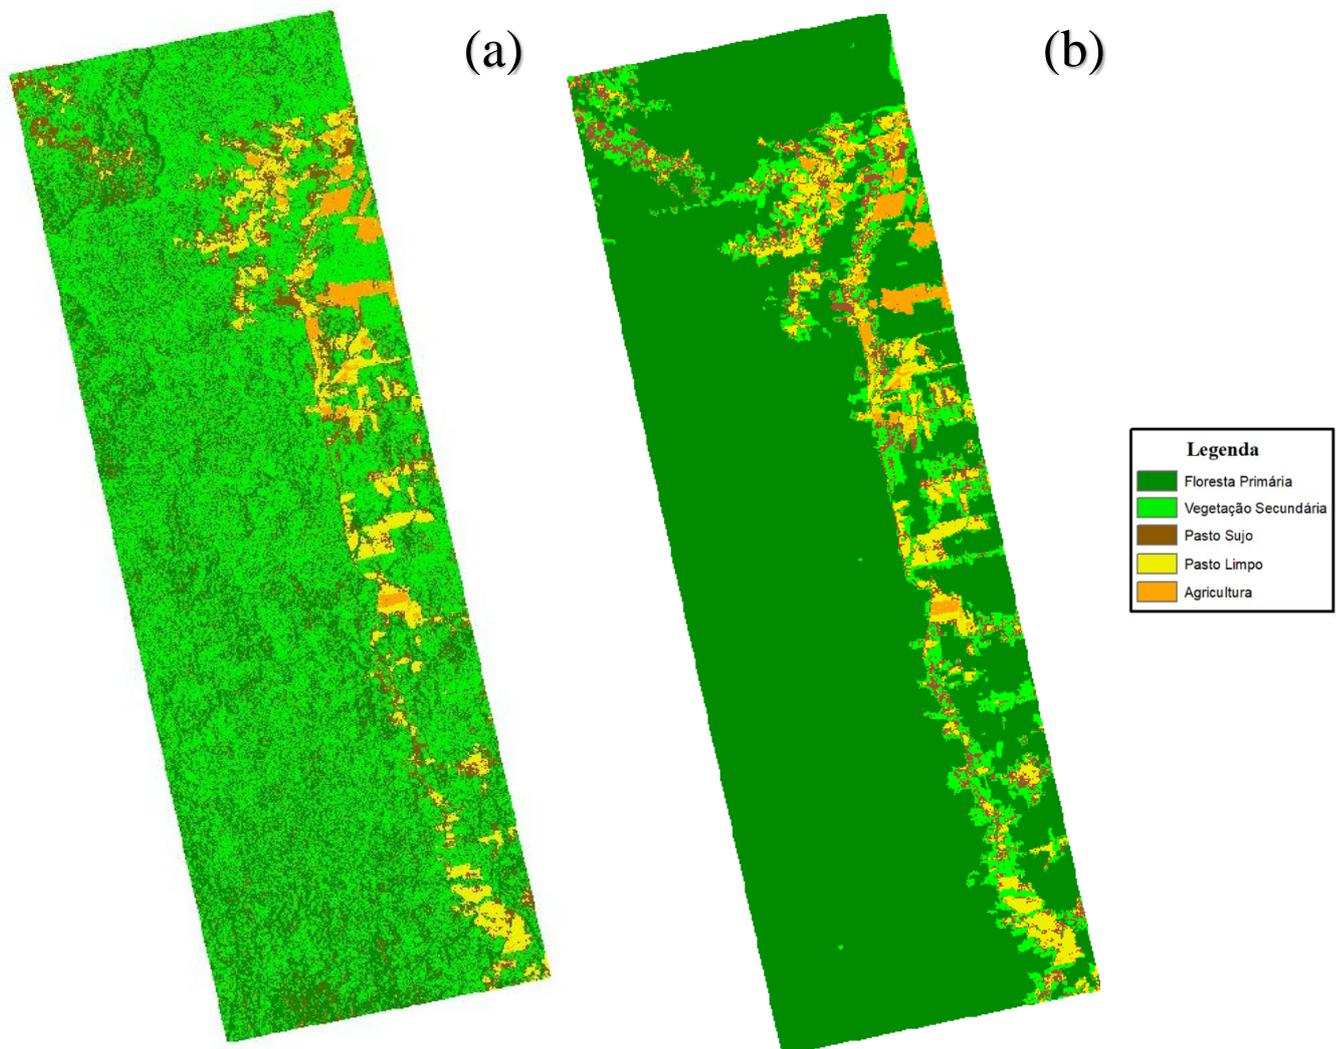
4.1.1 Comparação entre os resultados da classificação e pós-classificação

A fase de pós-classificação teve como objetivo distinguir as classes florestas e vegetação secundária por meio da máscara de floresta primária do PRODES do ano de 2014. Devido a essas duas classes possuírem características e estruturas de vegetação semelhantes, a metodologia adotada não foi eficaz em diferenciá-las. Portanto, foi necessário a utilização do dado auxiliar do PRODES para distinguir as classes de FP e VS, e assim melhorar os resultados de classificação.

Como pode ser observado na Tabela 4.1, os três primeiros lugares do ranking de 2014 permaneceram em suas posições mesmo após a etapa de pós-classificação (ranking 2014M). Pode-se pressupor a partir desse resultado, que essas combinações não dependem das classes de floresta e vegetação secundária para ter um valor *kappa* significativo. Em outras palavras, as classes de pasto sujo, pasto limpo e agricultura nessas combinações tiveram um alto índice de acerto, elevando o valor estimado do *kappa*. Nos três casos, os índices de acerto foram de aproximadamente 59%, 85% e 99% respectivamente das classes de PS, PL e AG. Esses valores podem ser observados na matriz de confusão de cada resultado de classificação nas Figuras 4.2 e 4.3.

Na Figura 4.1, pode-se observar a diferença visual anteriormente e posteriormente à etapa de pós-classificação. Essa figura é referente ao melhor resultado classificação de 2014 $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$. A alta confusão entre as classes VS e FP é visualmente perceptível nesta classificação. A classe FP é em grande parte erroneamente classificada como VS.

Figura 4.1 - Resultado da classificação do ano de 2014 para o conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$: (a) antes e (b) depois da etapa de pós-classificação.

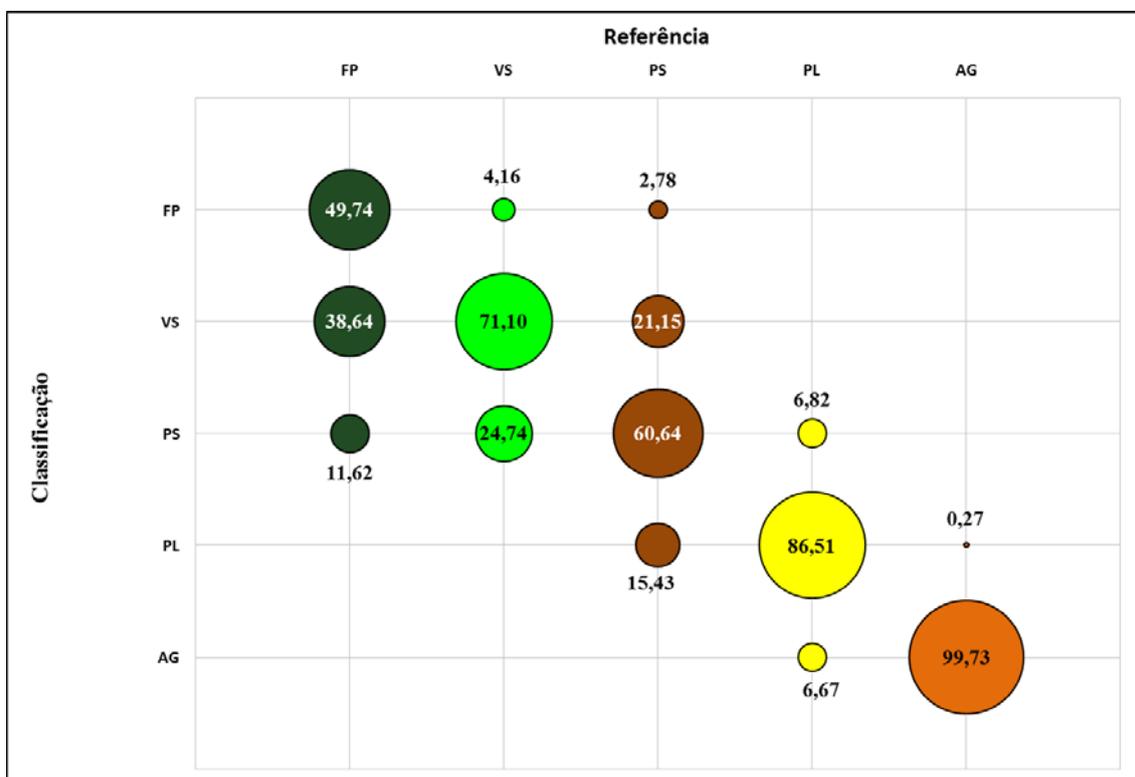


Fonte: Produção da Autora.

O resultado prévio referente ao valor estimado de *kappa* foi de 0,66. Depois da etapa de pós-classificação, a mesma obteve uma melhora de 20% no *kappa* com valor estimado de 0,82. Pode ser observado nas Figuras 4.2 e Figura 4.3 a diferença da tabela de confusão de antes e depois. A confusão da classe de FP com as classes de VS e PS não persiste após a pós classificação. De acordo com a matriz de confusão da classificação do conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$, observada na Tabela 4.2, o índice de acerto da

classe de VS aumentou em aproximadamente 10% na pós-classificação, confundindo cerca de 25% com a classe de PS.

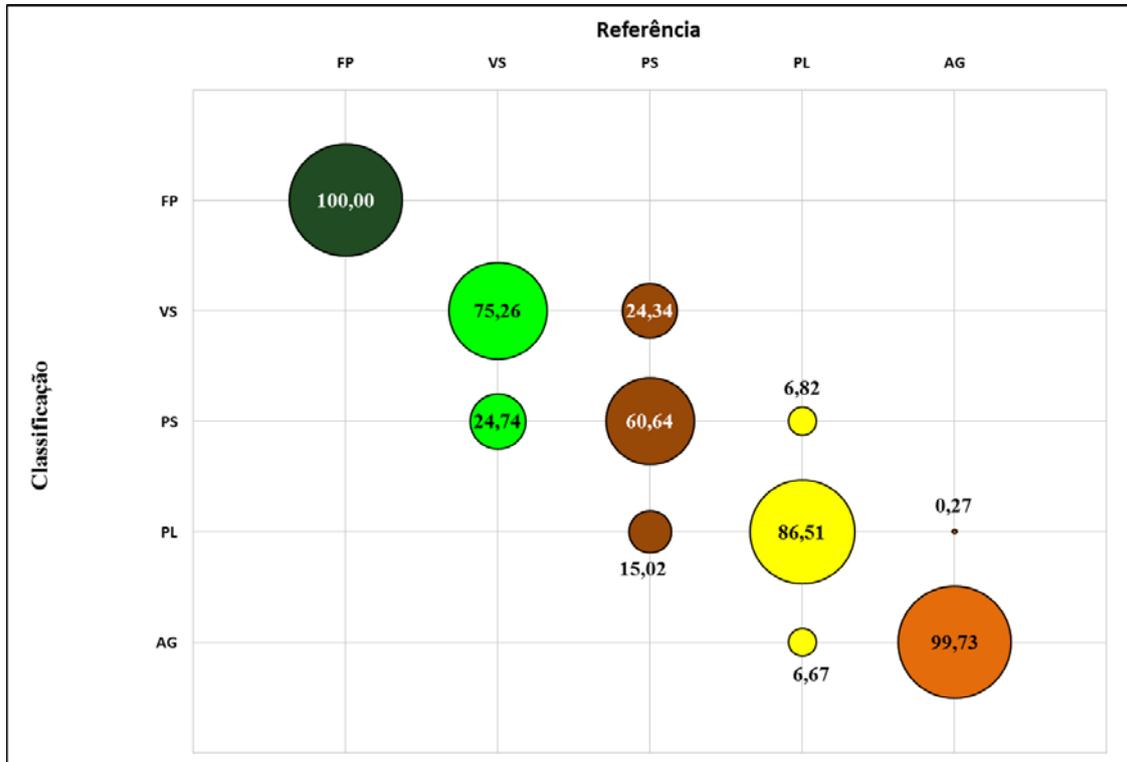
Figura 4.2 - Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ para o ano de 2014, representada graficamente.



onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo; AG=Agricultura

Fonte: Produção da Autora.

Figura 4.3 - Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ para o ano de 2014M, representada graficamente.



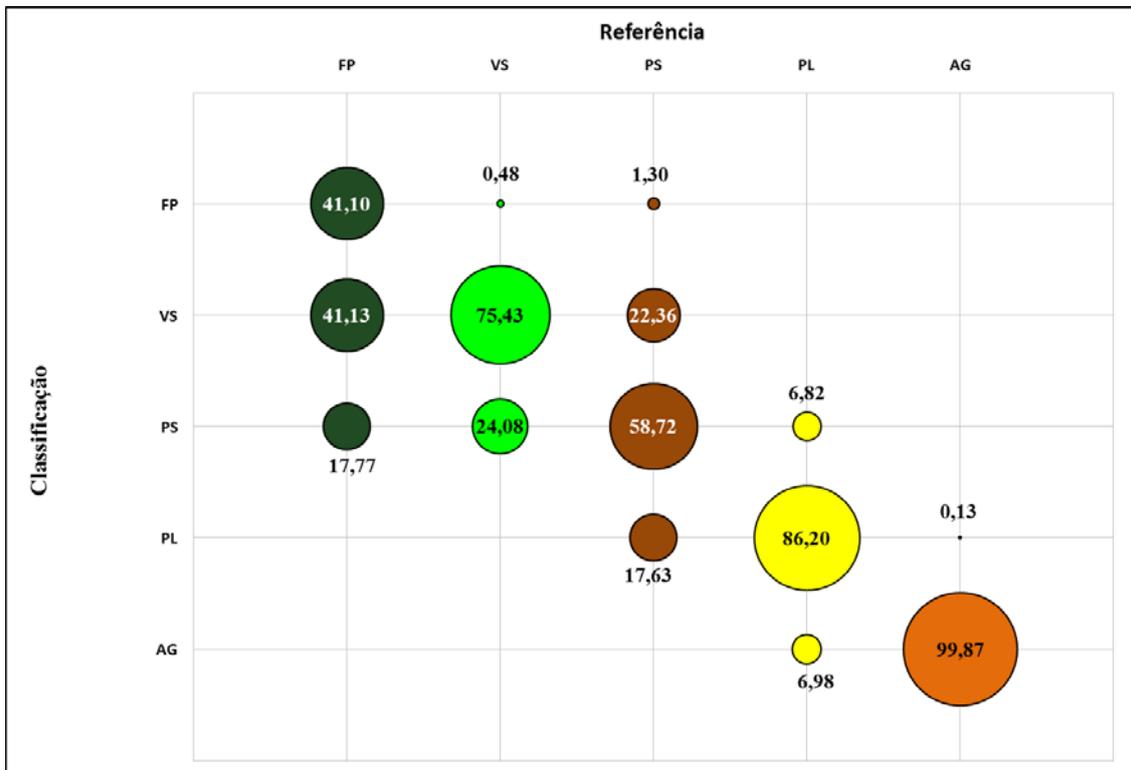
onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo;

AG=Agricultura

Fonte: Produção da Autora.

Para o conjunto $\{L_{VH}, L_{VV}, C_{VH}\}$, o índice *kappa* melhorou em 22% em relação ao resultado da pós-classificação, passando do valor de 0,64 para 0,82. Ao contrário do conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$, não houve uma melhora significativa quanto a discriminação da classe de VS, visto que a maior confusão está entre a classe PS, como se pode observar nas Figuras 4.4 a 4.5.

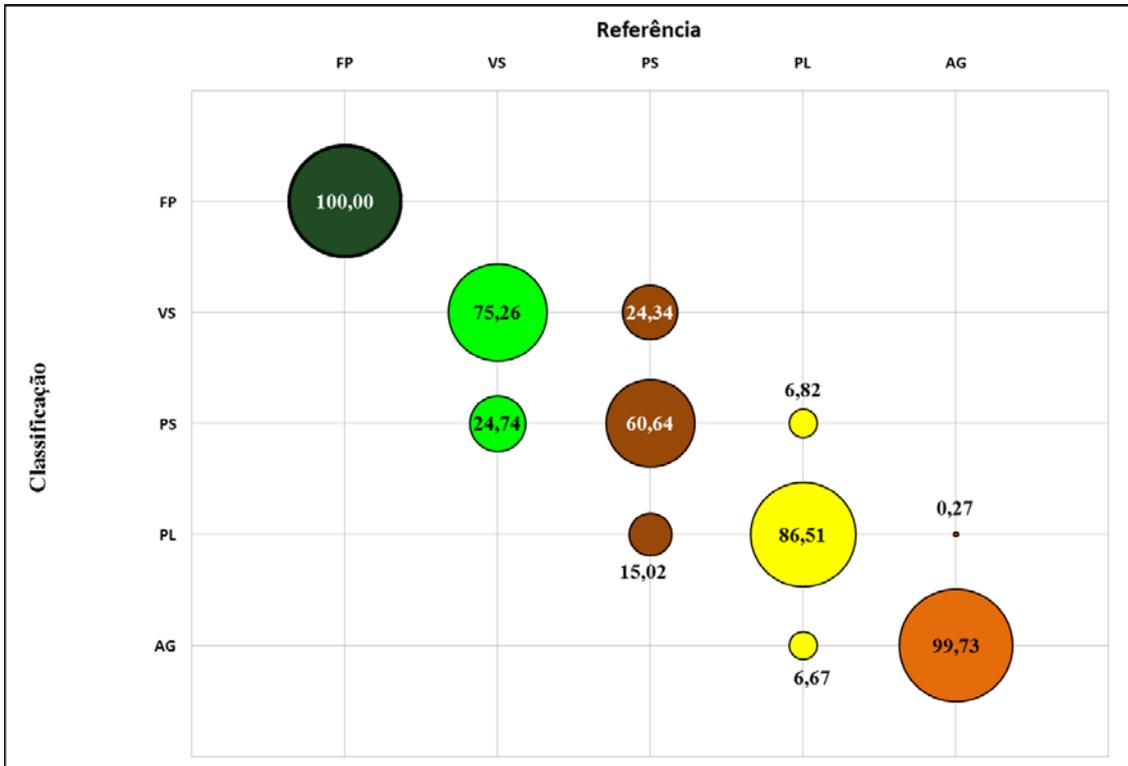
Figura 4.4 - Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VH}\}$ para o ano de 2014, representada graficamente.



onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo;
AG=Agricultura

Fonte: Produção da Autora.

Figura 4.5 - Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VH}\}$ para o ano de 2014M, representada graficamente.



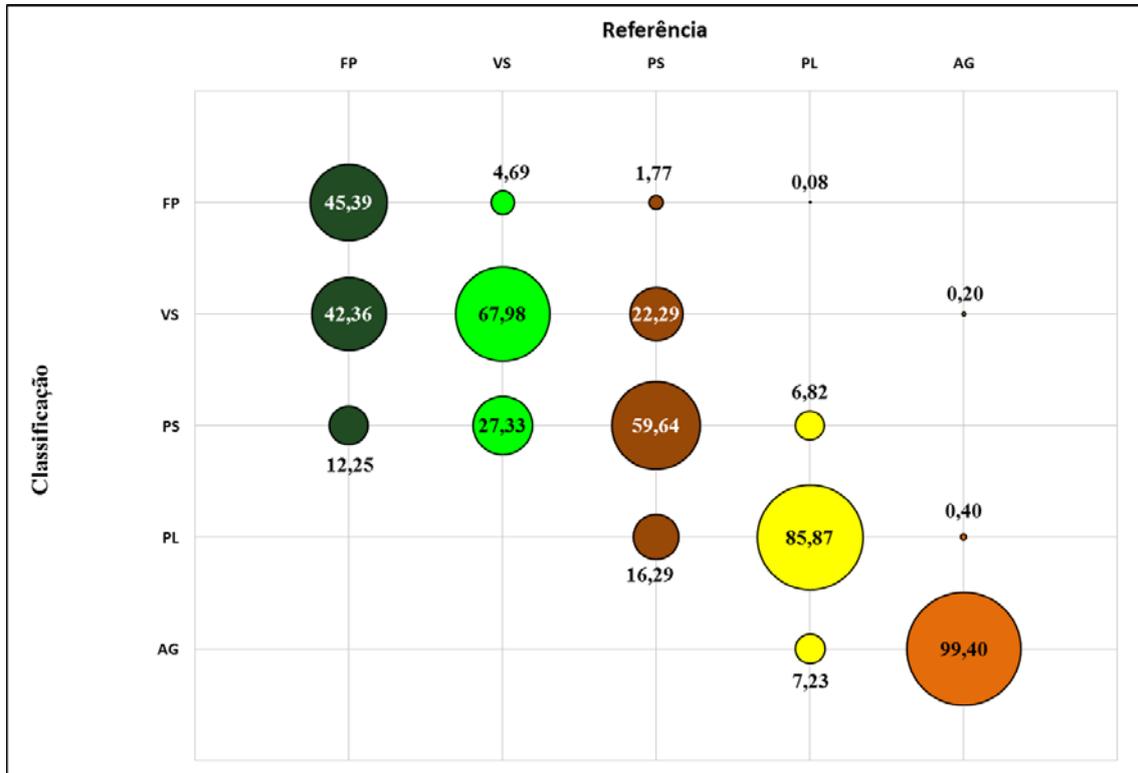
onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo;

AG=Agricultura

Fonte: Produção da Autora.

O conjunto $\{L_{HH}, L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ que foi ordenado em terceiro lugar no *ranking* das classificações, gerou uma classificação que obteve uma melhora de 22% no *kappa* com valores de 0,63 para 0,81. Melhora esta similar à obtida com a classificação do conjunto $\{L_{VH}, L_{VV}, C_{VH}\}$ (segundo lugar no ranking das classificações). Observa-se nas Figuras 4.6 e 4.7, a matriz de confusão da terceira posição do ranking que a classe VS melhorou em 6% em relação à classificação anterior. Em relação a classe de FP, em todas as classificações o índice de acerto foi para 100%, pelo fato de ter sido utilizado a máscara de FP do PRODES.

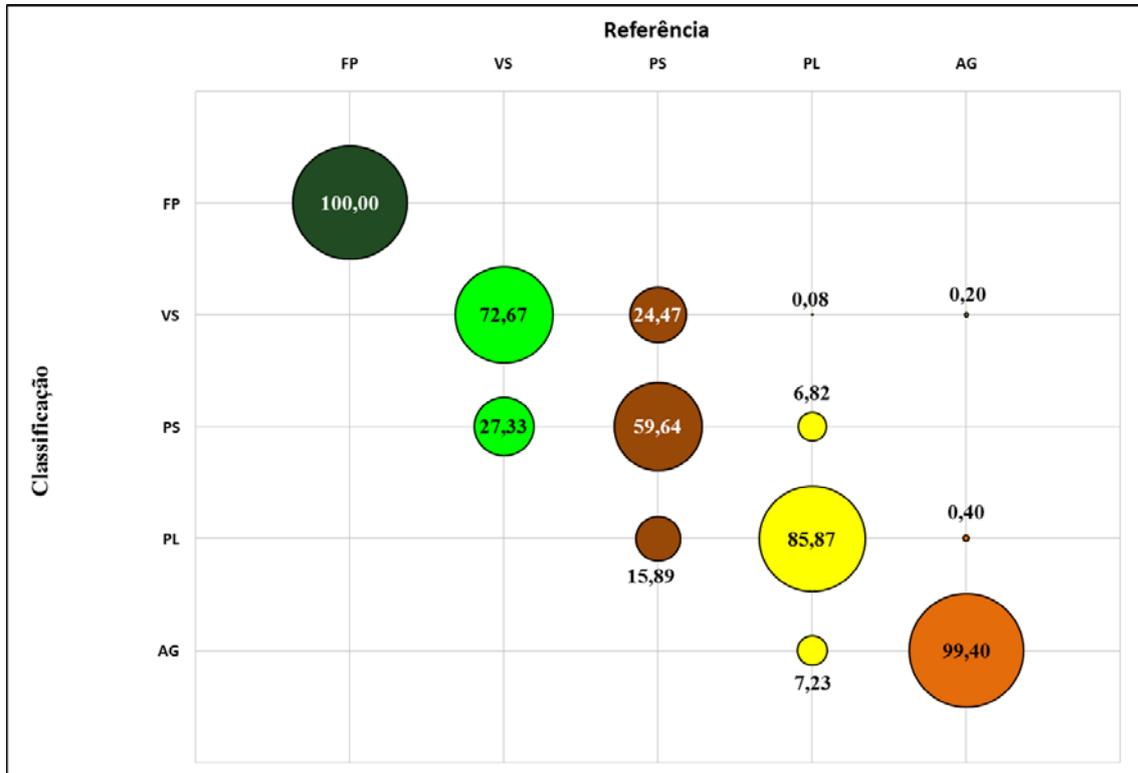
Figura 4.6 - Matriz de confusão do conjunto {L_{HH}, L_{VH}, L_{VV}, C_{VH}, C_{VV}} para o ano de 2014, representada graficamente.



onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo;
AG=Agricultura

Fonte: Produção da Autora.

Figura 4.7 - Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ para o ano de 2014M, representada graficamente.



onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo; AG=Agricultura

Fonte: Produção da Autora.

A partir do 4º conjunto de canais, nota-se que as classes de FP e VS influenciam na posição das outras combinações, alterando o resultado do *ranking* após a etapa de pós-classificação.

4.1.2 Comparação entre os resultados de diferentes modelagens de dados

Com objetivo de avaliar o classificador MAXVER-ICM em mapear a cobertura da terra com dados SAR polarizados multifrequência, os rankings dos anos de 2014M e 2016 foram explorados primeiramente em relação aos tipos de modelagens estatísticas utilizadas nos dados separadamente. Vale ressaltar que as amostras selecionadas no ano de 2016 foram baseadas em dados auxiliares de épocas distintas das imagens SAR adquiridas. Bem como, as imagens de 2016 das bandas L e C não estavam na mesma época do ano, ao contrário do ano de 2014, que tanto as imagens como os dados

auxiliares estavam em datas próximas. Isto é, as classificações de 2014 obtiveram valores dos índices *kappa* maiores do que das classificações de 2016, provavelmente devido a esse fato. Por esse motivo, os *rankings* foram explorados separadamente.

A partir do ranking de classificações de 2014M, observa-se que as doze primeiras posições são ocupadas por resultados de classificações derivados da modelagem multivariada dos dados como apresentado da Tabela 4.1. No entanto, no ranking de 2016, apenas as três primeiras posições são ocupadas com classificações proveniente da modelagem multivariadas. Desta forma, pode-se concluir que os dados SAR polarizados modelados a partir da distribuição Gaussiana multivariada sobressai às de modelagem uni e bivariada. Em outras palavras, o ganho de qualidade das classificações obtidas com dados polarizados sob modelagens multivariadas é superior às demais.

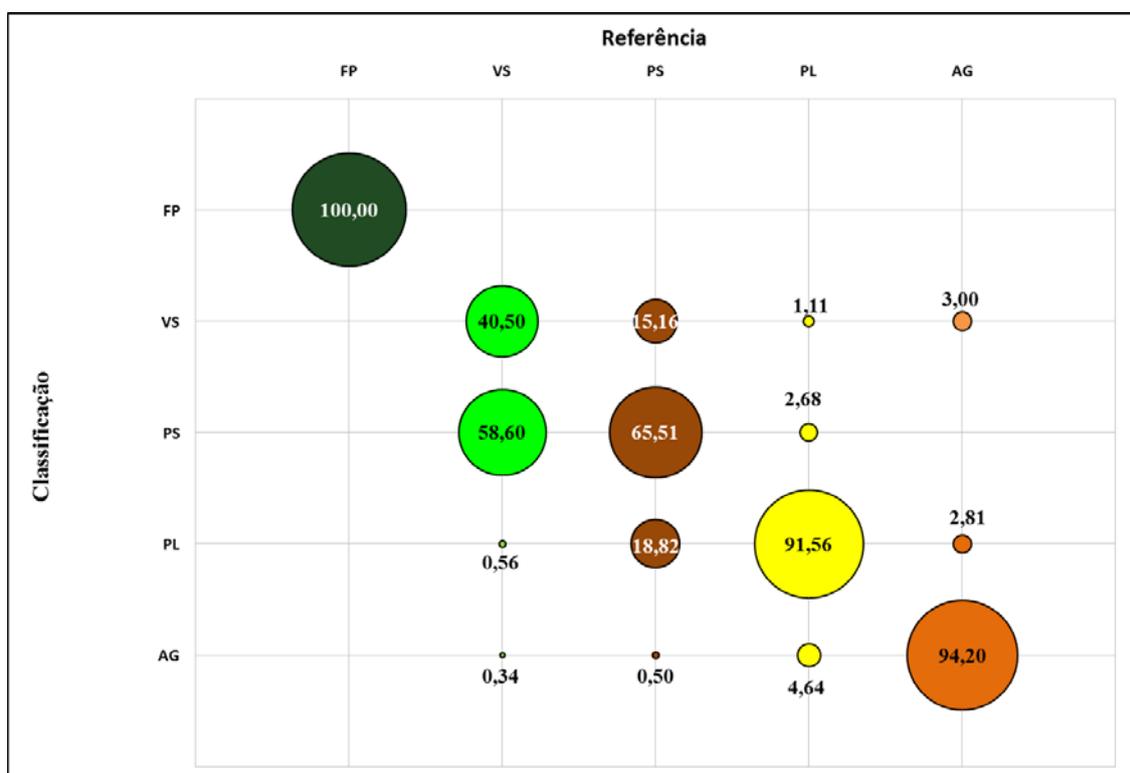
Os resultados de classificações obtidas através de modelagens bivariadas só foram encontrados na 13ª posição do ranking de 2014M. Entretanto, no ranking de 2016 as classificações oriundas das modelagens bivariadas encontram-se a partir da 4ª posição. Dessa maneira, nota-se que o desempenho dos dados SAR modelados a partir da distribuição par de intensidade são inferiores em relação à distribuição Gaussiana multivariada.

De acordo com a matriz de confusão da Figura 4.8, que representa o conjunto de dados $\{L_{VV}, C_{VH}\}$ de 2014, os resultados permitiram discriminar consideravelmente as classes de PL e AG e a classe PS de modo razoável, mas não adequadamente a classe VS de PS. Como mostrado na Figura 4.9, o conjunto bivariado $\{L_{VH}, C_{VV}\}$ não conseguiu separar as classes de cobertura, havendo confusão. Essa confusão se deve ao fato das classificações de 2016 não obtiveram resultados tão bons quanto as de 2014. Os valores estimados do *kappa* e AC para os conjuntos bivariados foram de 0,74 e 0,79 e 0,42 e 0,54 dos anos de 2014M e 2016, respectivamente. Levando em consideração a combinação do conjunto $\{L_{VV}, C_{VH}\}$, dependendo do tipo de aplicação desejada, como por exemplo a discriminação da cobertura agropecuária, a utilização de dados bivariados pode produzir bons resultados.

As classificações sob modelagens univariadas são as que apresentam os resultados menos eficientes em relação às demais modelagens. No ranking de 2014M dados que usam esta modelagem só aparecem a partir da 18ª colocação. Porém, no ranking de

2016 os resultados de modelagens univariadas se encontram a partir da 8ª posição. Analisando as matrizes de confusão referentes Figuras 4.10 e 4.11, somente a classe de AG obteve bons resultados em comparação as demais classes. Para o conjunto $\{L_{VH}\}$, que foi o melhor resultado para dados univariados em ambos os anos, obteve-se valores kappa e AC de 0,71 e 0,77 e de 0,38 e 0,49 respectivamente dos anos de 2014 e 2016.

Figura 4.8 - Matriz de confusão do conjunto $\{L_{VV}, C_{VH}\}$ para o ano de 2014M, representada graficamente.

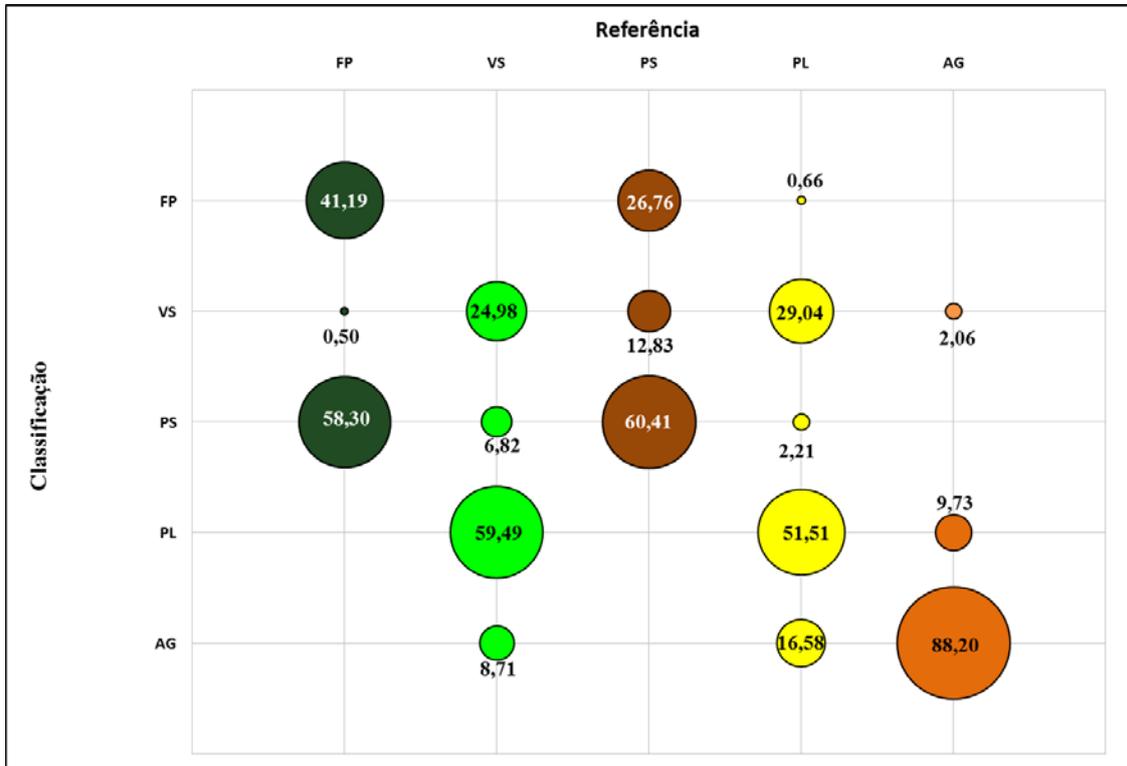


onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo;

AG=Agricultura

Fonte: Produção da Autora.

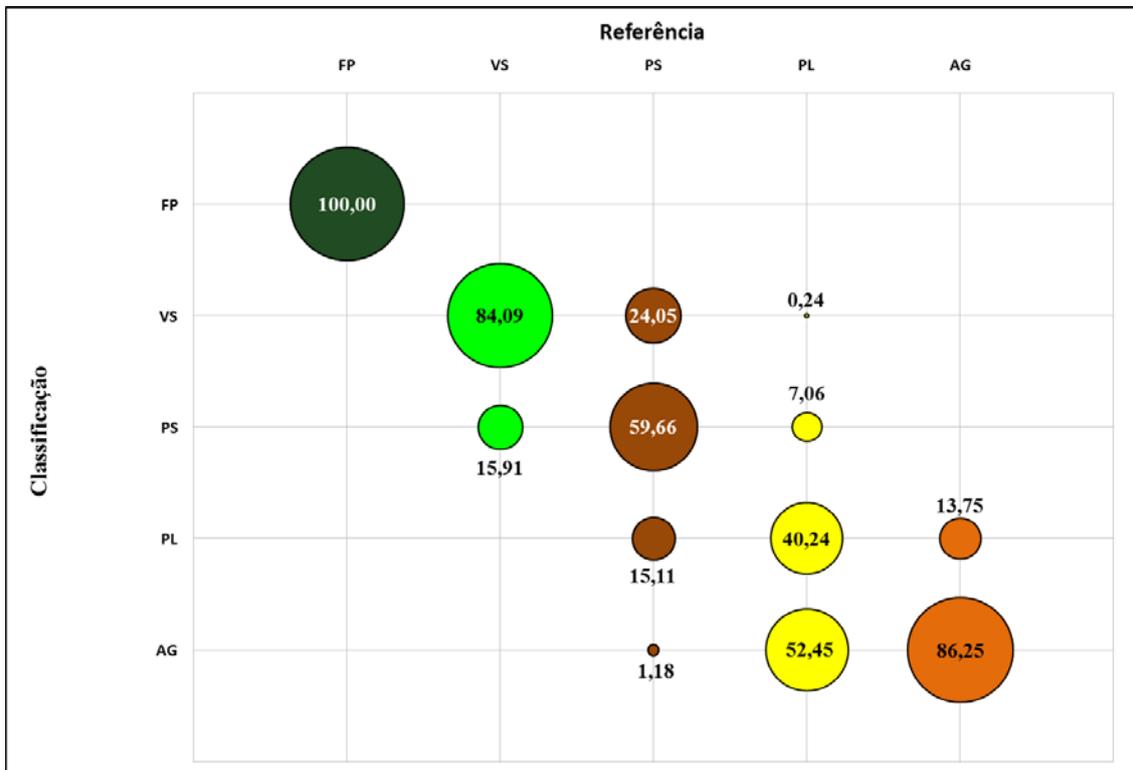
Figura 4.9 - Matriz de confusão do conjunto $\{L_{VH}, C_{VV}\}$ para o ano de 2016, representada graficamente.



onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo;
AG=Agricultura

Fonte: Produção da Autora.

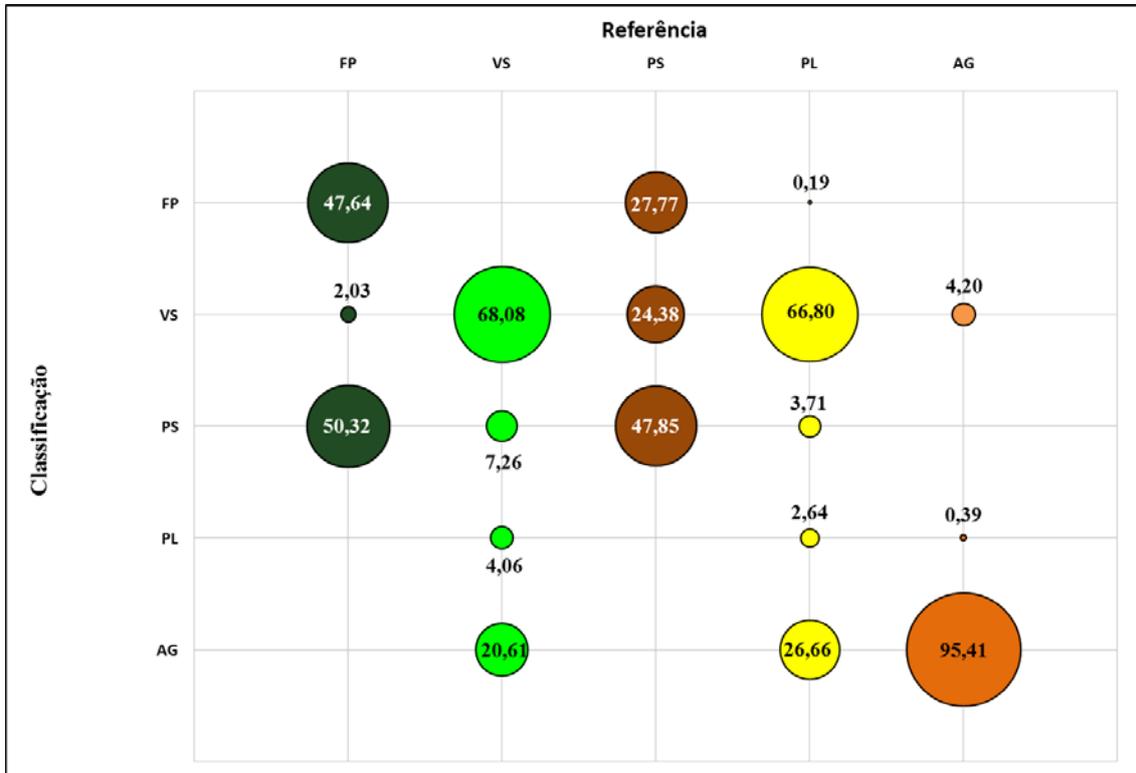
Figura 4.10 - Matriz de confusão do conjunto $\{L_{VH}\}$ para o ano de 2014M, representada graficamente.



onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo;
AG=Agricultura

Fonte: Produção da Autora.

Figura 4.11 - Matriz de confusão do conjunto $\{L_{VH}\}$ para o ano de 2016, representada graficamente.



onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo; AG=Agricultura

Fonte: Produção da Autora.

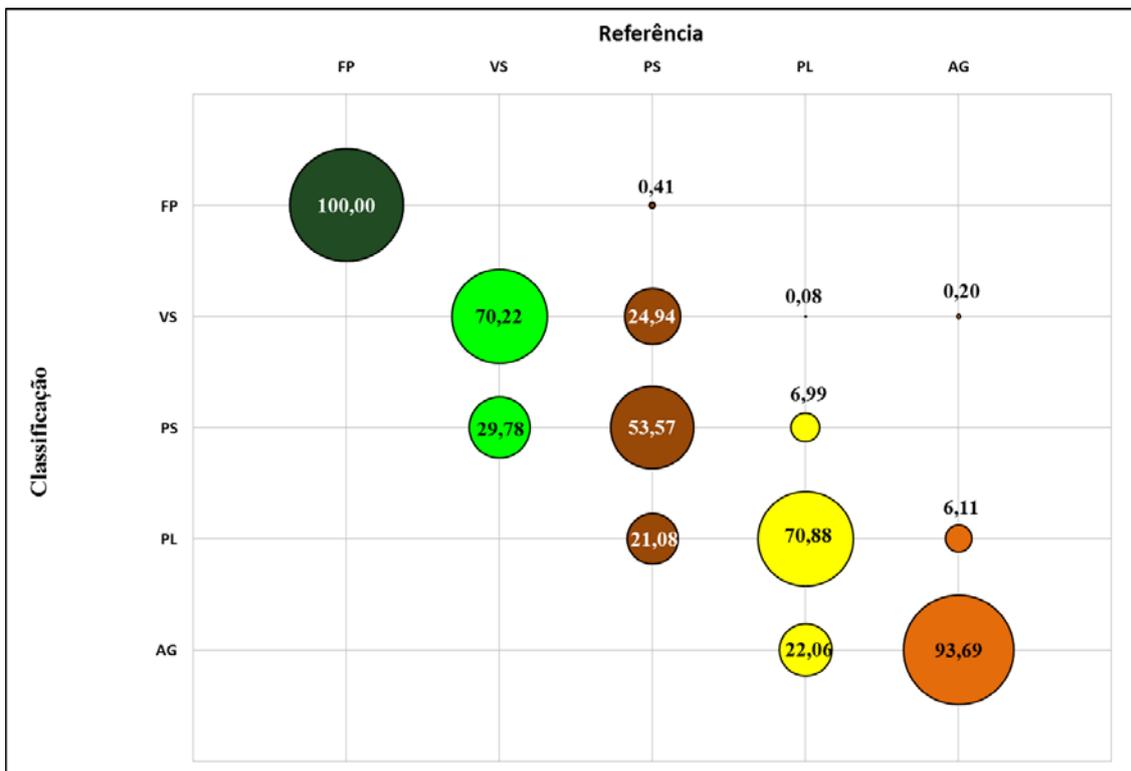
4.1.3 Comparação entre os resultados de diferentes bandas utilizadas

Após a avaliação do classificador em relação ao tipo de modelagem estatística utilizada para o mapeamento da cobertura de terra na área de estudo, a partir de dados SAR polarizados, o próximo passo é analisar os rankings quanto a banda na obtenção dos dados.

É possível observar no ranking de 2014M que as dez primeiras posições foram dos resultados de classificação utilizando dados obtidos das Bandas L e C em conjunto. O mesmo ocorreu de maneira semelhante com o *ranking* 2016, apresentando as suas sete primeiras classificações com a utilização do conjunto das duas bandas. A partir desse resultado, deduz-se que a utilização das bandas L e C juntas geram melhores resultados quando comparados aos de uma única banda.

Para o *ranking* de 2014M, o melhor resultado de classificação que inclui a combinação de duas bandas é o conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$. Já a melhor classificação com o uso de uma única banda é o conjunto $\{L_{HH}, L_{VH}, L_{VV}\}$. A partir destes dois resultados de classificação, é possível verificar que todas as classes de cobertura apresentam separabilidade superior na combinação das bandas em conjunto. Na Figura 4.12 pode-se observar que as classes de VS e AG apresentaram uma melhora de aproximadamente 6%, porém as classes de PS e PL sobressaíram apresentando um aumento de 11% e 18%, respectivamente, quando se utilizou o conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$.

Figura 4.12 - Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, L_{VV}\}$ para o ano de 2014M, representada graficamente.



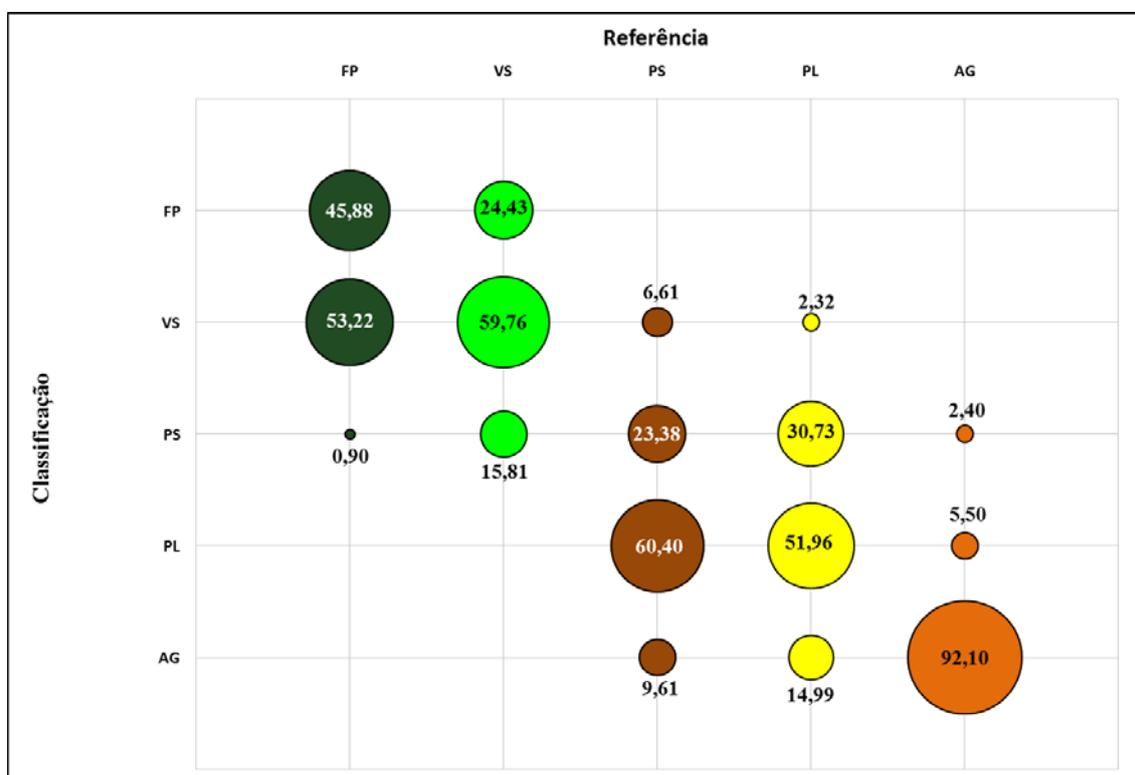
onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo; AG=Agricultura

Fonte: Produção da Autora.

De outro modo, ao analisar a matriz de confusão do *ranking* de classificação de 2016 na Figuras 4.11, a ideia inicial é que a melhor classificação de uma única banda $\{L_{VH}\}$

apresente melhor distinção das classes de uso e cobertura, excluindo a classe de PL que não se conseguiu distinguir adequadamente. Contudo, ao comparar a exatidão do produtor e a exatidão do usuário, verifica-se que a classificação posicionada em primeiro lugar, a classificação do conjunto $\{L_{VH}, C_{VH}, C_{VV}\}$ é mais eficaz na distinção das classes. A matriz de confusão da combinação $\{L_{VH}, C_{VH}, C_{VV}\}$ está ilustrada na Figura 4.13. Conferindo também o índice de concordância *kappa*, a classificação do conjunto $\{L_{VH}, C_{VH}, C_{VV}\}$ é maior que a classificação $\{L_{VH}\}$, obtendo um valor de 0,44 e 0,38, respectivamente.

Figura 4.13 - Matriz de confusão do conjunto $\{L_{VH}, C_{VH}, C_{VV}\}$ para o ano de 2016, representada graficamente.



onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo;
AG=Agricultura

Fonte: Produção da Autora.

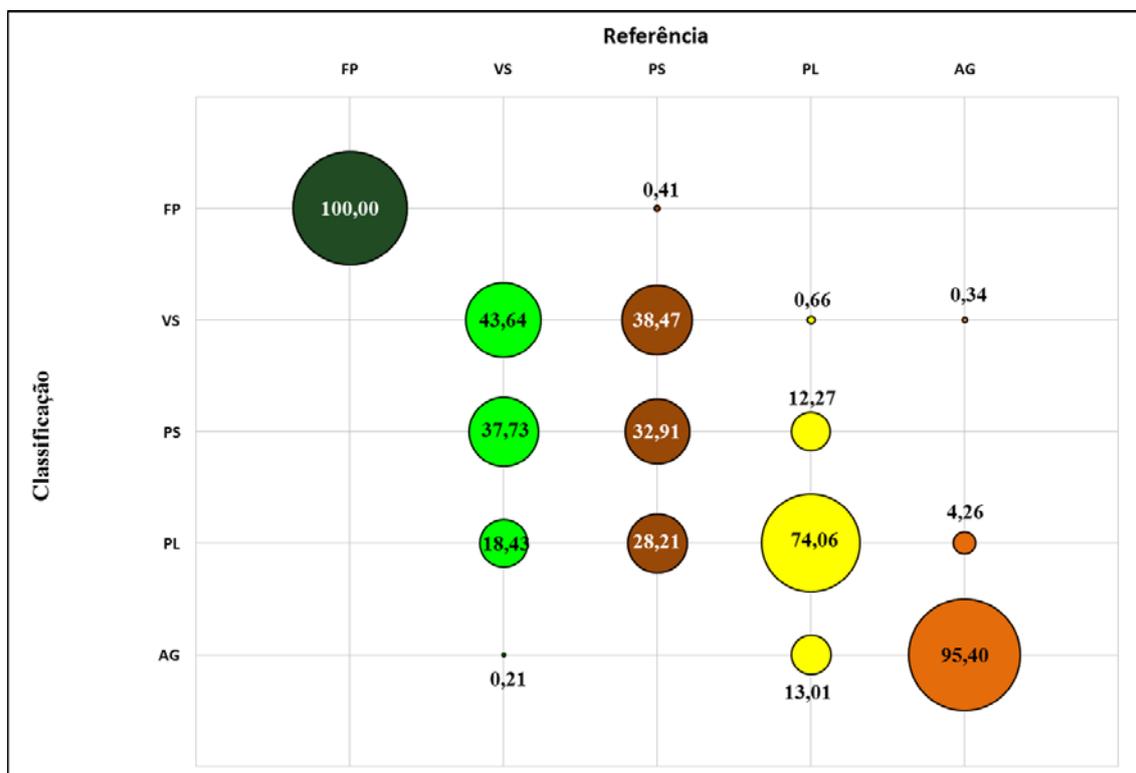
Quando se analisa o ranking em relação a banda utilizada, pode-se observar que a banda L está presente nas 22 primeiras posições do *ranking* de 2014M. Da mesma maneira ocorreu no *ranking* de 2016, onde os dados obtidos na banda L estão entre as 16

primeiras colocadas. Isto posto, conclui-se que a partir de dados obtidos em banda L é possível extrair mais informações a respeito das classes estudadas do que daqueles gerados em banda C.

Nota-se que os conjuntos somente derivados da banda C ($\{C_{VH}, C_{VV}\}$, $\{C_{VH}\}$, $\{C_{VV}\}$) estão presentes entre as últimas posições dos *rankings*.

Ao se comparar os melhores resultados de classificação dos dados de uma única banda (L e C) dos rankings, podemos compreender melhor o que cada frequência pode proporcionar no processo de classificação. Em relação ao *ranking* de 2014M, a matriz de confusão da classificação do conjunto $\{L_{HH}, L_{VH}, L_{VV}\}$, na Figura 4.12, comparada com a classificação do conjunto de $\{C_{VH}, C_{VV}\}$, na Figura 4.14, apresenta resultados superiores na extração de informações das classes de cobertura vegetal com presença ou dominância arbórea (VS e PS).

Figura 4.14 - Matriz de confusão do conjunto $\{C_{VH}, C_{VV}\}$ para o ano de 2014M, representada graficamente.



onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo;

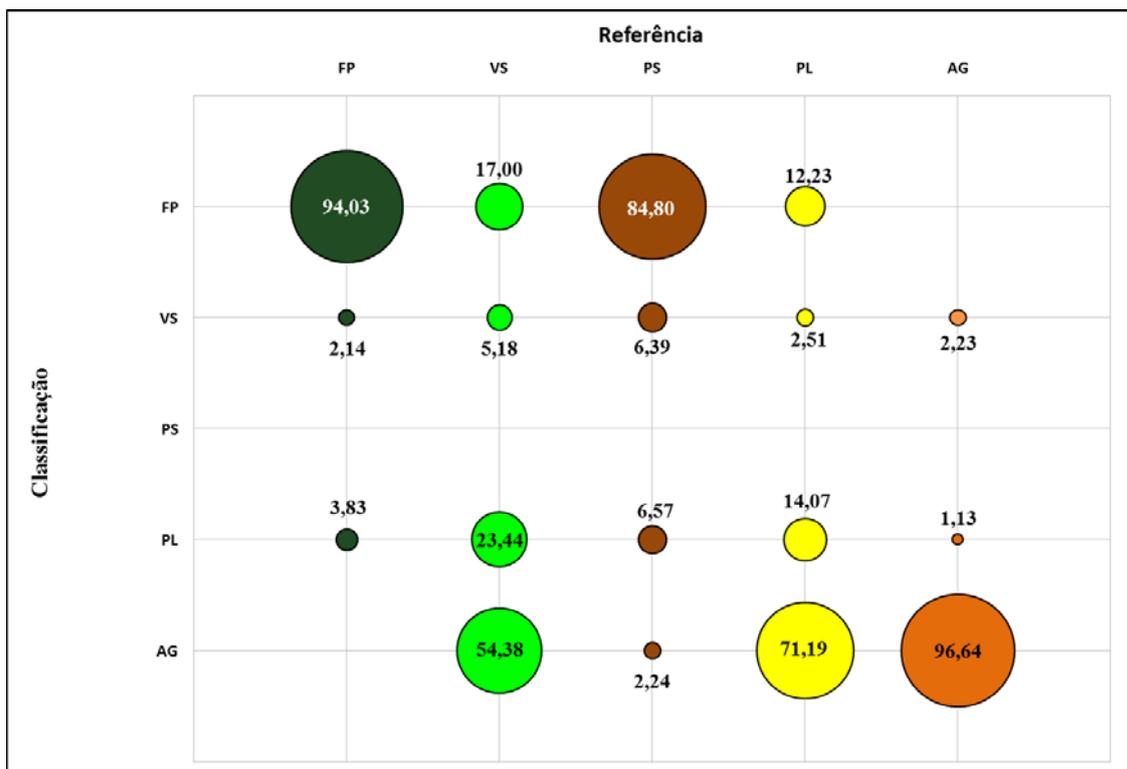
AG=Agricultura

Fonte: Produção da Autora.

Todavia, o conjunto $\{C_{VH}, C_{VV}\}$ obtém melhores resultados em relação às classes de cobertura vegetal rasteira e/ou solo exposto (PL e AG). Este resultado sugere, mais uma vez, que a combinação de dados obtidos em banda C e L melhoram a discriminabilidade das classes de cobertura em estudo.

A partir do *ranking* de 2016, a matriz de confusão da classificação $\{L_{VH}\}$, apresentada na Figura 4.11, associada à classificação $\{C_{VH}\}$, apresentada na Figura 4.15, mostra que na banda C se identifica melhor a classe de vegetação florestal (FP) do que na banda L. É interessante notar que em nenhuma das duas classificações a classe PL foi bem discriminada, porém as duas conseguem distinguir bem a classe AG. No geral, a banda L é mais adequada para caracterizar as classes de cobertura definidas neste estudo.

Figura 4.15 - Matriz de confusão do conjunto $\{C_{VH}\}$ para o ano de 2016, representada graficamente.



onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo; AG=Agricultura

Fonte: Produção da Autora.

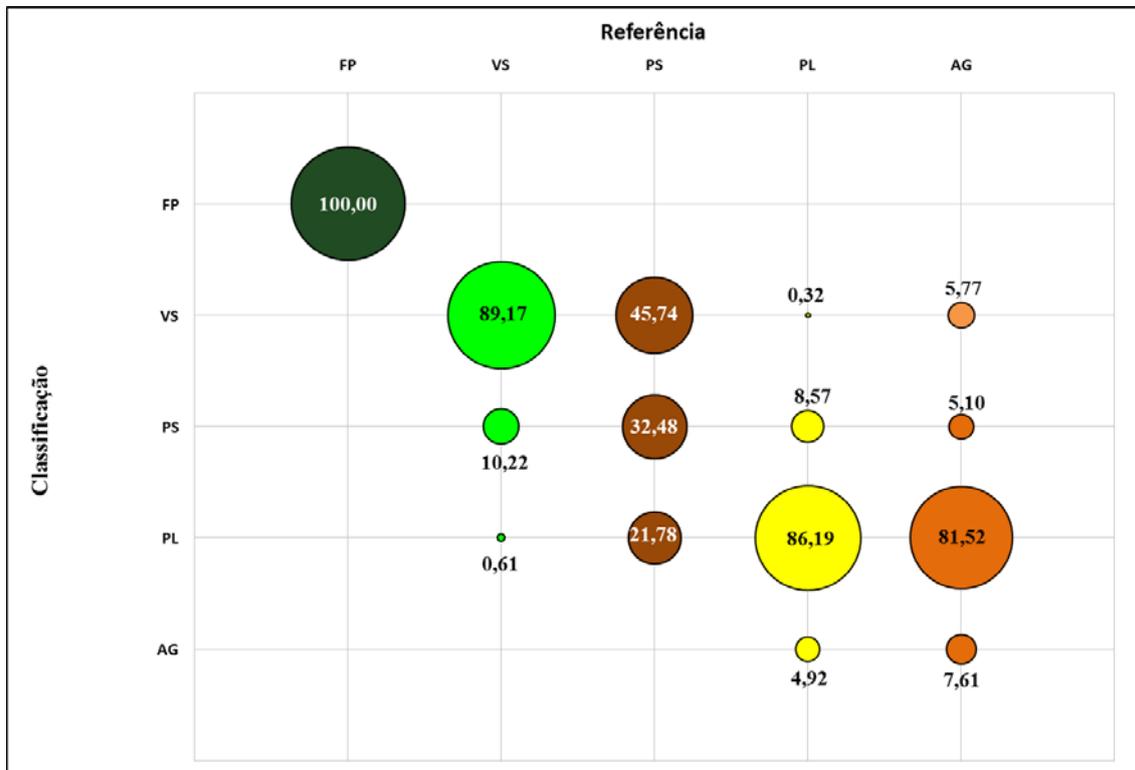
4.1.4 Comparação entre os resultados de diferentes canais utilizados

Após a avaliação das bandas SAR utilizadas para o mapeamento da cobertura da terra, o próximo passo é a análise do ranking quanto à polarização dos dados utilizados, ou seja, os canais HH, VH e VV. Deve-se lembrar que a Banda C é *dual* polarizada (VH e VV) e também que a polarização VH da banda L foi obtida a partir da média dos canais HV e VH.

A fim de avaliar o potencial de cada polarização para o mapeamento da área de estudo, foram observadas as matrizes de confusão das classificações de uma única banda de todos os canais para verificar separadamente a capacidade da caracterização das classes definidas neste estudo. Em seguida, foram observadas as combinações que estão entre as primeiras posições do ranking de cada ano.

Nas matrizes de 2014M, os canais com as polarizações HH e VV da banda L se comportaram de maneira semelhante quanto à discriminação das classes, como foi verificado na etapa de análise exploratória. Os resultados de classificação dos dois canais foram bem próximos um do outro, apenas com uma diferença de 9% a mais na classe PL para a polarização VV, como pode ser visto nas Figuras 4.16 e 4.17. Na comparação das polarizações HH e VV com a polarização VH, nota-se que com as co-polarizadas obteve-se melhores respostas nas classes VS e PL e a polarização cruzada proveu resultados melhores nas classes de PS e AG (Figura 4.10).

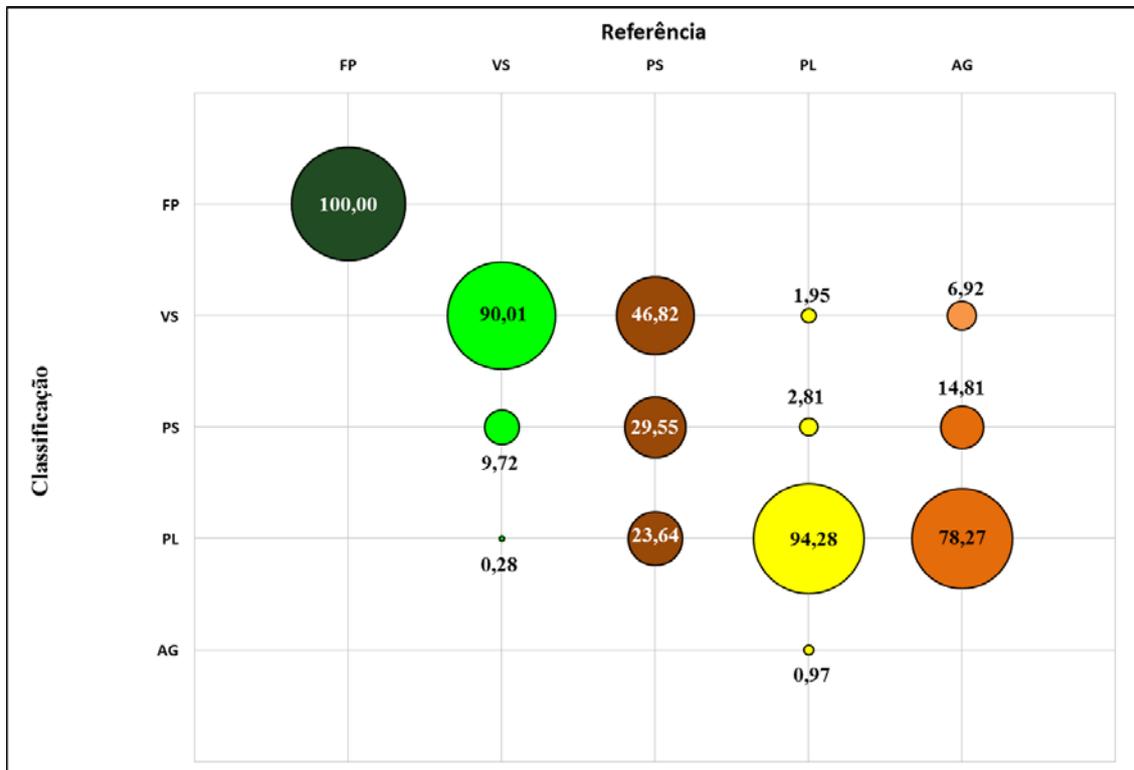
Figura 4.16 - Matriz de confusão do conjunto $\{L_{HH}\}$ para o ano de 2014M, representada graficamente.



onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo; AG=Agricultura

Fonte: Produção da Autora.

Figura 4.17 - Matriz de confusão do conjunto $\{L_{VV}\}$ para o ano de 2014M, representada graficamente.

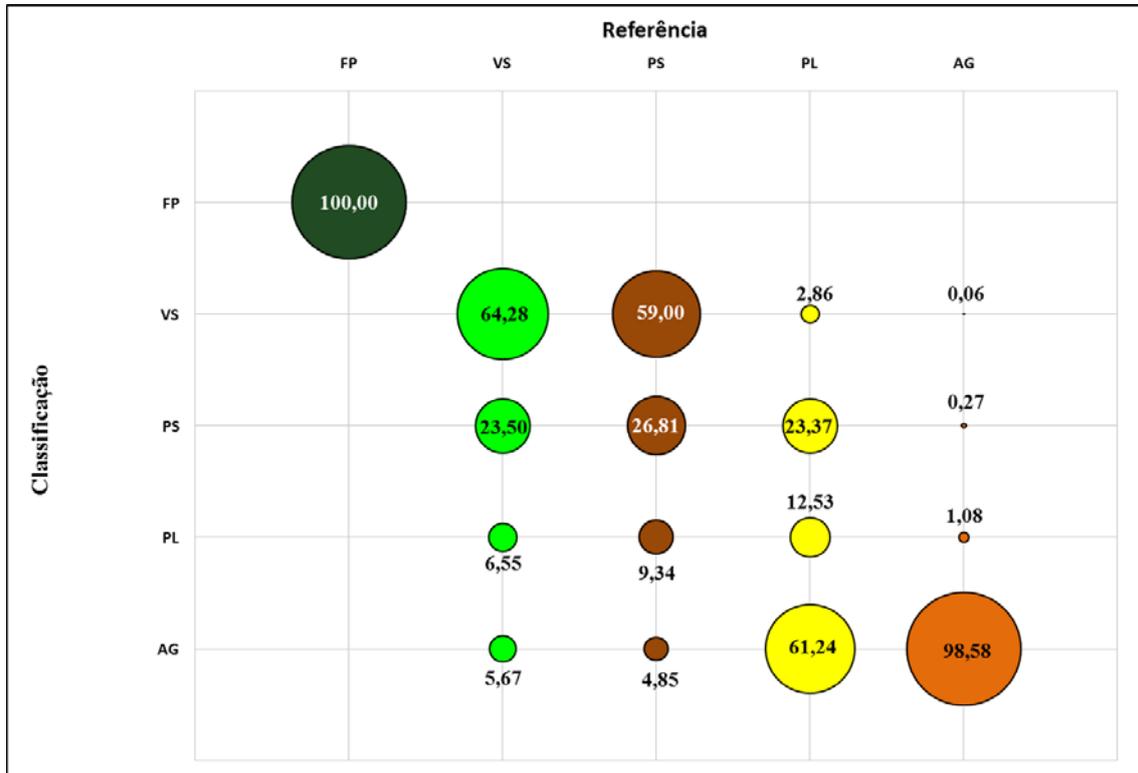


onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo; AG=Agricultura

Fonte: Produção da Autora.

As polarizações VH e VV da Banda C, nas matrizes de 2014M ilustradas nas Figuras 4.15 e 4.18, se comportaram de maneira oposta aos da Banda L, onde o canal *de polarização cruzada* caracterizou melhor as classes de VS e PL e a co-polarizada distinguiu melhor a classe de PS. Em ambas, a classe de AG foi identificada de modo similar.

Figura 4.18 - Matriz de confusão do conjunto $\{C_{VV}\}$ para o ano de 2014M, representada graficamente.

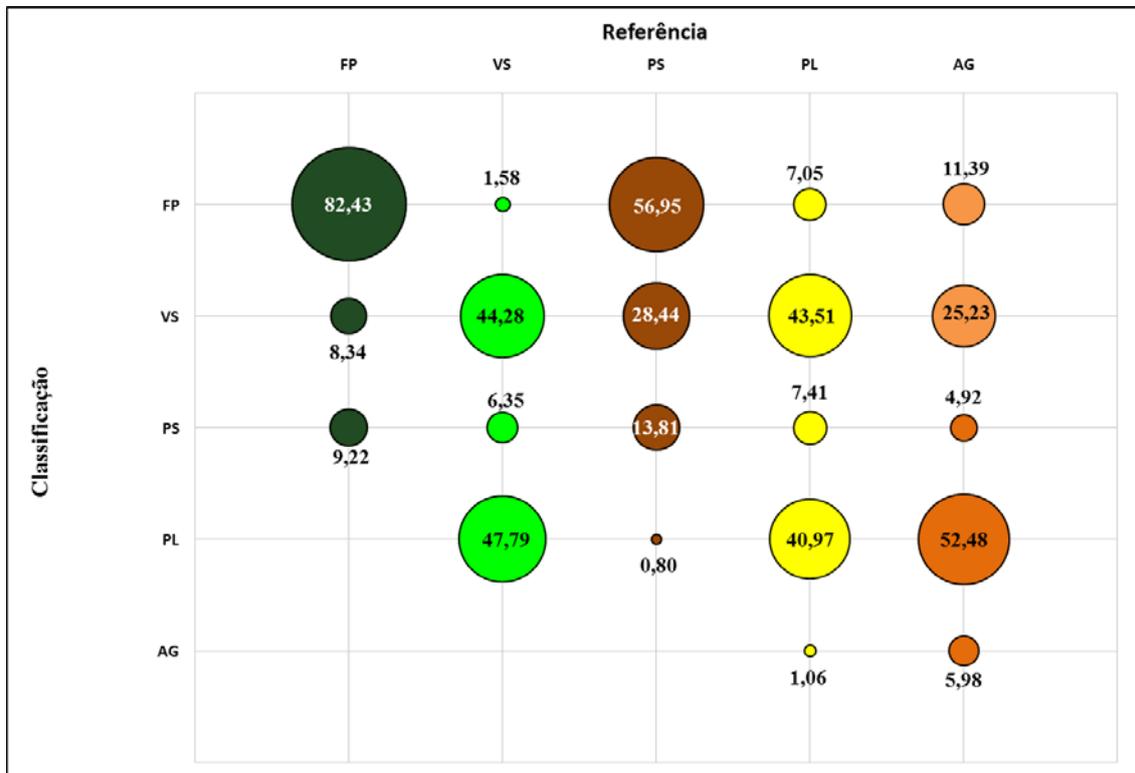


onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo;
AG=Agricultura

Fonte: Produção da Autora.

Em relação às matrizes de confusão de 2016, os canais HH e VV na banda L não se comportaram de maneira similar. A polarização cruzada foi superior às demais, identificando bem as classes de VS, PS e AG. No entanto, como mostrado na Figura 4.19, o canal VV distinguiu melhor a classe PL em relação às outras. As co-polarizações caracterizaram a classe de FP de modo mais satisfatório comparado à polarização cruzada. Ademais, como visto na Figura 4.20, o canal HH não caracterizou as classes de maneira adequada às demais.

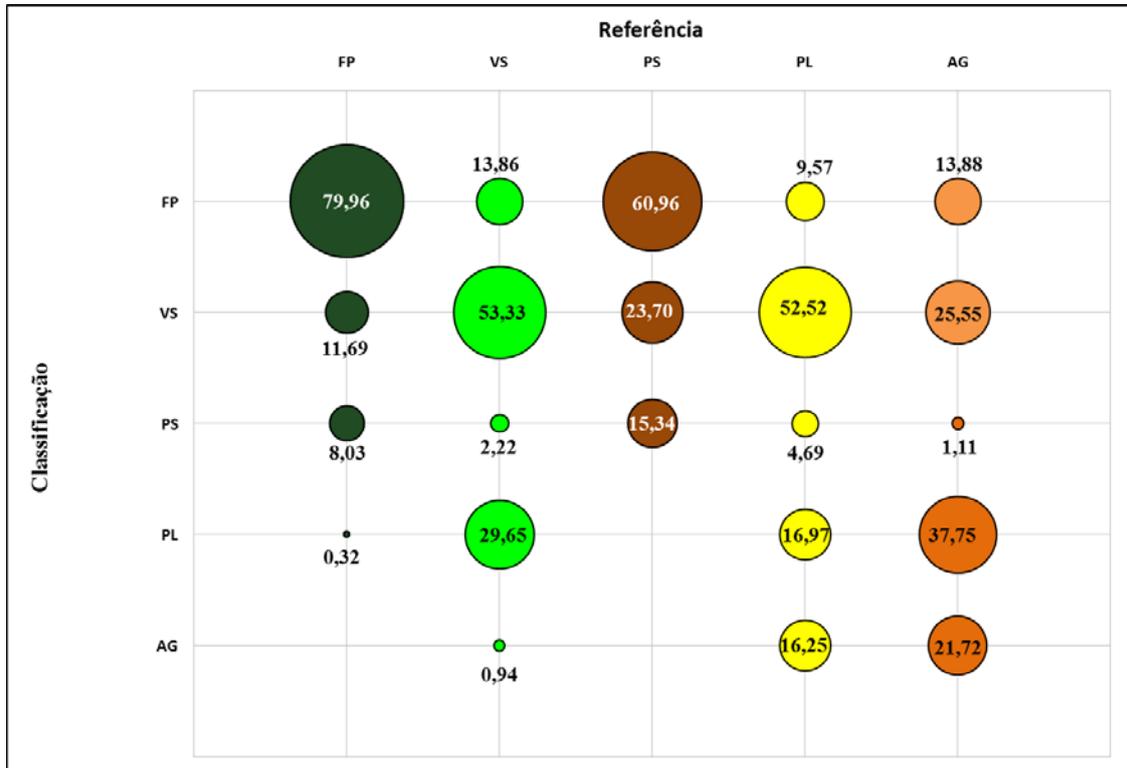
Figura 4.19 - Matriz de confusão do conjunto $\{L_{VV}\}$ para o ano de 2016, representada graficamente.



onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo;
AG=Agricultura

Fonte: Produção da Autora.

Figura 4.20- Matriz de confusão do conjunto $\{L_{HH}\}$ para o ano de 2016, representada graficamente.

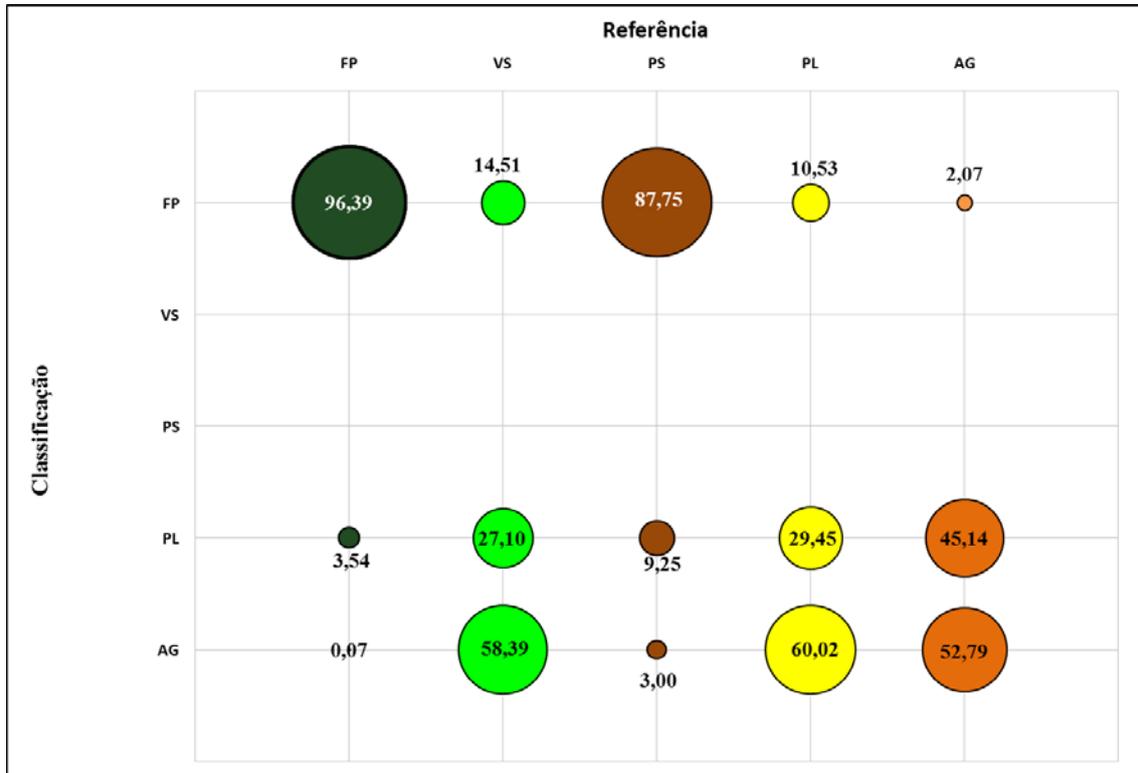


onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo; AG=Agricultura

Fonte: Produção da Autora.

Na banda C de 2016, a caracterização das classes não foi bem-sucedida. As únicas classes que foram identificadas devidamente foram FP e AG. Os dois canais identificaram a classe FP satisfatoriamente, porém só a polarização cruzada obteve bons resultados quanto a classe AG. Em suma, houve muita confusão entre as demais classes.

Figura 4.21- Matriz de confusão do conjunto {C_{VV}} para o ano de 2016, representada graficamente.



onde: FP=Floresta Primária; VS=Vegetação Secundária; PS=Pasto sujo; PL=Pasto Limpo; AG=Agricultura

Fonte: Produção da Autora.

Após a análise quanto aos canais distintos, pôde-se concluir que nenhuma das polarizações é capaz de extrair informações de todas as classes em geral. Em vista disso, os canais se complementam para amplificar a classificação das classes de uso e cobertura. Conforme os *rankings* de classificação, observamos que a combinação dos canais levou a um ganho qualitativo quanto ao mapeamento da área de estudo.

De acordo com os *rankings* de classificação, percebe-se que o canal VH está presente nas primeiras 19 posições de 2014M e nas 20 primeiras posições de 2016. Verificando as combinações univariadas dos dois anos, a polarização cruzada VH sempre apresenta resultados superiores às demais polarizações. Da mesma maneira ocorreu nas combinações bivariadas, onde os melhores resultados sempre constam a polarização cruzada VH no conjunto de dados. Observando a melhor classificação de 2014M e

2016, a combinação dos canais VH e VV foi o mais satisfatório. Todavia, a combinação das polarizações VH e HH também demonstra bons resultados.

4.2 Análise dos resultados de mudança

A partir da análise detalhada em relação aos tipos de modelagens estatísticas (uni/bivariada e multivariada), frequências (Bandas L e C) e canais (HH, VH, VV) utilizados na etapa de classificação, parte-se para a avaliação do potencial em detecção de mudanças das classes da cobertura a partir de dados SAR polarizados multifrequência na área de estudo.

No intuito de avaliar a capacidade de detecção de mudanças dos dados SAR, foram analisados os melhores resultados de classificação das combinações uni/bivariadas e multivariadas e os melhores resultados das combinações de uma única frequência, com base nos *rankings* de 2014M e 2016. Primeiramente, foi realizado o teste Z de Congaton para verificar se a classificação posicionada em primeiro lugar do *ranking* não se diferenciava significativamente, a um nível de confiança de 95% das demais classificações. Os resultados do teste Z são ilustrados na Tabela 4.3.

Tabela 4.3 - Resultado do teste estatístico de Congaton de 2014M e 2016.

TESTE Z						
	CLASSIFICAÇÃO		Z	valor-P	Alfa	CONCLUSÃO
2014 M	{L _{VH} , L _{VV} , C _{VH} , C _{VV} }	{L _{VH} , L _{VV} , C _{VH} }	0,18	0,4287	0,05	ACEITO H0
	{L _{VH} , L _{VV} , C _{VH} , C _{VV} }	{L _{HH} , L _{VH} , L _{VV} , C _{VH} , C _{VV} }	0,74	0,2286	0,05	ACEITO H0
	{L _{VH} , L _{VV} , C _{VH} , C _{VV} }	{L _{HH} , L _{VV} , C _{VH} }	1,59	0,0561	0,05	ACEITO H0
	{L _{VH} , L _{VV} , C _{VH} , C _{VV} }	{L _{HH} , L _{VH} , C _{VH} }	1,84	0,0332	0,05	REJEITO H0
2016	{L _{VH} , C _{VH} , C _{VV} }	{L _{HH} , L _{VH} , C _{VH} }	0,1	0,4601	0,05	ACEITO H0
	{L _{VH} , C _{VH} , C _{VV} }	{L _{HH} , L _{VH} , C _{VH} , C _{VV} }	0,9	0,1851	0,05	ACEITO H0
	{L _{VH} , C _{VH} , C _{VV} }	{L _{VH} , C _{VV} }	0,95	0,1706	0,05	ACEITO H0
	{L _{VH} , C _{VH} , C _{VV} }	{L _{VH} , L _{VV} , C _{VH} , C _{VV} }	1,03	0,1504	0,05	ACEITO H0
	{L _{VH} , C _{VH} , C _{VV} }	{L _{VH} , C _{VH} }	0,97	0,1664	0,05	ACEITO H0
	{L _{VH} , C _{VH} , C _{VV} }	{L _{VH} , L _{VV} , C _{VH} }	1,83	0,0339	0,05	REJEITO H0

Fonte: Produção da Autora.

De acordo com a Tabela 4.3, o resultado de classificação do conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$, ranqueado em primeiro lugar do ano de 2014 não é significativamente diferente dos 4 primeiros resultados de classificação. Em relação à primeira posição do ranking do ano 2016, a classificação de conjunto $\{L_{VH}, C_{VH}, C_{VV}\}$ não é significativamente diferente dos 6 primeiros colocados. Portanto, as classificações do conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ nos anos de 2014 e 2016 serão consideradas no estudo de detecção de mudança. Esta combinação de canais gera, estatisticamente, os melhores resultados de classificação.

Em resumo, serão analisados na detecção de mudanças a conversão ou modificação das classes de acordo com as classificações dos conjuntos de dados apresentados na Tabela 4.4. As classificações são organizadas a partir de modelagem dos dados e das diferentes bandas, gerando 5 cenários distintos de mudanças (matriz de transição). A seguir, na Tabela 4.4 estão descritos os cenários de mudança em relação à modelagem de dados, ao dado de entrada utilizado, ao conjunto e ano referente.

Tabela 4.4 - Descrição dos Cenários de Mudanças.

	Dados	Ano	Conjunto de Canais	Cenário
Modelagem	Multivariado	2014	$\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$	M1
		2016	$\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$	
	Bivariado	2014	$\{L_{VV}, C_{VH}\}$	M2
		2016	$\{L_{VH}, C_{VV}\}$	
	Univariado	2014	$\{L_{VH}\}$	M3
		2016	$\{L_{VH}\}$	
	Somente Banda L	2014	$\{L_{HH}, L_{VH}, L_{VV}\}$	M4
		2016	$\{L_{VH}\}$	
	Somente Banda C	2014	$\{C_{VH}, C_{VV}\}$	M5
		2016	$\{C_{VH}\}$	

Fonte: Produção da Autora.

As mudanças identificadas em cada resultado foram analisadas de acordo com a matriz de transição das classes da cobertura da terra. A fim de validar o desflorestamento detectado, especificamente a transição de FP para as demais classes, uma análise foi

feita comparando os resultados encontrados com os dados PRODES e foi verificada a concordância em área existente entre as classes.

4.2.1. Análise das matrizes de transição

A detecção de mudança foi feita a partir das combinações dos melhores resultados das classificações dos *rankings*, as modelagens estatísticas e as bandas utilizadas. A etapa de análise pós-classificação foi realizada a partir de duas classificações referentes aos anos de 2014 e de 2016. A partir do cruzamento destas duas classificações, gera-se uma imagem temática de ocorrência de mudanças, onde todo o tipo de transição entre classes é identificado. Portanto, é possível construir uma matriz de transição entre as classes de cobertura da terra em análise. Esse procedimento é criticado pois depende da exatidão das classificações, o que torna o método sensível aos equívocos da etapa precedente.

A matriz de transição é criada medindo-se a extensão, em área (ha), de cada um tipo de transição possível de ocorrer, levando-se em consideração o conjunto de classes de interesse. As mudanças foram analisadas a partir dessa matriz de transição, onde a diagonal principal representa as classes que permaneceram inalteradas (não mudança) e os demais elementos da matriz representam as mudanças. Também foi analisado a partir dos gráficos de transições (%) ocorridas em cada classe separadamente.

Devido a fase de pós-classificação de 2014, não foi possível identificar as transições ocorridas da classe FP para VS. Todas as mudanças detectadas com áreas inferiores a 6,25 hectares foram destinadas às classes de origem, e foram consideradas mudanças improváveis. As alterações ocorridas entre qualquer classe para a classe FP, foram consideradas impossíveis, atribuindo-as à classe de VS por ser um evento mais provável.

É possível observar na Tabela 4.5 a matriz de transição M1 realizada a partir das melhores classificações dos anos de 2014 e de 2016, usando o conjunto de dados $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$. As classificações podem ser vistas na Figura 4.22.

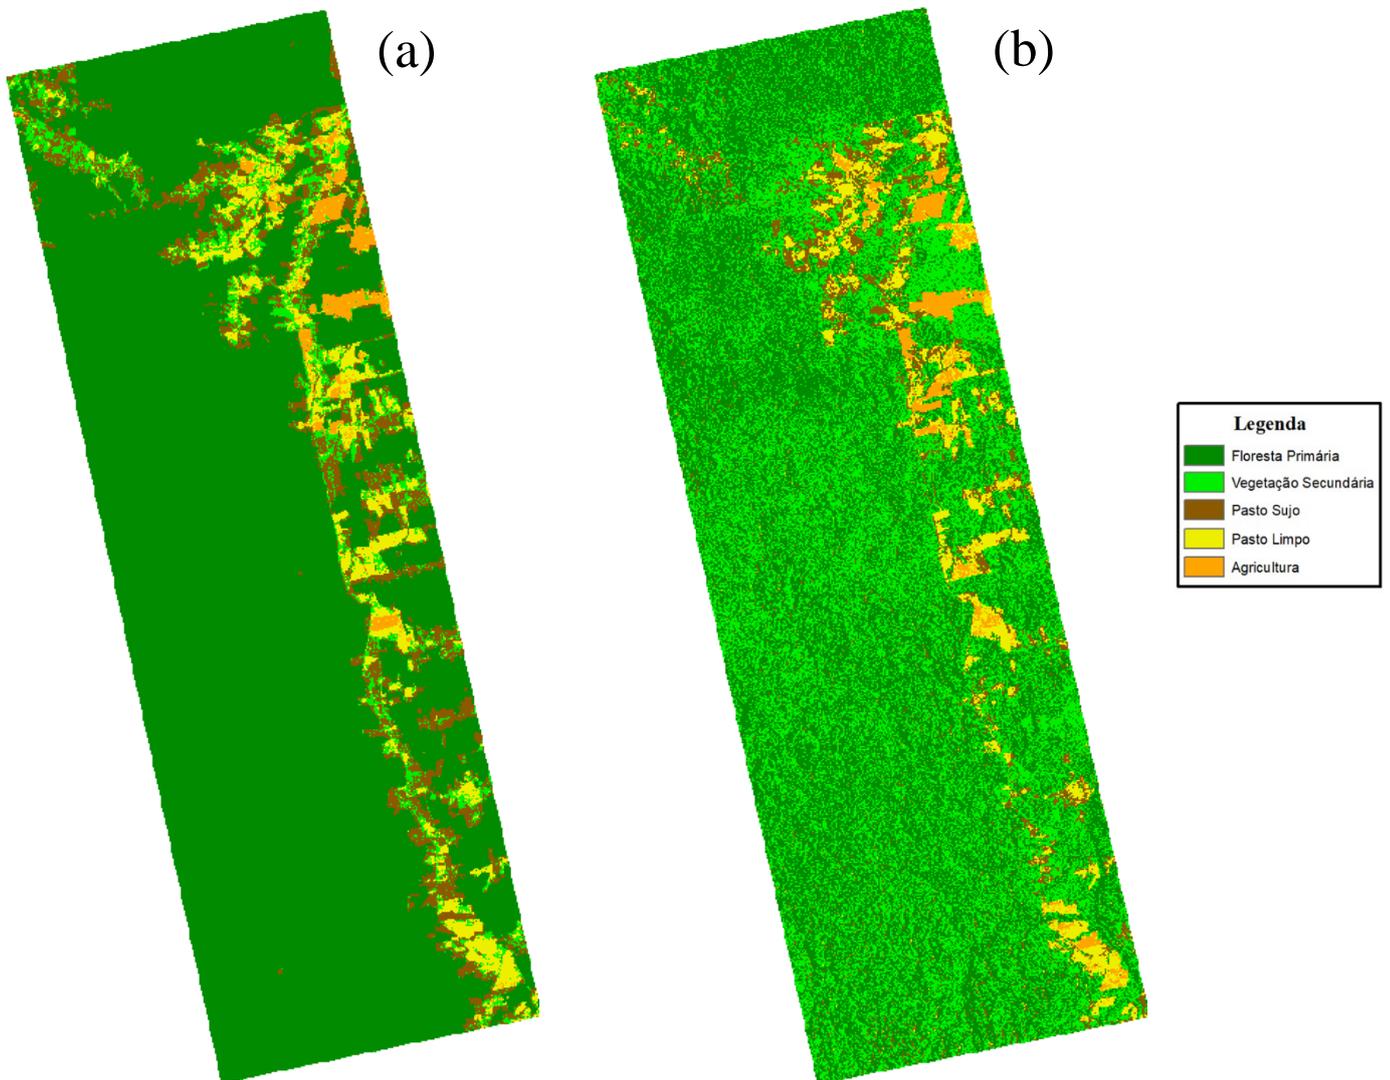
Tabela 4.5 - Matriz de transição do cenário M1.

		2014					
	Classes	FP	VS	PS	PL	AG	TOTAL
2016	FP	112883,1	-	-	-	-	112883,1
	VS	-	12108,9	399,8	7,0	12,5	12528,1
	PS	298,8	92,9	6623,1	505,6	6,6	7527,1
	PL	26,8	83,0	179,8	5987,3	315,8	6592,7
	AG	21,6	0,0	41,9	503,1	1911,9	2478,6
	TOTAL	113230,4	12284,8	7244,6	7003,0	2246,9	142009,6

onde: FP= Floresta Primária; VS= Vegetação Secundária; PS= Pasto sujo; PL= Pasto Limpo; AG= Agricultura.

Fonte: Produção da Autora.

Figura 4.22 - Melhores resultados de classificação com dados multivariados referentes aos anos de: (a) 2014 e (b) 2016.



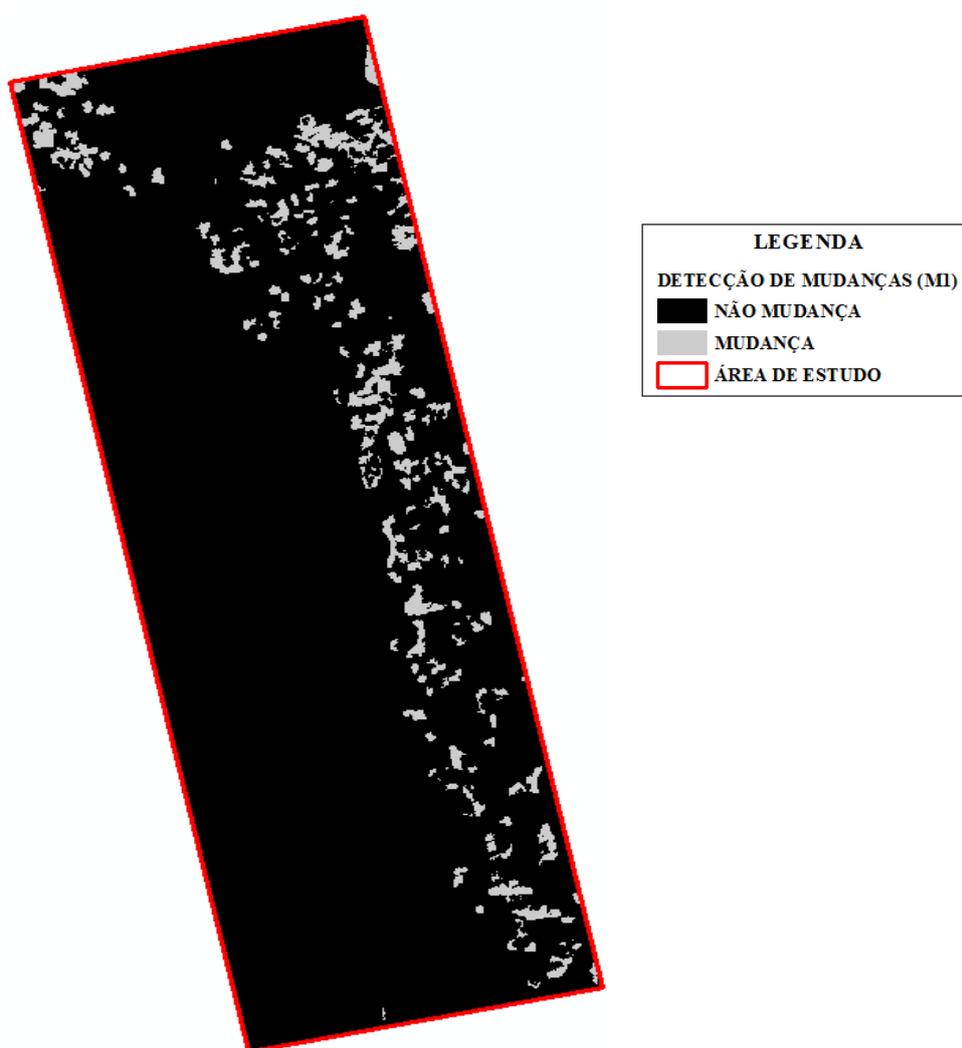
Fonte: Produção da Autora.

Avaliando as classificações em relação às mudanças de área (ha) referentes ao ganho e/ou redução de cada uma das classes, percebe-se que as classes FP, VS e PS possuem erros de inclusão e/ou omissão. Por outro lado, as classes PL e AG apresentam-se mais fiéis à realidade. De acordo com os resultados, FP reduziu cerca de 38% da sua área de 2014 à 2016. Ao contrário, as classes VS e PS aumentaram área em 22,5% e 20%, respectivamente. A classe de AG aumentou em 14%, em uma área de 312 ha e a classe PL diminuiu em 8% em uma área de 585 ha. A relação da matriz de transição quanto

aos eventos improváveis e impossíveis serviram para diminuir esses erros classificatórios.

As mudanças detectadas podem ser observadas na Figura 4.23, onde são representados espacialmente na área de estudo. Supostamente, esse resultado de detecção de mudanças na área de estudo é o mais adequado por ser relacionado as classificações com maiores valores estimados de índice *kappa*.

Figura 4.23 - Imagem temática de mudanças do cenário M1.

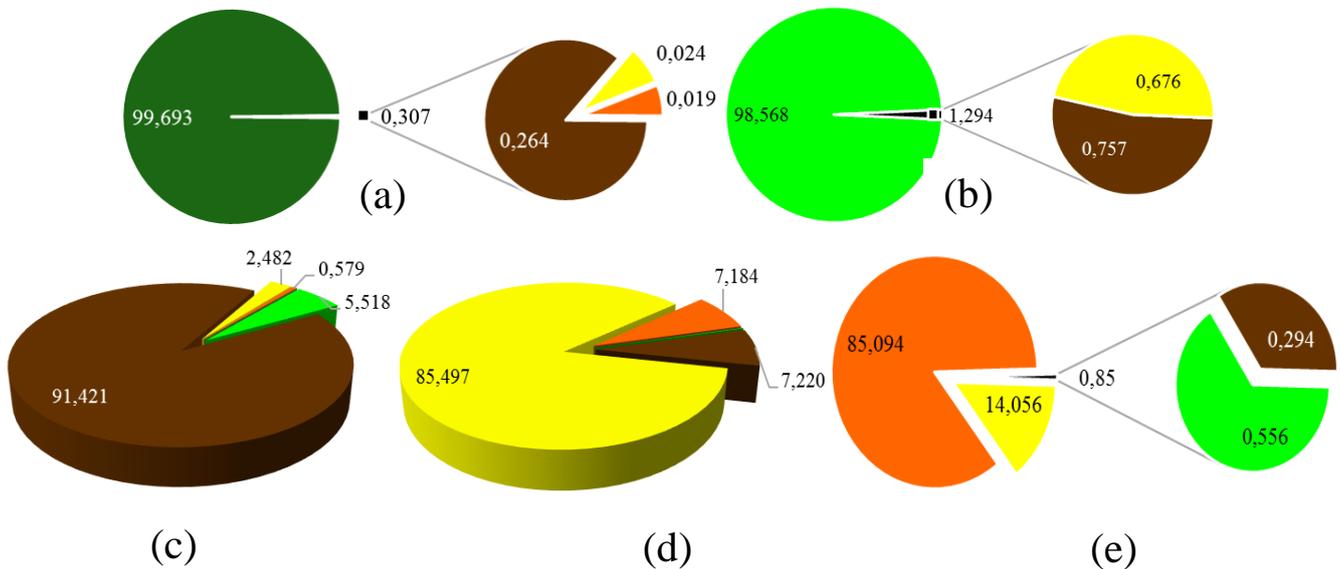


Fonte: Produção da Autora.

A partir da matriz de transição M1, as cinco classes foram analisadas separadamente. Observa-se na Figura 4.24 que a maior mudança ocorrida na cobertura florestal primária

foi para PS, seguidas de PL e AG. O mesmo ocorreu com a cobertura de vegetação secundária, onde a transição ocorreu quase na mesma proporção para PS e PL.

Figura 4.24 - Percentual de transições no cenário M1 da classe: (a) FP, (b) VS, (c) PS, (d) PL e (e) AG.



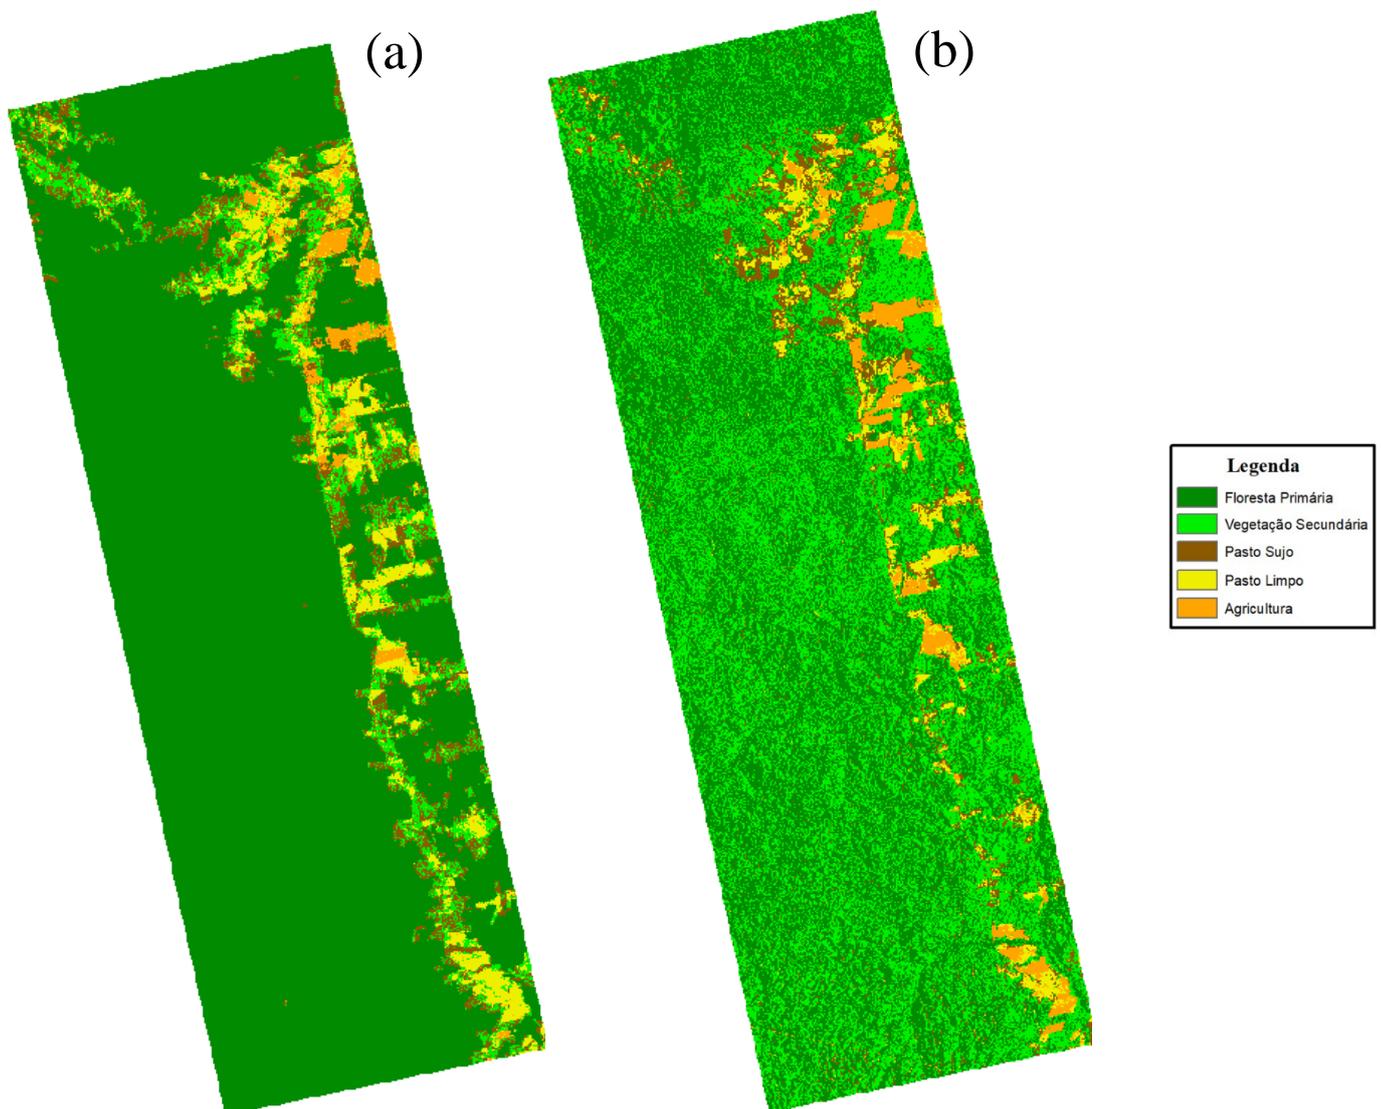
Fonte: Produção da Autora.

Em relação as classes de pastagem, a classe de PS converteu 5,5% da sua área para VS. Esse resultado é corroborado com trabalho de Oliveira et al. (2010), onde as classes de pastagem (PL e PS) tiveram mudanças significativas para a classe de vegetação secundária. Porém, nota-se que a mudança da classe de PL para VS é insignificante comparada com a análise anterior. A conversão relacionada à classe de PL está ligada com as classes de PS e AG. Por fim, a conversão da área de AG mostrada na Figura 4.24 está relacionada à classe de PL, por volta de 14% da sua extensão.

Comparando as conversões entre as classificações e a análise pós-classificação com os critérios mencionados, a classe FP diminuiu apenas 0,3% da área. Em relação às classes VS e PS houve um ganho de 2% e 4% respectivamente. Não houve muita diferença entre as classes de PL e AG. A classe PL diminuiu em 6% (2% a menos que a outra análise) e a classe AG aumentou 10% (4% de diferença).

O próximo cenário de mudança a ser analisado é o resultado entre as melhores classificações de dados bivariados dos conjuntos de 2014 $\{L_{VV}, C_{VH}\}$ e de 2016 $\{L_{VH}, C_{VV}\}$, que é demonstrado na matriz de transição M2 (Tabela 4.6). Na Figura 4.25 são mostradas as classificações bivariadas.

Figura 4.25 - Melhores resultados de classificação bivariada referentes aos anos de: (a) 2014 e (b) 2016.

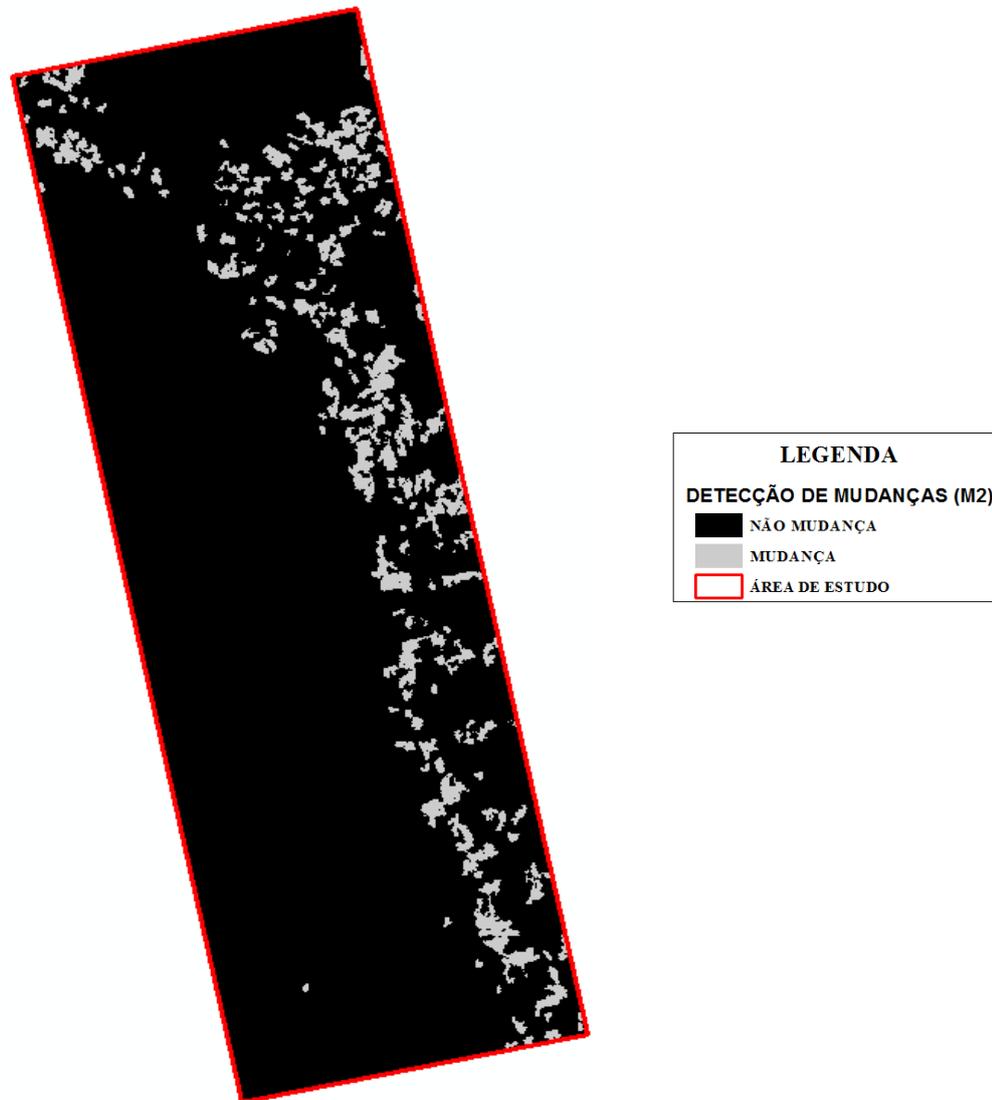


Fonte: Produção da Autora.

A partir de dados polarizados bivariados, as classificações constataram mais uma vez que as classes de FP e VS não tiveram resultados significativos. A respeito das classes

de pastagem, houve uma redução das áreas de uso com 30% de PS e 19% de PL. Por outro lado, a classe AG intensificou-se na área em 32%. É possível observar as mudanças ocorridas no cenário M2, representadas espacialmente na Figura 4.26.

Figura 4.26 - Imagem temática de mudanças do cenário M2.



Fonte: Produção da Autora.

Na Tabela 4.6 nota-se que as perdas de área das classes de floresta foram menores comparadas aos resultados de classificação, com cerca de 18% e 14% de PS e PL respectivamente. Entretanto, a classe de AG amplificou ainda mais sua área, em 41%.

Tabela 4.6 - Matriz de transição do cenário M2.

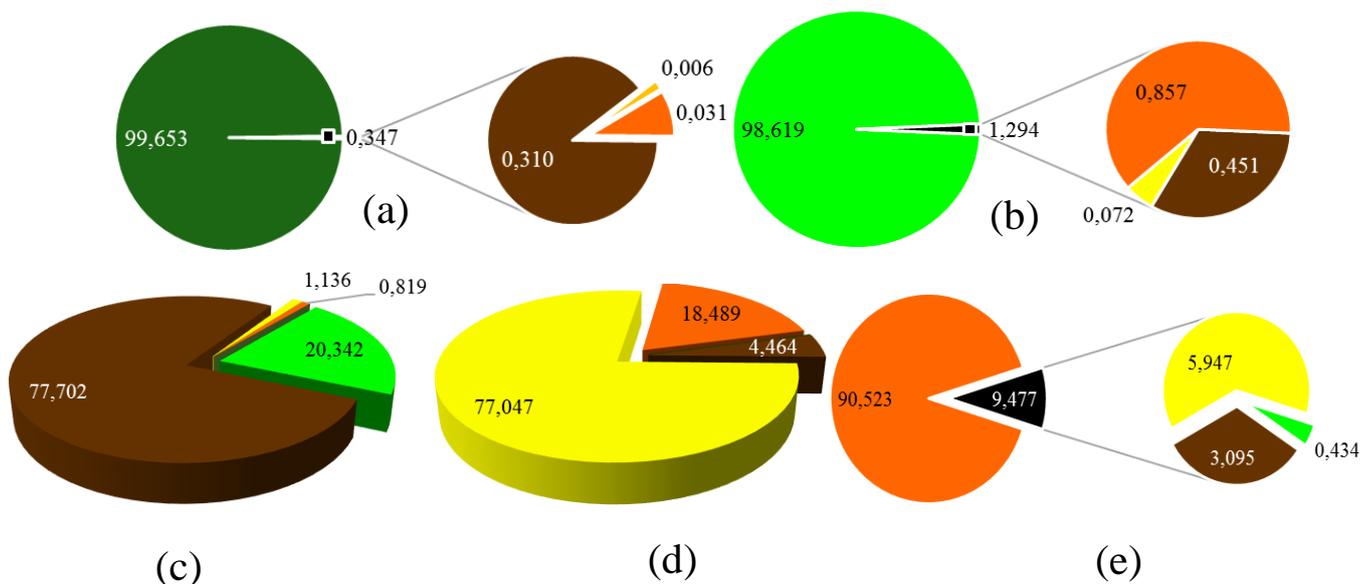
		2014					
		FP	VS	PS	PL	AG	TOTAL
2016	FP	112838,0	-	-	-	-	112838,0
	VS	-	8549,0	2050,9	0,0	12,8	10612,7
	PS	351,1	39,1	7834,1	316,4	91,0	8631,7
	PL	7,2	6,3	114,6	5460,8	174,8	5763,7
	AG	34,5	74,3	82,6	1310,4	2661,7	4163,5
TOTAL		113230,9	8668,7	10082,1	7087,6	2940,3	142009,6

onde: FP= Floresta Primária; VS= Vegetação Secundária; PS= Pasto sujo; PL= Pasto Limpo; AG= Agricultura.

Fonte: Produção da Autora.

As mudanças das classes de uso e cobertura da terra da transição M2 foram analisadas separadamente. A conversão da cobertura florestal primária foi semelhante à mencionada no cenário M1. A classe de PS prevaleceu na transição de FP (Figura 4.27), seguida de AG e PL. Porém, houve uma diferença quanto a conversão da cobertura vegetal secundária, onde se expandiram as áreas agrícolas em 74,3 ha.

Figura 4.27 - Percentual de transições no cenário M2 da classe: (a) FP, (b) VS, (c) PS, (d) PL e (e) AG.



Fonte: Produção da Autora.

A transição de PS está ligada à classe de VS, como percebe-se na Figura 4.26. Essas áreas podem estar relacionadas ao abandono de pastos ou áreas florestais que foram totalmente desflorestadas e regeneraram.

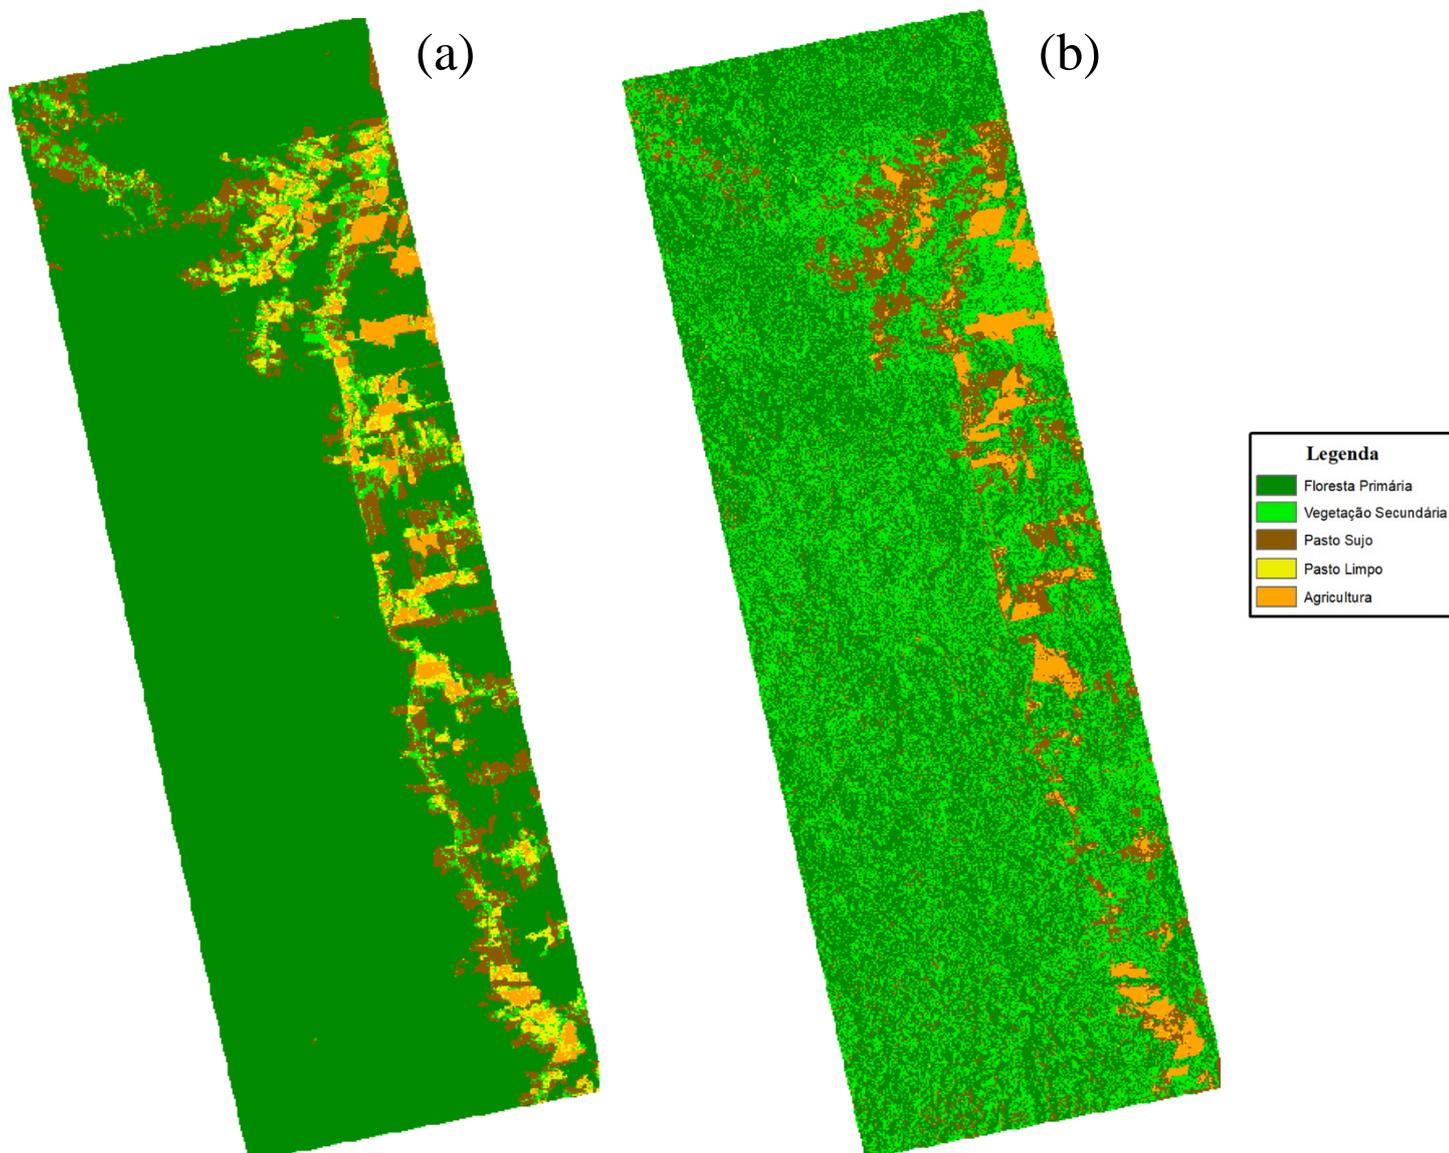
Verificou-se que grandes extensões de áreas de pastagens foram convertidas em áreas agrícolas, com cerca de 18% da área. O contrário ocorre em menores proporções para a classe AG onde só foram convertidos 5% da área em PL.

Em suma, no cenário M2 constatou-se que áreas agrícolas foram expandidas na área de estudo. A probabilidade desse cenário ocorrer é alta, visto que na área de Tapajós existe forte presença de grandes áreas agrícolas mecanizadas.

O cenário M3 foi analisado com base nos dados polarizados univariados de 2014 e 2016, que são mostrados na Figura 4.28. As mudanças detectadas no cenário M3 são apresentadas na Figura 4.29.

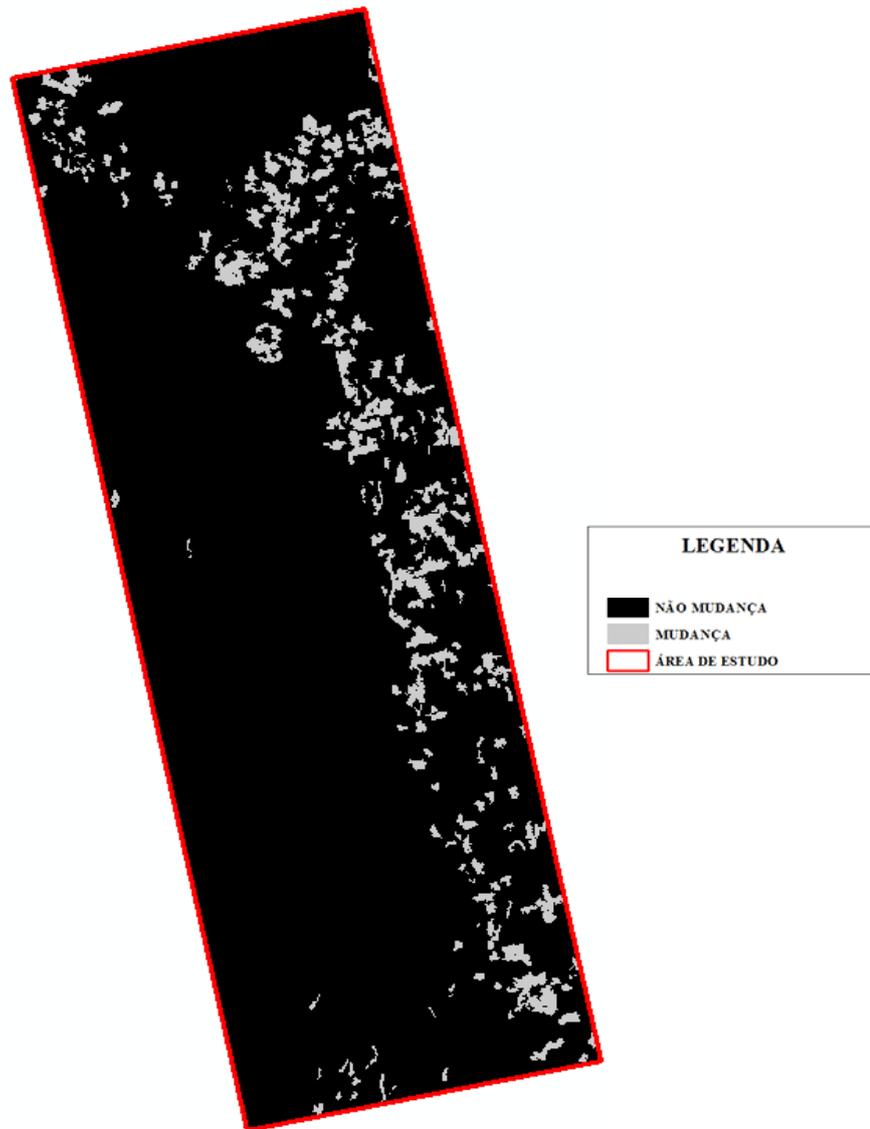
Comparando a matriz de transição (Tabela 4.7) e as classificações univariadas, percebe-se que houve uma discordância quanto às mudanças entre os anos de 2014 e 2016. Isso se deve ao baixo valor de *kappa* e exatidão global das imagens temáticas univariadas. Como mencionado na seção anterior, as combinações de uma única banda obtiveram resultados insatisfatórios em comparação às demais. Cada classe de uso e cobertura da terra em relação às mudanças foram analisadas separadamente.

Figura 4.28 - Melhores resultados da classificação univariada referentes aos anos de: (a) 2014 e (b) 2016.



Fonte: Produção da Autora.

Figura 4.29 - Imagem temática de mudanças do cenário M3.



Fonte: Produção da Autora.

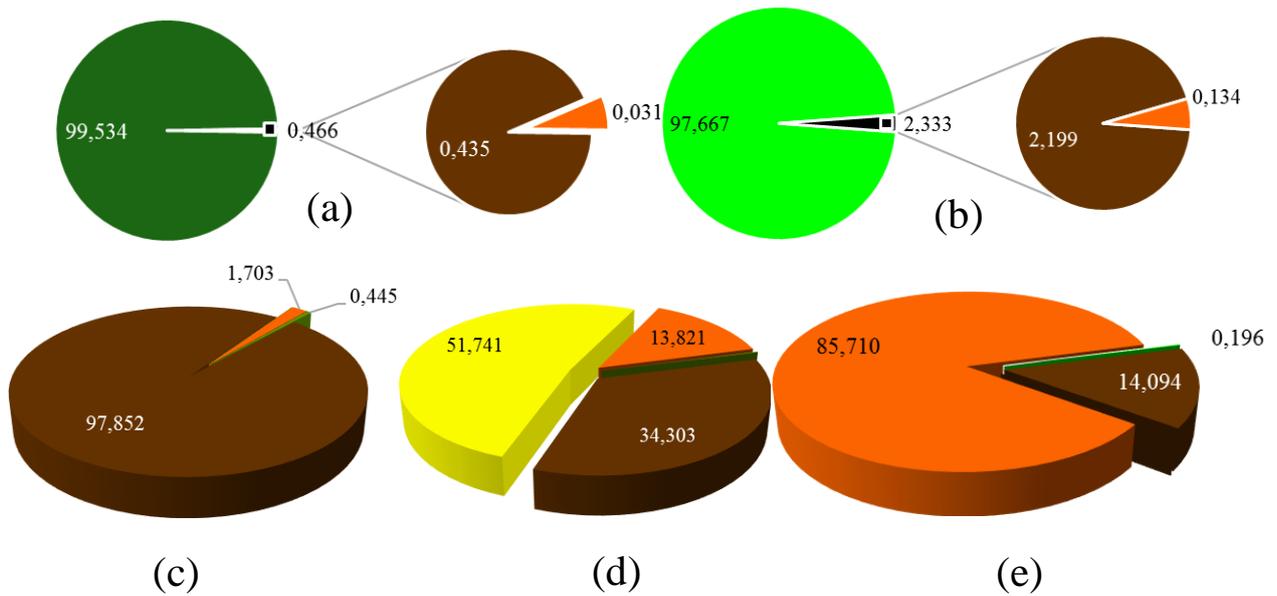
Tabela 4.7 - Matriz de transição do cenário M3.

		2014					
Classes		FP	VS	PS	PL	AG	TOTAL
2016	FP	112702,6	-	-	-	-	112702,6
	VS	-	12825,4	28,3	6,7	8,4	12868,8
	PS	492,1	288,8	6232,4	1710,9	604,8	9329,0
	PL	0,0	0,0	0,0	2580,6	0,0	2580,6
	AG	35,6	17,5	108,5	689,4	3677,6	4528,6
TOTAL		113230,3	13131,7	6369,3	4987,6	4290,8	142009,6

onde: FP= Floresta Primária; VS= Vegetação Secundária; PS= Pasto sujo; PL= Pasto Limpo; AG= Agricultura.

Fonte: Produção da Autora.

Figura 4.30 - Percentual de transições no cenário M2 da classe: (a) FP, (b) VS, (c) PS, (d) PL e (e) AG.



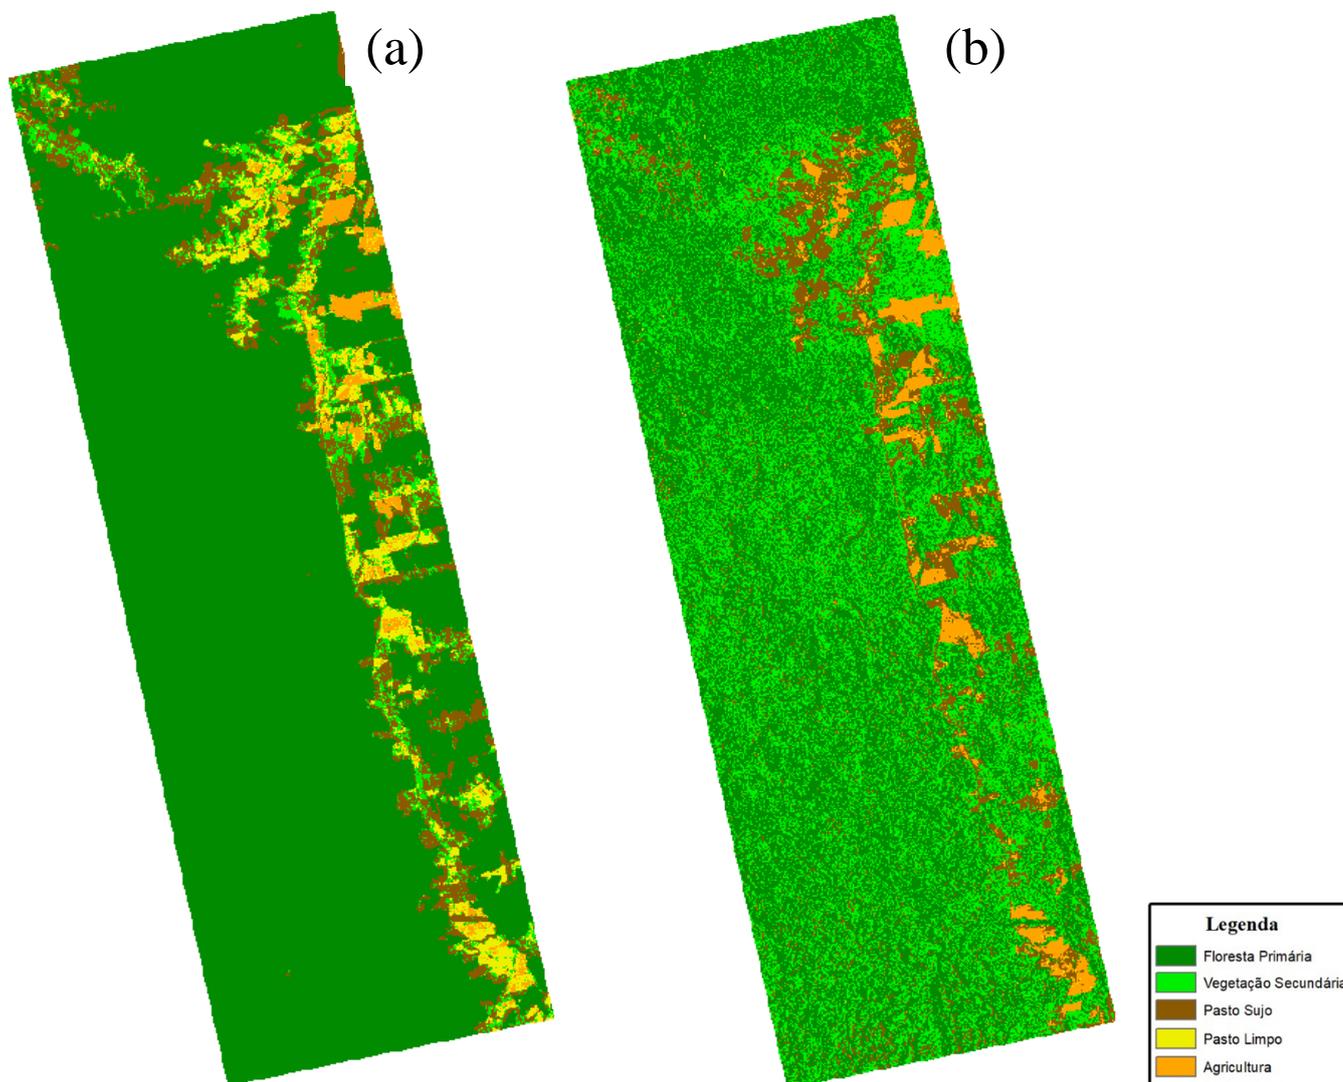
Fonte: Produção da Autora.

As mudanças da classe de FP (Figura 4.29) tiveram resultados parecidos aos cenários anteriores, convertendo a maior parte da sua área em PS, seguido de AG. Na Figura 4.23, observa-se que o mesmo comportamento ocorreu na classe de VS. Aproximadamente 108 ha da classe de PS foram convertidos em áreas agrícolas.

Em relação à classe de pasto limpo, metade da sua área foi alterada para outra classe, sendo 34% para PS e 14% para agricultura. Esse resultado pode ser fruto de erros de inclusão e omissão na classificação. Como dito anteriormente, a análise pós-classificação é muito sensível à precisão do mapeamento. Ou seja, a classe PL não foi caracterizada adequadamente em um ou em ambos dados temáticos. Nesta Figura nota-se ainda que 14% das áreas agrícolas foram abandonadas, onde ocorreu uma regeneração de vegetação.

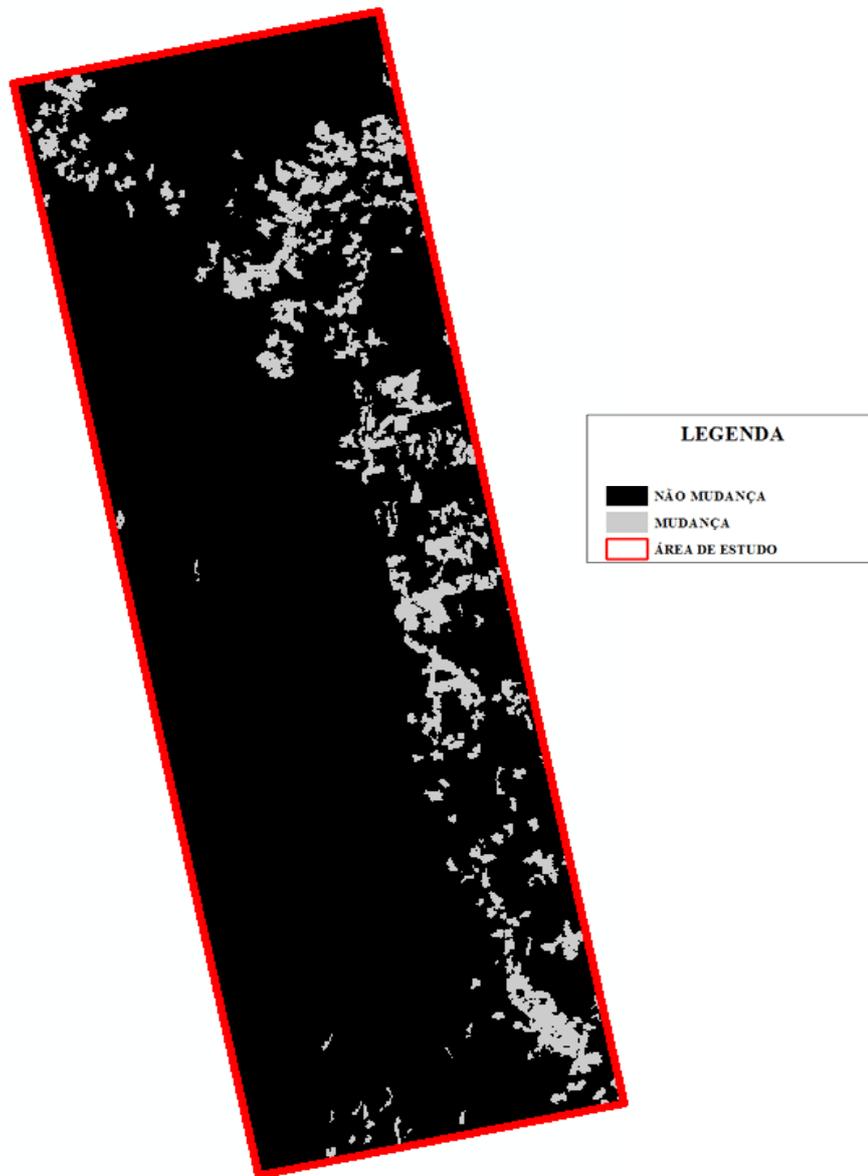
O quarto cenário de mudança (M4) foi realizado a partir das melhores classificações com as combinações da banda L $\{L_{HH}, L_{VH}, L_{VV}\}$ de 2014 e $\{L_{VH}\}$ de 2016. As imagens classificadas são mostradas na Figura 4.30 e a imagem temática de mudança na Figura 4.31.

Figura 4.31 - Melhores resultados de classificação da banda L referentes aos anos de:
(a) 2014 e (b) 2016.



Fonte: Produção da Autora.

Figura 4.32 - Imagem temática de mudanças do cenário M4.



Fonte: Produção da Autora.

Tabela 4.8 - Matriz de transição do cenário M4.

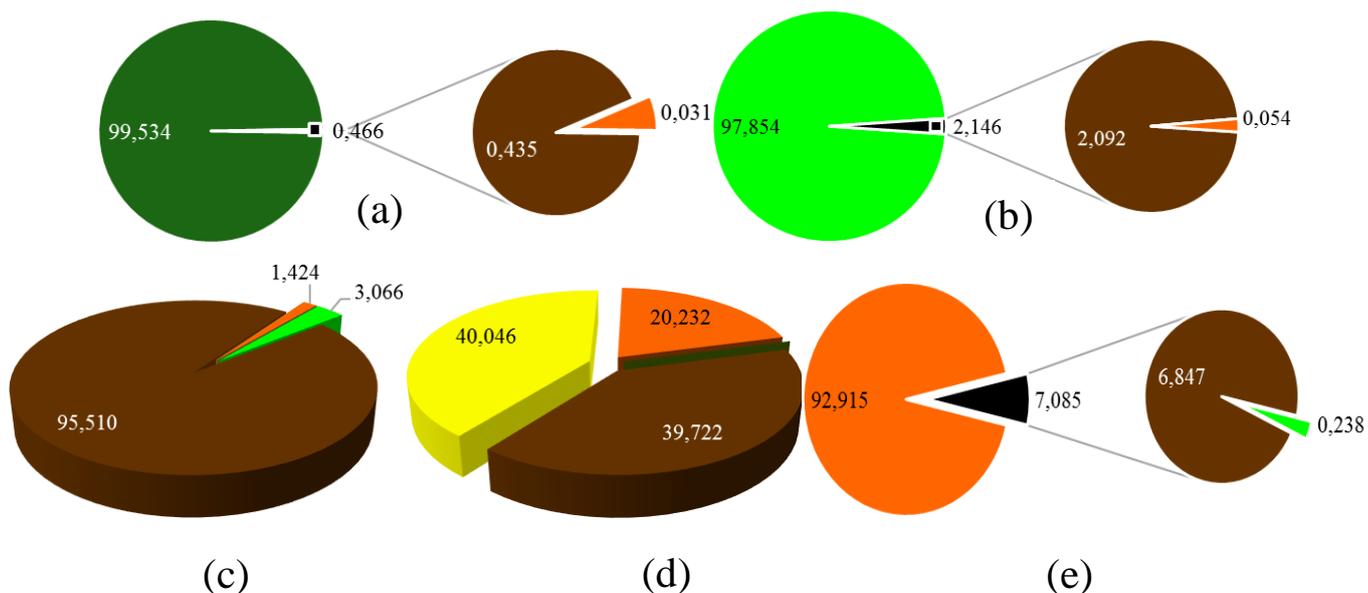
		2014					
		FP	VS	PS	PL	AG	TOTAL
2016	FP	112702,7	-	-	-	-	112702,7
	VS	-	12006,2	213,0	0,0	7,0	12226,3
	PS	492,1	256,7	6635,6	2630,6	201,3	10216,4
	PL	0,0	0,0	0,0	2652,1	0,0	2652,1
	AG	35,6	6,5	98,9	1339,9	2731,2	4212,2
TOTAL		113230,4	12269,5	6947,6	6622,6	2939,5	142009,6

Onde: FP= Floresta Primária; VS= Vegetação Secundária; PS= Pasto sujo; PL= Pasto Limpo; AG= Agricultura

Fonte: Produção da Autora.

Observando os gráficos e a matriz de transição M4 na Figura 4.32 e na Tabela 4.8, a maioria das classes sofreram a conversão para a classe de PS. É notável que os percentuais de transições nos cenários M3 e M4 são semelhantes. Em uma primeira impressão, pôde-se inferir que as classificações dos conjuntos $\{L_{HH}, L_{VH}, L_{VV}\}$ e $\{L_{VH}\}$ fossem parecidos. Porém, se observamos as matrizes de confusão das Figuras 4.10 e 4.12, vemos que os resultados têm suas diferenças, o que não levaria a esse resultado de transição. Outra ideia seria a etapa do filtro de área da mudança não ser menor que 6,25 ha, como adotado no PRODES.

Figura 4.33 - Percentual de transições no cenário M4 da classe: (a) FP, (b) VS, (c) PS, (d) PL e (e) AG.

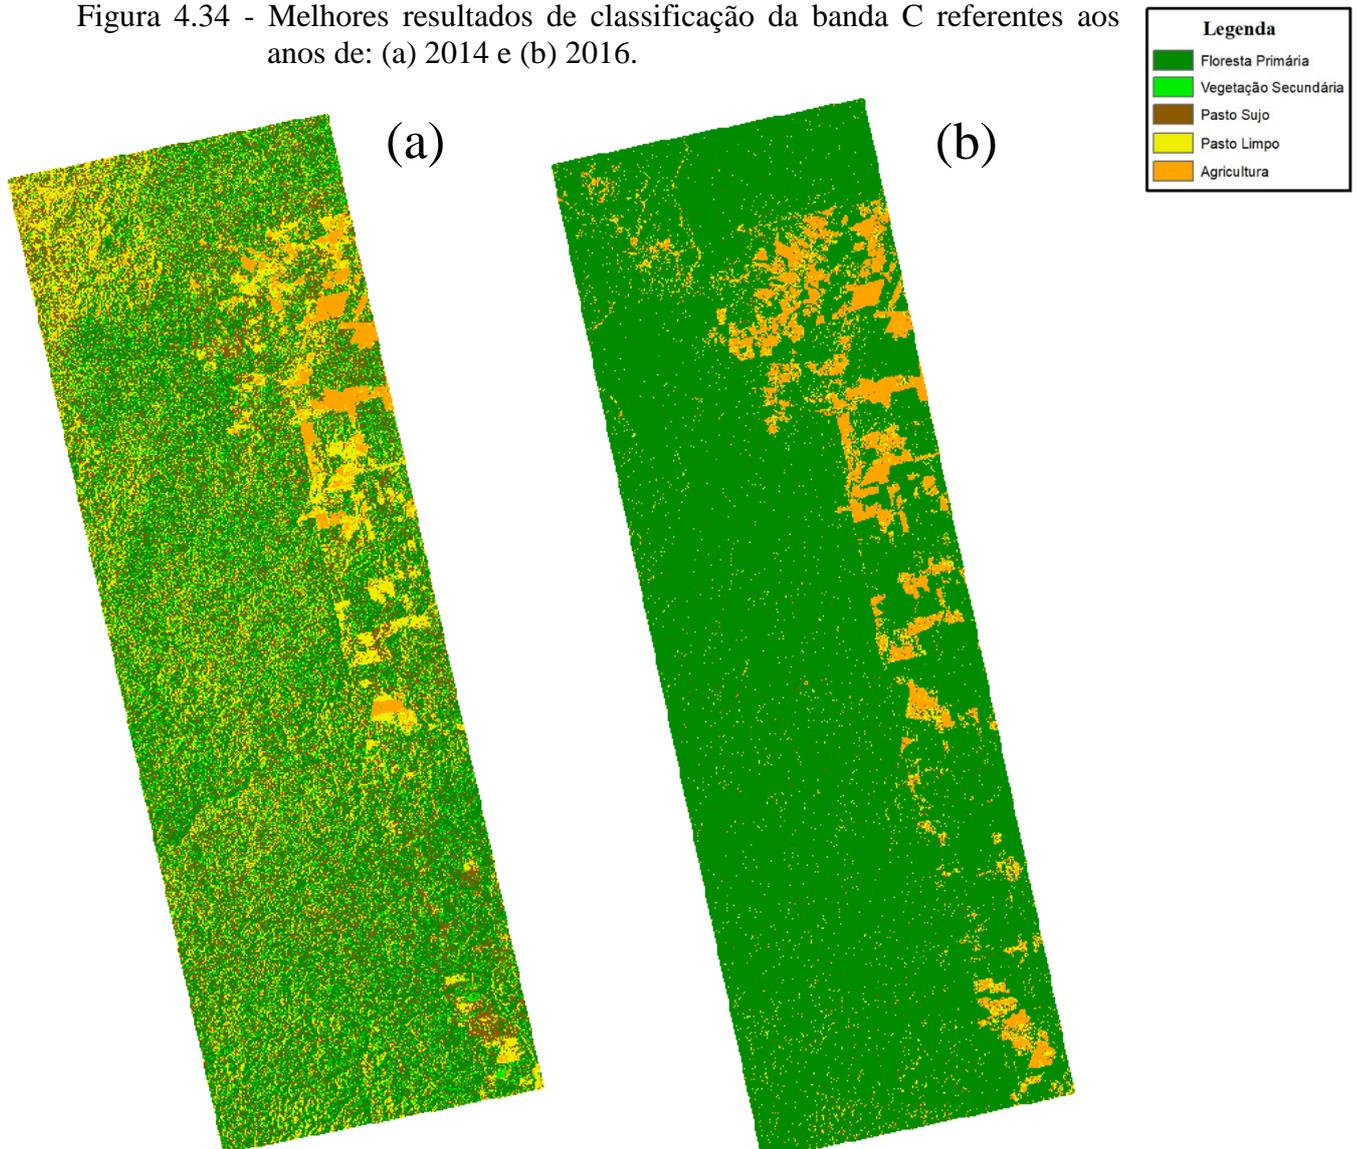


Fonte: Produção da Autora.

O próximo e último cenário é referente à melhor classificação dos conjuntos da Banda C $\{C_{VH}, C_{VV}\}$ de 2014 e $\{C_{VH}\}$ de 2016. É visível a confusão entre as classes de FP e PL no conjunto de dados $\{C_{VH}, C_{VV}\}$ do ano de 2014, como mostrado na Figura 4.33. Na Figura 4.34 é ilustrado o resultado de mudança das imagens classificadas do cenário M5.

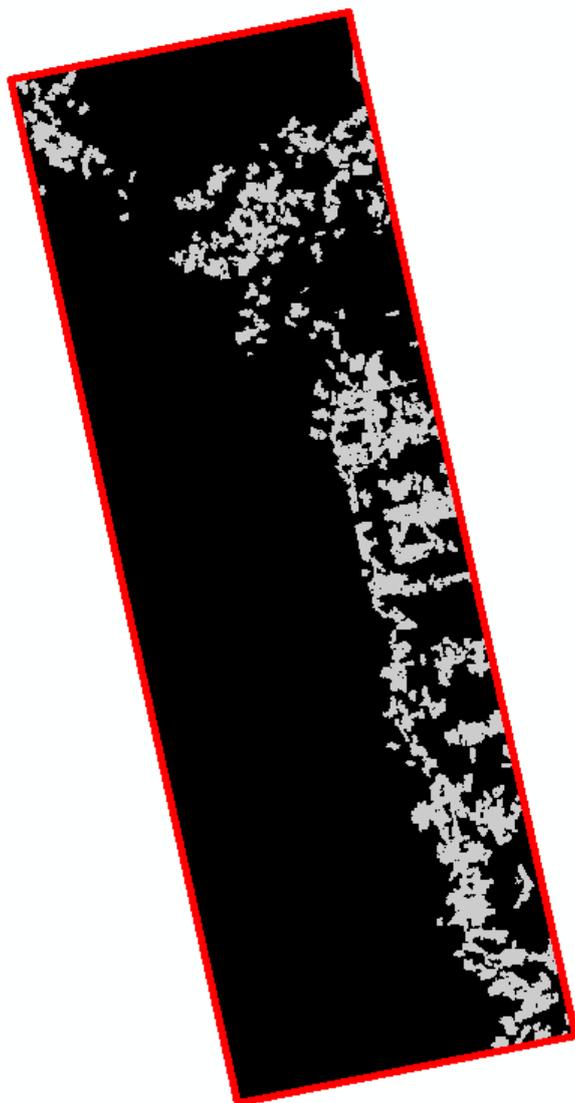
Na Tabela 4.9 é descrita a transição ocorrida nesse cenário.

Figura 4.34 - Melhores resultados de classificação da banda C referentes aos anos de: (a) 2014 e (b) 2016.



Fonte: Produção da Autora.

Figura 4.35 - Imagem temática de mudança do cenário M5.



Fonte: Produção da Autora.

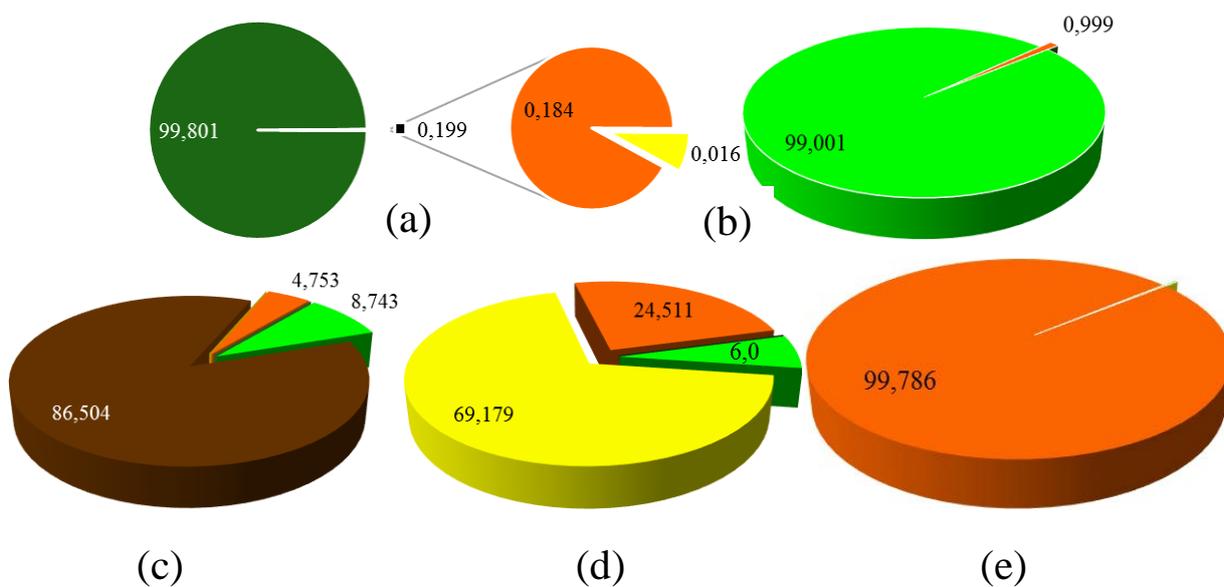
Tabela 4.9 - Matriz de transição do cenário M5.

		2014					
Classes		FP	VS	PS	PL	AG	TOTAL
2016	FP	113005,6	-	-	-	-	113005,6
	VS	-	9670,8	639,7	523,1	7,3	10840,9
	PS	0,0	0,0	6329,5	0,0	0,0	6329,5
	PL	17,6	0,0	0,0	5735,7	0,0	5753,4
	AG	208,0	97,6	347,8	2032,3	3394,6	6080,2
TOTAL		113231,2	9768,4	7317,1	8291,1	3401,9	142009,6

Onde: FP= Floresta Primária; VS= Vegetação Secundária; PS= Pasto sujo; PL= Pasto Limpo; AG= Agricultura.

Fonte: Produção da Autora.

Figura 4.36 - Percentual de transições no cenário M5 da classe: (a) FP, (b) VS, (c) PS, (d) PL e (e) AG.



Fonte: Produção da Autora.

Nesse cenário a maior conversão está relacionada ao PL, que altera cerca de 2500 ha, e que se deve pelo fato haver de erros de classificação no conjunto do ano de 2014. A classe PS também sofre uma perda considerável na sua cobertura, com cerca de 640 ha e 348 ha para classes de VS e AG, respectivamente. As classes VS e AG quase não sofreram alterações na sua cobertura.

Analisando todos os cenários de mudança minuciosamente, conclui-se que os cenários mais adequados para detectar mudanças na área de estudo foram M1 e M2. Os demais apresentam muitos equívocos na classificação da cobertura da terra. Estes cenários apresentam a combinação de dados em diferentes frequências e propiciam os melhores resultados, corroborando a necessidade de multifrequências para obter melhores resultados de classificação, ou seja, melhor discriminação das classes.

A seguir, os cenários de mudança foram analisados quanto à concordância de mudanças a partir do PRODES e TerraClass.

4.3 Análise da concordância com os desflorestamentos detectados a partir de programas de monitoramento

4.3.1 PRODES

Foi feita uma comparação com os resultados detectados da classe de desflorestamento dos cenários analisados, descritos na Seção 4.2.2, em relação aos dados PRODES de desflorestamento dos anos de 2015 e 2016. Os dados do ano de 2015 e 2016 foram escolhidos por fazerem parte do período analisado das mudanças ocorridas de 2014 a 2015 e de 2015 a 2016.

Observa-se na Tabela 4.10 a concordância de ambos os dados. Percebe-se nessa tabela que os cenários M1 e M2 apresentaram mais de 37% de concordância com os dados de desflorestamento do PRODES. Mais uma vez, esses resultados reforçam a ideia da necessidade da utilização de dados multifrequência para a melhoria dos resultados de classificação e a melhor separabilidade das classes de cobertura. É importante ressaltar que a concordância de ambos os dados pode ter sido afetada pelas diferentes datas de aquisição dos dados de radar e ópticos utilizados no PRODES. A área total de mudança detectada pelo PRODES foi de 517 ha.

Tabela 4.10- Concordância da classe de mudança de desflorestamento com dados PRODES nos cenários analisados.

Cenário de Mudança	Concordância em área total de mudança (ha)	Desflorestamento em concordância com PRODES (%)
M1	193,47	37,42
M2	210,04	40,61
M3	156,94	30,17
M4	156,76	30,17
M5	102,34	19,72

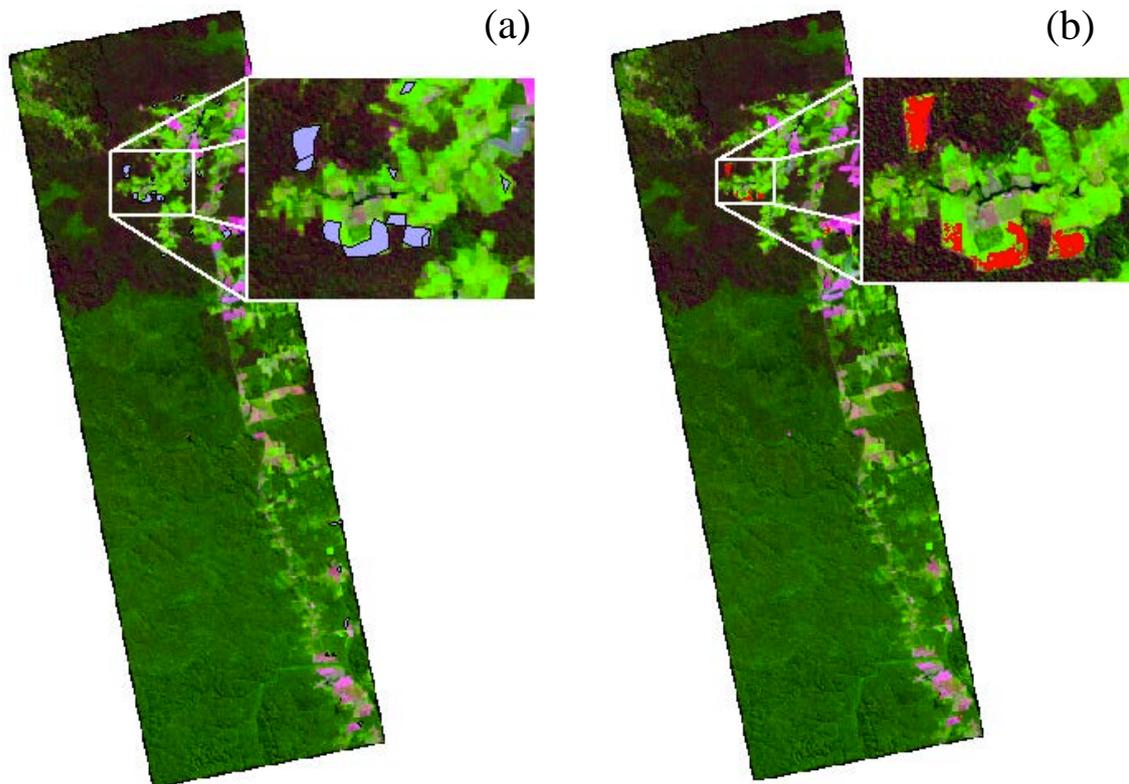
Fonte: Produção da autora.

Esse resultado também reafirma a importância da integração do monitoramento a partir de dados SAR com os monitoramentos existentes. Provavelmente, a implementação de dados SAR nesses programas de monitoramento ajudaria a melhorar a detecção de desflorestamento.

A Tabela 4.10 sintetiza o resultado da tabulação cruzada onde nota-se que no acumulado total do desmatamento detectado pelo PRODES até 2016, no melhor dos cenários (M2), 40,61% das áreas são mapeadas pela detecção de mudanças proposta nesse trabalho. Esse resultado confirma com trabalho de Aboud Neta (2009) que em seu estudo de detecção de desmatamento na Flona utilizando dados microondas concluiu que dados bivariados tiveram um resultado com maior concordância com dados PRODES.

A Figura 4.37 mostra áreas de desmatamento identificadas pelo PRODES e pelo método proposto tendo como fundo uma imagem OLI/Landsat 8, composição 6R5G4B. Os resultados aqui encontrados indicam que o método proposto apresentou resultados conservadores e subestimaram a área desmatada.

Figura 4.37 – Polígonos de desflorestamento encontrados pelo: (a) PRODES e (b) Cenário M1.



Fonte: Produção da Autora.

A Figura 4.38 mostra um exemplo de identificação de uma área desmatada em composição colorida RGB das bandas 6, 5 e 4 do satélite OLI/Landsat8 na área de estudo. Em vermelho são apresentadas as áreas detectadas pelo PRODES e em ciano as áreas encontradas pelo método proposto. Observa-se, claramente, as concordâncias e as incongruências.

Figura 4.38 – Polígonos de desflorestamento encontrados pelo PRODES e cenário M1.



Fonte: Produção da Autora.

Observa-se, portanto, com esse resultado que o método ora proposto subestima as áreas desmatadas, mapeando grande parte delas como floresta. Supõe-se que parte das áreas desmatadas não detectadas são áreas de vegetação secundária, o que mostra mais uma vez a limitação no método aqui proposto na identificação e separação das classes de FP e VS. Esta conclusão diverge do trabalho de Freitas (1999) que discriminou as classes de floresta primária e vegetação secundária com imagens do RADARSAT (banda C). Essa divergência pode estar associada à utilização de apenas uma polarização da banda C, o que não foi analisado neste trabalho porque estas classificações utilizando apenas uma polarização não obtiveram um *kappa* satisfatório e, portanto, não foram utilizadas na etapa de detecção de mudanças.

Esta comparação foi realizada utilizando a subtração de uma máscara de 2014 que continha as áreas já detectadas como antropizadas, sobrando, portanto, apenas vegetação. Essa área resultante contendo apenas vegetação em 2014 foi submetida à classificação do PRODES e do método proposto nesta pesquisa.

4.3.2 TerraClass

Uma outra comparação foi realizada utilizando como referência, o mapeamento do Uso e Cobertura da Terra para Amazônia Legal (TerraClass) desenvolvido em parceria entre INPE e a Empresa Brasileira de Pesquisa Agropecuária (Embrapa) para o ano de 2014. Nesta comparação foram utilizadas 4 classes, sendo elas: vegetação secundária, pasto sujo, pasto limpo e agricultura. Foram desconsideradas as classes de floresta e desflorestamento por terem sido analisadas no PRODES.

Embora o TerraClass possua mais classes, para fins de comparação, as classes nuvem, outros, hidrografia, área urbana e não observado foram negligenciadas por apresentarem no total, uma área inferior a 2,3% da área de estudo.

Hagensieker e Waske (2018) concluíram em seu trabalho que a integração de dados SAR multifrequência é promissor para classificação da cobertura da terra, principalmente para áreas tropicais. Esse resultado foi dado a partir da validação dos resultados de classificação baseado nos dados TerraClass. Esta conclusão evidencia os resultados aqui encontrados e são apresentados na Tabela X.

A Tabela 4.11 apresenta os valores de concordância entre o TerraClass e o método proposto em hectares e porcentagem.

Tabela 4.11 Concordância entre o TerraClass e a classificação pelo método proposto.

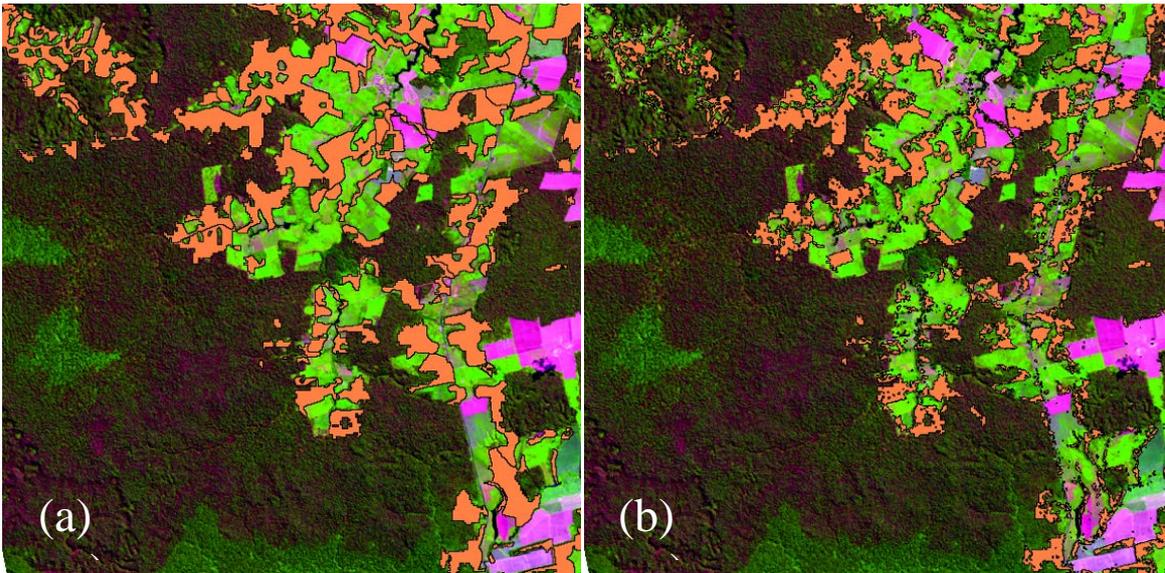
	Classes			
	VS	PS	PL	AG
TerraClass 2014	15974,56	1008,8	8653,24	1819,3
Classificação MAXVER-ICM	12298,02	7250	7005,4	2249,65
CONCORDÂNCIA (ha)	6996	481	4630	1175
CONCORDÂNCIA (%)	43,79%	47,68%	53,51%	64,59%

Fonte: Produção da Autora.

Para a vegetação secundária foram encontrados polígonos concordantes em 43,79% da área. Mais uma vez o método se mostrou conservador apresentando a classe dominante (floresta) como principal classe concorrente, como pode ser observado na Figura 4.39.

Hagensieker e Waske (2018) constataram que a confusão entre as classes de FP e VG aparece de forma mais aleatória e são distribuídas espacialmente, portanto não há uma separação adequada entre essas duas classes.

Figura 4.39 – Classificação da classe de vegetação secundária de uma parte da área de estudo do: (a) TerraClass 2014 e (b) conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ de 2014.

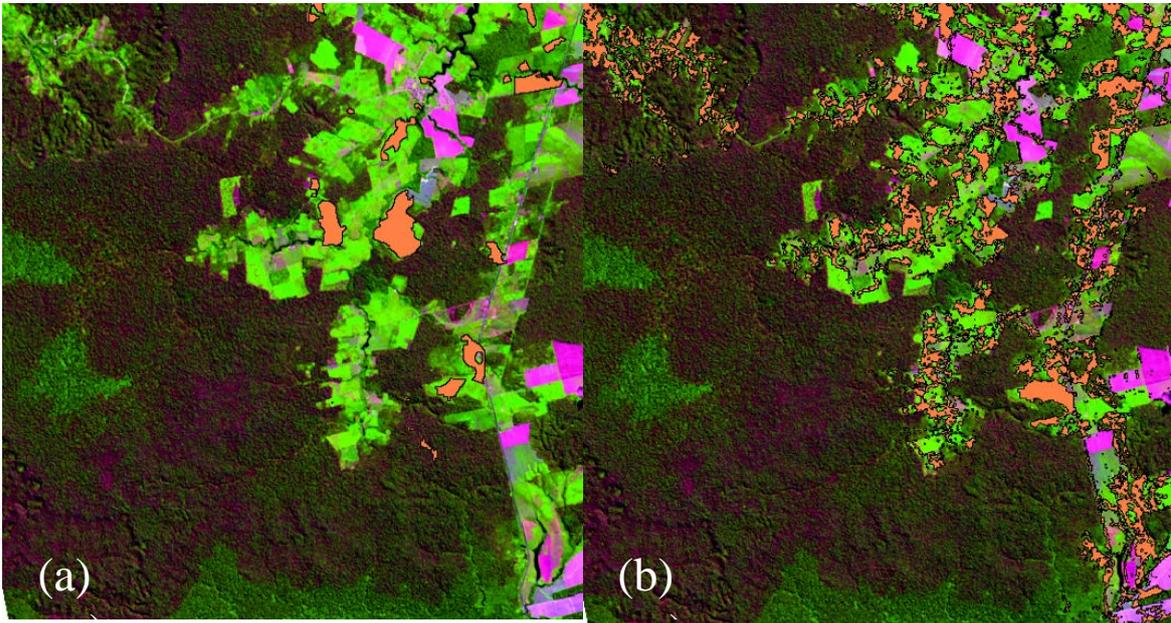


Fonte: Produção da Autora.

Outra classe que também foi muito confundida com floresta é pasto sujo, conforme mostrado na Figura 4.39. Entretanto, quando comparada à classe pasto limpo, ela foi bem individualizada, conforme Figura 4.40. Este resultado foi corroborado na comparação com o TerraClass que apresentou dados similares ao encontrado nesta pesquisa. A classe pasto sujo apresentou concordância de 47,68% entre os métodos e a classe pasto limpo, 53,51%.

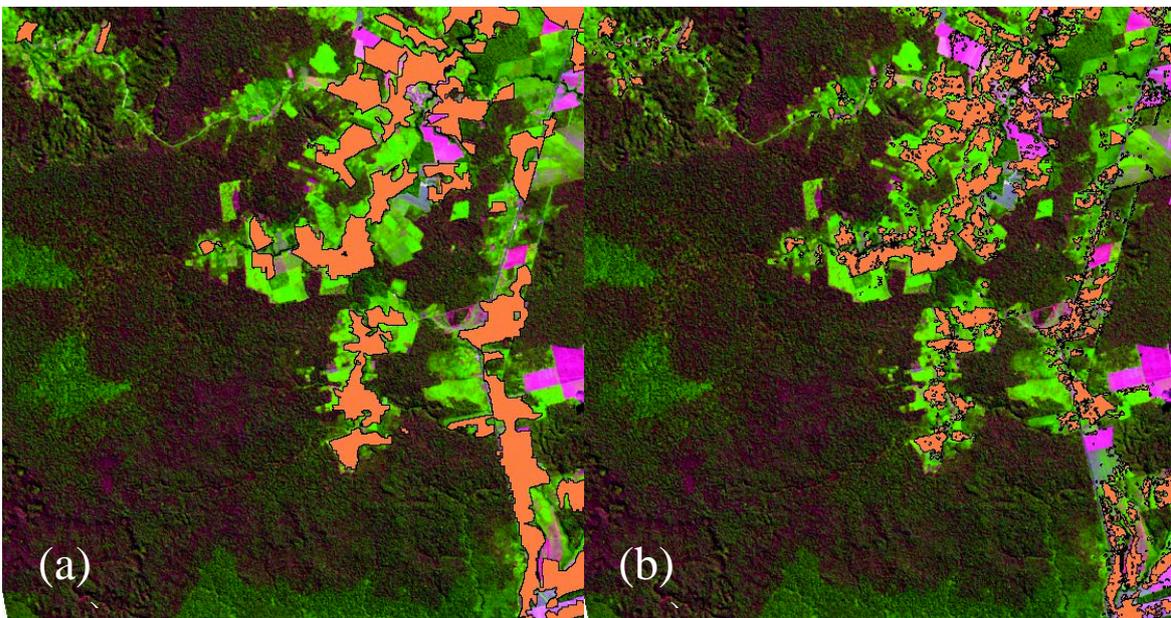
Pode-se também observar a partir das Figuras 4.40 e 4.41 que as classes VS e PS uma baixa confusão, mesmo podendo ser similares na estrutura da vegetação. Esse resultado corrobora com as conclusões encontradas em Hagensieker e Waske (2018).

Figura 4.40 – Classificação da classe de pasto sujo de uma parte da área de estudo do: (a) TerraClass 2014 e (b) conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ de 2014.



Fonte: Produção da Autora.

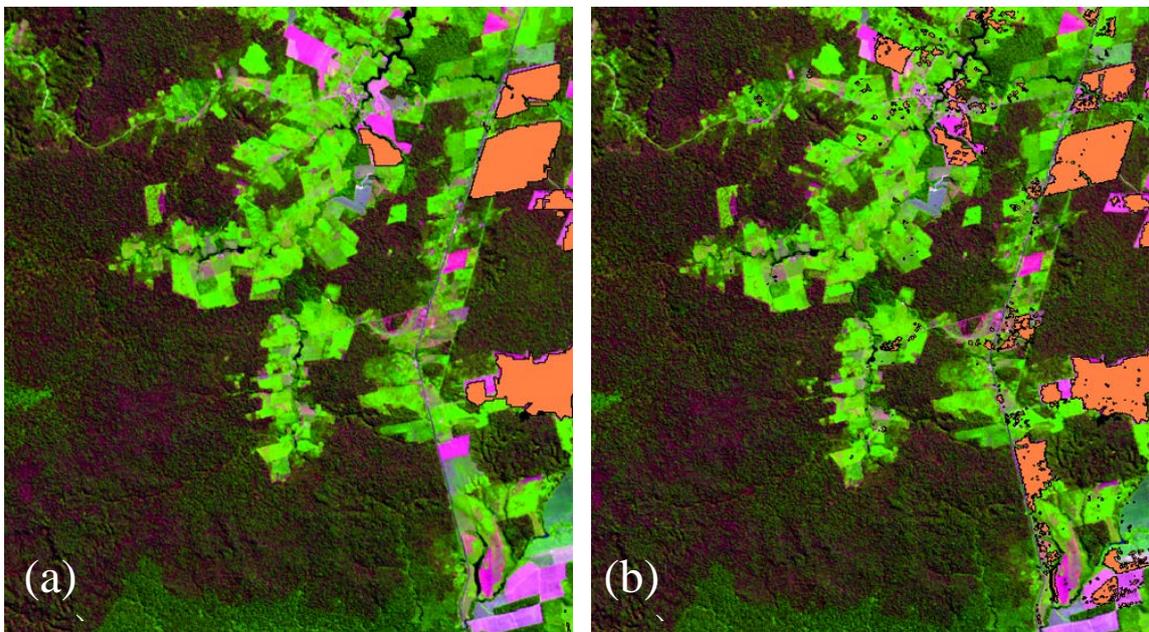
Figura 4.41 – Classificação da classe de pasto limpo de uma parte da área de estudo do: (a) TerraClass 2014 e (b) conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ de 2014.



Fonte: Produção da Autora.

A classe agricultura é que apresentou melhores resultados, principalmente quando comparadas ao resultado do TerraClass. Observa-se uma concordância de 64,59%, o que mostra a eficiência do método para detectar este tipo de classe. Lembrando que, para as datas das imagens SAR utilizadas, essas áreas agrícolas provavelmente estão em pousio ou início da plantação. Com isso, esse resultado corrobora com as conclusões apresentadas por Guerra (2008) e Sumaia (2009) onde as áreas desflorestadas identificadas que se tornaram solo exposto obtiveram menores erros de omissão nas classificações a partir de dados SAR quando comparadas aos dados do PRODES.

Figura 4.42 – Classificação da classe de agricultura de uma parte da área de estudo do: (a) TerraClass 2014 e (b) conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ de 2014.

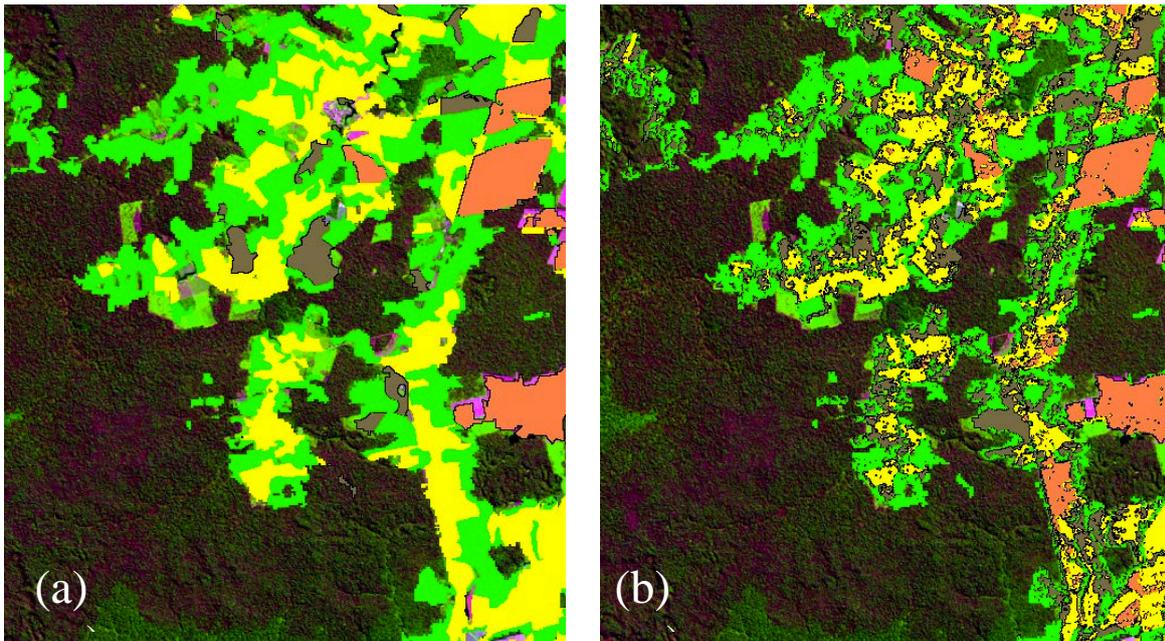


Fonte: Produção da Autora.

A partir desses resultados é possível concluir que as classes com menor quantidade de biomassa foram melhor identificadas no método proposto quando comparadas ao dado do TerraClass 2014. Mais uma vez, o método se mostrou com limitações para a discriminação de diferentes estágios de biomassa.

A concordância geral, contemplando todas as classes, apresentou um valor de 48,37% e é mostrada na Figura 4.43 Na figura a seguir, pode-se observar as classes de VS em verde claro, PS em marrom, PL em amarelo e AG em laranja.

Figura 4.43 – Classificação de uma parte da área de estudo do: (a) TerraClass 2014 e (b) conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ de 2014.



Fonte: Produção da Autora.

Como esperado, esses resultados mostram que a utilização de dados SAR é uma alternativa interessante para o monitoramento do desmatamento e para identificação de algumas classes de cobertura quando na falta de dados ópticos ou até mesmo na integração com os mesmos. Em sumo, a combinação de dados multifrequencia se mostrou útil para a identificação e detecção de mudanças das classes de cobertura na Amazônia brasileira.

5. CONCLUSÃO

A classificação foi realizada por diferentes tipos de conjunto de dados SAR multifrequência, bem como a detecção de mudanças a partir dos melhores resultados dos conjuntos univariados, bivariados e multivariados. A partir do *ranking* das classificações dos anos de 2014 e 2016, foi possível concluir que a utilização de dados multifrequência potencializa a caracterização das classes de cobertura da terra. A combinação dessas duas frequências das Bandas L e C teve resultados satisfatórios, o que permitiu a discussão e entendimento de como elas atuam quanto à discriminação da cobertura terrestre e das transições ocorridas entre dois tempos distintos.

O melhor resultado de classificação foi do conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ para os anos estudados, obtendo uma estimativa de índice *kappa* de 0,82 e 0,44 para o ano de 2014 e 2016, respectivamente. Destaca-se também a importância da obtenção de dados na mesma época do ano, no intuito de evitar resultados errôneos nas etapas classificatórias, como pode ter afetado a classificação do ano de 2016, e na detecção de mudanças.

Entretanto, com os dados utilizados e metodologia adotada, não foi possível discriminar as classes de floresta primária e vegetação secundária. Dados auxiliares foram necessários para a correção dos resultados de classificação. Por esse motivo, salienta-se a importância da possível integração entre dados SAR e programas de monitoramento existentes para fortalecer dados já consolidados.

Em relação à detecção de desmatamento, os cenários M1 e M2, apresentados na Tabela 4.10, se mostraram eficientes para a identificação dessas áreas. Foi possível identificar polígonos de desmatamento ocorridos entre os anos de 2014 e 2016 e que houve assim, mais de 37% de concordância com os dados de desmatamento do PRODES nesse período. Mais uma vez é evidente que a utilização de dados SAR multifrequência possa adquirir informações complementares e aperfeiçoar metodologias consolidadas e possível monitoramento constante da região Amazônica.

Como pesquisa futura, sugere-se construir um novo cenário de mudança a partir de uma imagem temática de dois anos distintos com os melhores resultados de classificação de cada classe, para depois gerar um novo mapa de mudanças e avaliar seu potencial para o monitoramento da cobertura para cada classe.

REFERÊNCIAS BIBLIOGRÁFICAS

ABOUD NETA, S. **Uso de imagens ALOS/PALSAR multipolarizadas para detecção de incremento de desflorestamento na Amazônia**. 2009. 264p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009. Disponível em: <http://mtc-m16d.sid.inpe.br/col/sid.inpe.br/mtcm19@80/2009/11.19.09.48/doc/publicacao.pdf>. Acesso em: 20 jun. 2019.

ABOUD NETA, S.; FREITAS, C.C.; DUTRA, L.V. Uso de imagens ALOS/PALSAR multipolarizadas para detecção de incremento de desflorestamento na Amazônia. **Revista Brasileira de Cartografia**, n.62, 2010.

AGUIAR, A.P.D. et al. Land use change emission scenarios: anticipating a forest transition process in the Brazilian Amazon. **Global Change Biology**, v. 22, n. 5, p.1821-1840, fev. 2016. Disponível em: <http://dx.doi.org/10.1111/gcb.13134>.
AKBARI, V.; ANFINSEN, S. N.; DOULGERIS, A. P.; ELTOFT, T.; MOSER, G.; SERPICO, S. B. Polarimetric SAR change detection with the complex Hotelling Lawley trace statistic. **IEEE Transactions on Geoscience and Remote Sensing**, v.54, n.7, p. 3953–3966, 2016.

ALENCAR, A.; NEPSTAD, N; MCGRATH, D; MOUTINHO, A.; PACHECO, P; DIAZ, M.D.C.V.; SOARES FILHO, B. **Desmatamento na Amazônia: indo além da emergência crônica**. Manaus: Instituto de Pesquisa Ambiental da Amazônia (IPAM), 2004.

ALMEIDA, C.A.; COUTINHO, A.C.; ESQUERDO, J.C.D.M.; ADAMI, M.; VENTURIERI, A.; DINIZ, C.G.; DESSAY, N.; DURIEUX, L.; GOMES, A.R. High spatial resolution land use and land cover mapping of the Brazilian Legal Amazon in 2008 using Landsat-5/TM and MODIS data. **Acta Amazonica**, v.46, n.3, p.291-302, 2016. Disponível em: <http://dx.doi.org/10.1590/1809-4392201505504>.

ALVES, D. S. O processo de desmatamento na Amazônia. **Parcerias Estratégicas**, v.12, p. 259-257, 2001. Disponível em: http://seer.cgee.org.br/index.php/parcerias_estrategicas/article/viewFile/176/170. Acesso em: 15 jan. 2019.

AMIN, A. et al. Neighborhood effects in the Brazilian Amazônia: protected areas and deforestation. **Journal of Environmental Economics and Management**, v. 93, p.272-288, jan. 2019. Disponível em: <http://dx.doi.org/10.1016/j.jeem.2018.11.006>.
ANDERSON, T.W. **An introduction to multivariate statistical analysis**. New York: Wiley, 1958.

ANJOS, D. S. 2016. **Detecção de mudanças da cobertura da terra na região da floresta nacional de tapajós utilizando dados de múltiplos sensores**. 2016. 153 p. Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016. Disponível em: <http://mtc-m21b.sid.inpe.br/col/sid.inpe.br/mtcm21b/2016/01.28.18.56/doc/publicacao.pdf> . Acesso em: 18 jun. 2019.

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.

ASSUNÇÃO, J; GANDOUR, C; ROCHA, R. Deforestation slowdown in the Brazilian Amazon: prices or policies. **Environment and Development Economics**, v. 20, n. 6, p.697-722, 2015. Disponível em: <http://dx.doi.org/10.1017/s1355770x15000078>.

BECKER, B. K. **Amazônia**. São Paulo: Ática, 1997.

BECKER, B. K. Cenários de curto prazo para o desenvolvimento da Amazônia. **Cadernos do Napiam**, v. 1, n. 6, p. 10, 1999.

BECKER, B. K. Geopolítica da Amazônia. **Estudos Avançados**, v.19, n. 53, p. 71-86, 2005.

BELTRAME, E.; BITTENCOURT, H.R.; JANSEN, S.L. Uma proposta para a detecção de mudanças pós-classificação. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal, RN. **Anais...** São José dos Campos: INPE, 2009. p.1261-1266.

BENEDITTI, C. **Imagens multitemporais ALOS/PALSAR baseada em orientação a objeto na discriminação da cobertura da terra**. Dissertação (Mestrado em Ciências Cartográficas) – Universidade Estadual Paulista (UNESP), Presidente Prudente, 2010.

BRITO, C. C.; GOMES-SILVA, F.; RÊGO, L. C.; OLIVEIRA, W.R. A new class of gamma distribution. **Acta Scientiarum**, v. 39, n. 1, p.79-87, 2017.

CALDEIRA, C. R. T.; GALO, M.; IMAI, N. N.; GALO, M. L. B. T.; HASEGAWA, J. K.; SHIMABUKURO, M. H.; PINTO, M. S. Detecção de mudanças de forma automática no entorno de reservatórios: estudo de caso - Canoas I. **Revista Brasileira de Cartografia**, v. 70, n. 4, p. 1348 – 1377, 2018.

CANO-CRESPO, A et al. Forest edge burning in the Brazilian Amazon promoted by escaping fires from managed pastures. **Journal of Geophysical Research - Biogeosciences**, v. 120, n. 10, p.2095-2107, out. 2015. Disponível em: <http://dx.doi.org/10.1002/2015jg002914>.

CANTY, M. J. **Image analysis, classification and change detection in remote sensing**. Boca Raton, FL: CRC Press, 2007.

CATALUNHA, M. J. et al. Aplicação de cinco funções densidade de probabilidade a séries de precipitação pluvial no Estado de Minas Gerais. **Revista Brasileira de Agrometeorologia**, v. 10, n.1, p. 153-162, 2002.

COPPIN, P.; JONCKHEERE, I.; NACKAERTS, K.; MUYS, B.; LAMBIN, E. Digital change detection methods in ecosystem monitoring: a review. **International Journal of Remote Sensing**, v. 25, n. 9, p. 1565–1596, 2004.

CORDEIRO, G. M., ORTEGA, E. M. M., & SILVA, G. O. The exponentiated generalized gamma distribution with application to lifetime date. **Journal of Statistical Computation and Simulation**, v.81, n.7, p.827-842, 2011.

CORREIA, A. H. **Projeto, desenvolvimento e avaliação de classificadores estatísticos pontuais e contextuais para imagens SAR polarimétricas**. 1998. 271 p. (INPE-7178-TDI/679). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São Jose dos Campos. 1998. Disponível em: <http://urlib.net/sid.inpe.br/deise/1999/09.14.14.45>. Acesso em: 21 jun. 2019.

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

DINIZ, J. M. F. S. **Avaliação do potencial dos dados polarimétricos SENTINEL-1A para mapeamento do uso e cobertura da terra na região de Ariquemes – RO**. 2019. 134 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2019. Disponível em: <http://mtc-m21c.sid.inpe.br/col/sid.inpe.br/mtc-m21c/2019/01.28.12.01/doc/publicacao.pdf>. Acesso em: 19 jun. 2019.

FEARNSIDE, P.M. Desmatamento na Amazônia brasileira: história, índices e conseqüências. **Megadiversidade**, v. 1, n. 4, p. 113-123, 2005.

FEARNSIDE, P.M. Soybean cultivation as a threat to the environmental in Brazil. **Environmental Conservation**. v.28, p. 23-38, 2001.

FEARNSIDE, P.M. Desmatamento na Amazônia: dinâmica, impactos e controle. **Acta Amazônica**, v.36, n.3, p.395-400, 2006. Disponível em: <http://dx.doi.org/10.1590/S0044-59672006000300018>.

FEIZIZADEH, B.; BLASCHKE, T.; TIEDE, D; MOGHADDAM, M. H. R. Evaluating fuzzy operators of an object-based image analysis for detecting landslides and their changes. **Geomorphology**, v.293, p.240–254, 2017. Disponível em: <https://doi.org/10.1016/j.geomorph.2017.06.002>.

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

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: 20 jun. 2019.

GOODMAN, N. R. Statistical analysis based on a certain multivariate complex Gaussian distribution: an introduction. **Annals of Mathematical Statistics**, v.34, p.152-177, 1963.

GUERRA, J. B. **Análise metodológica do tratamento de dados SAR R99B para discriminar incremento de desflorestamento no sudeste da Amazônia brasileira**. 2009. 121p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009. Disponível em: <<http://mtc-m16c.sid.inpe.br/col/sid.inpe.br/mtcm18@80/2009/02.18.14.18/doc/publicacao.pdf>>. Acesso em: 20 jun. 2019.

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.

GUPTA R. C.; GUPTA, P. L.; GUPTA, R. D. Modeling failure time data by Lehman Alternative. **Communication in Statistics - Theory and Methods**, v.27, n.4, p.877-904, 1998.

HAAN, C.T. **Statistical methods in hydrology**. Ames: Iowa State University Press, 1977.

HAGENSIEKER, R.; WASKE, B. Evaluation of multi-frequency SAR images for tropical land cover mapping. **Remote Sensing**, v.10, n.2, p.257, 2018, Disponível em: <https://doi.org/10.3390/rs10020257>.

HENDERSON, F.M.; LEWIS, A.J. **Principles and applications of imaging radar**. 3.ed. New York: John Wiley and Sons, 1998.

HÖBLING, D.; FRIEDL, B.; EISANK, C. An object-based approach for semi-automated landslide change detection and attribution of changes to landslide classes in northern Taiwan. **Earth Science Informatics**, v.8, p.327–335, 2015. Disponível em: <https://doi.org/10.1007/s12145-015-0217-3>.

HUERTAS, D. M. **Da fachada atlântica à imensidão amazônica: fronteira agrícola e integração territorial**. São Paulo: Annablume, 2009.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS - INPE. **Programa de monitoramento da Floresta Amazônica brasileira por satélite – PRODES**. Disponível em: <http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes>. Acesso em: 16 jun. 2019a.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS - INPE. **TerraClass**. Disponível em: < http://www.inpe.br/cra/projetos_pesquisas/dados_terraclass.php>. Acesso em: 16 jun. 2019b.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS – INPE. **Deter**. Disponível em: < http://www.inpe.br/cra/projetos_pesquisas/deter.php>. Acesso em: 16 jun. 2019c.

JENSEN, J. R. **Sensoriamento remoto do ambiente**: uma perspectiva em recursos terrestres. São José dos Campos, SP: Parêntese, 2009. 598 p.

JUNG, S; POLASKY, S. Partnerships to prevent deforestation in the Amazon. **Journal of Environmental Economics and Management**, v. 92, p.498-516, 2018. Disponível em: <http://dx.doi.org/10.1016/j.jeem.2018.11.001>.

KENNEDY, R. E.; COHEN, W. B.; SCHROEDER, T. A. Trajectory-based change detection for automated characterization of forest disturbance dynamics. **Remote Sensing of Environment**, v.110, n.3, p.370-386, 2007.

KLEYNHANS, W.; SALMON, B. P.; WESSELS, K. J.; OLIVIER, J. C. Rapid detection of new and expanding human settlements in the Limpopo province of South Africa using a spatio-temporal change detection method. **International Journal of Applied Earth Observation and Geoinformation**, v.40, p.74–80, 2015. Disponível em: <https://doi.org/10.1016/j.jag.2015.04.009>.

LANDERS, J. N. **Tropical crop-livestock systems in conservation agriculture: the Brazilian experience**. Rome: FAO, 2007. (Integrated Crop Management, 5). Disponível em: <http://www.fao.org/3/aa1083e.pdf>.

LENTON, T. M. et al. Tipping elements in the Earth's climate system. **Proceedings of the National Academy of Sciences**, v. 105, n. 6, p.1786-1793, 2008. Disponível em: <http://dx.doi.org/10.1073/pnas.0705414105>.

LILLESAND, T. M; KIEFER, R. W.; CHIPMAN, J. W. **Remote sensing and image interpretation**. New York: John Wiley & Sons, 2007. 756p.

LIU, J.; GONG, M.; QIN, K.; ZHANG, P. A deep convolutional coupling network for change detection based on heterogeneous optical and radar images. **IEEE Transactions on Neural Networks and Learning Systems**, v.29, p.545–559, 2018a. Disponível em: <https://doi.org/10.1109/TNNLS.2016.2636227>.

LIU, M.; ZHANG, H.; WANG, C.; TANG, Y. Change detection of polarimetric SAR images applied to specific land cover type. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2012, Munich, German. **Proceedings...** IEEE, 2012.

LIU, Q.; HANG, R.; SONG, H.; LI, Z. Learning multiscale deep features for high-resolution satellite image scene classification. **IEEE Transactions on Geoscience and Remote Sensing**, v.56, p.117–126, 2018b. Disponível em: <https://doi.org/10.1109/TGRS.2017.2743243>.

- LIU, T.; ABD-ELRAHMAN, A.; ZARE, A.; DEWITT, B.A.; FLORY, L.; SMITH, S.E. A fully learnable context-driven object-based model for mapping land cover using multi-view data from unmanned aircraft systems. **Remote Sensing of Environment**, v.216, p.328–344, 2018c. Disponível em: <https://doi.org/10.1016/j.rse.2018.06.031>.
- LIU, Y.; REN, Q.; GENG, J.; DING, M. Efficient patch-wise semantic segmentation for large-scale remote sensing images. **Sensors**, v.18, p.1-6, 2018d. Disponível em: <https://doi.org/10.3390/s18103232>.
- LIU, Z.; LI, G.; MERCIER, G.; HE, Y.; PAN, Q. Change detection in heterogeneous remote sensing images via homogeneous pixel transformation. **IEEE Transactions on Image Processing**, v.27, p.1822–1834, 2018e. Disponível em: <https://doi.org/10.1109/TIP.2017.2784560>.
- LO, C. P.; CHOI, J. A hybrid approach to urban land use/cover mapping using Landsat 7 enhanced thematic mapper plus (ETM+) images. **ISPRS Journal of Photogrammetry and Remote Sensing (P&RS)**, v. 25, n. 14, p. 2687-2700, 2004.
- LOPES, A.; LAW, H.; NE-, E. Statistical distribution and texture in multilook and complex SAR images. In: ANNUAL INTERNATIONAL SYMPOSIUM ON GEOSCIENCE AND REMOTE SENSING, 10., 1990. **Proceedings...** IEEE, 1990. p. 2427-2430.
- LOVEJOY, T. E.; NOBRE, C. Amazon tipping point. **Science Advances**, v. 4, n. 2, p.1-2, 2018. Disponível em: <http://dx.doi.org/10.1126/sciadv.aat2340>.
- MALHI, Y. et al. Climate change, deforestation, and the fate of the Amazon. **Science**, v.319, n. 5860, p.169-172, 2008. Disponível em: <http://dx.doi.org/10.1126/science.1146961>.
- MAS, J. F. Monitoring land-cover changes: a comparison of change detection techniques. **International Journal of Remote Sensing**, v.20, p. 139-152, 1999.
- MCNAIRN, H.; CHAMPAGNE, C.; SHANG, J.; HOLMSTROM, D.; REICHERT, G. Integration of optical and Synthetic Aperture Radar (SAR) imagery for delivering operational annual crop inventories. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.64, n.5, p.434-449, 2009.
- MERCIER, G.; DERRODE, S. SAR image change detection using distance between distributions of classes. In: GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2004, 2004, Anchorage, AK. **Proceedings...** Anchorage: IEEE, 2004. p. 3872 – 3875. Disponível em: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=1369969. Acesso em: 20 jun. 2019.
- MONTEIRO, M. Construindo imagens e territórios: pensando a visualidade e a materialidade do sensoriamento remoto. **História, Ciências, Saúde**, v.22, n.2, p.577-591, 2015.

MUDHOLKAR, G. S.; SRIVASTAVA, D. K. Exponentiated Weibull family for analyzing bathtub failure-rate data. **IEEE Transactions on Reliability**, v.42, n.2, p.299-302, 1993.

MÜLLER-HANSEN, F. et al. Can intensification of cattle ranching reduce deforestation in the Amazon? insights from an agent-based social-ecological model. **Ecological Economics**, v. 159, p.198-211, 2019. Disponível em: <http://dx.doi.org/10.1016/j.ecolecon.2018.12.025>.

NEGRI, R.G. **Avaliação de dados polarimétricos do sensor ALOS PALSAR para classificação da cobertura da terra da Amazônia**. 2009. 170 p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009.

NEPSTAD, D. C.; STICKLER, C. M.; ALMEIDA, O. T. Globalization of the Amazon soy and beef industries: opportunities for conservation. **Conservation Biology**, v. 20, n.6, p.1595-1603, 2006. Disponível em: <http://dx.doi.org/10.1111/j.1523-1739.2006.00510.x>.

NOBRE, A. D. **O futuro climático da Amazônia**: relatório de avaliação científica. São José dos Campos: Articulação Regional Amazônica, 2014.

OLIVEIRA, L. J. C. et al. Large-scale expansion of agriculture in Amazonia may be a no-win scenario. **Environmental Research Letters**, v. 8, n. 2, p.198-211, 2013. Disponível em: <http://dx.doi.org/10.1088/1748-9326/8/2/024021>.

OLIVEIRA, S.N.; CARVALHO JUNIOR, O.A.; GOMES, R.A.T.; GUIMARÃES, R.F.; MARTINS, E.S. Detecção de mudança do uso e cobertura da terra usando o método de pós-classificação na fronteira agrícola do Oeste da Bahia sobre o grupo Urucua durante o período 1988-2011. **Revista Brasileira de Cartografia**, n. 66, p.1157-1176, 2014.

OLIVEIRA, W. V. **Desenvolvimento de uma meta-metodologia para classificação contextual que preserve feições estreitas (META-CCP) em imagens digitais**. 2019. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2019.

PACIFI, F.; DEL, F. F.; SOLIMINI, C.; EMERY, W. An innovative neural-net method to detect temporal changes in high-resolution optical satellite imagery. **IEEE Transactions on Geosciences and Remote Sensing**, v. 45, n. 9, p. 2940–2952, 2007.

PANTOJA, N.V.; SAITO, E.A.; FONSECA, L.; ANDERSON, L.O.; SOARES, J.V.; VALERIANO, D. M. Detecção de mudanças a partir de imagens TM/Landsat na Amazônia Sul Ocidental. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14, Natal, RN. **Anais...** São José dos Campos: INPE, 2009. p.6037-6044.

PASCOA, M. A.; ORTEGA, E. M.; CORDEIRO, G. M. The Kumaraswamy generalized gamma distribution with application in survival analysis. **Statistical Methodology**, v. 8, n. 5, p. 411–433, 2011.

PAVANELLI, J. A. P.; SANTOS, J. R.; GALVÃO, L. S.; XAUD, M. R.; XAUD, H. A. M. PALSAR-2/ALOS-2 and OLI/LANDSAT-8 data integration for land use and land cover mapping in northern Brazilian Amazon. **Bulletin of Geodetic Sciences**, v. 24, n.2, p.250-269, 2018.

PEREIRA, L. O. **Avaliação de métodos de integração de imagens ópticas e de radar para a classificação do uso e cobertura da terra na Região Amazônica**. 2012. 134 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2012. Disponível em: <http://mtc-m16d.sid.inpe.br/rep/sid.inpe.br/mtc-m19/2012/08.30.12.50?mirror=sid.inpe.br/mtc-m19@80/2009/08.21.17.02.53&metadatarepository=sid.inpe.br/mtc-m19/2012/08.30.12.50.42>. Acesso em: 19 jun. 2019.

PERZ, S. G.; SKOLE, D. L. Secondary forest expansion in the Brazilian Amazon and the refinement of forest transition theory. **Society & Natural Resources**, v. 16, n. 4, p.277-294, 2003. Disponível em: <http://dx.doi.org/10.1080/08941920390178856>.
QIN, D.; JIANWEN; M.; YUN, O. Y. Remote sensing data change detection based on the CI test of Bayesian networks. **Computers & Geosciences**, v. 32, p. 195-202, 2006.

RADKE, R. J.; ANDRA, S.; AL-KOFAHI, O.; ROYSAM, B. Image change detection algorithms: a systematic survey. **IEEE Transactions on Image Processing**, v. 14, n. 3, p. 294–307, 2005.

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

RAWAT, J. S.; KUMAR, M.; BISWAS V. Land use/cover dynamics using multi-temporal satellite imagery: a case study of Haldwani Town area, district Nainital, Uttarakhand, India. **ISPRS Journal of Photogrammetry and Remote Sensing (P&RS)**, v. 4, n. 3, p. 536-543, 2014.

REIS, M. S. **Deteção de mudanças de uso e cobertura da terra utilizando dados ópticos e de micro-ondas em uma região da Amazônia brasileira**. 2014. 331 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2014. Disponível em: <<http://mtc-m21b.sid.inpe.br/col/sid.inpe.br/mtcm21b/2014/06.30.19.09/doc/publicacao.pdf>>. Acesso em: 19 jun. 2019.

RICHARDS, J. A.; JIA, X. **Remote sensing digital image analysis: an introduction**. 4.ed. Berlin: Springer-Verlag, 2006. 439 p.

RICHARDS, P. et al. Are Brazil's deforesters avoiding detection? **Conservation Letters**, v. 10, n. 4, p.470-476, 2016. Disponível em: <http://dx.doi.org/10.1111/conl.12310>.

ROSENQVIST, A.; MILNE, A.; LUCAS, R.; IMHOFF, M.; DOBSON, C. A review of remote sensing technology in support of the Kyoto Protocol. **Environment Science & Policy**, v. 6, n. 5, p. 441-455, 2003.

SCHLEHER, D.C. Radar detection in log-normal clutter. In: IEEE INTERNATIONAL RADAR CONFERENCE, 1975. **Proceedings...** IEEE, 1975.

SCHLEHER, D.C. Radar detection in weibull clutter. **IEEE Transactions on Aerospace and Electronic Systems**, v.12, n. 6, p.736-741, 1976.

SCHMULLIUS, C. et al. Radar time series for land cover and forest mapping. In: KUENZER, C; DECH, S.; WAGNER, W. (Ed.). **Remote sensing and digital image processing**. Berlin: Springer, 2015. p. 323-356.

SELCUK, R.; NISANCI, R.; UZUN, B.; YALCIN, A.; INAN, H.; YOMRALIOGLU, T. **Monitoring land-use changes by GIS and remote sensing techniques: case study of Trabzon**. 2003. Disponível em: https://www.fig.net/resources/proceedings/fig_proceedings/morocco/proceedings/TS18/TS18_6_reis_el_al.pdf. Acesso em: 28 dez. 2018.

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

SOARES-FILHO, B. et al. Cracking Brazil's Forest Code. **Science**, v. 344, n. 6182, p.363-364, 2014. Disponível em: <http://dx.doi.org/10.1126/science.1246663>.

SOUZA, N. S. A Amazônia brasileira: processo de ocupação e a devastação da floresta. **Boletim Científico ESMPU**, Brasília, v. 33, n. 32, p.199-235, 2010.

SRIVASTAVA, M.S. On the complex Wishart distribution. **The Annals of Mathematical Statistics**, p. 313-315, 1964.

TEIXEIRA, W.; PINHEIRO, E. Uso de imagens R99-SAR/SIPAM no programa de monitoramento do desmatamento da floresta amazônica brasileira. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17., 2015, João Pessoa. **Anais...** São José dos Campos, INPE, 2015.

VIEIRA, P. R. **Desenvolvimento de classificadores de máxima verossimilhança e ICM para imagens SAR**. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1996. Disponível em: <http://mtc-m12.sid.inpe.br/col/sid.inpe.br/deise/1999/09.14.14.45/doc/publicacao.pdf>

WARD, K.D.; TOUGH, R.J.A; WATTS, S. Sea clutter: scattering, the K distribution and radar performance. **Waves in Random and Complex Media**, v. 17, n. 2, p.233–234, 2007.

WIEDERKEHR, N. C. **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**. 2018. 146 p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018. Disponível em: <http://urlib.net/8JMKD3MGP3W34P/3QE2MAL>. Acesso em: 20 jun. 2019.

YANASSE, C. C. F.; FRERY, A. C.; SANT'ANNA, S. J. S.; DUTRA, L. V. On the Use of Multilook Amplitude K Distribution for SAR Image Analysis. In:

INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 1994, Pasadena, CA. **Proceedings...** IEEE, 1994.

ZEMP, D. C. et al. Deforestation effects on Amazon forest resilience. **Geophysical Research Letters**, v. 44, n. 12, p. 6182-6190, 2017. Disponível em:

<http://dx.doi.org/10.1002/2017gl072955>.

ZHOU, Q.; LI, B.; KURBAN, A. Trajectory analysis of land cover change in arid environment of China. **International Journal of Remote Sensing**, v. 29, n. 4, p. 1093-1107, 2008.

APÊNDICE A – MATRIZES DE CONFUSÃO

A.1. Matrizes de confusão para a classificação MAXVER-ICM do ano de 2014

Tabela A.1 - Matriz de confusão do conjunto $\{L_{HH}\}$ do ano de 2014, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	89,17	45,74	0,32	5,77	26,92
	PS	0	10,22	32,48	8,57	5,10	9,93
	PL	0	0,61	21,78	86,19	81,52	35,33
	AG	0	0,00	0,00	4,92	7,61	2,42
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,54					
AC	0,63						

Fonte: Produção da Autora.

Tabela A.2 - Matriz de confusão do conjunto $\{L_{VH}\}$ do ano de 2014, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	84,09	24,05	0,24	0	21,11
	PS	0	15,91	59,66	7,06	0	14,23
	PL	0	0	15,11	40,24	13,75	12,18
	AG	0	0	1,18	52,45	86,25	27,08
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,67					
AC	0,74						

Fonte: Produção da Autora.

Tabela A.3- Matriz de confusão do conjunto $\{L_{VV}\}$ do ano de 2014, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	90,01	46,82	1,95	6,92	27,78
	PS	0	9,72	29,55	2,81	14,81	10,39
	PL	0	0,28	23,64	94,28	78,27	36,26
	AG	0	0	0	0,97	0	0,16
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,53					
AC	0,63						

Fonte: Produção da Autora.

Tabela A.4 - Matriz de confusão do conjunto $\{C_{VV}\}$ do ano de 2014, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	64,28	59,00	2,86	0,06	23,27
	PS	0	23,50	26,81	23,37	0,27	13,21
	PL	0	6,55	9,34	12,53	1,08	5,22
	AG	0	5,67	4,85	61,24	98,58	32,90
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,50					
AC	0,60						

Fonte: Produção da Autora.

Tabela A.5- Matriz de confusão do conjunto $\{C_{VH}\}$ do ano de 2014, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	73,82	58,46	19,17	0	27,88
	PS	0	2,06	0,77	0,82	0	0,69
	PL	0	23,84	40,76	62,77	1,51	22,51
	AG	0	0,27	0	17,25	98,49	23,52
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,59					
AC	0,67						

Fonte: Produção da Autora.

Tabela A.6 - Matriz de confusão do conjunto $\{L_{HH}, L_{VH}\}$ do ano de 2014, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	61,36	24,23	0,08	1,64	16,82
	PS	0	38,64	55,11	6,91	0,00	18,09
	PL	0	0	20,66	79,35	11,67	19,29
	AG	0	0	0,00	13,66	86,69	20,40
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,70					
	AC	0,76					

Fonte: Produção da Autora.

Tabela A.7 - Matriz de confusão do conjunto $\{L_{VH}, L_{VV}\}$ do ano de 2014, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	65,82	21,18	0,08	0	16,89
	PS	0	34,18	59,06	6,75	0	17,80
	PL	0	0	19,76	92,83	38,79	27,09
	AG	0	0	0	0,33	61,21	12,82
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,70					
	AC	0,76					

Fonte: Produção da Autora.

Tabela A.8- Matriz de confusão do conjunto $\{L_{HH}, L_{VV}\}$ do ano de 2014, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	64,68	31,39	0,32	1,20	18,63
	PS	0	35,32	50,15	8,38	11,53	19,25
	PL	0	0	18,46	91,29	75,64	34,30
	AG	0	0	0	0	11,62	2,42
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,54					
	AC	0,63					

Fonte: Produção da Autora.

Tabela A.9- Matriz de confusão do conjunto $\{C_{VH}, C_{VV}\}$ do ano de 2014, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0,41	0	0	25,40
	VS	0	43,64	38,88	0,66	0,34	15,45
	PS	0	37,73	32,91	12,27	0	15,17
	PL	0	18,43	28,21	74,06	4,26	21,84
	AG	0	0,21	0	13,01	95,40	22,15
	TOTAL (%)	100	100	100	100	100	100
		kappa	0,61				
		AC	0,69				

Fonte: Produção da Autora.

Tabela A.10- Matriz de confusão do conjunto $\{L_{HH}, C_{VH}\}$ do ano de 2014, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	30,08	17,49	0,16	2,38	9,52
	PS	0	69,78	65,89	8,47	1,22	26,71
	PL	0	0	16,63	79,97	1,85	16,69
	AG	0	0,14	0	11,40	94,54	21,68
	TOTAL (%)	100	100	100	100	100	100
		kappa	0,68				
		AC	0,74				

Fonte: Produção da Autora.

Tabela A.11- Matriz de confusão do conjunto $\{L_{HH}, C_{VV}\}$ do ano de 2014, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	39,98	21,46	0,16	0,79	11,85
	PS	0	59,55	66,32	9,05	6,85	25,97
	PL	0	0	11,21	68,08	29,65	19,58
	AG	0	0,47	1,02	22,71	62,71	17,20
	TOTAL (%)	100	100	100	100	100	100
		kappa	0,59				
		AC	0,67				

Fonte: Produção da Autora.

Tabela A.12- Matriz de confusão do conjunto $\{L_{VH}, C_{VH}\}$ do ano de 2014, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	42,90	14,29	0	0	11,08
	PS	0	57,10	67,29	5,47	0	23,60
	PL	0	0	18,42	80,40	4,02	17,51
	AG	0	0	0	14,14	95,98	22,41
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,72					
AC	0,77						

Fonte: Produção da Autora.

Tabela A.13- Matriz de confusão do conjunto $\{L_{VH}, C_{VV}\}$ do ano de 2014, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	44,50	15,59	0	0	11,62
	PS	0	55,50	67,61	6,45	0	23,49
	PL	0	0	16,73	58,09	11,77	15,06
	AG	0	0	0,09	35,47	88,23	24,43
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,65					
AC	0,72						

Fonte: Produção da Autora.

Tabela A.14- Matriz de confusão do conjunto $\{L_{VV}, C_{VH}\}$ do ano de 2014, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	40,50	15,16	1,11	3,00	11,55
	PS	0	58,60	65,51	2,68	0	23,14
	PL	0	0,56	18,82	91,56	2,81	19,33
	AG	0	0,34	0,50	4,64	94,20	20,58
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,73					
AC	0,78						

Fonte: Produção da Autora.

Tabela A.18- Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, C_{VH}\}$ do ano de 2014, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	71,16	24,46	0,08	0	18,51
	PS	0	28,84	57,00	6,84	0	16,39
	PL	0	0	18,55	83,58	1,45	17,53
	AG	0	0	0	9,51	98,55	22,17
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,77					
AC	0,82						

Fonte: Produção da Autora.

Tabela A.19- Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, C_{VV}\}$ do ano de 2014, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	62,06	23,76	0,08	0,20	16,59
	PS	0	37,94	59,95	6,67	0	18,70
	PL	0	0	16,21	67,52	2,66	14,67
	AG	0	0	0,09	25,74	97,14	24,64
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,72					
AC	0,77						

Fonte: Produção da Autora.

Tabela A.20- Matriz de confusão do conjunto $\{L_{HH}, L_{VV}, C_{VH}\}$ do ano de 2014, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	73,81	31,42	0,87	0,62	20,46
	PS	0	25,57	50,94	3,67	0	14,19
	PL	0	0,62	17,65	88,16	0,87	18,17
	AG	0	0	0	7,30	98,51	21,78
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,78					
AC	0,82						

Fonte: Produção da Autora.

Tabela A.21- Matriz de confusão do conjunto $\{L_{HH}, L_{VV}, C_{VV}\}$ do ano de 2014, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0,00	0	0	0	25,40
	VS	0	74,90	35,5	0,08	0,20	21,14
	PS	0	24,16	48,79	5,26	0,06	13,83
	PL	0	0	15,09	82,55	38,78	24,57
	AG	0	0,94	0,52	12,12	60,95	15,05
	TOTAL (%)	100	100	100	100	100	100
		kappa	0,67				
		AC	0,73				

Fonte: Produção da Autora.

Tabela A.22- Matriz de confusão do conjunto $\{L_{VH}, L_{VH}, C_{VV}\}$ do ano de 2014, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	66,77	18,28	0	0	16,59
	PS	0	33,23	66,53	6,28	0	18,75
	PL	0	0	15,18	80,35	3,05	16,77
	AG	0	0	0	13,37	96,95	22,49
	TOTAL (%)	100	100	100	100	100	100
		kappa	0,78				
		AC	0,82				

Fonte: Produção da Autora.

Tabela A.23- Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VH}\}$ do ano de 2014, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	75,92	24,06	0	0	19,40
	PS	0	24,08	58,72	6,82	0	15,70
	PL	0	0	17,22	86,20	0,13	17,48
	AG	0	0	0	6,98	99,87	22,01
	TOTAL (%)	100	100	100	100	100	100
		kappa	0,80				
		AC	0,84				

Fonte: Produção da Autora.

Tabela A.24- Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VV}\}$ do ano de 2014, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	71,75	24,01	0	0	18,55
	PS	0	28,25	60,79	6,90	0,13	16,93
	PL	0	0	15,20	80,27	9,15	18,03
	AG	0	0	0	12,83	90,72	21,10
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,76					
	AC	0,81					

Fonte: Produção da Autora.

Tabela A.25- Matriz de confusão do conjunto $\{L_{VV}, C_{VH}, C_{VV}\}$ do ano de 2014, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	67,18	30,90	0,71	0	18,87
	PS	0	32,68	53,08	3,08	0	15,89
	PL	0	0	16,01	87,71	3,90	18,33
	AG	0	0,14	0	8,49	96,10	21,51
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,76					
	AC	0,80					

Fonte: Produção da Autora.

Tabela A.26- Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, C_{VH}, C_{VV}\}$ do ano de 2014, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	62,21	24,58	0,08	0	16,71
	PS	0	37,79	59,81	6,44	0	18,60
	PL	0	0	15,61	82,91	1,37	16,92
	AG	0	0	0,00	10,58	98,63	22,36
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,76					
	AC	0,81					

Fonte: Produção da Autora.

Tabela A.27- Matriz de confusão do conjunto $\{L_{HH}, L_{VV}, C_{VH}, C_{VV}\}$ do ano de 2014, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	71,79	33,60	0,08	1,01	20,35
	PS	0	28,07	51,04	4,62	0,00	14,88
	PL	0	0	15,28	87,91	2,20	17,89
	AG	0	0,14	0,08	7,39	96,79	21,48
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,77					
	AC	0,81					

Fonte: Produção da Autora.

Tabela A.28- Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ do ano de 2014, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	75,26	24,34	0	0	19,31
	PS	0	24,74	60,64	6,82	0	16,15
	PL	0	0	15,02	86,51	0,27	17,20
	AG	0	0	0	6,67	99,73	21,93
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,80					
	AC	0,84					

Fonte: Produção da Autora.

Tabela A.29- Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ do ano de 2014, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	100	0	0	0	0	25,40
	VS	0	72,67	24,47	0,08	0,20	18,86
	PS	0	27,33	59,64	6,82	0	16,51
	PL	0	0	15,89	85,87	0,40	17,26
	AG	0	0	0	7,23	99,40	21,96
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,79					
	AC	0,83					

Fonte: Produção da Autora.

A.2. Matrizes de confusão para a classificação MAXVER-ICM do ano de 2016

Tabela A.30 - Matriz de confusão do conjunto $\{L_{HH}\}$ do ano de 2016, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	79,96	13,86	60,96	9,57	13,88	37,61
	VS	11,69	53,33	23,70	52,52	25,55	32,20
	PS	8,03	2,22	15,34	4,69	1,11	6,46
	PL	0,32	29,65	0	16,97	37,75	15,62
	AG	0	0,94	0	16,25	21,72	8,11
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,22					
AC	0,37						

Fonte: Produção da Autora.

Tabela A.31 - Matriz de confusão do conjunto $\{L_{VH}\}$ do ano de 2016, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	47,64	0	27,77	0,19	0	16,70
	VS	2,03	68,08	24,38	66,80	4,20	31,36
	PS	50,32	7,26	47,85	3,71	0	23,03
	PL	0	4,06	0	2,64	0,39	1,28
	AG	0	20,61	0	26,66	95,41	27,63
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,40					
AC	0,52						

Fonte: Produção da Autora.

Tabela A.32 - Matriz de confusão do conjunto $\{L_{VV}\}$ do ano de 2016, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	82,43	1,58	56,95	7,05	11,39	34,58
	VS	8,34	44,28	28,44	43,51	25,23	28,83
	PS	9,22	6,35	13,81	7,41	4,92	8,43
	PL	0	47,79	0,80	40,97	52,48	26,76
	AG	0	0	0	1,06	5,98	1,40
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,22					
AC	0,37						

Fonte: Produção da Autora.

Tabela A.33 - Matriz de confusão do conjunto $\{C_{VV}\}$ do ano de 2016, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	96,39	14,51	87,75	10,53	2,07	44,66
	VS	0,00	0,00	0,00	0,00	0,00	0,00
	PS	0,00	0,00	0,00	0,00	0,00	0,00
	PL	3,54	27,10	9,25	29,45	45,14	22,11
	AG	0,07	58,39	3,00	60,02	52,79	33,23
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,20					
AC	0,36						

Fonte: Produção da Autora.

Tabela A.34 - Matriz de confusão do conjunto $\{C_{VH}\}$ do ano de 2016, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	94,03	17,00	84,80	12,23	0	43,89
	VS	2,14	5,18	6,39	2,51	2,23	3,49
	PS	0	0	0	0	0	0,00
	PL	3,83	23,44	6,57	14,07	1,13	9,06
	AG	0	54,38	2,24	71,19	96,64	43,56
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,27					
AC	0,42						

Fonte: Produção da Autora.

Tabela A.35 - Matriz de confusão do conjunto $\{L_{HH}, L_{VH}\}$ do ano de 2016, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	41,54	0	27,44	0,20	0	15,18
	VS	0,69	30,13	21,81	34,01	0,08	16,61
	PS	57,77	9,26	50,51	10,54	8,13	28,77
	PL	0	60,61	0,24	48,29	35,69	26,98
	AG	0	0	0	6,96	56,10	12,46
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,32					
	AC	0,45					

Fonte: Produção da Autora.

Tabela A.36 - Matriz de confusão do conjunto $\{L_{VH}, L_{VV}\}$ do ano de 2016, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	59,87	0	0	1,87	0	16,01
	VS	1,99	40,34	25,06	42,15	2,38	21,04
	PS	38,13	7,48	74,37	3,70	1,52	21,24
	PL	0	51,42	0,58	47,64	51,73	31,09
	AG	0	0,76	0,00	4,64	44,38	10,61
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,42					
	AC	0,53					

Fonte: Produção da Autora.

Tabela A.37 - Matriz de confusão do conjunto $\{L_{HH}, L_{VV}\}$ do ano de 2016, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	88,47	7,51	57,63	8,16	21,05	39,14
	VS	2,12	9,72	9,07	18,48	2,83	8,49
	PS	2,20	4,61	13,01	6,28	0,00	5,13
	PL	1,29	67,09	3,76	54,82	64,18	35,92
	AG	5,92	11,08	16,53	12,26	11,94	11,33
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,19					
	AC	0,35					

Fonte: Produção da Autora.

Tabela A.38 - Matriz de confusão do conjunto $\{C_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	60,11	4,71	46,23	3,22	0	24,58
	VS	13,35	16,22	22,39	10,47	2,32	12,69
	PS	24,14	1,78	27,11	4,94	0	12,33
	PL	1,95	34,88	2,81	16,26	1,51	10,14
	AG	0,45	42,42	1,46	65,11	96,16	40,27
	TOTAL (%)	100	100	100	100	100	100
		kappa	0,29				
		AC	0,43				

Fonte: Produção da Autora.

Tabela A.39 - Matriz de confusão do conjunto $\{L_{HH}, C_{VH}\}$ do ano de 2016, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	65,29	13,45	49,76	13,02	13,13	32,57
	VS	2,02	9,32	11,75	14,53	0	7,45
	PS	23	6,83	31	6,25	0,49	13,93
	PL	0,63	64,11	1,79	52,43	64,86	34,53
	AG	9,05	6,29	5,71	13,77	21,52	11,52
	TOTAL (%)	100	100	100	100	100	100
		kappa	0,20				
		AC	0,36				

Fonte: Produção da Autora.

Tabela A.40 - Matriz de confusão do conjunto $\{L_{HH}, C_{VV}\}$ do ano de 2016, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	41,15	3,25	30,13	4,83	7,48	18,6
	VS	4,71	4,17	10,04	7,79	4,18	6,26
	PS	52,57	7,34	53,88	6,13	2,22	25,72
	PL	0,69	40,87	0,71	36,44	61,36	26,57
	AG	0,87	44,38	5,24	44,81	24,75	22,85
	TOTAL (%)	100	100	100	100	100	100
		kappa	0,15				
		AC	0,32				

Fonte: Produção da Autora.

Tabela A.41 - Matriz de confusão do conjunto $\{L_{VH}, C_{VH}\}$ do ano de 2016, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	59,61	0	28,89	2,41	0	20,29
	VS	0,63	33,06	21,36	43,03	3,97	19,79
	PS	39,76	8,54	49,75	1,98	0	20,65
	PL	0	50,16	0	36,26	8,7	17,40
	AG	0	8,25	0	16,32	87,33	21,87
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,41					
	AC	0,53					

Fonte: Produção da Autora.

Tabela A.42 - Matriz de confusão do conjunto $\{L_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	41,19	0	26,76	0,66	0	15,08
	VS	0,5	24,98	12,83	29,04	2,06	13,34
	PS	58,3	6,82	60,41	2,21	0	26,91
	PL	0	59,49	0	51,51	9,73	22,50
	AG	0	8,71	0	16,58	88,2	22,16
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,41					
	AC	0,53					

Fonte: Produção da Autora.

Tabela A.43 - Matriz de confusão do conjunto $\{L_{VV}, C_{VH}\}$ do ano de 2016, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	67,91	1,07	37,57	1,42	10,89	25,95
	VS	3,5	29,78	16,83	25,3	10,18	16,21
	PS	16,12	5,89	21,82	2,93	0	9,53
	PL	1,17	53,37	6,95	53	60,69	33,41
	AG	11,31	9,89	16,84	17,35	18,24	14,9
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,23					
	AC	0,38					

Fonte: Produção da Autora.

Tabela A.44 - Matriz de confusão do conjunto $\{L_{VV}, C_{VV}\}$ do ano de 2016, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	55,67	0	32,22	1,1	8,03	21,23
	VS	1,67	4,21	7,07	2,12	0,4	2,92
	PS	38,38	7,14	44,02	4,78	0	19,68
	PL	0,26	70,85	4,17	63,04	69,1	39,16
	AG	4,03	17,79	12,52	28,96	22,47	17,01
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,22					
	AC	0,38					

Fonte: Produção da Autora.

Tabela A.45 - Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, L_{VV}\}$ do ano de 2016, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	37,96	0	27,29	0	0	14,25
	VS	4,72	33,53	25,28	41,06	0,08	20,37
	PS	57,33	8,09	47,36	6,89	3,82	26,21
	PL	0	58,38	0,07	51,62	58,56	31,81
	AG	0	0	0	0,44	37,54	7,36
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,27					
	AC	0,42					

Fonte: Produção da Autora.

Tabela A.46 - Matriz de confusão do conjunto $\{L_{HH}, C_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	89,93	5,04	0	0,65	0	25,91
	VS	7,49	8,05	52	9,23	0	9,11
	PS	2,46	4,09	32,52	2,08	0	3,93
	PL	0,13	45,06	1,73	26,88	8,49	16,87
	AG	0	37,76	13,74	61,16	91,51	44,18
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,37					
	AC	0,50					

Fonte: Produção da Autora.

Tabela A.47 - Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, C_{VH}\}$ do ano de 2016, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	54,61	0	29,28	0	0	18,61
	VS	0,9	22,84	20,80	31,62	3,18	15,46
	PS	44,49	5,47	49,92	4,37	0	21,93
	PL	0	67,91	0	53,34	7,51	23,72
	AG	0	3,78	0	10,67	89,31	20,29
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,42					
AC	0,54						

Fonte: Produção da Autora.

Tabela A.48 - Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	27,22	0	17,71	0,73	0	10,04
	VS	1,45	26,85	16,78	34,81	3,65	16,24
	PS	71,33	5,15	65,34	4,49	0	31,25
	PL	0	66,5	0,17	48,18	13,25	23,46
	AG	0	1,5	0	11,79	83,11	19,02
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,38					
AC	0,50						

Fonte: Produção da Autora.

Tabela A.49 - Matriz de confusão do conjunto $\{L_{HH}, L_{VV}, C_{VH}\}$ do ano de 2016, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	70,08	0,21	50,09	1,69	0	26,68
	VS	4,51	15,44	21,4	14,22	0	10,7
	PS	25,4	6,52	24,64	1,56	0	12,06
	PL	0	73,41	2,01	67,17	70,72	40,33
	AG	0	4,42	1,86	15,36	29,28	10,23
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,27					
AC	0,41						

Fonte: Produção da Autora.

Tabela A.50 - Matriz de confusão do conjunto $\{L_{HH}, L_{VV}, C_{VV}\}$ do ano de 2016, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	29,31	0,42	16,61	3,72	0,95	11,27
	VS	7,45	25,51	18,94	30,85	9,11	18,02
	PS	63,11	6,2	60,66	4,02	0,31	28,5
	PL	0	67,22	1,30	60,61	74,55	38,51
	AG	0,13	0,65	2,48	0,8	15,09	3,7
	TOTAL (%)	100	100	100	100	100	100
		kappa	0,23				
		AC	0,38				

Fonte: Produção da Autora.

Tabela A.51 - Matriz de confusão do conjunto $\{L_{VH}, C_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	45,88	24,43	0	0	0	15,6
	VS	53,22	59,76	6,61	2,32	0	25,57
	PS	0,9	15,81	23,38	30,73	2,4	14,23
	PL	0	0	60,4	51,96	5,5	21,92
	AG	0	0	9,61	14,99	92,1	22,68
	TOTAL (%)	100	100	100	100	100	100
		kappa	0,43				
		AC	0,55				

Fonte: Produção da Autora.

Tabela A.52 - Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VH}\}$ do ano de 2016, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	42,48	0	28,6	0,74	0	15,75
	VS	0,38	28,34	18,06	32,98	3,89	16,07
	PS	57,14	5,15	53,01	3,51	0	25,29
	PL	0	65,87	0,33	52,69	14,08	24,61
	AG	0	0,64	0	10,08	82,03	18,29
	TOTAL (%)	100	100	100	100	100	100
		kappa	0,40				
		AC	0,52				

Fonte: Produção da Autora.

Tabela A.53 - Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VV}\}$ do ano de 2016, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	32,84	0	23,57	3,26	0	13,08
	VS	0,89	29,89	16,26	37,29	3,89	17,07
	PS	66,26	5,15	58,32	1,99	0	28,12
	PL	0	63,65	1,85	51,79	37,15	28,82
	AG	0	1,31	0	5,67	58,95	12,9
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,33					
	AC	0,46					

Fonte: Produção da Autora.

Tabela A.54 - Matriz de confusão do conjunto $\{L_{VV}, C_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	67,2	2,1	39,09	1,23	0	24,07
	VS	6,46	6,3	16,65	5,52	0	6,91
	PS	26,34	4,62	39,97	2,57	0	15,16
	PL	0	76,54	1,29	69,84	60,1	39,22
	AG	0	10,43	3	20,84	39,9	14,64
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,31					
	AC	0,45					

Fonte: Produção da Autora.

Tabela A.55 - Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, C_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).

	REFERÊNCIA						
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	40,56	0	25,19	0	0	14,48
	VS	0,38	24,65	16,88	29,5	3,89	14,5
	PS	59,06	5,25	57,93	5,36	0	27,13
	PL	0	64,52	0	54,66	7,84	23,6
	AG	0	5,58	0	10,47	88,26	20,3
	TOTAL (%)	100	100	100	100	100	100
	kappa	0,41					
	AC	0,53					

Fonte: Produção da Autora.

Tabela A.56 - Matriz de confusão do conjunto $\{L_{HH}, L_{VV}, C_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	62,11	1,37	40,20	1,17	0	22,94
	VS	5,07	11,85	16,68	13,84	0	9,32
	PS	32,83	5,76	38,01	2,36	0	16,45
	PL	0	78,57	1,29	67,79	64,69	39,92
	AG	0	2,45	3,83	14,84	35,31	11,36
	TOTAL (%)	100	100	100	100	100	100
		kappa	0,29				
		AC	0,43				

Fonte: Produção da Autora.

Tabela A.57 - Matriz de confusão do conjunto $\{L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	46,03	26,19	0	0,55	0	16,1
	VS	52,25	56,9	5,14	3,1	0	24,76
	PS	1,72	16,51	26,36	31,41	3,89	15,44
	PL	0	0,41	67,96	54,99	16,17	25,86
	AG	0	0	0,53	9,94	79,93	17,84
	TOTAL (%)	100	100	100	100	100	100
		kappa	0,41				
		AC	0,53				

Fonte: Produção da Autora.

Tabela A.58 - Matriz de confusão do conjunto $\{L_{HH}, L_{VH}, L_{VV}, C_{VH}, C_{VV}\}$ do ano de 2016, representada em (%).

		REFERÊNCIA					
		FP	VS	PS	PL	AG	TOTAL (%)
CLASSIFICAÇÃO	FP	40,64	0	32,93	0	0,	15,96
	VS	1,66	26,36	17,72	31,46	3,65	15,62
	PS	57,71	5,25	49,35	5,76	0	25,27
	PL	0	68,39	0	55,01	20,76	26,74
	AG	0	0	0	7,77	75,6	16,41
	TOTAL (%)	100	100	100	100	100	100
		kappa	0,37				
		AC	0,49				

Fonte: Produção da Autora.