



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

sid.inpe.br/mtc-m21c/2019/01.28.12.01-TDI

**AVALIAÇÃO DO POTENCIAL DOS DADOS
POLARIMÉTRICOS SENTINEL-1A PARA
MAPEAMENTO DO USO E COBERTURA DA TERRA
NA REGIÃO DE ARIQUEMES - RO**

Juliana Maria Ferreira de Souza Diniz

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelo Dr. Fábio Furlan Gama,
aprovada em 15 de fevereiro de
2019.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3SL65N8>>

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:

Dr. 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)

Murilo Luiz Silva Gino - Serviço de Informação e Documentação (SESID)



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

sid.inpe.br/mtc-m21c/2019/01.28.12.01-TDI

**AVALIAÇÃO DO POTENCIAL DOS DADOS
POLARIMÉTRICOS SENTINEL-1A PARA
MAPEAMENTO DO USO E COBERTURA DA TERRA
NA REGIÃO DE ARIQUEMES - RO**

Juliana Maria Ferreira de Souza Diniz

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelo Dr. Fábio Furlan Gama,
aprovada em 15 de fevereiro de
2019.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3SL65N8>>

INPE
São José dos Campos
2019

Dados Internacionais de Catalogação na Publicação (CIP)

Diniz, Juliana Maria Ferreira de Souza.

D615a Avaliação do potencial dos dados polarimétricos Sentinel-1A para mapeamento do uso e cobertura da terra na região de Ariquemes - RO / Juliana Maria Ferreira de Souza Diniz. – São José dos Campos : INPE, 2019.

xxvi + 134 p. ; (sid.inpe.br/mtc-m21c/2019/01.28.12.01-TDI)

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

Orientador : Dr. Fábio Furlan Gama.

1. Aprendizagem de máquina. 2. Simulação de Monte Carlo. 3. Radares de abertura sintética. 4. Banda C. 5. Floresta Amazônica. I.Título.

CDU 528.8:332.3(811.1)



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): *Juliana Maria Ferreira de Souza Diniz*

Título: "AVALIAÇÃO DO POTENCIAL DOS DADOS POLARIMÉTRICOS SENTINEL-1A PARA MAPEAMENTO DO USO E COBERTURA DA TERRA NA REGIÃO DE ARIQUEMES - RO"

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

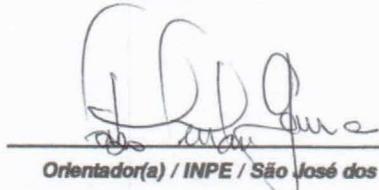
Dr. Yosio Edemir Shimabukuro


Presidente / INPE / São José dos Campos - SP

() Participação por Vídeo - Conferência

Aprovado () Reprovado

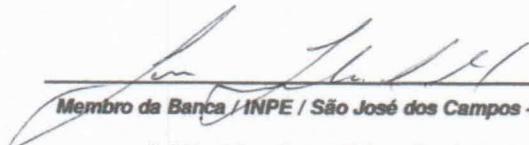
Dr. Fábio Furlan Gama


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

() Participação por Vídeo - Conferência

Aprovado () Reprovado

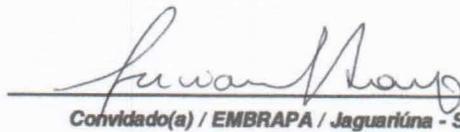
Dr. José Claudio Mura


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

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Dra. Luciana Spinelli Araujo


Convidado(a) / EMBRAPA / Jaguariúna - SP

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Este trabalho foi aprovado por:

() maioria simples

unanimidade

São José dos Campos, 15 de fevereiro de 2019

“Para realizar grandes conquistas, devemos não apenas agir, mas também sonhar, não apenas planejar, mas também acreditar.”

Anatole France

A meus pais Ana Rita e Julio....

AGRADECIMENTOS

Ao meu orientador Doutor Fabio Furlan Gama, por ter me guiado durante essa trajetória, compartilhando conhecimentos e experiências. Obrigada pela dedicação, paciência, disposição, confiança e amizade.

Ao Instituto Nacional de Pesquisas Espaciais pela oportunidade de cursar o mestrado em Sensoriamento Remoto. Ao programa de Sensoriamento Remoto, pelos ensinamentos compartilhados durante esses dois anos e em especial pelo apoio ao trabalho de campo, que foi fundamental para essa pesquisa.

Aos doutores Yosio Edemir Shimabukuro e José Claudio Mura, por todas as sugestões durante a proposta desta dissertação, e por aceitarem o convite para participarem da banca examinadora. À Doutora Luciana Spinelli, pesquisadora da Embrapa, por ter aceitado o convite para compor a banca examinadora, e pela sua disponibilidade em comparecer no INPE.

Aos meus pais, Ana Rita e Julio, agradeço por serem essas pessoas tão maravilhosas, que estão sempre ao meu lado, me apoiando e incentivando. Pai, você é o porto seguro, pra onde eu sei que sempre vou poder ir quando alguma coisa der errada, obrigada pelo incentivo constante. Mãe, você é a minha melhor amiga, obrigada por estar ao meu lado sempre e por, mesmo sem entender nada de radar, ler a minha dissertação e me ajudar quando faltava inspiração. Ter você ao meu lado, nesses últimos dias escrevendo, fez toda a diferença.

Agradeço à minha família, pelo apoio incondicional em todos os momentos da minha vida, sempre torcendo e incentivando. Aos meus avós, vó Walderez, vó Verinha e vô Lafaiete pelas orações e torcida de sempre. Aos meus tios, Tia Miriam, Tio Fred e Tio Daniel pelos momentos de alegria que sempre passamos juntos e pela confiança que vocês sempre têm em mim. Lu, nossa escritora, obrigada pela torcida e apoio e o nosso pequeno João, que veio trazer alegria aos nossos dias.

Ao Alisson, meu amor, por ser esse apoio constante, sempre incentivando o meu crescimento profissional e pessoal. Obrigada pelo companheirismo, amizade, paciência e pelos momentos de descontração nos dias mais tensos. Obrigada por fazer parte de mais essa conquista!

Aos queridos amigos que o INPE me presenteou: Ana Carolina, Debora, Daniel, Jessica e Wesley. Vocês não foram apenas amigos nestes dois anos, vocês se tornaram família. Carol, obrigada pela sua espontaneidade, que deixa a vida muito mais gostosa e obrigada por todos os comentários na dissertação. Debora, as segundas-feiras não são mais as mesmas, obrigada por todos os conselhos nesta etapa e, principalmente, obrigada pela nossa princesinha Alice. Jessica, os dias em que você vai pra São José são os melhores, obrigada por estar sempre presente, mesmo distante e por sempre me ajudar. Wesley, você é a inspiração para os nossos mapas e fluxogramas, obrigada por estar sempre presente nos salvando e ajudando. Daniel, obrigada pelas ótimas ideias, que só acrescentaram nessa dissertação e por sempre estar disponível para ajudar, você sabe o quanto eu tenho que te agradecer.

A minha querida amiga Aliny, por todo conhecimento compartilhado durante toda a minha trajetória acadêmica, desde o primeiro projeto de iniciação científica até o mestrado. Obrigada por estar sempre presente na minha vida e por todos os conselhos tanto profissionais como pessoais.

Agradeço também à todos os amigos e colegas que fizeram parte desta caminhada, vocês tornaram essa trajetória mais leve e com certeza, muito mais enriquecedora.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Obrigada!

RESUMO

O processo de ocupação humana vem ocorrendo de forma cada vez mais acentuada na Amazônia Legal, devido principalmente a expansão da fronteira agrícola. Entender o processo de mudança no uso e cobertura da terra é fundamental para o planejamento e gerenciamento dos recursos naturais. Através das técnicas de sensoriamento remoto é possível mapear o uso e cobertura da terra de forma rápida e eficaz. A utilização de dados de radares de abertura sintética (SAR) vem se mostrando uma alternativa para o monitoramento e mapeamento em regiões tropicais, principalmente por serem pouco influenciados pela cobertura de nuvens. Nesse sentido, o objetivo principal desta dissertação foi avaliar o potencial do uso das imagens dual VV-VH do satélite Sentinel-1A (banda C) para o mapeamento do uso e cobertura da terra na região de Ariquemes, RO. Para isso, foram testados sete cenários de classificações a partir dos atributos extraídos dos dados de radar: coeficientes de retroespalhamento, decomposição polarimétrica e coerência interferométrica, com os classificadores SVM (*Support Vector Machine*) e RF (*Random Forest*). O mapeamento foi dividido em duas fases, a Fase 1 buscando discriminar as classes Pastagem, Agricultura e Floresta e a Fase 2, realizando-se uma estratificação da classe Floresta nas classes Floresta Degradada, Floresta Primária e Sucessões Secundárias Avançada, Intermediária e Inicial. A validação dos mapeamentos foi realizada através da Simulação de Monte Carlo, utilizando-se as amostras de campo, com 1000 iterações, onde se obteve os valores médios de Kappa, acurácia Global e matriz de confusão para cada cenário. A análise da diferença estatística entre os mapeamentos foi realizada pelo teste de McNemar. Além disso, foi realizado o mapeamento com o sensor óptico Sentinel-2B com o objetivo de comparar os resultados em relação ao radar. A partir da comparação dos cenários, observou-se que o cenário sete, que utilizou todos os atributos em conjunto, apresentou os melhores resultados com os classificadores SVM e RF, com uma acurácia global igual a 81,6% e 69,6% para as Fases 1 e 2, respectivamente, com o classificador SVM e 85,7% e 71,6% para as Fases 1 e 2 com o classificador RF, respectivamente. Além disso, o algoritmo RF apresentou superioridade para o mapeamento em relação ao SVM, sendo considerados diferentes estatisticamente pelo teste de McNemar com 95% de confiança. A partir da análise de importância das variáveis pelo RF, notou-se que a coerência interferométrica foi o atributo que apresentou a maior importância para a discriminação das classes temáticas para as duas fases do mapeamento. Através da comparação do mapeamento realizado com o cenário RF-7 do Sentinel-1A com o mapeamento realizado com o sensor óptico, observou-se uma diferença de 4,3% na acurácia global para a Fase 1 e de 13,8% para a Fase 2, com o melhor desempenho do sensor óptico. Além disso, evidenciou-se a limitação da utilização de dados ópticos diante dos efeitos atmosféricos, como a presença de fumaça. De modo geral, notou-se que os dados de radar foram capazes de discriminar as classes temáticas analisadas, apresentando valores de acurácia global e Kappa considerados satisfatórios.

Palavras-chave: Aprendizagem de máquina. Simulação de Monte Carlo. Radares de Abertura Sintética. Banda C. Floresta Amazônica.

EVALUATION OF THE POTENTIAL OF POLARIMETRIC DATA SENTINEL-1A FOR MAPPING LAND USE AND LAND COVER AT THE ARIQUEMES-RO REGION

ABSTRACT

The human occupation process in the Legal Amazon has occurred in an increasingly pronounced way, especially with the expansion of the agricultural frontier. Understanding the process of land use and land cover change is critical to the planning and management of natural resources. Through remote sensing techniques, it is possible to map land use and land cover quickly and efficiently. The use of synthetic aperture radar (SAR) data have shown to be an alternative for monitoring and mapping in tropical regions, mainly because they are little influenced by cloud cover. So, the main objective of this dissertation was to evaluate the potential of the VV-VH dual images of the Sentinel-1A satellite (band C) for mapping land use and land cover in the region of Ariquemes, RO. Seven classification scenarios were tested using the attributes extracted from the radar data: backscatter coefficients, polarimetric decomposition and interferometric coherence, and the SVM (Support Vector Machine) and RF (Random Forest) classifiers. The mapping process was divided into two phases, Phase 1, which aimed to discriminate the classes Pasture, Agriculture and Forest, and Phase 2, whose Forest class was stratified in the classes: Degraded Forest, Primary Forest and Advanced, Intermediate and Initial Successions. The validation of the mappings was done through the Monte Carlo Simulation, using the field samples, with 1000 iterations, where the mean values of Kappa, Global Accuracy and confusion matrix were obtained for each scenario. The analysis of the statistical difference between the mappings was performed by the McNemar test. In addition, it was carried out the mapping using the Sentinel-2B optical image in order to compare to the results obtained using the radar data. From the scenario comparison, it was observed that scenario seven, which used all the attributes together, presented the best results for both SVM and RF classifiers, with a global accuracy of 81.6% and 69.6% for Phases 1 and 2, respectively, with SVM classifier and 85.7% and 71.6% for Phases 1 and 2 with Rf classifier, respectively. In addition, RF algorithm showed superiority over the SVM algorithm for mapping the region. The mappings obtained using the RF and SVM classifiers were considered statistically different by the McNemar test with 95% confidence. From the analysis of variable importance by the RF, it was noticed that the interferometric coherence was the attribute that presented the most importance for the discrimination of the thematic classes for the two phases of the mapping. By comparing the mapping performed with the Sentinel-1A RF-7 scenario with the mapping performed with the optical sensor, a difference of 4.3% was observed in the overall accuracy for Phase 1 and 13.8% for Phase 2, with the best optical sensor performance. In addition, it was evidenced the limitation of optical data to the atmospheric effects, such as the presence of smoke. In general, it was observed that the radar data were able to discriminate the classes of land use and land cover analyzed in this dissertation, presenting values of global accuracy and Kappa considered satisfactory.

Keywords: Machine learning. Monte Carlo Simulation. Synthetic Aperture Radars (SAR). C band. Amazon Forest.

LISTA DE FIGURAS

Pág.

Figura 2.1- Elipse de polarização representando o vetor campo elétrico no plano xy, ângulo de rotação (ψ), ângulo de elipticidade (χ) e ângulo auxiliar (α) para uma onda viajando na direção ez.....	13
Figura 2.2 - Mecanismos de espalhamento.....	16
Figura 2.3 - Retroespalhamento teórico na banda C considerando áreas de floresta e vegetação herbácea, em condições de inundação e não inundação.....	21
Figura 2.4 - Representação da geometria InSAR.....	22
Figura 2.5 - Modos de aquisição da missão Sentinel-1.....	24
Figura 2.6 - Cenário de uma classificação SVM em um espaço bidimensional, para discriminação de duas classes.....	26
Figura 2.7 - Fases de treinamento e classificação do <i>Random Forest</i>	27
Figura 3.1 - Imagem do satélite Sentinel-2B com a localização geográfica da área de estudo...	34
Figura 3.2 - Localização geográfica dos pontos coletados em campo.....	36
Figura 3.3 - MDE Alos-PalSAR.....	40
Figura 3.4 - Precipitação acumulada diariamente e temperatura média diária na estação meteorológica de Ariquemes (RO) no mês de setembro de 2017.....	41
Figura 3.5 - Fluxograma geral das etapas metodológicas desenvolvidas.....	42
Figura 3.6 - Fluxograma das etapas de pré-processamento das imagens.....	43
Figura 3.7 - Representação de uma amostra utilizada para o mapeamento. a) Imagem do Sentinel-2B; b) Imagem σ_{VH0} do Sentinel-1A; c) Imagem σ_{VH0} do Sentinel-1A com os pontos correspondentes aos pixels.....	47
Figura 3.8 - Metodologia para mapeamento do uso e cobertura da terra com os classificadores SVM e RF para as duas fases.....	49
Figura 3.9 - Fluxograma para elaboração do mapa com o sensor óptico Sentinel-2B.....	52
Figura 4.1 - Análise quantitativa dos filtros para tratamento do ruído <i>Speckle</i>	54
Figura 4.2 - Análise qualitativa da redução do ruído <i>Speckle</i>	55
Figura 4.3 - Análise qualitativa da suavização das bordas.....	56
Figura 4.4 - Gráficos <i>boxplot</i> representando o quartil inferior, superior e mediana das classes temáticas pelo atributo σ_{VH0} , σ_{VV0} e $\sigma_{VH0}\sigma_{VV0}$	58
Figura 4.5 - Retroespalhamento médio para cada classe nos atributos analisados.....	59
Figura 4.6 - Gráficos <i>boxplot</i> representando o quartil inferior, superior e mediana das classes temáticas pelo atributo entropia (H) e ângulo alfa (α).....	60
Figura 4.7 - Imagem γ_{VH} para as diferentes janelas sem aplicação do filtro Lee.....	61
Figura 4.8 - Gráficos <i>boxplot</i> representando o quartil inferior, superior e mediana das classes temáticas pelos atributos γ_{VH} e γ_{VV}	62
Figura 4.9 - Coerência Interferométrica média para cada classe nas polarizações VH e VV.....	62
Figura 4.10 - Acurácia do produtor média para cada classe temática nos cenários analisados com o classificador SVM na Fase 1.....	65
Figura 4.11 - Acurácia do usuário média para cada classe temática nos cenários analisados com o classificador SVM na Fase 1.....	66
Figura 4.12 - Acurácia do produtor média para cada classe temática nos cenários analisados com o classificador SVM na Fase 2.....	70

Figura 4.13 - Acurácia do usuário média para cada classe temática nos cenários analisados com o classificador SVM na Fase 2.....	70
Figura 4.14 - Mapa do uso e cobertura da terra com o classificador SVM-7 para as duas fases da classificação.	72
Figura 4.15 - Acurácia do produtor média para cada classe temática nos cenários analisados com o classificador RF na Fase 1.....	75
Figura 4.16 - Acurácia do usuário média para cada classe temática nos cenários analisados com o classificador RF na Fase 1.....	75
Figura 4.17 - Variáveis de Importância pelo índice de Gini para a Fase 1 do mapeamento e para cada classe analisada no Cenário RF-7.	77
Figura 4.18 - Acurácia do produtor média para cada classe temática nos cenários analisados com o classificador RF na Fase 2.....	79
Figura 4.19 - Acurácia do usuário média para cada classe temática nos cenários analisados com o classificador RF na Fase 2.....	79
Figura 4.20 - Variáveis de Importância pelo índice de Gini para a Fase 2 do mapeamento e para cada classe analisada no Cenário RF-7.	81
Figura 4.21 - Mapa de uso e cobertura da terra com o classificador RF para o cenário RF-7.	83
Figura 4.22 - Diferença entre as classificações do RF pelo SVM na Fase 1.....	84
Figura 4.23 - Resultado do mapeamento da Fase 1: a) Mapeamento SVM; b) Mapeamento RF e c) Diferença entre SVM e RF.....	86
Figura 4.24 - Diferença entre as classificações RF e SVM na Fase 2.....	87
Figura 4.25 - Resultado do mapeamento da Fase 2: a) Mapeamento SVM; b) Mapeamento RF e c) Diferença entre SVM e RF.....	90
Figura 4.26 - Acurácia do Produtor (%) para os mapeamentos realizados com os sensores óptico e radar (RF-7) na Fase 1.....	92
Figura 4.27 - Acurácia do Usuário (%) para os mapeamentos realizados com os sensores óptico e radar (RF-7) na Fase 1.....	92
Figura 4.28 - Comparação dos mapeamentos realizados na Fase 1: a) Mapeamento Sentinel-1A cenário RF-7, b) Imagem Sentinel-2B; c) Mapa de diferenças.....	93
Figura 4.29 - Acurácia do Produtor (%) para os mapeamentos realizados com os sensores óptico e radar na Fase 2.....	95
Figura 4.30 - Acurácia do Usuário (%) para os mapeamentos realizados com os sensores óptico e radar na Fase 2.....	95
Figura 4.31 - Comparação dos mapeamentos realizados na Fase 2: a) Mapeamento Sentinel-1A, b) Imagem Sentinel-2B; c) Mapa de diferenças.....	96
Figura 4.32 - Efeito da fumaça sobre o mapeamento: a) Imagem Sentinel-2B na composição verdadeira (RGB: 4, 3, 2); b) Mapeamento com o sensor óptico Sentinel-2B; c) Mapeamento com o radar Sentinel-1A (RF-7).....	97

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1- Bandas de sensores imageadores radar.	9
Tabela 2.2 - Modos de aquisições do Sentinel-1A.	24
Tabela 2.3 - Conceitos das classificações baseados no coeficiente Kappa.	30
Tabela 2.4 - Matriz de contingência.	31
Tabela 3.1 - Características das imagens Sentinel-1A.	35
Tabela 3.2 - Pontos coletados em cada classe de uso e cobertura da terra.	36
Tabela 3.3 - Descrição das classes de uso e cobertura da terra identificadas em campo.	37
Tabela 3.4 - Características das bandas espectrais do sensor MSI do Sentinel-2.	39
Tabela 3.5 - MDEs AlosPalSAR-1 utilizados na área de estudo.	39
Tabela 3.6 - Descrição dos cenários das classificações realizadas com os classificadores RF e SVM.	48
Tabela 3.7 - Número de amostras (pixels) do conjunto amostral para treinamento e validação de cada classe temática em cada fase do mapeamento.	49
Tabela 4.1 - Acurácia Global (AC), Kappa e Intervalos de Credibilidade a 5% de significância para todos os cenários com o classificador SVM para a Fase 1.	63
Tabela 4.2 - Matriz de confusão média do cenário SVM-7 para a Fase 1.	66
Tabela 4.3 - Acurácia Global (AC), Kappa e Intervalos de Credibilidade a 5% de significância para todos os cenários com o classificador SVM para a Fase 2.	68
Tabela 4.4 - Matriz de confusão média do cenário SVM-7 para a Fase 2.	71
Tabela 4.5 - Acurácia Global (AC), Kappa e Intervalos de Credibilidade a 5% de significância para todos os cenários com o classificador RF na Fase 1.	73
Tabela 4.6 - Matriz de confusão média do cenário RF-M7 para a Fase 1.	76
Tabela 4.7 - Acurácia Global (AC), Kappa e Intervalos de Credibilidade a 5% de significância para todos os cenários com o classificador RF na Fase 2.	78
Tabela 4.8 - Matriz de confusão média para o cenário RF-7 na Fase 2.	80
Tabela 4.9 - Teste de McNemar comparando os classificadores SVM e RF para cada cenário realizado na Fase 1, com um nível de confiança de 95% (Teste McNemar $\chi^2 > 3,84$).	85
Tabela 4.10 - Teste de McNemar comparando os classificadores SVM e RF para cada cenário realizado na Fase 2, com um nível de confiança de 95% (Teste McNemar $\chi^2 > 3,84$).	88
Tabela 4.11 - Acurácia Global (AC), Kappa e Intervalos de Credibilidade a 5% de significância para as classificações com os sensores óptico (Sentintel-2B) e radar (Sentinel-1A, cenário RF-7) na Fase 1.	91
Tabela 4.12 - Acurácia Global (AC), Kappa e Intervalos de Credibilidade a 5% de significância para as classificações com os sensores óptico (Sentintel-2B) e radar (Sentinel-1A, cenário RF-7) na Fase 1.	94

Tabela A. 1 - Matriz de confusão média dos cenários com o classificador SVM para a Fase 1. AU: Acurácia do Usuário (%) e AP: Acurácia do Produtor (%).	128
Tabela A. 2 - Matriz de confusão média dos cenários com o classificador SVM para a Fase 2. AU: Acurácia do Usuário (%) e AP: Acurácia do Produtor (%).	129
Tabela A. 3 - Matriz de confusão média dos cenários com o classificador RF para a Fase 1. AU: Acurácia do Usuário (%) e AP: Acurácia do Produtor (%).	131
Tabela A. 4 - Matriz de confusão média dos cenários com o classificador RF para a Fase 1. AU: Acurácia do Usuário (%) e AP: Acurácia do Produtor (%).	132

SIGLAS E ABREVIATURAS

AG	Agricultura
AC	Acurácia global
ASF	Alaska Satellite Facility
AP	Acurácia do Produtor
AU	Acurácia do Usuário
CV	Coefficiente de variação
ENVI	Environment for Visualizing Images
ESA	European Space Agency
EW	Extra-Wide Swath Mode
FD	Floresta Degradada
FP	Floresta Primária
GPS	Global Positioning System
GRD	Ground Range Detected
ICM	Interactive Conditional Mode
IW	Interferometric Wide Swath Mode
LUTs	Look Up Tables
MAXVER	Máxima Verossimilhança
MDE	Modelo Digital de Elevação
MDG	Mean Decrease Gini
MI	Mineração
MSI	Multispectral Instrument
NEL	Número Equivalente de Looks
OSW	Ocean Swell Spectra
OWI	Ocean Wind Field
PA	Pastagem
PAD	Projetos de Assentamento Dirigidos
PRODES	Projeto de Monitoramento do Desmatamento na Amazônia Legal por Satélite
RADAR	Radio Detection And Ranging
RAR	Real Aperture Radar
RF	Random Forest
RO	Rondônia

RTC	Radiometric Terrain Correction
RVL	Surface Radial Velocity
SAR	Synthetic Aperture Radar
SLAR	Side-Looking Airborne Radar
SLC	Single Look Complex
SM	Stripmap Mode
SNAP	Sentinel Application Platform
SSA	Sucessão Secundária Avançada
SSI	Sucessão Secundária Inicial
SSInt	Sucessão Secundária Intermediária
SVM	Support Vector Machine
UTM	Universal Transversa de Mercator
WGS 84	World Geodetic System
WM	Wave Mode

LISTA DE SÍMBOLOS

σ_{VH}^0	Coeficiente de retroespalhamento VH
σ_{VV}^0	Coeficiente de retroespalhamento VV
$\sigma_{VH}^0/\sigma_{VV}^0$	Razão crosspolarizada
γ_{VH}	Coerência Interferométrica na polarização VH
γ_{VV}	Coerência Interferométrica na polarização VV
H	Entropia
α	Ângulo Alfa

SUMÁRIO

	<u>Pág.</u>
1. INTRODUÇÃO.....	1
1.1 Objetivos.....	4
1.1.1 Objetivos específicos	4
2. FUNDAMENTAÇÃO TEÓRICA	5
2.1 Mapeamento do uso e cobertura da terra.....	5
2.2 Uso e ocupação da terra em Ariquemes – RO.....	6
2.3 Sensoriamento Remoto por sensores ativos	7
2.4 Fundamentos de Radares de Abertura Sintética – SAR.....	8
2.5 Ruído <i>Speckle</i> e filtros adaptativos.....	10
2.6 Princípios básicos em polarimetria.....	12
2.7 Tipos de Interações com os Alvos.....	15
2.8 Decomposição de Alvos	17
2.9 Coeficiente de Retroespalhamento	20
2.10 Coerência Interferométrica	21
2.11 Missão Sentinel-1	23
2.12 Classificações supervisionada	25
2.12.1 Classificação <i>Support Vector Machine</i> – SVM	25
2.12.2 Classificação <i>Random Forest</i> – RF	27
2.13 Validação do desempenho classificatório.....	29
3. MATERIAL E MÉTODOS.....	33
3.1 Área de estudo	33
3.2 Dados SAR	34
3.3 Dados de campo	35
3.4 Dados auxiliares	38
3.5 Metodologia utilizada.....	41
3.6 Processamento dos dados SAR	42

3.6.1	Pré-processamento	42
3.6.2	Seleção de amostras e análise exploratória.....	46
3.6.3	Classificações.....	47
3.7	Comparação com o sensor óptico Sentinel-2B.....	51
4.	RESULTADOS	54
4.1	Definição do filtro e do tamanho da janela de filtragem	54
4.2	Análise exploratória dos atributos	56
4.2.1	Coeficientes de retroespalhamento	56
4.2.2	Decomposição polarimétrica	59
4.2.3	Coerência Interferométrica	60
4.3	Classificações <i>Support Vector Machine</i>	63
4.3.1	Classificações SVM Fase 1.....	63
4.3.2	Classificações SVM Fase 2.....	67
4.4	Classificações <i>Random Forest</i>	72
4.4.1	Classificações RF Fase 1.	72
4.4.2	Classificação RF Fase 2.....	77
4.5	Comparação SVM-RF	83
4.5.1	Comparação SVM-RF Fase 1	83
4.5.2	Comparação SVM-RF Fase 2	87
4.6	Comparação dos mapeamentos com os sensores óptico e radar	91
4.6.1	Comparação óptico e radar Fase 1.....	91
4.6.2	Comparação óptico e radar Fase 2.....	94
5.	DISCUSSÃO DOS RESULTADOS	97
5.1	Classificações com atributos de radar	98
5.2	Classificadores SVM e RF	102
5.3	Comparação óptico e radar	104
6.	CONCLUSÕES E RECOMENDAÇÕES	107
	REFERÊNCIAS BIBLIOGRÁFICAS	109
	APÊNDICE A – MATRIZES DE CONFUSÃO.....	128

A.1 Matrizes de confusão para o classificador SVM	128
A.2 Matrizes de confusão para o classificador RF	131
ANEXO A - PROBABILIDADE DE OBTENÇÃO DE IMAGENS LIVRE DE NUVENS NA BACIA AMAZÔNICA ENTRE 1984 E 1997.....	134

1. INTRODUÇÃO

O processo de ocupação humana vem ocorrendo de forma cada vez mais acentuada na Amazônia Legal, principalmente, com a expansão da fronteira agrícola, que teve início na década de 1960, a partir da colonização e construção das primeiras rodovias na região, provocando grandes impactos ambientais. O uso inadequado da terra pode agravar fenômenos como erosão, impermeabilização do solo, perda da biodiversidade, assoreamento de cursos d'água entre outros (VAEZA et al., 2010; NASCIMENTO; FERNANDES, 2017).

De acordo com Lambin (1997), muitas das mudanças no uso da terra que apresentam grande impacto climático e ecológico estão ocorrendo em regiões tropicais, como fragmentação, desmatamento e urbanização. A incorporação de áreas florestais para uso antrópico acontece na maioria das vezes, sem planejamento, provocando mudanças significativas em algumas regiões. Essa expansão de forma desordenada do setor agropecuário tem provocado danos principalmente em regiões dos estados do Pará, Mato Grosso, Rondônia e Acre (LORENA, 2008). Dentre essas mudanças, o desmatamento representa uma das mais importantes, sendo uma das maiores ameaças ao meio ambiente (LORENA, 2008).

Segundo Oliveira (2016), o maior problema na alteração do ambiente nos dias atuais está na velocidade e escala com que estas modificações estão ocorrendo. De acordo com Morales-Hidalgo et al. (2015), de 1990 a 2015 a perda de florestas primárias tropicais foi de aproximadamente 2 milhões de km². Em 2016, o PRODES (Projeto de Monitoramento do Desmatamento na Amazônia Legal por Satélite) estimou 7.893 km² de corte raso na Amazônia Legal, indicando um aumento de 29% na área desmatada em relação ao ano anterior (INPE, 2016). Já em 2017, o projeto observou uma redução de 16% em relação à 2016 (INPE, 2017). Enquanto para 2018 observou-se um aumento de 13,72% em relação à 2017, com 7900 km² de corte raso na Amazônia Legal (INPE, 2018).

No entanto, muitas das áreas desmatadas são abandonadas, resultando na formação de um mosaico de florestas secundárias (NEEFF et al., 2006), que apresentam grande importância na manutenção da biodiversidade e absorção de carbono atmosférico

(GIBSON et al., 2011). Na Amazônia Legal Brasileira, a estimativa é que as Florestas Secundárias representem aproximadamente 30% das áreas de desflorestamentos desde 1998, ocupando uma área entre 140.000 km² e 228.000 km² (ALMEIDA et al., 2010; INPE/TerraClass, 2010).

Entender o processo de mudança no uso e cobertura da terra é fundamental para o planejamento e gerenciamento dos recursos naturais. Através das técnicas de sensoriamento remoto é possível mapear o uso e cobertura da terra de forma rápida e eficaz, permitindo a identificação, avaliação e monitoramento em escalas espaciais, temporais e temáticas (ENGELBRECHT et al., 2017). Segundo Gómez et al. (2016) identificar os tipos de cobertura da terra possibilita o fornecimento de informações para a geração de novos mapas temáticos e a base para atividades de monitoramento.

A utilização de dados de radares de abertura sintética (SAR) vem se mostrando uma alternativa para o monitoramento e mapeamento de regiões tropicais, principalmente por serem pouco influenciados pela cobertura de nuvens e por demais constituintes atmosféricos (ASNER, 2001; ENGELBRECHT et al., 2017; HENDERSON; LEWS, 1998) e por serem sensíveis à estrutura e à biomassa florestal, o que permite a discriminação de diferentes tipos de cobertura do solo em ambientes florestais.

Desse modo, as imagens de radares se tornam uma alternativa para a detecção de desflorestamentos em regiões tropicais, como a região Amazônica, onde a probabilidade de obtenção de uma imagem de sensor óptico com menos de 30% de cobertura de nuvens é mínima (ASNER, 2001; MARTINS et al. 2018), além de serem afetadas diretamente pela presença de aerossóis (MARTINS et al. 2018).

No entanto, apesar de muitos estudos empregarem dados SAR para mapeamento do uso e cobertura da terra, poucos têm utilizado dados da banda-C buscando discriminar um grande número de classes temáticas (BALZTER, 2015; SCHMULLIUS et al., 2015). Servello (2010) utilizou dados polarimétricos do RADARSAT-2 (banda C), para discriminação do uso e cobertura da terra na região da Floresta Nacional do Tapajós. Cable et al. (2014), utilizaram dados multi-temporais polarimétricos do RADARSAT-2 (banda C) para mapear quatro tipos de classes de uso e cobertura da terra (florestas, área urbana, água superficial e pântano) no nordeste de Ontário, Canadá. Por outro lado,

Varghese et al. (2016), analisaram diferentes métodos de decomposição polarimétrica para classificação do dossel florestal, utilizando dados da banda C.

Nesse sentido, nota-se uma crescente utilização de dados SAR na banda C em estudos ambientais. Com a disponibilização de dados do satélite Sentinel-1 (banda C) a partir de 2015, pesquisas relacionadas ao estudo do seu potencial, principalmente em regiões tropicais, apresentam grande importância na comunidade científica.

Os dados da missão Sentinel são atualmente disponibilizados gratuitamente pela Agência Espacial Europeia (ESA), o que facilita seu acesso e a sua utilização em diversos estudos ambientais. De acordo com Wagner et al. (2012), a combinação entre alta resolução espacial e a melhora na resolução temporal no modo IW do Sentinel-1 iria proporcionar novas possibilidades para classificações de mapeamento do uso e cobertura da terra e para monitoramento da dinâmica de parâmetros hidrológicos. Além disso, Banqué et al. (2015), observaram que os dados Sentinel-1 apresentam um grande potencial para classificação do uso e cobertura da terra, buscando discriminar cinco classes: água, floresta, solo exposto, agricultura e área urbana, obtendo valores de exatidão global de aproximadamente 95% para algumas classes de uso e cobertura da terra.

A utilização de algoritmos de aprendizagem de máquina para realizar o mapeamento do uso e cobertura da terra tem se tornado cada vez mais frequente, principalmente devido à sua aplicabilidade em diferentes sensores e por apresentarem resultados superiores a outros classificadores frequentemente utilizados (SHANG; CHISHOLM, 2014; WHYTE et al., 2018). Dentre estes algoritmos, destacam-se o SVM (*Support Vector Machine*) (CORTES; VAPNIK, 1995) e RF (*Random Forest*) (BREIMAN, 2001), que apresentam grande flexibilidade e são muito aplicados para classificações com dados de radar, principalmente por serem não paramétricos (WHYTE et al., 2018; FURTADO et al., 2016).

Dessa forma, estudos relacionados ao mapeamento do uso e cobertura da terra em regiões tropicais utilizando dados de radares apresentam grande importância científica e visam buscar soluções aos desafios encontrados, principalmente devido à cobertura de nuvens nessas regiões, o que impede o monitoramento de atividades exploratórias como o desmatamento e queimadas.

1.1 Objetivos

O objetivo principal desta pesquisa de mestrado foi avaliar o potencial das imagens dual nas polarizações VV-VH do satélite Sentinel-1A (banda C) para o mapeamento do uso e cobertura da terra na região de Ariquemes, RO.

1.1.1 Objetivos específicos

- Analisar a capacidade discriminatória dos atributos provenientes dos dados de radar do Sentinel-1A: coeficientes de retroespalhamento (σ_{VH}^0 , σ_{VV}^0 , $\sigma_{VH}^0/\sigma_{VV}^0$); decomposição polarimétrica (H e α) e coerência interferométrica (γ_{VH} e γ_{VV}).
- Avaliar o desempenho classificatório destes atributos através de cenários de classificações com os classificadores SVM (*Support Vector Machine*) e RF (*Random Forest*).
- Comparar o desempenho dos classificadores SVM e RF para os diferentes cenários obtidos com os atributos dos dados de radar;
- Avaliar o potencial do mapeamento obtido com os dados de radar (Sentinel-1A), comparando-o com o mapeamento realizado pelo sensor óptico Sentinel-2B.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Mapeamento do uso e cobertura da terra

A mudança no uso e cobertura da terra é considerada uma das principais causas para a mudança climática global (TURNER et al., 2007). Além das abruptas transições das florestas e outros ecossistemas nativos para áreas agrícolas e de pastagem, que impactam diretamente os estoques de carbono, a biodiversidade e o clima, existem modificações sutis que alteram os ecossistemas, como por exemplo, a extração de madeira pelo corte seletivo. Esses processos, no entanto, ainda são pouco quantificados, apesar de possuírem impactos ambientais inerentes (JOSHI et al., 2016).

Para entender os processos de mapeamento e monitoramento do uso e cobertura da terra, é necessário compreender os seus conceitos e as suas diferenças. Segundo Lambin e Geist (2006), o mapeamento da cobertura terrestre, está relacionado às propriedades físicas de uma superfície, enquanto o uso da terra está relacionado às atividades desenvolvidas pelos seres humanos naquele ambiente. O mapeamento é representado em mapas temáticos, através das classes de cobertura de terra.

Já a mudança no uso da terra, pode ser definida como uma conversão de uma classe de uso da terra em outra, como ocorre em expansões agrícolas, ou como modificações sutis nas propriedades existentes dentro de cada classe (HANSEN; DEFRIES, 2004). Portanto, percebe-se que o uso e a mudança na cobertura da terra são diretamente relacionados, sendo conceitualmente distintos, ou seja, podem ocorrer mudanças na cobertura da terra sem que ocorra a conversão desta em uma nova classe. Além disso, as mudanças podem ser causadas tanto por processos antrópicos quanto por processos naturais (JOSHI et al., 2016).

As mudanças no uso e cobertura da terra estão relacionadas ao contexto social, econômico e político das regiões em que se encontram (GREEN et al., 1994) e podem provocar diversos impactos, principalmente em relação à perda da biodiversidade (WALKER, 2004; COSTA, 2011).

A utilização de técnicas de sensoriamento remoto marcou uma nova era dos estudos do uso da terra (IBGE, 2013), permitindo a obtenção de dados de forma rápida em grandes

áreas, auxiliando no mapeamento e monitoramento das mudanças no uso e cobertura da terra (JOSHI et al., 2016).

Apesar disso, são muitos os desafios e limitações na utilização de dados de sensoriamento remoto. Os dados obtidos pelos sensores, nem sempre expressam unicamente as propriedades físicas existentes dentro das classes de cobertura, mas estão ambigualmente relacionados com o uso da terra, tornando-se necessário a utilização de modelos para inferir as propriedades da terra (JOSHI et al., 2016).

Outra limitação presente nos dados de sensoriamento remoto é que a informação gerada pelos dados orbitais deve ser baseada também no conhecimento de campo e na interpretação do usuário, tornando o mapeamento de grandes áreas, uma operação dispendiosa e desafiadora (JOSHI et al., 2016).

2.2 Uso e ocupação da terra em Ariquemes – RO

A década de 1970 marca o início do processo de desmatamento na Amazônia Legal, junto com a ocupação e exploração humana na região (BECKER, 2005; FERREIRA; SALATI, 2005). Essa grande expansão foi motivada principalmente pelos incentivos fiscais, facilidade de crédito e abundância de terras (REIS; MARGULLIS, 1991).

Um dos principais fatores impulsionadores para o desmatamento foi a relação entre a migração e a criação de corredores de acesso (ANDERSEN; REIS, 1997; NEPSTAD et al., 2001; PFAFF, 1997; SOARES-FILHO et al., 2005). Um estudo realizado por Nepstad et al. (2001), em uma faixa de 100 Km das rodovias BR 010 (Belém-Brasília), BR 364 (Cuiabá- Porto Velho) e PA 150, mostrou que três quartos do desmatamento entre 1978 e 1994 ocorreu nessa faixa.

Na região de Ariquemes, em Rondônia, foram implantados dois Projetos de Assentamento Dirigidos (PAD), o PAD Burareiro e o PAD Marechal Dutra como iniciativa de colonização na década de 1970. O PAD Burareiro distribuía lotes de 250 ha e destinava-se principalmente ao plantio de cacau. Já o PAD Marechal Dutra distribuía lotes de 100 ha e cultivava-se principalmente café. Na Amazônia Legal, mais de 100 mil famílias foram beneficiadas pelos PADs, sendo que mais da metade foi para o estado de Rondônia, cerca de 56.702 famílias (CORDEIRO, 2015).

Atualmente, a maioria dos lotes dos PADs próximos à cidade de Ariquemes são pequenas chácaras para moradia ou produção de hortifrutigranjeiros. Já os lotes mais afastados da cidade destinam-se, principalmente, à criação de gado de corte, sendo que as primeiras culturas implantadas (cacau e café) apresentam um pequeno papel na economia do município (CORDEIRO, 2015).

Outra atividade que exerceu grande impacto na região foi a mineração. Em 1987, o garimpo Bom Futuro abrigava mais de quinze mil garimpeiros e eram lançados mais 800.000 m³/mês de resíduos da exploração de cassiterita em mais de 200 Km de rios e igarapés, provocando diversos danos à vida aquática (VANUCHI et al., 2014).

De uma forma geral, na Amazônia Legal, a pecuária extensiva é um dos fatores mais relevantes para o aumento do desmatamento (BARONA et al., 2010; CARVALHO T. et al., 2016; CASTRO, 2005; CHOMITZ; THOMAS, 2001; FEARNSSIDE, 2005; MARGULIS, 2003; MIRAGAYA, 2008; OLIVEIRA JUNIOR et al., 2010; RIVERO et al., 2009). Da área total desmatada estima-se que cerca de 70% foi convertida em pastagem (AGUIAR et al., 2007), que juntamente com a baixa produtividade foram responsáveis por estender o arco do desmatamento (CHOMITZ; THOMAS, 2001).

No entanto, nos últimos anos, a expansão da agricultura mecanizada para produção de grãos, como milho e soja, tem apresentado destaque para expansão da fronteira agrícola (BICKEL; DROSS, 2003; CARVALHO, G. et al., 2002; CARVALHO, T. et al., 2016; CASTRO, 2005; FEARNSSIDE, 2005; JARAMILLO; KELLY, 1999). Alguns estudos mostram que a conversão de florestas para agricultura ocorre muito rapidamente e vêm se expandindo a uma taxa maior que a pecuária (KAIMOWITZ et al., 2004; MERTENS et al. 2002; MORTON et al., 2006). Contudo, deve-se ressaltar que muitas áreas relacionadas à expansão da soja, são áreas onde anteriormente eram pastagens e, portanto, não representam um novo processo de desmatamento (ALENCAR et al., 2004; LAURANCE et al., 2014).

2.3 Sensoriamento Remoto por sensores ativos

Os sistemas sensores ativos apresentam como principal característica a sua independência da energia eletromagnética do Sol, ou das propriedades termais da Terra,

possibilitando que o imageamento da superfície seja realizado a qualquer momento. A energia eletromagnética gerada pelo sensor é transmitida para a superfície, interage e é retroespalhada. Por sua vez, a energia retroespalhada pelos alvos é registrada pelo receptor do sensor remoto (JENSEN, 2009).

Segundo Jensen (2009), os sistemas sensores ativos podem ser classificados em:

- Microondas ativos – RADAR (*Radio Detection And Ranging*): baseados na transmissão de REM de comprimentos de ondas mais longos (faixa das micro-ondas) através da atmosfera e na detecção da energia retroespalhada pelos objetos presentes na superfície da Terra.
- LIDAR: baseados na transmissão de REM de comprimentos de onda curtos (faixa do ótico) através da atmosfera e na detecção da energia retroespalhada pela superfície.
- SONAR: baseados na transmissão de ondas sonoras através da coluna de água e na detecção da energia retroespalhada pelo fundo ou por objetos presentes no interior da coluna de água.

Os radares são sistemas ativos que possuem sua própria fonte de energia e operam na faixa do espectro eletromagnético denominada de microondas. Nesta faixa espectral, as ondas eletromagnéticas sofrem pouca influência da atmosfera, possibilitando que o imageamento da superfície seja realizado mesmo com cobertura de nuvens ou neblina.

Na década de 1950, foi desenvolvido o SLAR (*Side-looking Airborne Radar*), possibilitando o mapeamento em faixas contínuas do radar aerotransportado de visada lateral, ou seja, possibilitando a cobertura de uma ampla região, à esquerda e à direita da aeronave. O SLAR pode utilizar a tecnologia de radar de abertura real (RAR) ou de radar de abertura sintética (SAR), que se diferenciam pelas suas capacidades de resolução e da qualidade dos dados (JENSEN, 2009).

2.4 Fundamentos de Radares de Abertura Sintética – SAR

Os sistemas SAR apresentam resoluções muito finas para grandes distâncias, devido à sua capacidade de simular uma antena muito maior em comparação com os radares de abertura real, gerando um maior número de pulsos em direção ao objeto. Portanto, com

o aumento da antena, obtém-se uma grande melhora na resolução em azimute (JENSEN, 2009).

As imagens SAR, devido à sua característica de sofrerem pouca influência das condições atmosféricas (HENDERSON; LEWIS, 1998), podem ser uma alternativa para a detecção de desflorestamentos em regiões tropicais. Além disso, por serem sensíveis à estrutura e à biomassa florestal, permitem a discriminação de diferentes tipos de cobertura da terra em ambientes florestais (GUERRA et al., 2010; TEBALDINI et al., 2011).

A obtenção das informações sobre os alvos está relacionada às regiões espectrais utilizadas. Os comprimentos de onda mais usados em sensoriamento remoto ativo são muito maiores que os comprimentos de onda relacionados às faixas espectrais do visível, do infravermelho próximo ou do infravermelho termal (Tabela 2.1).

Tabela 2.1- Bandas de sensores imageadores radar.

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

Fonte: Adaptada de Jensen (2009).

A penetração das ondas é diretamente proporcional ao comprimento de onda da radiação eletromagnética. Portanto, quanto maior o comprimento de onda de operação do sistema radar, maior será a sua capacidade de penetração na vegetação (KASISCHKE et al., 1997).

Os radares de abertura sintética operam em geometria de visada lateral, onde a direção de iluminação é perpendicular à linha de voo. Nesse caso, define-se a direção de voo como direção de azimute e o eixo ortogonal à direção de azimute como direção de alcance ou *range*. Assim, a região do terreno mais próxima ao sensor é denominada

Near Range e a região mais distante denominada *Far Range* (LEE; POTTIER, 2009; RANEY, 1998).

Os dados de radar, devido a sua visada lateral, apresentam distorções em relação ao relevo. Essas distorções são conhecidas como *sombreamento*, *layover* (inversão de relevo) e *foreshortening* (encurtamento de rampa) (JENSEN, 2009).

O sinal de retorno do sistema SAR é estruturado em duas componentes, que compõem um número complexo. A parte real é representada pela componente em fase (I), enquanto a parte imaginária é representada pela componente quadratura de fase (Q) (RANEY, 1998). Assim, esses dados permitem a geração de imagens amplitude e intensidade.

Além disso, deve-se destacar que as imagens radar apresentam um ruído inerente à sua formação, responsável por apresentar um aspecto granuloso, dificultando análises como interpretação visual e classificação digital, esse ruído é um efeito multiplicativo denominado *Speckle* (HENDERSON; LEWIS, 1998).

2.5 Ruído *Speckle* e filtros adaptativos

A presença do ruído *Speckle* é uma característica inerente aos dados de radar, relacionada à interação das ondas coerentes. O *Speckle* é considerado um ruído multiplicativo (Equação 2.1), sendo mais intenso onde a intensidade do sinal for maior.

$$Z = X \cdot Y \quad (2.1)$$

Nesse caso, Z representa o sinal observado, que é o produto das variáveis aleatórias (independentes): X , que modela o retroespalhamento e Y , que modela o ruído *Speckle* (HENDERSON; LEWIS, 1998; LEE et al., 1991).

O *Speckle* atribui às imagens de radar um aspecto granuloso por tornar a relação sinal-ruído mais baixa, dificultando o processamento das imagens e a sua interpretação visual (SABINS, 1996; SANT'ANNA, 1995). Nesse sentido, são realizados processamentos para redução do ruído *Speckle*, como a aplicação de *multilooking* ou de filtros espaciais.

A técnica *multilooking* consiste na redução do tamanho da abertura sintética por um fator que seria o número de visadas (*looks*) do mesmo pixel. No entanto, quanto maior o número de *looks* empregados, maior será a perda na resolução em azimute (LEE et al., 1991). O Número Equivalente de *Looks* (NEL) pode ser estimado pela Equação 2.2 (SOLBO; ELTOFT, 2008):

$$NEL = \left(\frac{1}{CV} \right)^2 \quad (2.2)$$

onde CV representa o coeficiente de variação e é estimado pela razão entre o desvio padrão e a média. Tanto o NEL quanto o CV são medidas que mostram o grau de suavização das imagens SAR, ou seja, redução do ruído *Speckle*.

De acordo com Shi e Fung (1994), esse processamento equivale à aplicação de filtros passa-baixas, que além de reduzir o ruído, diminui as informações relacionadas à textura. Por isso, são empregados filtros adaptativos para redução do ruído *Speckle*, que preservam a informação da textura (LOPES et al., 1990). Os filtros adaptativos modificam a imagem a partir de estatísticas obtidas com o retroespalhamento de cada pixel.

Muitos filtros adaptativos foram desenvolvidos, e a avaliação da sua qualidade varia de acordo com o objetivo de cada estudo. Segundo Sant'Anna e Mascarenhas (1996), uma maneira de comparar os filtros é através da relação sinal-ruído, quanto maior for a relação sinal-ruído da imagem filtrada, mais eficiente foi o filtro em reduzir o efeito *Speckle*. De acordo com Dong et al. (2001), um filtro do ruído *Speckle* deve considerar a redução da variância, a manutenção da média da intensidade recebida e preservar as bordas e textura.

Os filtros adaptativos muito utilizados para minimizar o efeito *Speckle* são: Frost, Gamma e Lee (DONG et al., 2001; KIM et al., 2007; LOPES et al., 1990; SHI; FUNG, 1994; VELHO et al., 2011).

O filtro Frost é um filtro de convolução linear, que minimiza o ruído *Speckle* através de uma função de correlação espacial exponencial entre os pixels, que minimiza o erro quadrático médio e incorpora a dependência espacial dos pixels vizinhos.

O filtro Lee é linear e local, considera a não estacionaridade da média e variância do sinal, utilizando as estatísticas do pixel a ser filtrado. Esse filtro expande o modelo multiplicativo da série de Taylor e utiliza apenas os termos de 1ª ordem.

Já o filtro Gamma é um filtro adaptativo que considera a distribuição do ruído *Speckle* baseada na distribuição Gamma. Por utilizar as propriedades da cena, esse filtro é capaz de minimizar as perdas de informações de textura em imagens que apresentam a distribuição Gama, quando comparado aos filtros Frost e Lee.

2.6 Princípios básicos em polarimetria

A onda eletromagnética é constituída pelos campos elétrico e magnético e se propaga na direção perpendicular a esses campos (WOODHOUSE, 2006). A vibração do campo elétrico (\vec{E}) pode ocorrer na horizontal (H) ou vertical (V), determinando a polarização da onda eletromagnética. Nesse sentido, são possíveis quatro combinações de polarização (BOERMER et al., 1998; LEWIS et al., 1998; ULABY, ELACHI, 1990).

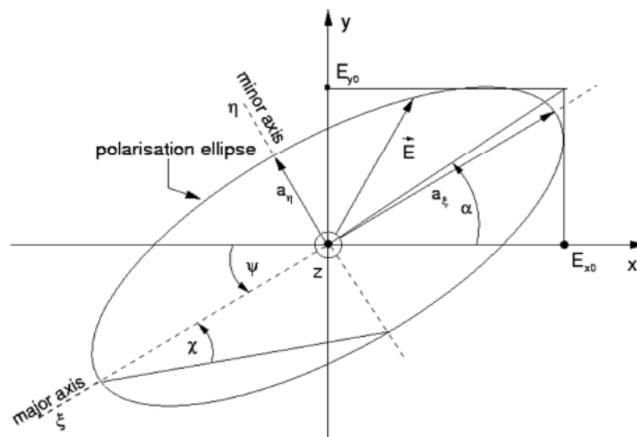
- HH – radiação eletromagnética é transmitida e recebida na polarização horizontal;
- VV – radiação eletromagnética é transmitida e recebida na polarização vertical;
- HV – radiação eletromagnética é transmitida na polarização horizontal e recebida na polarização vertical;
- VH – radiação eletromagnética é transmitida na polarização vertical e recebida na polarização horizontal.

A polarização empregada pelo sistema irá definir o grau de penetração e o tipo de interação da onda eletromagnética com os alvos. De acordo com Lewis et al., (1998), os radares podem apresentar polarização simples (*single*), quando transmitem e recebem nas polarizações HH ou VV; polarização dupla (*dual*) (HH e HV, VV e VH ou HH e VV); polarização quádrupla (*quad*) (HH, VV, HV, e VH) e podem ser completamente polarimétrico (*full*), quando apresentam as quatro combinações de polarização (HH, VV, HV, VH) e a fase relativa entre as polarizações.

Pode ocorrer uma despolarização da onda eletromagnética quando a radiação for espalhada mais de uma vez, dando origem a um retroespalhamento de polarização cruzada (HV, VH) (LECKIE; RANSON, 1998), que apresentam uma menor intensidade, se comparadas com as ondas co-polarizadas (HH e VV) (LEWIS et al., 1998).

Além disso, a onda eletromagnética pode ser descrita pelos vetores de Stokes e Jones e pela elipse de polarização. Duas propriedades da elipse de polarização estão diretamente relacionadas ao estado de polarização da onda eletromagnética: a elipticidade (χ) e o ângulo de rotação (ψ) (Figura 2.1). A elipticidade descreve a forma da elipse e o sentido de rotação do vetor, enquanto o ângulo de rotação é o ângulo formado entre o eixo maior (ξ) e o eixo X, e está relacionado à inclinação em relação à horizontal. Estas propriedades se relacionam com a amplitude e fase da onda eletromagnética (HELLMANN, 2001; RICHARDS, 2009; WOODHOUSE, 2006).

Figura 2.1- Elipse de polarização representando o vetor campo elétrico no plano xy, ângulo de rotação (ψ), ângulo de elipticidade (χ) e ângulo auxiliar (α) para uma onda viajando na direção \vec{e}_z .



Fonte: Hellmann (2001).

Na descrição pelo vetor de Stokes (Equação 2.3), são utilizados quatro parâmetros reais e mensuráveis para caracterizar a polarização de uma onda, que descrevem a magnitude e a fase relativa (LEE; POTTIER, 2009).

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

Nesse caso, o parâmetro I_0 refere-se à intensidade total da onda, e os demais parâmetros descrevem o estado da polarização. O parâmetro Q indica a quantidade da polarização na direção vertical ou horizontal e é obtido pela diferença de intensidade da onda nessas duas direções. Já os parâmetros U e V expressam a diferença de fase entre as componentes da onda polarizadas verticalmente e horizontalmente, indicando a quantidade de polarização circular para cada direção (ULABY; ELACHI, 1990; WOODHOUSE, 2006). O vetor de Stokes é bastante utilizado em aplicações ópticas (HELLMANN, 2001).

Já em aplicações por radar o vetor de Jones é o mais utilizado. O vetor de Jones é descrito pelo vetor do campo elétrico complexo \vec{E}_{ab} (Equação 2.4), que é uma combinação linear de dois estados arbitrários ortogonais da polarização (\vec{a}, \vec{b}), ponderado por suas amplitudes (E_a, E_b), e fases (δ_a, δ_b) (HELLMANN, 2001; LEE; POTTIER, 2009).

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

Além disso, existem espalhadores determinísticos e não determinísticos. Os alvos que produzem espalhamentos onde as ondas eletromagnéticas são completamente polarizadas são descritos como alvos determinísticos ou coerentes. Já os alvos que produzem espalhamento parcial, são alvos não determinísticos (alvos incoerentes), ou seja, a onda eletromagnética é parcialmente polarizada (ULABY; ELACHI, 1990).

A matriz de espalhamento $[S]$ é outra das formas de representação matemática para espalhadores determinísticos, relacionando o vetor da onda incidente \vec{E}^i e da onda espalhada \vec{E}^s . A matriz $[S]$ é uma matriz simétrica descrita pela Equação 2.5.

$$[S] = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix} \quad (2.5)$$

Onde S_{hh} , S_{hv} , S_{vh} e S_{vv} são elementos complexos que representam o espalhamento do alvo imageado nas respectivas polarizações. Em sistemas monoestáticos, pressupõe-se o princípio da reciprocidade, ou seja, as componentes HV e VH são iguais ($S_{hv} = S_{vh}$). (CLOUDE, 2009; HENDERSON; LEWIS, 1998; LEE, POTTIER, 2009). Para uma

célula de resolução, a matriz [S] consiste na sobreposição das matrizes [S]_i de todos os centros de espalhamento presentes no interior da célula de resolução (HELLMANN, 2001; LEE; POTTIER, 2009).

Para representar alvos de natureza não determinística é empregada a matriz de covariância [C] (Equação 2.6), que é definida como o valor esperado do produto do vetor de espalhamento e seu complexo conjugado transposto (RICHARDS, 2009).

$$[C]=E\langle kk^{*T}\rangle=\begin{bmatrix} \langle |S_{HH}|^2 \rangle & \langle S_{HH}S_{HV}^* \rangle & \langle S_{HH}S_{HV}^* \rangle & \langle S_{HH}S_{VV}^* \rangle \\ \langle S_{HV}S_{HH}^* \rangle & \langle |S_{HV}|^2 \rangle & \langle S_{HV}S_{HV}^* \rangle & \langle S_{HV}S_{VV}^* \rangle \\ \langle S_{VH}S_{HH}^* \rangle & \langle S_{VH}S_{HV}^* \rangle & \langle |S_{VH}|^2 \rangle & \langle S_{VH}S_{VV}^* \rangle \\ \langle S_{VV}S_{HH}^* \rangle & \langle S_{VV}S_{HV}^* \rangle & \langle S_{VV}S_{HV}^* \rangle & \langle |S_{VV}|^2 \rangle \end{bmatrix} \quad (2.6)$$

onde $\langle \quad \rangle$ denota a média espacial dos pixels vizinhos. Na matriz [C] os elementos da diagonal principal representam a intensidade do sinal.

Além da matriz de covariância [C], é também empregada a matriz de coerência polarimétrica [T], que é formada pelo produto vetorial entre o vetor de Pauli e seu complexo conjugado (Equação 2.7).

$$[T]_{3 \times 3} = \frac{1}{2} \begin{bmatrix} \langle K_a K_a^* \rangle & \langle K_a K_b^* \rangle & \langle K_a K_c^* \rangle & \langle K_a K_d^* \rangle \\ \langle K_b K_a^* \rangle & \langle K_b K_b^* \rangle & \langle K_b K_c^* \rangle & \langle K_b K_d^* \rangle \\ \langle K_c K_a^* \rangle & \langle K_c K_b^* \rangle & \langle K_c K_c^* \rangle & \langle K_c K_d^* \rangle \\ \langle K_d K_a^* \rangle & \langle K_d K_b^* \rangle & \langle K_d K_c^* \rangle & \langle K_d K_d^* \rangle \end{bmatrix} \quad (2.7)$$

onde: $K_a = S_{HH} + S_{VV}$; $K_b = S_{HH} - S_{VV}$; $K_c = S_{HV} - S_{VH}$; $K_d = S_{HV} + S_{VH}$, em que K_a está relacionado ao espalhamento superficial, K_b ao espalhamento do tipo *double-bounce* e K_c e K_d ao espalhamento volumétrico, considerando-se o princípio de reciprocidade.

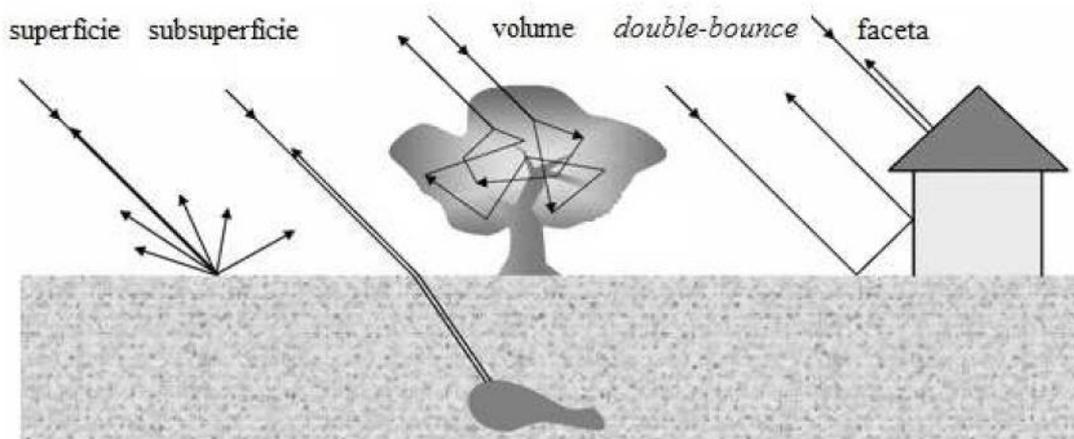
Segundo Hellmann (2001), as matrizes [C] e [T] fornecem os valores de intensidade total da onda, apresentando os mesmos autovalores, mas diferentes autovetores.

2.7 Tipos de Interações com os Alvos

O comprimento de onda do radar irá afetar de forma direta a interação das micro-ondas com os alvos na superfície terrestre (ULABY et al., 1984). Desse modo, são definidos

mecanismos de espalhamento que irão auxiliar na interpretação das imagens SAR. Existem três tipos principais de mecanismos de espalhamentos, sendo eles: espalhamento superficial, volumétrico e *double-bounce*. Além desses mecanismos, observa-se na Figura 2.2, a faceta de espalhamento produzida por refletores planos e o espalhamento subsuperfície (RICHARDS, 2009).

Figura 2.2 - Mecanismos de espalhamento.



Fonte: Richards (2009).

O mecanismo de espalhamento superficial está relacionado à dispersão que ocorre na superfície do alvo, sendo dependente da rugosidade superficial e da sua constante dielétrica (JENSEN, 2009). O espalhamento volumétrico acontece quando o sinal é refletido pelos vários elementos presentes no meio, o que ocorre com frequência em áreas florestais (RICHARDS, 2009). Já o espalhamento do tipo *double-bounce* provoca um forte sinal de retorno, resultando em pixels claros na imagem e é provocado quando o sinal interage com uma superfície vertical adjacente a um plano horizontal, orientados para a frente de onda do sinal (RICHARDS, 2009).

Segundo Dobson et al. (1995), a magnitude dos mecanismos de espalhamento está relacionada aos fatores geométricos e propriedades dielétricas do solo e vegetação. O grau de penetrabilidade da onda eletromagnética com o alvo está relacionado à fatores como ângulo de incidência, polarização e características do meio (RANEY, 1998).

Quanto maior for o ângulo de incidência, menor será a capacidade de penetração da radiação eletromagnética (VAN DER SANDEN, 1997). Em vegetações onde a estrutura

é predominantemente vertical nota-se uma maior atenuação da radiação eletromagnética para a polarização VV, ocorrendo uma maior penetração das ondas horizontalmente polarizadas (LE TOAN et al., 2002). Uma das características do meio que influencia a penetrabilidade é a umidade, cujo aumento no alvo provoca um decréscimo logarítmico na profundidade de penetração da radiação (WOODHOUSE, 2006).

Em uma imagem SAR a cobertura florestal é representada pela combinação de respostas provenientes dos diferentes mecanismos de espalhamento, resultantes das interações entre o sinal emitido pelo sensor e elementos da superfície como solo, troncos e copa das árvores (LECKIE; RANSON, 1998).

Nesse ambiente, o comprimento de onda é o parâmetro que apresenta maior influência no tipo de interação entre a radiação e o alvo (LE TOAN et al., 2002). Com isso, as faixas espectrais das bandas X e C, que apresentam menores comprimentos de onda são caracterizadas por apresentarem baixa penetração em florestas densas. Nesse caso, a interação da radiação eletromagnética ocorre com os elementos do topo do dossel, resultando em uma maior contribuição do espalhamento superficial (WOODHOUSE, 2006).

De maneira oposta, as bandas L e P são caracterizadas por apresentarem uma maior penetração em florestas densas, com uma maior contribuição do espalhamento volumétrico, relacionado aos múltiplos espalhamentos sofridos no interior da floresta (HENDERSON; LEWIS, 1998; LE TOAN et al., 1992; WOODHOUSE, 2006).

2.8 Decomposição de Alvos

A decomposição de alvos é uma técnica que facilita a interpretação de imagens polarimétricas SAR, expressando o mecanismo médio de espalhamento como uma soma de elementos independentes, permitindo que cada elemento seja associado a um mecanismo físico (TOUZI, 2007). A decomposição de alvos pode ser dividida em duas classes: coerente e incoerente.

A decomposição coerente é empregada em alvos determinísticos, sendo caracterizada pela matriz [S] (CLOUDE, 2009). Nesse caso, são empregadas as decomposições de

Pauli (CLOUDE; POTTIER, 1996), Krogager, (KROGAGER, 1990) e Cameron (CAMERON; LEUNG, 1990).

Já a decomposição incoerente pode ser caracterizada pelas matrizes de Muller, covariância [C] e coerência [T] (CLOUDE, 2009). Nesse caso, as decomposições mais empregadas são as decomposições de Freeman (FREEMAN; DURDEN, 1998) e decomposição por autovalor e autovetor (CLOUDE; POTTIER, 1996).

Este trabalho propõe-se a aplicação da técnica de decomposição de alvos por autovalores e autovetores proposta por Cloude e Pottier (1996). A decomposição de Cloude e Pottier utiliza um algoritmo de suavização baseado em estatísticas de segunda ordem para extrair os atributos médios. Além disso, pressupõe que sempre haverá um mecanismo de espalhamento médio dominante em cada célula de resolução.

A partir dessa decomposição são gerados três atributos a partir da matriz [T], a entropia (H), anisotropia (A) e ângulo alfa (α). A matriz [T] passa a ser representada pela soma de três outras matrizes compostas por autovetores e autovalores, onde os autovetores estão relacionados com o espalhamento e os autovalores irão indicar a contribuição de cada tipo de espalhamento para o espalhamento total (CLOUDE, 2009; LEE; POTTIER, 2009).

A entropia é um atributo que mede o grau de aleatoriedade da distribuição dos mecanismos de espalhamento (Equação 2.8) e é representada por uma medida escalar ($0 \leq H \leq 1$). Quando o valor de entropia for baixo ($H = 0$) indica que há apenas um mecanismo de espalhamento dominante, já quando a entropia assume um valor alto, indica que não há um mecanismo de espalhamento dominante (CLOUDE, 2009; LEE; POTTIER, 2009).

$$H = - \sum_{i=1}^3 P_i \log_3 (P_i) \quad (2.8)$$

Onde:

$$P_i = \frac{\lambda_i}{\sum \lambda_i} \quad (2.9)$$

P_i e λ_i são os autovalores da matriz de coerência.

Já a anisotropia indica a importância relativa dos mecanismos de espalhamento secundários (Equação 2.10), sendo complementar à entropia, produzindo informações quando os valores da entropia variam entre $0,5 < H < 0,7$ (LEE; POTTIER, 2009). A anisotropia varia entre $0 \leq A \leq 1$. Nesse caso, quando a anisotropia assumir valores elevados é uma indicação que o segundo mecanismo de espalhamento (λ_2) apresenta importância, já quando os valores de A forem baixos, indicam que o terceiro mecanismo (λ_3) também apresenta importância (HELLMANN, 2001).

$$A = \frac{\lambda_2 - \lambda_3}{\lambda_2 + \lambda_3} \quad (2.10)$$

Por fim, o ângulo alfa ($0^\circ \leq \alpha \leq 90^\circ$), indica o tipo de mecanismo de espalhamento (Equação 2.11), se $\alpha = 0^\circ$, o espalhamento é superficial, se $\alpha = 45^\circ$, refere-se ao espalhamento volumétrico e quando $\alpha = 90^\circ$, representa um espalhamento *double-bounce* (LEE; POTTIER, 2009).

$$\alpha = \sum P_i \alpha_i \quad (2.11)$$

onde α_i são derivadas dos autovetores da matriz [T].

A base conceitual para decomposição de alvos foi desenvolvida para dados SAR QuadPol (CLOUDE; POTTIER, 1996). No entanto, como demonstrado por Cloude (2007), pode ser aplicada para dados de polarização dual, gerando-se as matrizes de covariância e coerência 2x2. Nesse caso, as matrizes irão apresentar apenas dois autovalores, sendo que os parâmetros entropia e anisotropia irão representar a mesma informação. As Equações 2.11 e 2.12 representam a matriz de espalhamento [S] para dados dual-pol HV-VV e seu vetor de espalhamento, respectivamente (JI; WU, 2015).

$$S = \begin{bmatrix} 0 & S_{HV} \\ S_{HV} & S_{VV} \end{bmatrix} \quad (2.11)$$

$$k = [S_{vv} \quad 2S_{HV}]^T \quad (2.12)$$

Ji e Wu (2015) analisaram os mecanismos de espalhamento da decomposição de Cloude-Pottier modificada para dados SAR de polarização dual e observaram que dados com polarizações HH-VV permitem a extração de oito mecanismos de espalhamento do plano H/ α , apesar da ausência da polarização cruzada. Enquanto dados SAR com as polarizações HH-HV e VV-VH permitiram apenas a extração parcial dos mecanismos

de espalhamento, não possibilitando a separação dos mecanismos de espalhamento de superfície, dipolo e múltiplos, o que representa a necessidade da co-polarização para a extração completa dos mecanismos de espalhamento.

2.9 Coeficiente de Retroespalhamento

O coeficiente de retroespalhamento (σ°) representa a seção cruzada de radar por unidade de área no alcance do terreno e corresponde a energia que retorna ao sensor. Além disso, representa a razão da densidade de potência espalhada média pela superfície numa esfera de raio r , variando de acordo com os parâmetros do sensor e dos alvos (HENDERSON; LEWIS, 1998; LEE; POTTIER, 2009).

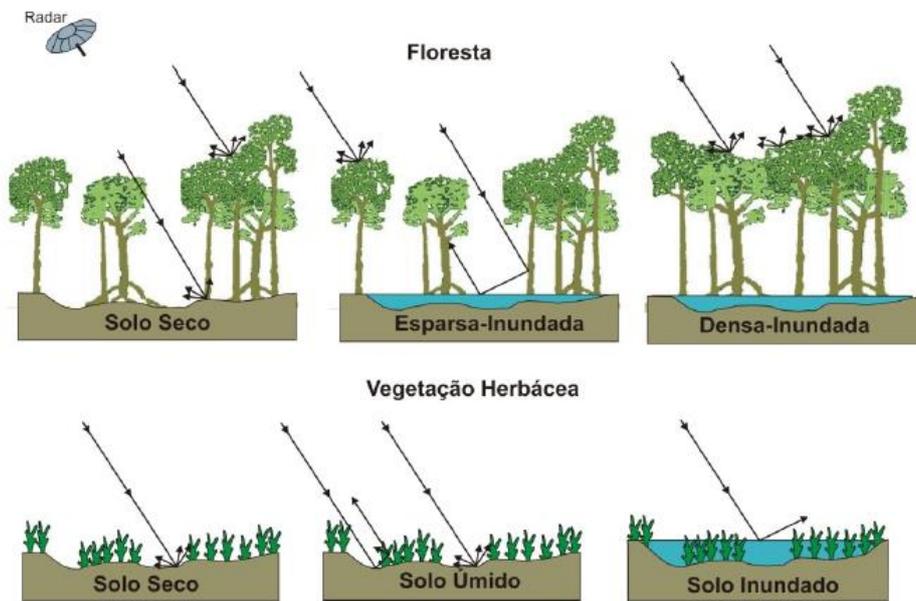
Os principais parâmetros relacionados ao sensor são frequência, ângulo de incidência, azimute de visada, resolução espacial e polarização, enquanto os parâmetros relacionados aos alvos são rugosidade da superfície, propriedades dielétricas e inclinação.

Em um ambiente florestal o coeficiente de retroespalhamento expressa a interação entre o espalhamento direto e a atenuação da radiação eletromagnética pelas camadas florestais, dossel, troncos e superfície (KASISCHKE; BOURGEAU-CHAVEZ, 1997; TOWNSEND, 2002; LANG; KASISCHKE, 2008).

De acordo com Lang et al. (2008), para sensores que utilizam a banda C, o coeficiente de retroespalhamento será influenciado, principalmente, pelo retroespalhamento do topo do dossel (Figura 2.3), o que também ocorre quando a radiação é transmitida em grandes ângulos de incidência, provocando uma diminuição na transmissividade da copa.

No caso de vegetações herbáceas, quando presentes em solo seco, a sua interação com a radiação eletromagnética irá resultar em espalhamentos múltiplos, causando um baixo retorno do sinal. No entanto, em solos úmidos, pode ocorrer o espalhamento *double-bounce*, devido ao aumento na constante dielétrica da vegetação e do solo. Já em superfícies com vegetação inundada, a energia incidente será totalmente refletida em sentido oposto ao sensor, gerando um retroespalhamento menor do que o gerado por solo seco (BOURGEAU-CHAVEZ et al., 2005).

Figura 2.3 - Retroespalhamento teórico na banda C considerando áreas de floresta e vegetação herbácea, em condições de inundação e não inundação.

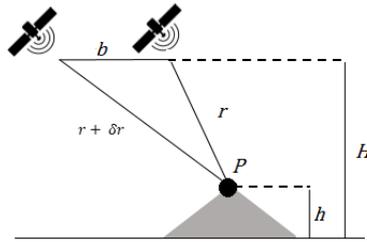


Fonte: Adaptada de Bourgeau-Chavez et al. (2005).

2.10 Coerência Interferométrica

A técnica de interferometria se baseia na diferença de fase formada pelo recebimento de um sinal coerente por duas antenas, separadas por uma distância (linha-base) ou por uma mesma antena em diferentes períodos, obtendo-se assim, um par de imagens do mesmo alvo com visadas diferentes, permitindo a geração do modelo de elevação do terreno (GAMA et al., 2013; GRAHAM, 1974; MADSEN et al., 1993; MADSEN; ZEBKER, 1998; MURA et al., 2012). A Figura 2.4 mostra a representação da geometria InSAR.

Figura 2.4 - Representação da geometria InSAR.



Fonte: Produção do autor.

A fase do sinal de retorno de um alvo situado a uma distância r em relação ao SAR é dada pela Equação 2.13.

$$\varphi = \frac{4\pi r(t)}{\lambda} \quad (2.13)$$

onde: φ é a fase, que varia de 0 a 2π ; r = distância da fonte emissora no instante t ; 4π = relacionado à distância de ida e retorno do sinal e λ = comprimento de onda.

Graham (1974), propôs a técnica de interferometria SAR com o objetivo de produzir modelos digitais de elevação (MDE) a partir da informação de diferença de fase entre as duas imagens. O interferograma é utilizado para retratar a variação de fase relativa, que é representada por franjas de mesmo valor (GENS; GENDEREN, 1996; MASSONNET; FEIGL, 1998).

Segundo Zebker e Villasenor (1992), a coerência interferométrica é uma medida da correlação da informação de fase correspondente ao sinal dos pixels homólogos das duas imagens, utilizada para avaliar a qualidade do interferograma.

Na imagem coerência, as áreas escuras estão relacionadas às áreas de floresta, que representam as áreas com baixa correlação, enquanto as áreas claras representam áreas com alta correlação que estão relacionadas às regiões estáveis como áreas de solo exposto.

Apesar da baixa coerência em áreas florestais dificultar a análise interferométrica para geração do MDE, a sua utilização para o mapeamento do uso e cobertura da terra possibilita a separação entre áreas de florestas e não florestas (ASKNE; SMITH, 1996). A utilização da imagem coerência possibilita uma melhor discriminação entre essas

áreas do que a utilização de imagens baseadas em retroespalhamento, com informações de intensidade e amplitude (GENS; GENDEREN, 1996).

Vários estudos comprovam o potencial de utilização das imagens de coerência para o mapeamento do uso e cobertura da terra. Gaboardi (2003) avaliou o potencial de utilização das imagens de coerência interferométrica da banda C, presentes nos satélites ERS-1/2 para separação de floresta/não floresta e para o mapeamento do uso e cobertura da terra em áreas de florestas tropicais. Strozzi et al. (1999), mapearam áreas de floresta, solo exposto e áreas urbanas, na região de Ariquemes – RO, utilizando imagens de coerência interferométrica e intensidade.

2.11 Missão Sentinel-1

O Sentinel-1 é o primeiro componente espacial da família Copernicus (Sentinel 1, 2 e 3), desenvolvido pela ESA (Agência Espacial Europeia). O Sentinel-1 é composto por dois satélites, Sentinel-1A e Sentinel-1B, que operam na banda C e compartilham do mesmo plano orbital, com uma diferença de órbita de 180°, coletando imagens diurnas ou noturnas, independentes das condições atmosféricas (ESA, 2018a). Os sensores do Sentinel-1 dão continuidade às missões ERS 1 e 2 e ENVISAT, com o objetivo de garantir fluxo contínuo de dados de cobertura global.

Os dados adquiridos pela missão Sentinel-1 são disponibilizados gratuitamente, com uma resolução temporal de 12 dias, com o objetivo de aumentar a investigação científica e promover o crescimento de mercados de observação da Terra (ESA, 2018a).

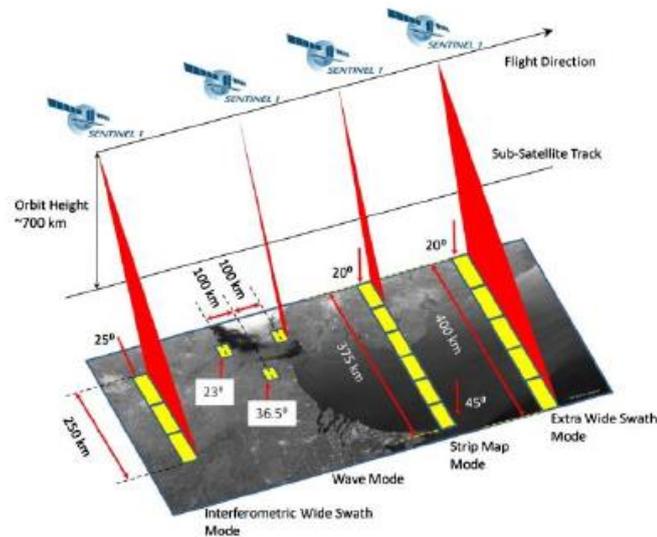
O sistema opera nos modos de polarização dupla (HH/HV ou VV/VH) e polarização única (HH ou VV) e possui quatro modos de imageamento (Tabela 2.2 e Figura 2.5): *Stripmap Mode* (SM), *Interferometric Wide Swath Mode* (IW); *Extra-Wide Swath Mode* (EW) e *Wave Mode* (WM).

Tabela 2.2 - Modos de aquisições do Sentinel-1A.

Modo	Ângulo Incidente	Resolução Espacial (m)	Largura de Faixa (Km)	Polarização
SM	20° - 45°	5x5	80	HH/HV, VV/VH, HH, VV
IW	29° - 46°	5x20	250	HH/HV, VV/VH, HH, VV
EW	19° - 47°	20x40	400	HH/HV, VV/VH, HH, VV
WV	22° - 35°e 35° - 38°	5x5	20	HH, VV

Fonte: Adaptada de ESA (2018a).

Figura 2.5 - Modos de aquisição da missão Sentinel-1.



Fonte: ESA (2018a).

Além disso, as imagens Sentinel estão disponíveis em três diferentes níveis de processamento. De modo geral, os produtos do Nível-0 são dados SAR brutos e não focalizados. Os produtos do Nível-1 são produzidos como SLC (*Single Look Complex*) e GRD (*Ground Range Detected*), já os produtos do Nível-2 podem ser OWI (*Ocean Wind Field*), OSW (*Ocean Swell Spectra*) e RVL (*Surface Radial Velocity*) (ESA, 2018a).

Os produtos SLC consistem em dados SAR focalizados, georreferenciados, através de dados de órbita e atitude do satélite, sendo fornecidos em geometria de alcance

inclinado (*slant range*). Além disso, os produtos estão na orientação zero-Doppler e consistem em dados complexos que preservam a informação de fase (ESA, 2018a).

2.12 Classificações supervisionada

A classificação de imagens busca reconhecer padrões e relacionar um objeto na imagem com uma classe temática, através de uma análise quantitativa do espaço de atributos da imagem (CRÓSTA, 1992; MATHER; TSO, 2009).

Na classificação supervisionada é necessária a seleção de amostras pelo analista, que utiliza de conhecimentos prévios sobre a área de estudo para definição das classes temáticas e amostras. Nesse caso, as amostras coletadas são a base para a classificação dos demais pixels que não possuem uma classe temática definida (MATHER, 1999). A classificação supervisionada é um dos métodos mais utilizados em sensoriamento remoto para uma análise quantitativa dos dados (RICHARDS; JIA, 1999).

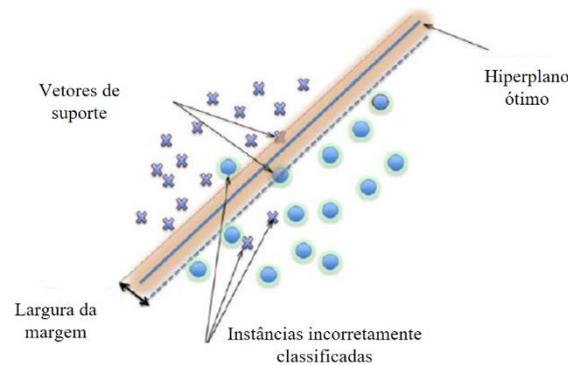
Segundo Mather e Tso (2009), as classificações podem ser pixel-a-pixel, quando se utiliza a informação espectral de cada pixel para encontrar os padrões, ou por regiões, quando se utiliza, além da informação espectral, a informação espacial.

2.12.1 Classificação *Support Vector Machine* – SVM

O classificador SVM (*Support Vector Machine*) (CORTES; VAPNIK, 1995) é uma técnica de classificação supervisionada de imagens, baseada em um algoritmo de otimização que define, através das amostras de treinamento, planos de separação ótimos entre as classes a fim de maximizar a distância entre elas (HAYKIN, 2001).

De modo geral, existe um número infinito de hiperplanos, no entanto, apenas um irá maximizar a margem entre as classes, sendo definido como o hiperplano ótimo (Figura 2.6). Os pontos que limitam a largura da margem entre as classes são definidos como vetores de suporte (Oommén et al., 2008), e correspondem aos elementos críticos da amostra de treinamento, pois delimitam a superfície de decisão (CORTES; VAPNIK, 1995).

Figura 2.6 - Cenário de uma classificação SVM em um espaço bidimensional, para discriminação de duas classes.



Fonte: Adaptada de Mountrakis et al. (2011).

Como na maioria dos casos os dados não apresentam uma separabilidade linear, o algoritmo SVM utiliza uma função de *kernel* para possibilitar a dispersão dos dados de forma a permitir o ajuste do hiperplano linear (OOMMEN et al., 2008). Podem ser empregadas várias funções de *kernel* (linear, polinomial, *Radial Basis Function* – RBF e sigmoide), sendo a RBF (Equação 2.14) a função que, na maioria dos casos, apresenta resultados positivos (EXELIS, 2015).

$$\varphi = e^{-\gamma \|x-x_i\|^2} \quad (2.14)$$

onde γ representa a largura de *kernel*, x é um vetor de suporte e x_i é um dos pontos dos dados de treinamento (OOMMEN et al., 2008).

Além disso, essa função utiliza os parâmetros custo (C), que possibilita um grau de erro na definição de hiperplanos de separação (ADAM et al., 2014), e gamma (g). Quanto maior o valor do custo, menor a tolerância ao erro, ou seja, os hiperplanos são menos flexíveis, podendo criar um modelo que não generalize corretamente (EXELIS, 2015). Já o parâmetro g influencia a forma de separação dos hiperplanos (LI; DU, 2015), expressando o nível de confiança dos segmentos mais próximos de um determinado segmento representarem a mesma classe. Nesse caso, valores altos indicam uma maior confiança, resultando na classificação somente de segmentos mais próximos. Por outro lado, valores baixos possibilitam que segmentos mais distantes sejam classificados, enquanto a confiança dos segmentos vizinhos pertencerem à mesma classe é menor

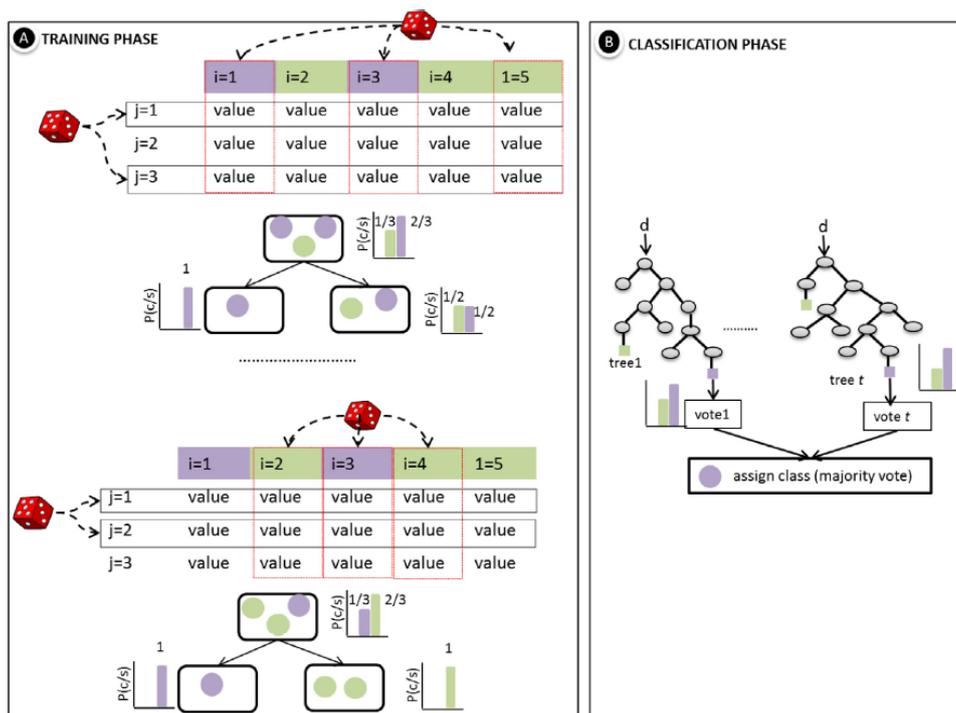
(EXELIS, 2015). De acordo com Lin e Liu (2007), a estimativa dos parâmetros ótimos da função RBF é realizada através de métodos exaustivos de tentativa e erro.

2.12.2 Classificação *Random Forest* – RF

O *Random Forest* vem sendo muito utilizado nas últimas décadas, por ser um classificador que apresenta excelentes resultados de classificação e rápida velocidade de processamento (BREIMAN, 2001; Du et al., 2015; PAL, 2005; RODRIGUEZ-GALIANO et al., 2012).

O classificador *Random Forest* utiliza um conjunto de árvores de decisão para realizar uma previsão (BREIMAN, 2001). As árvores de decisão são criadas independentemente, através de um subconjunto de amostras de treinamento (Figura 2.7). A divisão de cada nó é realizada através de recursos definidos pelo usuário (BELGIU; DRAGUT, 2016; BREIMAN, 2001; LU; WENG, 2007).

Figura 2.7 - Fases de treinamento e classificação do *Random Forest*.



Fonte: Belgiu e Dragut (2016).

Na Figura 2.7 são definidos os seguintes parâmetros: i = amostras; j = variáveis; p = probabilidade; c = classe; s = data; t = número de árvores; d = novo dado para ser classificado e $value$ = valores que a variável j pode assumir.

Dois parâmetros devem ser definidos para produzir as árvores de decisão: o número de árvores a serem geradas (N_{tree}) e o número de variáveis a serem testadas (M_{try}). Ao possibilitar o crescimento do número de árvores de decisões (N_{tree}), o algoritmo cria árvores com alta variação e baixa tendência (BREIMAN, 2001).

Lawrance et al. (2006), definiu um valor de N_{tree} igual a 500, devido a estabilização dos erros ocorrer antes de atingir esse número de árvores de decisão. Além disso, uma das implementações mais utilizadas para o algoritmo é no pacote R, que apresenta o 500 como o valor padrão para o *Random Forest*.

Para estudos de classificações utilizando imagens de radares de abertura sintética polarimétrica, Du et al. (2015), observaram que este parâmetro não tem influência nos resultados da classificação. Já o parâmetro M_{try} pode ser obtido pela raiz quadrada do número de variáveis de entrada (GISLASON et al., 2006).

Além disso, o RF permite calcular a análise da importância das variáveis de acordo com o índice de Gini. O índice de Gini é uma medida de homogeneidade que varia de 0 (completamente homogêneo) a 1 (completamente heterogêneo). No caso do RF, esse índice é calculado toda vez que uma variável de entrada for utilizada na divisão do nó, então o índice Gini dos nós filhos é comparado ao nó original. Quando a divisão dos nós melhorar a homogeneidade das classes, ocorrerá uma diminuição do valor de Gini após a divisão do nó. Por fim, todas as diminuições do índice de Gini obtidas durante o processo de classificação são somadas para cada variável de entrada. Portanto, as variáveis que apresentarem nós com maior pureza de classificação terão maiores valores no índice de Gini geral (*Mean Decrease Gini*) (BALZTER et al., 2015; BREIMAN, 2001).

Nesse algoritmo, de acordo com Breiman (2001), dois terços das amostras são utilizadas para treinamento e o restante para validação. De acordo com Colditz (2015), as amostras de treinamento devem representar 0,25% da área de estudo. Du et al., (2015), observaram que há uma melhora no método quando há uma grande quantidade de amostras disponíveis.

2.13 Validação do desempenho classificatório

A análise dos resultados obtidos com as classificações é realizada através da matriz de confusão e de estatísticas como o índice Kappa. Segundo Congalton e Green (1999), a matriz de confusão representa uma das formas de avaliar a exatidão de uma classificação, através da comparação entre os resultados da classificação e dados de referência.

A exatidão global da classificação é obtida a partir da razão entre a soma do número de pixels das amostras classificados corretamente (diagonal principal) pelo número total de pixels das amostras de treinamento. Além disso, a matriz de confusão ou matriz de erros permite definir os erros de inclusão (erros de comissão) e os erros de exclusão (omissão) e possibilita calcular a precisão de cada classe temática (CONGALTON; GREEN, 1999; CONGALTON; GREEN, 2009).

Para realizar a comparação entre diferentes matrizes de confusão, são empregados os índices de concordância, e um desses índices muito utilizado é o índice Kappa que é calculado a partir dos elementos da matriz de confusão. O índice Kappa é estimado pela Equação 2.15.

$$\hat{K} = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_i + n_{+i}}{n^2 - \sum_{i=1}^k n_i + n_{+i}} \quad (2.15)$$

onde: \hat{K} = Coeficiente Kappa; k = número de linhas na matriz; n_{ii} = número de observações na linha [i] e coluna [i]; n_i e n_{+i} = totais marginais da linha [i] e coluna [i], respectivamente; n = número total de observações.

Segundo Brites et al. (1996), o índice Kappa é recomendado para avaliar a exatidão da classificação, por representar completamente a matriz de confusão, sendo considerado uma padronização para representar os resultados das classificações. Landis e Koch (1977), relacionaram intervalos de valores desse índice a níveis nominais qualitativos (Tabela 2.3), como uma forma de expressar a qualidade dos resultados.

Tabela 2.3 - Conceitos das classificações baseados no coeficiente Kappa.

Kappa	Conceito
< 0	Péssima
$0 < K < 0,2$	Ruim
$0,2 < K < 0,4$	Razoável
$0,4 < K < 0,6$	Bom
$0,6 < K < 0,8$	Muito bom
$0,8 < K < 1,0$	Excelente

Fonte: Landis e Koch (1977).

Além disso, pode ser utilizado o método de Simulação de Monte Carlo que permite estabelecer intervalos de credibilidade, através de múltiplos experimentos, baseado na teoria das grandes amostras (ALMEIDA et al., 2010; LANDAU; BINDER, 2009). Este método possibilita explorar as variações nos fatores de entrada sem necessitar de pressuposições sobre a estrutura do modelo empregada (BAUDRY et al., 2018; MADANI; LUND, 2011; MOSADEGHI et al., 2013).

Moreira et al. (2016) empregaram o método de Monte Carlo para avaliar os índices Kappa obtidos em suas classificações com o objetivo de analisar o efeito da topografia sobre a classificação do uso e cobertura da terra por análise de imagens baseada em objetos. Já Marujo et al. (2017) utilizaram essa abordagem para avaliar os resultados das classificações obtidas para o mapeamento da cultura cafeeira por meio da classificação automática.

Além disso, podem ser aplicados testes para avaliar se as classificações apresentam diferenças significativas entre si. Muitas vezes esta diferença é avaliada através da comparação entre os Kappas dos dois mapeamentos. Nesse caso, as amostras devem ser independentes (FOODY, 2004). No entanto, na maioria dos casos e principalmente devido à dificuldade de coleta de amostras em campo, as amostras utilizadas para realizar as diversas classificações são as mesmas, sendo amostras dependentes. Para o caso em que as amostras utilizadas nos mapeamentos são dependentes, existem testes alternativos para avaliar a diferença entre as classificações.

O teste de McNemar (MCNEMAR, 1947) é baseado na hipótese nula de que a mesma proporção de pixels será corretamente classificada pelo método 1 e pelo método 2 (LEEuw et al., 2006). É um teste não paramétrico baseado em uma matriz de

contingência 2x2 (Tabela 2.4), que apresenta uma tabulação cruzada da distribuição correta e incorreta dos pixels de cada classificador.

Na matriz, f_{ij} indica a frequência nos dados de validação da linha i e coluna j . Nesse caso, f_{12} e f_{21} indicam o número de pixels corretamente classificados por um método e incorretamente classificados pelo outro, enquanto f_{11} indica os pixels que foram corretamente classificados por ambos os métodos e f_{22} indicam os pixels que foram incorretamente classificados por ambos os métodos (FOODY, 2004).

Tabela 2.4 - Matriz de contingência.

Alocação	Classificação 2		Total
	Correto	Incorreto	
Classificação 1			
Correto	f_{11}	f_{12}	
Incorreto	f_{21}	f_{22}	
Total			

Fonte: Adaptada de Foody (2004).

O teste de McNemar usa a razão populacional $\psi = f_{12}/f_{21}$ e a hipótese nula é obtida quando $\psi = 1$. Além disso, é baseado em uma distribuição qui-quadrado (χ^2) onde o quadrado de Z segue uma distribuição qui-quadrado com um grau de liberdade (LEEuw et al., 2006). Assim, o resultado do teste pode ser obtido pela Equação 2.16, que será comparado com o valor do qui-quadrado tabelado para indicar a significância das classificações.

$$\chi^2 = \frac{(f_{12} - f_{21})^2}{f_{12} + f_{21}} \quad (2.16)$$

Além disso, quando o tamanho amostral é pequeno, recomenda-se a utilização da correção de continuidade (FOODY, 2004).

Leeuw et al. (2006), compararam os resultados observados com o teste de McNemar em relação ao tradicional teste Z do Kappa e observaram que o teste de McNemar apresenta maior precisão quando relacionado à amostras correlacionadas.

Fu et al. (2017), utilizaram o teste de McNemar para comparar as abordagens pixel-a-pixel e orientada ao objeto empregadas em diversos cenários de classificação, utilizando diferentes sensores.

3. MATERIAL E MÉTODOS

3.1 Área de estudo

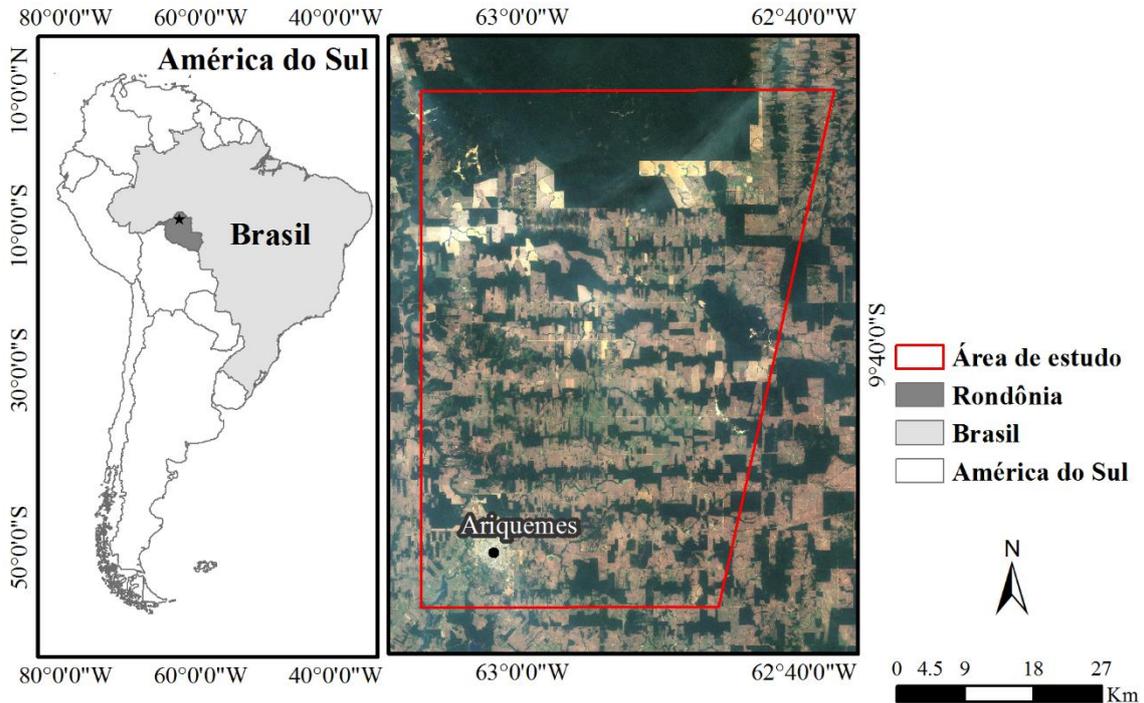
A área de estudo compreende parte da região de Ariquemes, ao norte do Estado de Rondônia, entre as coordenadas geográficas 62°40'0"O e 9°40'0"S, totalizando uma área de 3140,3 km² (Figura 3.1).

A região é caracterizada por apresentar clima tropical chuvoso (tipo Aw), segundo a classificação de Köppen, com temperatura média de 25,5°C e precipitação total anual em torno de 2.290 mm/ano. Além disso, apresenta duas estações climáticas bem definidas, a estação chuvosa possui sete meses de duração, de outubro a abril, enquanto a estação seca acontece entre os meses de junho a agosto (CARVALHO, R. et al., 2016). De acordo com Almeida et al. (1996), os principais tipos de solo encontrados na região são Litólicos Eutróficos com afloramentos rochosos, Podzólicos Vermelho-Amarelo Eutróficos e Álicos e Latossolo Vermelho-Amarelo Álico.

De acordo com Carvalho R. et al. (2016), a economia da região se concentra principalmente na agropecuária, baseada nos cultivos de milho, café, feijão e soja e criação de gado de leite e corte. Nos últimos anos, o setor da piscicultura tem apresentado grande expansão e desenvolvido a economia local.

Como pode ser observado na Figura 3.1, a área de estudo sofreu grande ocupação antrópica, sendo uma região caracterizada por um intenso processo de fragmentação florestal.

Figura 3.1 - Imagem do satélite Sentinel-2B com a localização geográfica da área de estudo.



Fonte: Produção do autor.

3.2 Dados SAR

Para a realização desta dissertação foram utilizados dados do sensor Sentinel-1A (banda C), que são disponibilizados gratuitamente pelo site da Agência Espacial Europeia (ESA). Os dados utilizados foram adquiridos no modo IW (*Interferometric Wide Swath*), com uma faixa de imageamento de 250 Km e resolução espacial de 5 m x 20 m (ESA, 2018).

O modo IW captura três sub-faixas e nesta dissertação foi utilizada a sub-faixa referente à área de estudo IW2, nas polarizações VV e VH. Os dados originais são disponibilizados no nível 1 de processamento no formato SLC (*Single Look Complex*), que consistem em dados SAR focalizados e georreferenciados através de informações de órbita e atitude do satélite e são fornecidos em geometria de alcance inclinado (*Slant Range*) em zero-Doppler. Os produtos utilizados consistem de dados complexos e preservam a informação de fase (ESA, 2018a). A Tabela 3.1 apresenta algumas características dos dados Sentinel-1A que foram adquiridos.

Tabela 3.1 - Características das imagens Sentinel-1A.

Atributos	Imagem Sentinel-1A
Data das aquisições	13/09/2017 e 25/09/2017
Ponto-órbita	135-018282
Modo de Imageamento	Interferometric Wide Swath - IW
Sub-faixa	IW1, IW2 e IW3
Órbita	Descendente
Largura de faixa	250 km
Resolução espacial	5 x 20 m
Comprimento de onda	3,9 – 7,5 cm
Polarizações	VV e VH
Formato	SLC e Slant Range

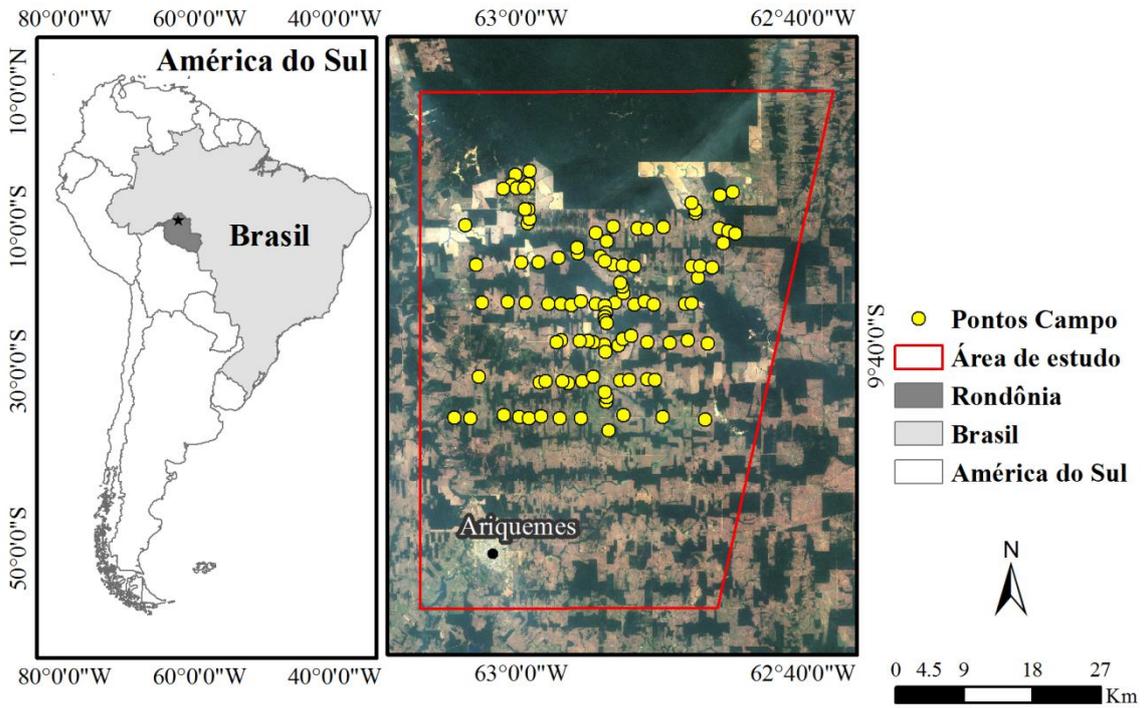
Fonte: Adaptada de ESA (2018a).

3.3 Dados de campo

O trabalho de campo foi realizado na região de Ariquemes – RO, em setembro de 2017, onde foram coletados pontos georreferenciados, através do Sistema de Posicionamento Global (GPS), na projeção *Universal Transversa de Mercator* (UTM) e Datum *World Geodetic System 1984* (WGS 84). Além disso, foi realizado o registro fotográfico de todos os pontos coletados. A Figura 3.2 apresenta a posição dos pontos coletados em campo e a Tabela 3.2 indica o número de pontos coletados em cada classe de uso e cobertura da terra.

Durante o trabalho de campo foi possível observar a grande dinâmica existente na região, com muitas áreas sendo preparadas para grandes cultivos agrícolas, principalmente milho e soja. No entanto, também foram observados pequenos cultivos familiares, com diversas fruticulturas, como guaraná, abacaxi e outros plantios como mandioca.

Figura 3.2 - Localização geográfica dos pontos coletados em campo.



Fonte: Produção do autor.

Tabela 3.2 - Pontos coletados em cada classe de uso e cobertura da terra.

Sigla	Classe	Número de pontos
FP	Floresta Primária	7
FD	Floresta Degradada	7
SSA	Sucessão Secundária Avançada	3
SSInt	Sucessão Secundária Intermediária	9
SSI	Sucessão Secundária Inicial	8
AG	Agricultura	30
PA	Pastagem	40
Total		104

Fonte: Produção do autor.

A Tabela 3.3 mostra a descrição das classes de uso e cobertura da terra identificadas através do levantamento de campo.

Tabela 3.3 - Descrição das classes de uso e cobertura da terra identificadas em campo.

Classe	Uso e Cobertura	Descrição	Registro Fotográfico
FP	Floresta Primária	Florestas sem alteração antrópica aparente.	
FD	Floresta Degradada	Florestas que sofreram perda de densidade por atividades de corte indiscriminado.	
SSA	Sucessão Secundária Avançada	Regeneração natural com mais de 15 anos.	
SSInt	Sucessão Secundária Intermediária	Regeneração natural de 5 a 15 anos.	
SSI	Sucessão Secundária Inicial	Regeneração natural com menos de 5 anos.	

continua

Tabela 3.4 - Conclusão.

Classe	Uso e Cobertura	Descrição	Registro Fotográfico
AG	Agricultura	Cultivos agrícolas ao longo da fase de desenvolvimento fenológico.	
PA	Pastagem	Pastagens manejadas e pastagens abandonadas.	

Fonte: Produção do autor.

3.4 Dados auxiliares

Para auxiliar na coleta de amostras de treinamento foram utilizadas imagens do sensor MSI (*Multispectral Instrument*) a bordo do satélite Sentinel-2B. As imagens deste sensor são disponibilizadas gratuitamente pelo site da Agência Espacial Europeia (ESA), nas projeções UTM e Datum WGS84 com uma resolução temporal de 10 dias. O sensor apresenta treze bandas espectrais e a sua resolução espacial está relacionada a essas bandas espectrais (Tabela 3.5). Para compor a área de estudo, foram utilizadas as imagens dos *tiles* T20LMQ e T20LNQ (ESA, 2018b).

Tabela 3.5 - Características das bandas espectrais do sensor MSI do Sentinel-2.

Banda	Comprimento de onda central (nm)	Resolução Espacial (m)
1	443	60
2	490	10
3	560	10
4	665	10
5	705	20
6	740	20
7	783	20
8	842	10
8a	865	20
9	940	60
10	1375	60
11	1610	20
12	2190	20

Fonte: Adaptada de ESA (2018b).

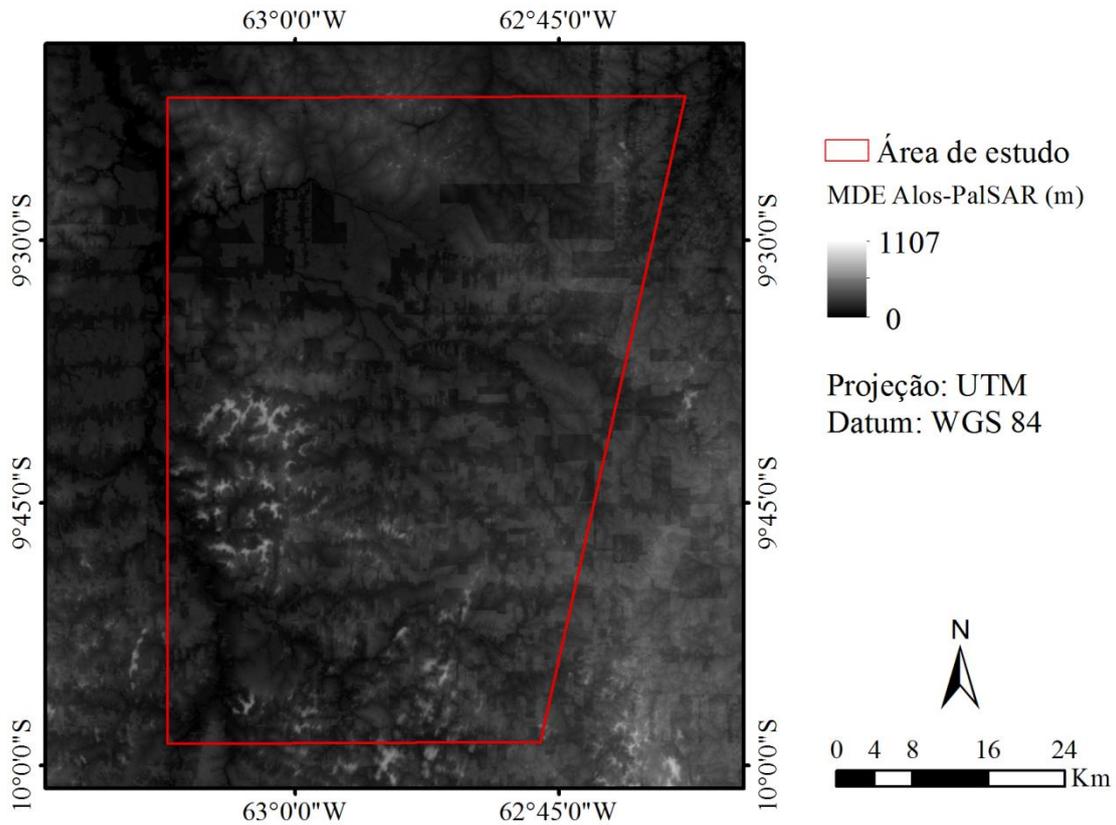
Além disso, foi utilizado o Modelo Digital de Elevação (MDE) do Alos-PalSAR-1 (Figura 3.3) da região de estudo, na etapa de pré-processamento dos dados. O modelo foi obtido a partir do produto *Radiometric Terrain Correction* (RTC), que possui uma resolução espacial de 12,5m. Este MDE, georreferenciado na projeção UTM, Datum WGS84, é disponibilizado gratuitamente no formato *geoTIFF* pelo *Alaska Satellite Facility* (ASF, 2015). Foi realizado o pré-processamento do MDE aplicando-se o método *Fill Sinks* (WANG; LIU, 2006), para identificar e preencher depressões de superfície. Para compor a área de estudo foi realizado o mosaico com quatro MDEs do Alos-PalSAR-1, como apresentado na Tabela 3.6.

Tabela 3.6 - MDEs AlosPalSAR-1 utilizados na área de estudo.

Órbita	26169	26592
Ponto	80	80
	90	90

Fonte: Produção do autor.

Figura 3.3 - MDE Alos-PalSAR.

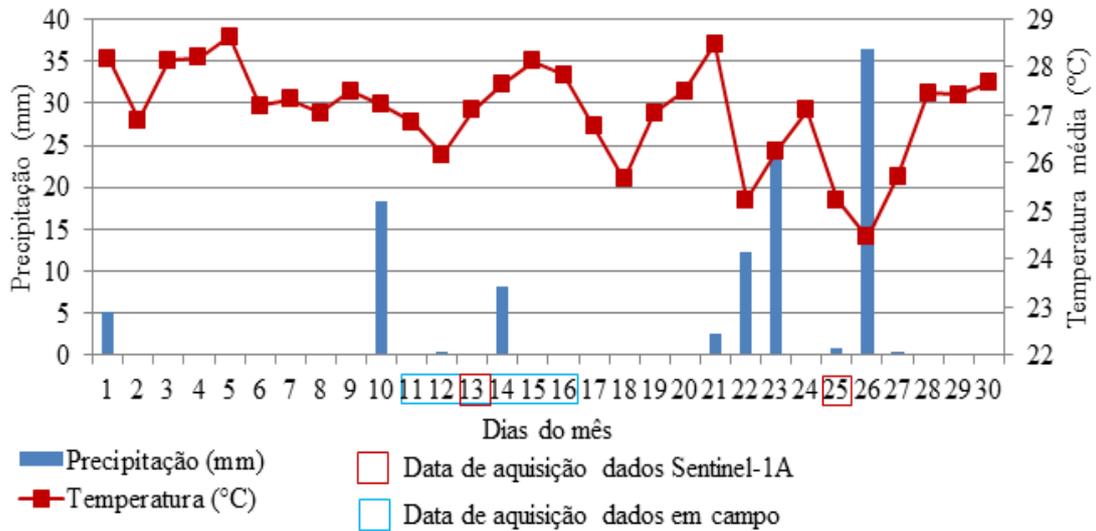


Fonte: Produção do autor.

Além disso, foram utilizados dados meteorológicos de precipitação pluviométrica diária acumulada nas datas de aquisição das imagens (Figura 3.4). Segundo Ulaby e Batlivala (1976), quanto maior o teor de umidade, maior será o efeito da constante dielétrica e de acordo com Lewis et al. (1998), a constante dielétrica é responsável por alterar a absorção, reflexão e transmissão do sinal pelo alvo, sendo assim importante a utilização de dados meteorológicos para a análise dos resultados.

Para a área de estudo não ocorreram precipitações significativas nas 24 horas anteriores ao imageamento do Sentinel-1 que interferissem na geração dos atributos SAR e nos resultados finais de classificação.

Figura 3.4 - Precipitação acumulada diariamente e temperatura média diária na estação meteorológica de Ariquemes (RO) no mês de setembro de 2017.



Fonte: INMET (2018).

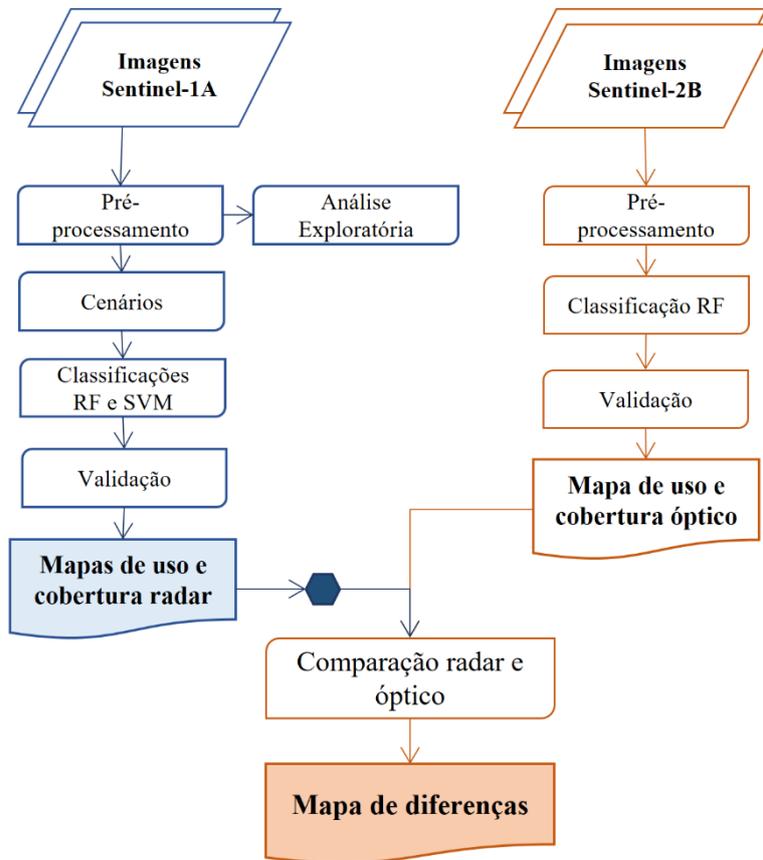
3.5 Metodologia utilizada

O fluxograma apresentado na Figura 3.5 representa a metodologia geral que foi utilizada no processamento e análise dos dados de acordo com os objetivos propostos.

De modo geral, foram realizados os processamentos dos dados de radar (Sentinel-1A), buscando-se responder os três primeiros objetivos específicos: a) Extrair os atributos provenientes dos dados de radar do Sentinel-1A: coeficientes de retroespalhamento (σ_{VH}^0 , σ_{VV}^0 , $\sigma_{VH}^0/\sigma_{VV}^0$); decomposição polarimétrica (H e α) e coerência interferométrica (γ_{VH} e γ_{VV}) e analisar a capacidade discriminatória destes em relação às classes temáticas analisadas; b) Avaliar o desempenho classificatório destes atributos através de cenários de classificações com os classificadores SVM (*Support Vector Machine*) e RF (*Random Forest*) e c) Comparar o desempenho dos classificadores SVM e RF para os diferentes cenários obtidos com os atributos dos dados de radar.

Para avaliar o potencial do mapeamento obtido com os dados de radar foi realizada a comparação do melhor cenário obtido com os dados do Sentinel-1A com o mapeamento realizado pelo sensor óptico (Sentinel-2B). Todas as etapas serão descritas detalhadamente nos próximos itens.

Figura 3.5 - Fluxograma geral das etapas metodológicas desenvolvidas.



Legenda:  Mapeamento do cenário com o melhor desempenho

Fonte: Produção do autor.

3.6 Processamento dos dados SAR

3.6.1 Pré-processamento

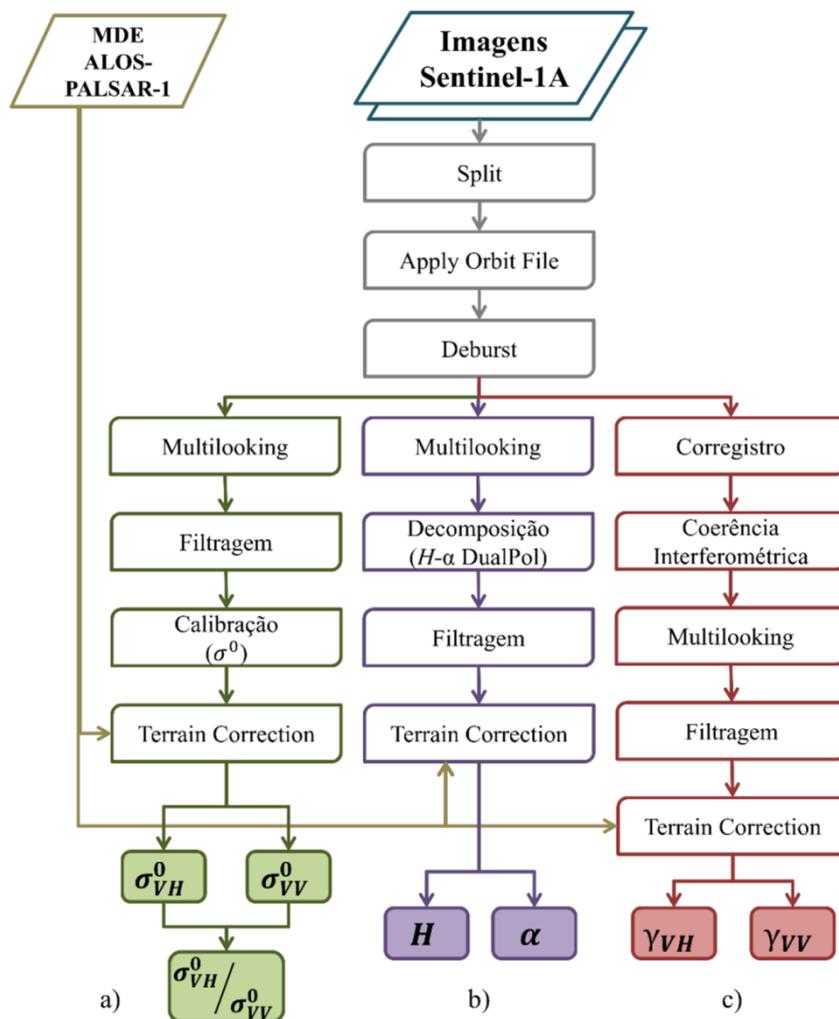
As etapas de pré-processamento (Figura 3.6) foram realizadas no software SNAP (*Sentinel Application Platform*) versão 4.0, para a extração dos atributos provenientes dos dados de radar: a) coeficientes de retroespalhamento; b) decomposição polarimétrica e c) coerência interferométrica.

A operação *Split*, foi realizada para extrair a área de interesse presente na sub-faixa IW2, aumentando a velocidade do processamento das etapas posteriores. Em seguida, foi realizada a operação *Apply Orbit File* que atualizou as informações presentes nos

metadados da imagem através de informações precisas de posição e velocidade do satélite.

A operação *Deburst* realiza uma retificação da imagem, possibilitando que esta seja reamostrada para uma grade comum de espaçamento de pixels em range e azimuth, permitindo a obtenção de uma imagem contínua, ou seja, realiza a junção dos *bursts* que geraram a imagem.

Figura 3.6 - Fluxograma das etapas de pré-processamento das imagens.



Fonte: Produção do autor.

As operações *Multilooking* e filtragem foram aplicadas em todos os atributos, seguindo a ordem descrita na Figura 3.6. A técnica *Multilooking* foi aplicada com quatro *looks*,

sendo 1 em azimute e 4 em range, devido a sua característica de tornar as dimensões dos pixels regulares e reduzir o efeito *Speckle*, através de uma média espacial (LEE; POTTIER, 2009).

Para o tratamento do ruído *Speckle* foram testados os filtros Gamma, Lee e Sigma Lee, disponíveis no *software* SNAP, e a definição do tamanho da janela de filtragem foi realizada através de testes variando o tamanho da janela de 3x3 a 9x9. Além disso, foram empregados critérios de avaliação baseados em análises quantitativas e qualitativas, para determinar a efetividade do filtro e do tamanho da janela de filtragem.

A análise quantitativa foi realizada através do Coeficiente de Variação (CV), que é obtido pela razão entre o desvio padrão e a média de uma vizinhança próxima ao pixel ruidoso (PENNA, 2014). O CV varia de 0 a 1 e, de acordo com Rosa (2012), regiões homogêneas tendem a apresentar valores de CV baixos, enquanto regiões heterogêneas apresentam altos valores de CV. Neste trabalho, a análise do CV foi realizada em áreas de Floresta Primária, que são consideradas áreas homogêneas. Já a análise qualitativa foi realizada através de interpretação visual das imagens após a aplicação dos filtros, observando-se parâmetros como o nível de borramento e a preservação de bordas e pontos.

Para a obtenção dos coeficientes de retroespalhamento (σ_{VH}^0 e σ_{VV}^0), foi realizada a calibração radiométrica, que consiste na transformação dos números digitais da imagem para valores de retroespalhamento por unidade de área no alcance do terreno (σ^0). A calibração radiométrica para as imagens Sentinel-1A, no nível 1 de processamento foi realizada a partir da Equação 3.1.

$$\sigma_i^0 = \frac{DN_i^2}{A_i^2} \quad (3.1)$$

Onde σ_i^0 são os valores de retroespalhamento por unidade de área no alcance do terreno; DN são os valores de números digitais dos pixels e A_i é o coeficiente de calibração obtido em tabelas de pesquisa de calibração (LUTs).

Para a obtenção dos atributos referentes à decomposição polarimétrica de Cloude e Pottier (H e α), foi realizada a decomposição polarimétrica, através do cálculo da matriz de coerência [T2] disponível no *software* SNAP (Equação 3.2).

$$T_{dual} = \begin{pmatrix} T_{11} & T_{12} \\ T_{12} & T_{22} \end{pmatrix} = U \begin{bmatrix} \lambda_1 & \\ & \lambda_2 \end{bmatrix} U^H = \lambda_1 u_1 u_1^H + \lambda_2 u_2 u_2^H \quad (3.2)$$

Assim, foram calculados os valores de entropia e ângulo alfa para dados DualPol a partir das Equações 3.3 e 3.4.

$$H = \sum_{i=1}^2 (-P_i \log_2 P_i) \quad (3.3)$$

$$\alpha = \sum_{i=1}^2 P_i \alpha_i \quad (3.4)$$

Onde P_i , que representa a importância relativa de λ_i , é obtido pela Equação 3.5.

$$P_i = \frac{\lambda_i}{\sum_{j=1}^2 \lambda_j} \quad (3.5)$$

A entropia indica o grau de aleatoriedade da distribuição dos mecanismos de espalhamento, variando entre 0 e 1. Enquanto o ângulo alfa pode ser utilizado para descrever o tipo de mecanismo de espalhamento, variando de 0° a 90°. É importante ressaltar que a decomposição de alvos foi desenvolvida para dados SAR QuadPol, no entanto, pode também ser aplicada para dados DualPol (CLOUDE, 2007).

Para a geração das imagens de coerência interferométrica (γ_{VH} e γ_{VV}), após o pré-processamento *Split*, foi realizado o corregristo das imagens do Sentinel-1A adquiridas com um intervalo de 12 dias. Esse corregristo é realizado na ordem de sub-pixel, de forma que todas as distorções da imagem fossem corrigidas, obtendo um interferograma com baixo nível de ruído. A partir da imagem corregristada foi realizado o cálculo da coerência interferométrica (Equação 3.6). A definição da janela para o cálculo da coerência interferométrica foi realizada através de testes com os tamanhos das janelas variando de 2x2, 5x1 e 10x3, disponíveis no *software* SNAP.

$$\gamma = \frac{|\langle S_1(x) S_2(x)^* \rangle|}{\sqrt{\langle |S_1(x)|^2 \rangle \langle |S_2(x)|^2 \rangle}} \quad (3.6)$$

Onde γ representa a coerência interferométrica e S_1 e S_2 são as duas imagens complexas corregristadas e $\langle \rangle$ é a média em relação ao tamanho da janela.

A partir da extração dos atributos, foi realizada a correção do terreno nas imagens resultantes, através do método *Range Doppler Terrain Correction* (SMALL; SCHUBERT, 2008) no SNAP, utilizando-se o Modelo Digital de Elevação do Alos-PalSAR-1. Essa etapa tem como objetivo melhorar a representação geométrica da superfície no mundo real. De acordo com Wang et al. (2013) esse procedimento é necessário devido as variações topográficas e distorções *off-nadir* que ocorrem nas imagens durante a aquisição.

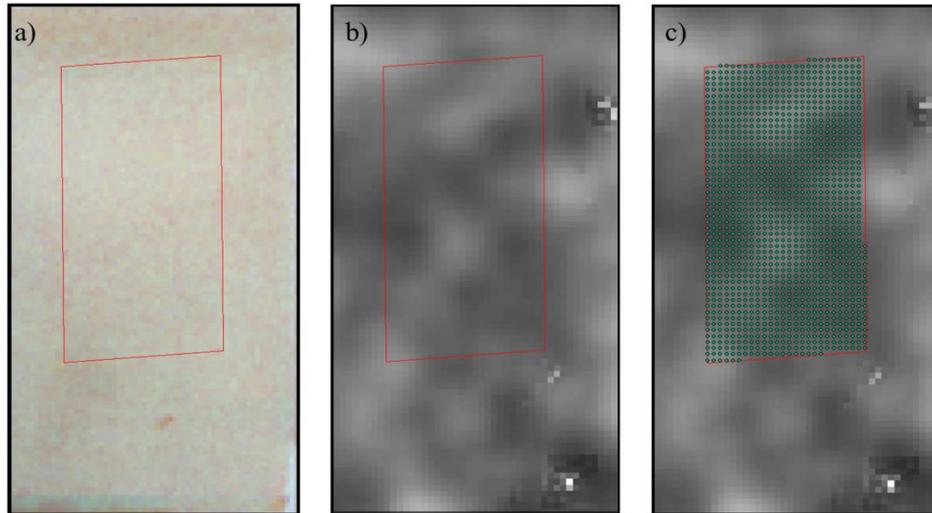
Através dos produtos σ_{VH}^0 e σ_{VV}^0 corrigidos geometricamente, foi obtida a razão crosspolarizada no software ENVI 4.8 (*Environment for Visualizing Images*) (Equação 3.7).

$$\text{Razão Crosspolarizada} = \frac{\sigma_{VH}^0}{\sigma_{VV}^0} \quad (3.7)$$

3.6.2 Seleção de amostras e análise exploratória

A seleção das amostras foi realizada com base no conjunto amostral coletado em campo com o auxílio das imagens do Sentinel-2B, utilizando-se o software ArcMap 10.1 (ESRI, 2010), através da criação de polígonos de regiões de interesse (da sigla em inglês ROIs). Devido à resposta dos dados de radar ser muito heterogênea, não se pode assumir que um único pixel de uma ROI representa cada classe. Deste modo, foram utilizados os pontos correspondentes aos pixels pertencentes às ROIs como amostras. A Figura 3.7 mostra um exemplo desta heterogeneidade observada nos dados de radar.

Figura 3.7 - Representação de uma amostra utilizada para o mapeamento. a) Imagem do Sentinel-2B; b) Imagem σ_{VH}^0 do Sentinel-1A; c) Imagem σ_{VH}^0 do Sentinel-1A com os pontos correspondentes aos pixels.



Fonte: Produção do autor.

Para a análise exploratória dos dados, foram elaborados gráficos *boxplot* com o objetivo de avaliar a separabilidade entre as classes, através das amostras selecionadas. Esses gráficos fornecem informações sobre a distribuição e aspecto dos dados, através de atributos como mediana, quartil inferior e superior e *outliers*. Essa etapa permite um maior entendimento sobre as confusões que podem ser geradas no processo de classificação.

3.6.3 Classificações

Para avaliar a capacidade discriminatória dos atributos provenientes da imagem de radar (Sentinel-1A), foram realizados diversos cenários de classificações, utilizando-se os atributos individualmente e agrupados entre si, como é descrito na Tabela 3.7. Onde os Cenários 1, 2 e 3 representam a análise dos atributos individualmente, sendo o cenário 1 composto pelos atributos provenientes dos coeficientes de retroespalhamento, o cenário 2 pela decomposição polarimétrica, e o cenário 3 pelos atributos da coerência interferométrica. Enquanto os Cenários 4, 5 e 6 representam o agrupamento desses

atributos entre si e o Cenário 7 representa a utilização de todos os atributos para a classificação.

Tabela 3.7 - Descrição dos cenários das classificações realizadas com os classificadores RF e SVM.

Cenários	Descrição	Sigla RF	Sigla SVM
1	$\sigma_{VH}^0 + \sigma_{VV}^0 + \text{razão}$	RF-1	SVM-1
2	$H + \alpha$	RF-2	SVM-2
3	$\gamma_{VH} + \gamma_{VV}$	RF-3	SVM-3
4	$\sigma_{VH}^0 + \sigma_{VV}^0 + \text{razão} + H + \alpha$	RF-4	SVM-4
5	$H + \alpha + \gamma_{VH} + \gamma_{VV}$	RF-5	SVM-5
6	$\sigma_{VH}^0 + \sigma_{VV}^0 + \text{razão} + \gamma_{VH} + \gamma_{VV}$	RF-6	SVM-6
7	$\sigma_{VH}^0 + \sigma_{VV}^0 + \text{razão} + H + \alpha + \gamma_{VH} + \gamma_{VV}$	RF-7	SVM-7

Fonte: Produção do autor.

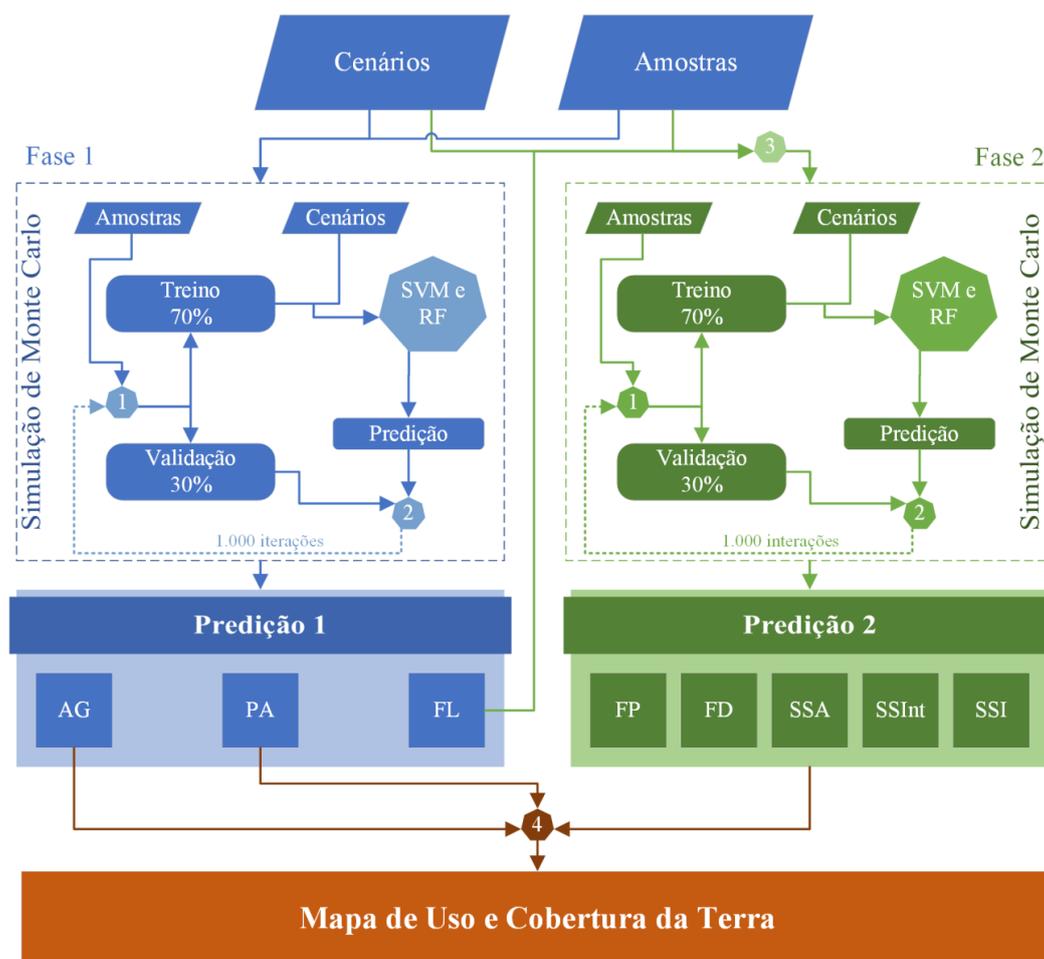
Para a realização das classificações foram extraídos os valores dos atributos provenientes dos coeficientes de retroespalhamento (σ_{VH}^0 , σ_{VV}^0 , $\sigma_{VH}^0/\sigma_{VV}^0$), da decomposição polarimétrica (H e α) e da coerência (γ_{VH} , γ_{VV}) para cada pixel. Os atributos foram normalizados de 0 a 1 para que todos estivessem com a mesma escala durante os processos de classificação. A partir da extração dos atributos, realizou-se a classificação, que foi dividida em duas fases (Figura 3.8). A Fase 1, objetivou classificar as classes Agricultura, Pastagem e Floresta e a Fase 2, realizar uma estratificação da classe Floresta nas classes: Floresta Degradada, Floresta Primária e Sucessões Secundárias Avançada, Intermediária e Inicial. Nessa etapa, uma parte do conjunto amostral (70%) foi utilizada como amostras de treinamento e o restante (30%) como amostras de validação (Tabela 3.8).

Tabela 3.8 - Número de amostras (pixels) do conjunto amostral para treinamento e validação de cada classe temática em cada fase do mapeamento.

	Classe	Treinamento	Validação	Total
Fase 1	AG	5754	2466	8220
	PA	3071	1316	4387
	FL	4430	1899	6329
	Total	13256	5681	18936
Fase 2	FD	1114	478	1592
	FP	1571	674	2245
	SSA	507	218	725
	SSInt	267	115	382
	SSI	969	416	1385
	Total	4428	1901	6329

Fonte: Produção do autor.

Figura 3.8 - Metodologia para mapeamento do uso e cobertura da terra com os classificadores SVM e RF para as duas fases.



Fonte: Produção do autor.

A Fase 1 consistiu da realização da classificação buscando-se discriminar três classes (AG, PA e FL). Nessa etapa foram utilizadas as amostras coletadas na área de estudo correspondentes às classes analisadas e as classificações foram realizadas para todos os cenários analisados, com os classificadores *Support Vector Machine* (SVM) (CHANG; LIN, 2001) e *Random Forest* (RF) (LIAW; WIENER, 2002) no *software* R 3.3.2 (R CORE TEAM, 2018).

Para as classificações SVM foi aplicada a função de *Kernel* RBF (Função de Base Radial), devido à sua superioridade em relação às demais funções observada em outros estudos (HUANG et al., 2002; DURO et al., 2012). Nessa função, foram definidos os valores ótimos para os parâmetros custo (C) e γ iguais a 64 e 0,1, respectivamente, através de métodos exaustivos de tentativa e erro.

Para as classificações RF foram definidos o número de árvores de decisão (N_{tree}) igual a 500 e o número de variáveis a serem testadas (M_{try}) que foi correspondente à raiz quadrada do número de variáveis de entrada (GISLASON et al., 2006). Além disso, o RF possibilita calcular a importância das variáveis através do índice *Mean Decrease Gini* (MDG) durante o processamento do modelo (BREIMAN, 2002; CALLE; URREA, 2011).

A validação dos cenários de classificações empregados foi realizada através de uma simulação de Monte Carlo com 1000 iterações. A cada iteração, foram definidas aleatoriamente, 70% das amostras para treinamento e 30% para validação em cada classe temática (Processo 1). As amostras de treinamento foram utilizadas nos classificadores RF e SVM para realizar a predição das classes temáticas, em seguida foram utilizadas as amostras de validação para verificar a acurácia do mapeamento. A partir da primeira predição e validação, esse processo se repetiu por 1000 vezes (Processo 2). A simulação de Monte Carlo é uma técnica que busca simular um sistema real, a partir de experimentos aleatórios, tendo como base a teoria de grandes amostras (ALMEIDA et al., 2010; MOREIRA et al., 2016; RUBISTEIN, 1981; SAITO et al., 2011). Nessa fase foi possível classificar as classes AG, PA e FL, permitindo criar uma máscara da classe Floresta que foi utilizada na segunda fase do mapeamento.

A Fase 2 do mapeamento consistiu nas mesmas etapas realizadas durante a Fase 1, mas utilizando-se apenas as amostras correspondentes à classe Floresta (Processo 3). Com

isso, foi possível discriminar as classes de estratificação da FL (FP, FD, SSA, SSInt e SSI). Por fim, para gerar o mapa final de uso e cobertura da terra, as classes AG e PA, obtidas da Fase 1, foram agregadas com as classes obtidas na Fase 2 (Processo 4).

A partir das amostras de validação para cada iteração, foram calculados os valores médios da matriz de confusão, do Índice Kappa (CONGALTON; GREEN, 2009) da Acurácia Global e acurácias do produtor e usuário para cada cenário nas duas fases do mapeamento. Além disso, a partir dos 1000 valores de Kappa e Acurácia Global, foi possível determinar um intervalo de credibilidade, onde se desprezou 2,5% dos maiores e menores valores, de forma a garantir que 95% dos resultados estivessem contidos neste intervalo.

Para verificar e comparar se havia diferença significativa entre os cenários e os métodos de classificações empregados, foi aplicado o Teste de McNemar (AGRESTI, 1996; BRADLEY, 1968; FOODY, 2004; FU et al., 2017; MCNEMAR, 1947) com 95% de confiança.

3.7 Comparação com o sensor óptico Sentinel-2B

A classificação utilizando o sensor Sentinel-2B foi realizada com o intuito de comparar os mapeamentos e analisar as características presentes em cada um. Foram utilizadas imagens do Sentinel-2B obtidas no dia 29/08/2017, data próxima ao trabalho de campo, correspondentes aos *Tiles*: T20LMQ e T20LNQ.

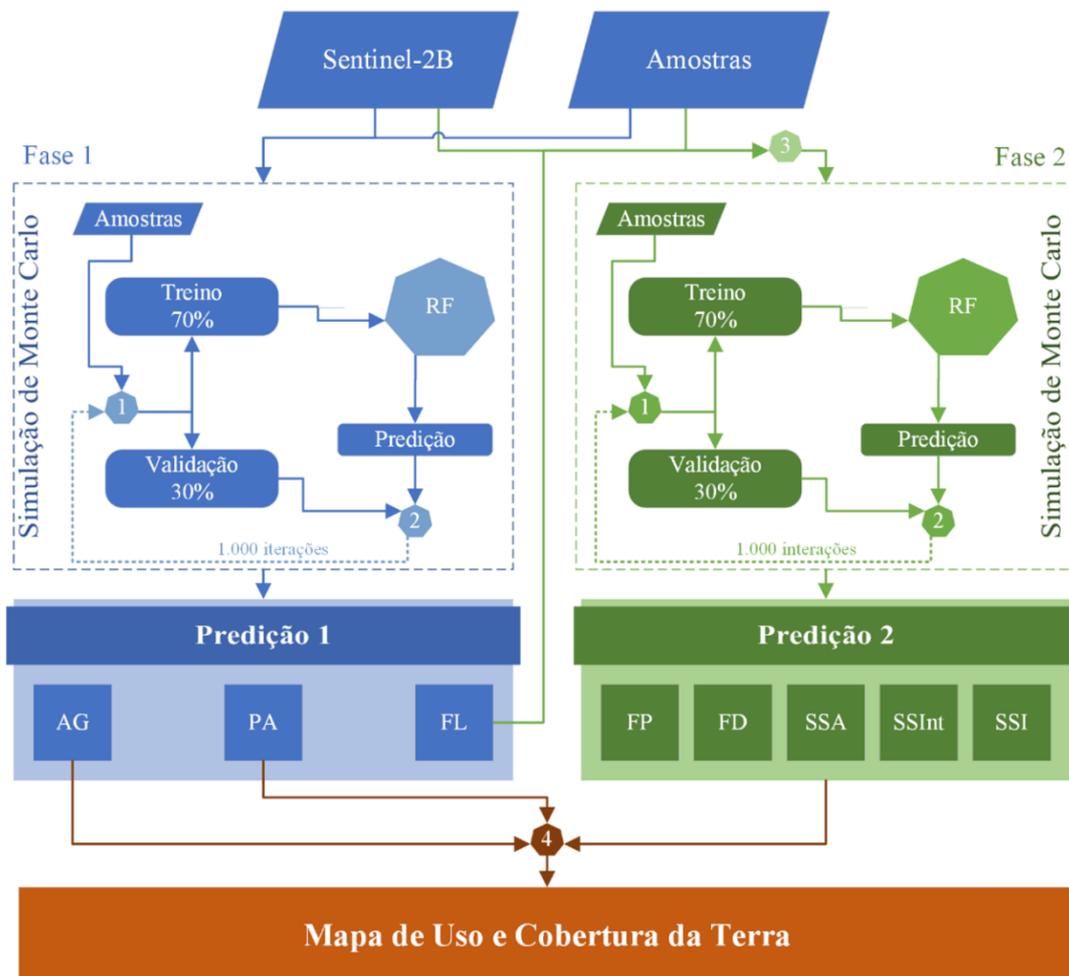
Na etapa de pré-processamento dos dados do sensor Sentinel-2B foi realizada a correção atmosférica das imagens utilizando-se o método *Dark Object Subtraction 1* (DOS1), proposto por Chavez Júnior (1988) através do *Semi-Automatic Classification Plugin* do *software QGIS 3.2.3*. (CONGEDO, 2017). Esse método utiliza dados da imagem para estimar a interferência da atmosfera através da avaliação da refletância de alvos em que a refletância deveria ser 0, como água e sombra (LANTZANAKIS et al., 2017; SANTOS et al., 2016). A partir das imagens corrigidas foi gerado um mosaico das duas cenas e posteriormente o recorte da área de estudo.

Buscando-se obter uma classificação com uma boa discriminação entre as classes temáticas, foram utilizadas como variáveis as bandas espectrais das imagens Sentinel-

2B. Diniz et al. (submetido em 2018) observaram que a utilização das bandas espectrais do Sentinel-2B apresentaram resultados satisfatórios para o mapeamento do uso e cobertura da terra na região de estudo, quando comparadas e agregadas com o Índice de Vegetação por Diferença Normalizada (NDVI) (ROUSE et al., 1974) e com as frações extraídas do Modelo Linear de Mistura Espectral (MLME) (SHIMABUKURO; SMITH, 1991).

Para a realização da classificação foram extraídos os atributos, ou seja, os valores espectrais das bandas utilizadas e foi realizada a classificação pixel-a-pixel através do classificador RF, seguindo a mesma metodologia empregada para as classificações com os dados de radar (Figura 3.9).

Figura 3.9 - Fluxograma para elaboração do mapa com o sensor óptico Sentinel-2B.



Fonte: Produção do autor.

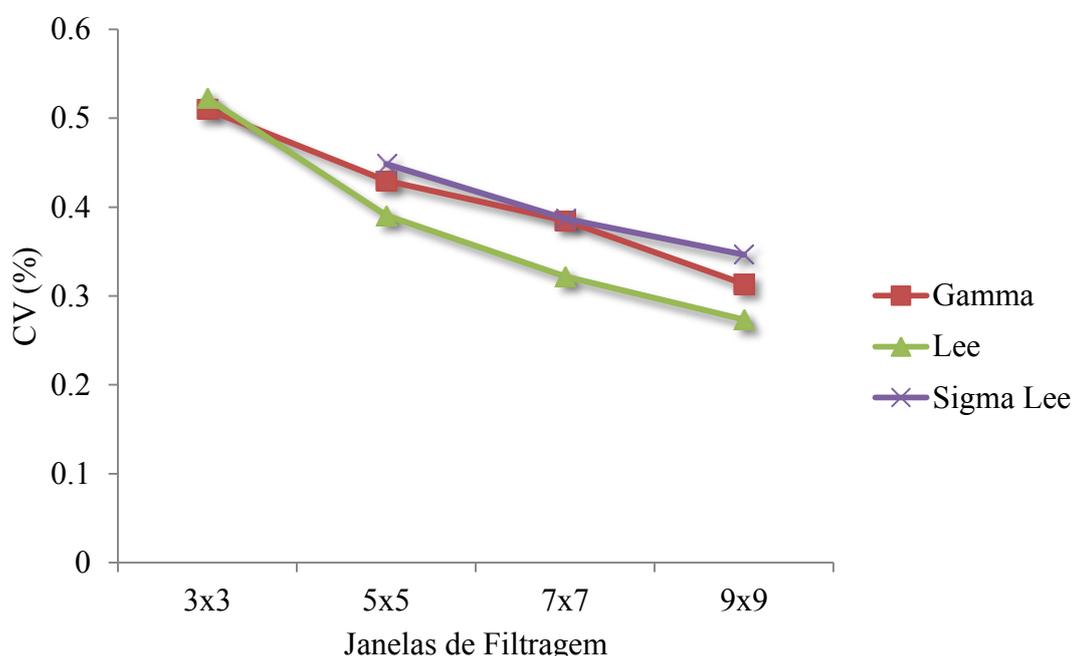
A partir do mapeamento do uso e cobertura da terra com o Sentinel-2B foi possível realizar a comparação entre o mapeamento óptico e o mapeamento obtido pelos dados de radar. Nesse caso, foi utilizado como comparação o cenário que obteve o melhor desempenho com os dados de radar, permitindo-se obter o mapa de diferenças entre os dois mapeamentos.

4. RESULTADOS

4.1 Definição do filtro e do tamanho da janela de filtragem

Os resultados obtidos através da análise quantitativa dos filtros para redução do ruído *Speckle* são apresentados na Figura 4.1.

Figura 4.1 - Análise quantitativa dos filtros para tratamento do ruído *Speckle*.



Fonte: Produção do autor.

Nota-se que o filtro Lee foi o que apresentou a maior diminuição no coeficiente de variação (CV), com uma redução de 86% para a janela 9x9, em relação à imagem sem filtro, que apresentou um CV igual a 1,13%, considerando-se todas as janelas. Já em relação aos filtros Gamma e Sigma Lee, percebe-se que o filtro Lee apresentou uma redução no CV em todas as janelas de filtragem, sendo de 4,0% em relação ao Gamma e de 7,3% ao Sigma Lee, para a janela de 9x9.

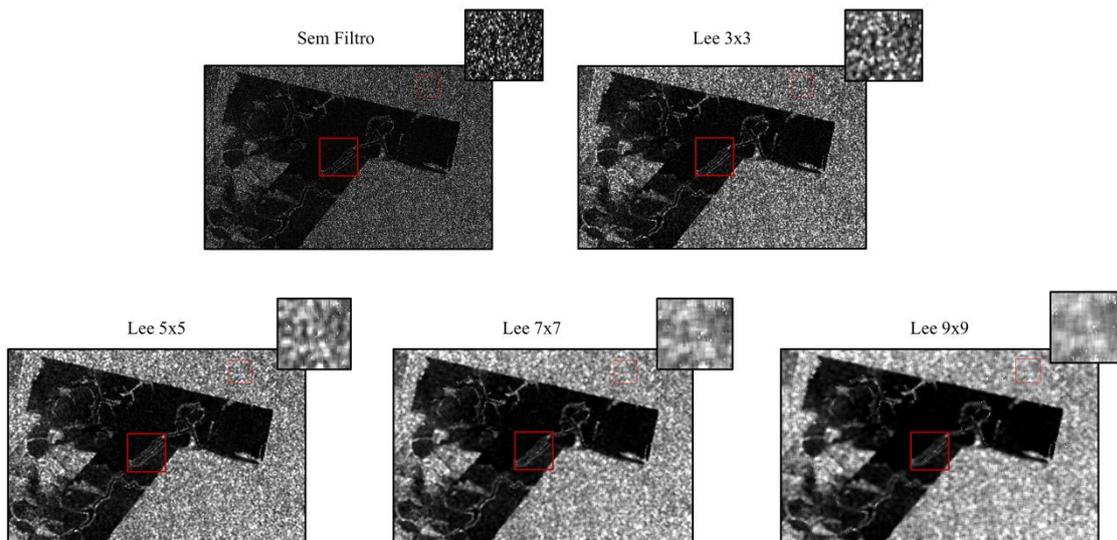
Analisando-se separadamente o comportamento do filtro Lee para os diferentes tamanhos de janelas de filtragem, nota-se que houve uma diminuição crescente dos

valores do CV das janelas 3x3 a 9x9. A imagem filtrada na janela 9x9 representou uma redução do CV de 85,97% em relação à imagem sem filtro.

Além disso, nota-se que a maior redução do CV entre uma janela e outra ocorreu entre as janelas 3x3 e 5x5, com uma diferença de 13,20%, enquanto a diferença entre as janelas 5x5 para 7x7 e 7x7 para 9x9 foram de 6,83% e 4,87%, respectivamente. Até a janela 5x5 houve uma redução no CV de 74,26% em relação à imagem sem filtro.

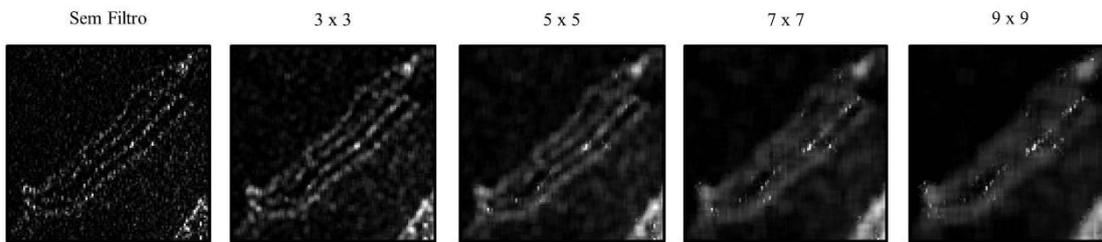
Através da análise qualitativa do filtro Lee (Figura 4.2), foi possível observar uma redução do ruído *Speckle* à medida que o tamanho da janela de filtragem aumenta. Além disso, percebe-se um crescente aumento na suavização das bordas (Figura 4.3), com o aumento do efeito de borramento nas imagens.

Figura 4.2 - Análise qualitativa da redução do ruído *Speckle*.



Fonte: Produção do autor.

Figura 4.3 - Análise qualitativa da suavização das bordas.



Fonte: Produção do autor.

Analisando-se a aplicação da janela 9x9 tanto quantitativamente quanto qualitativamente, nota-se que apesar de apresentar um maior efeito de borramento em relação às demais janelas (Figura 4.3), o valor do CV apresentou a maior redução. Além disso, nota-se que este efeito de borramento ocorreu com maior intensidade sobre feições que apresentam bordas muito próximas, como é o caso de cursos d'água (Figura 4.4), enquanto nas feições como agricultura e floresta não houve uma diferença na delimitação das suas bordas (Figura 4.2).

Desse modo, foi definido o filtro Lee com uma janela 9x9 para a realização deste estudo, buscando-se o melhor custo-benefício, ou seja, baixa degradação das feições de interesse e redução do ruído *Speckle*.

4.2 Análise exploratória dos atributos

4.2.1 Coeficientes de retroespalhamento

Analisando-se a separabilidade das classes, através da análise exploratória pelos gráficos *boxplot* (Figura 4.4), nota-se que algumas classes foram melhor discriminadas por determinados atributos.

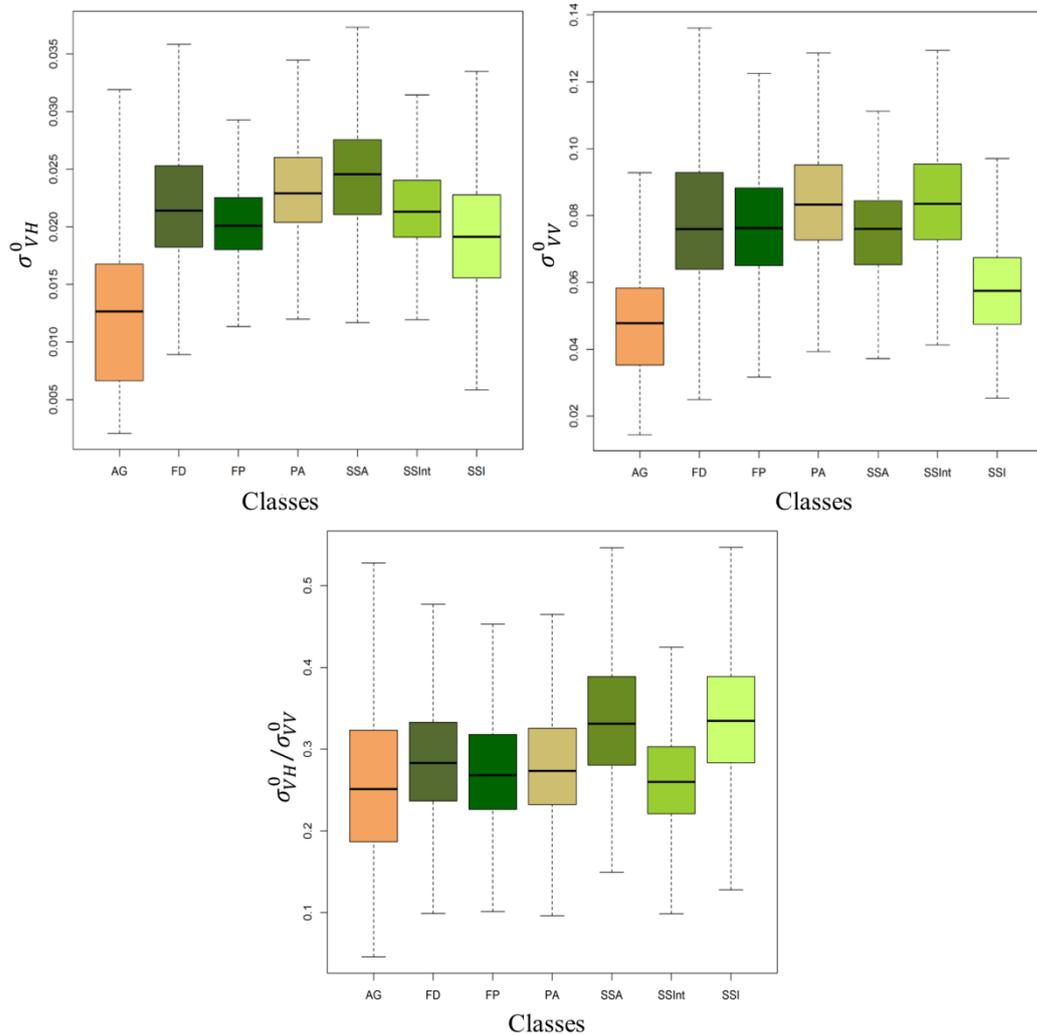
Observa-se um comportamento semelhante entre as classes florestais e os estágios sucessionais pelo atributo σ_{VH}^0 , com valores médios variando entre 0,019 e 0,024. Percebe-se que há uma redução gradual no retroespalhamento entre as classes de sucessão SSA (0,024), SSInt (0,022) e SSI (0,019). Enquanto destaca-se a classe AG,

com o menor valor médio de retroespalhamento, igual a 0,012, apresentando uma boa separabilidade em relação às outras classes.

Ao se analisar a separabilidade das classes pelo atributo σ_{VV}^0 , é possível perceber uma maior confusão na discriminação das classes FD, FP e SSA, com uma distribuição dos valores bem próxima. Entre as classes sucessionais, a classe SSI apresentou os menores valores (0,057), com uma melhor separabilidade em relação às outras classes, o que também pode ser observado para a classe AG (0,048).

A partir da análise do atributo da razão crosspolarizada ($\sigma_{VH}^0/\sigma_{VV}^0$) percebe-se uma melhora na discriminação da classe SSA e SSI, que apresentaram maiores valores médios (0,36 e 0,34, respectivamente).

Figura 4.4 - Gráficos *boxplot* representando o quartil inferior, superior e mediana das classes temáticas pelo atributo σ_{VH}^0 , σ_{VV}^0 e $\sigma_{VH}^0/\sigma_{VV}^0$.

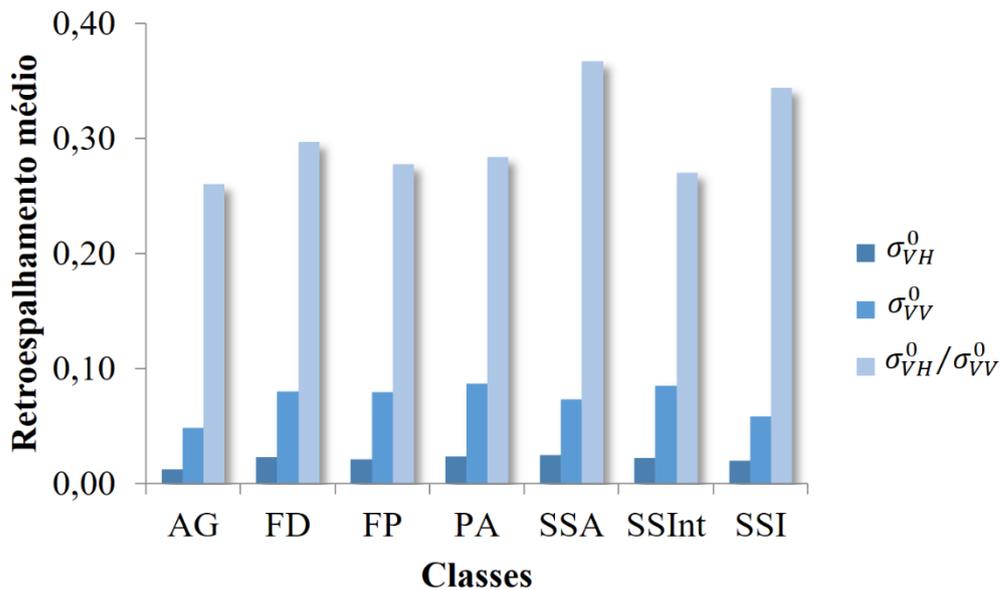


Legenda: AG: Agricultura; FD: Floresta Degradada; FP: Floresta Primária; PA: Pastagem; SSA: Sucessão Secundária Avançada; SSInt: Sucessão Secundária Intermediária; SSI: Sucessão Secundária Inicial.

Fonte: Produção do autor.

Além disso, através da análise exploratória dos atributos provenientes dos coeficientes de retroespalhamento médios (Figura 4.5), nota-se que as classes SSA e SSI se destacaram das demais principalmente através da razão crosspolarizada. Enquanto as demais classes pouco se diferenciaram entre si quando se analisa os atributos provenientes dos coeficientes de retroespalhamento.

Figura 4.5 - Retroespalhamento médio para cada classe nos atributos analisados.



Legenda: AG: Agricultura; FD: Floresta Degradada; FP: Floresta Primária; PA: Pastagem SSA: Sucessão Secundária Avançada; SSInt: Sucessão Secundária Intermediária; SSI: Sucessão Secundária Inicial.

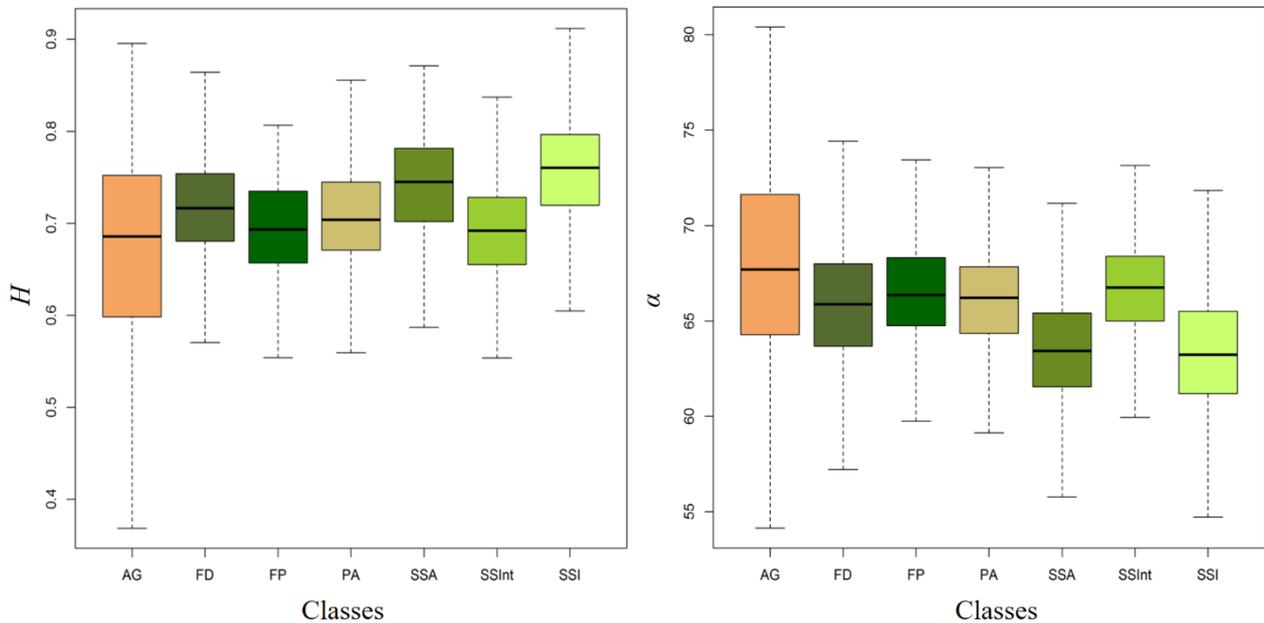
Fonte: Produção do autor.

Além disso, ao se observar o retroespalhamento médio no atributo σ_{VV}^0 , nota-se que este apresentou valores mais altos de retroespalhamento para todas as classes quando comparado com o σ_{VH}^0 principalmente para as classes florestais. Devido ao baixo comprimento de onda da banda C, as ondas eletromagnéticas penetram pouco na vegetação da floresta, ou seja, sofrem pouca despolarização da onda, causando pouco retorno da polarização cruzada.

4.2.2 Decomposição polarimétrica

A partir da análise da separabilidade das classes (Figura 4.6) foi possível observar que o atributo entropia apresentou uma grande confusão entre as classes florestais FP e SSInt, com valores médios iguais a 0,69. Além disso, nota-se que a classe AG apresentou uma distribuição do *boxplot* com maior diferenciação, enquanto a classe PA também apresentou comportamento semelhante às classes florestais. Entre as classes de sucessão florestal, nota-se uma melhor diferenciação da classe SSA e SSI, que apresentaram os maiores valores médios de entropia, iguais a 0,73 e 0,75, respectivamente.

Figura 4.6 - Gráficos *boxplot* representando o quartil inferior, superior e mediana das classes temáticas pelo atributo entropia (H) e ângulo alfa (α).



Legenda: AG: Agricultura; FD: Floresta Degradada; FP: Floresta Primária; PA: Pastagem; SSA: Sucessão Secundária Avançada; SSInt: Sucessão Secundária Intermediária; SSI: Sucessão Secundária Inicial.

Fonte: Produção do autor.

Em relação a análise da separabilidade pelo atributo ângulo alfa, nota-se comportamento inverso à entropia, onde as classes que apresentaram os maiores valores para H passaram a apresentar os menores valores para α , mantendo-se as confusões existentes entre as classes.

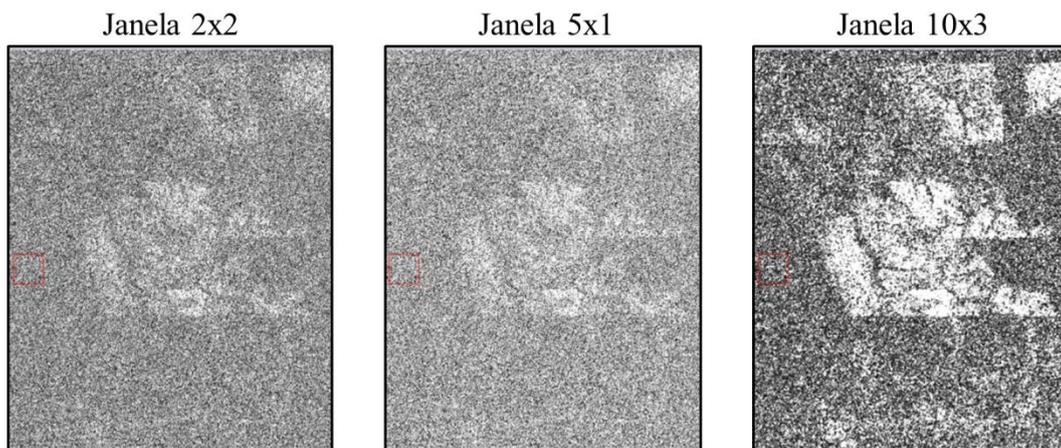
Dentre as classes de sucessão florestal, a classe SSI apresentou o menor valor de ângulo alfa, com α igual a $63,15^\circ$. De modo geral, nota-se que os atributos oriundos da decomposição polarimétrica apresentaram comportamento semelhante na separabilidade das classes temáticas. Em relação às classes de sucessão florestal e as classes de floresta, percebe-se grande dificuldade para as suas discriminações.

4.2.3 Coerência Interferométrica

Observando-se a Figura 4.7, que representa a análise qualitativa das imagens de coerência interferométrica (γ_{VH}, γ_{VV}) obtidas em cada janela (2x2, 5x1 e 10x3), é

possível perceber uma melhor definição na imagem da janela 10x3, podendo-se diferenciar áreas agrícolas e pequenos cursos d'água com mata ciliar. Desse modo, a imagem de coerência utilizada neste trabalho foi a da janela 10x3.

Figura 4.7 - Imagem γ_{VH} para as diferentes janelas sem aplicação do filtro Lee.

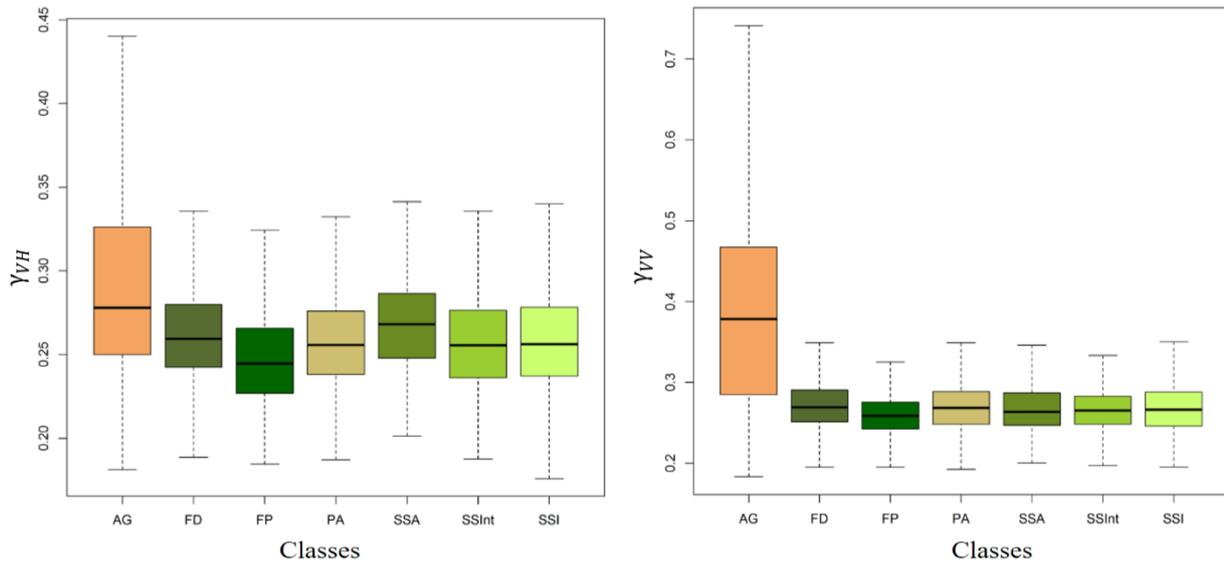


Fonte: Produção do autor.

A partir da análise exploratória dos atributos γ_{VH} e γ_{VV} (Figura 4.8), nota-se que a maioria das classes apresentou distribuições semelhantes. Nesse caso, houve pouca discriminação entre as classes sucessionais, florestais e a pastagem, que apresentaram distribuições similares, com uma maior diferenciação pelo atributo γ_{VH} entre as classes FP (0,24) e SSA (0,26) e a classe AG que apresentou γ_{VH} igual a 0,30. Já em relação ao atributo γ_{VV} , nota-se uma grande diferenciação da classe AG, com uma média de 0,39 em relação às demais classes que apresentaram valores médios variando de 0,26 a 0,27. Percebe-se ainda, que o atributo γ_{VH} apresentou uma melhor diferenciação das classes florestais.

Analisando-se os valores médios das coerências interferométricas nas polarizações VH e VV (Figura 4.9), percebe-se uma melhor discriminação da classe AG na polarização VV, se destacando em relação às demais classes, enquanto as classes florestais e pastagem apresentaram valores médios de γ_{VH} e γ_{VV} muito semelhantes.

Figura 4.8 - Gráficos *boxplot* representando o quartil inferior, superior e mediana das classes temáticas pelos atributos γ_{VH} e γ_{VV} .



Legenda: AG: Agricultura; FD: Floresta Degradada; FP: Floresta Primária; PA: Pastagem SSA: Sucessão Secundária Avançada; SSInt: Sucessão Secundária Intermediária; SSI: Sucessão Secundária Inicial.

Fonte: Produção do autor.

Figura 4.9 - Coerência Interferométrica média para cada classe nas polarizações VH e VV.



Legenda: AG: Agricultura; FD: Floresta Degradada; FP: Floresta Primária; PA: Pastagem; SSA: Sucessão Secundária Avançada; SSInt: Sucessão Secundária Intermediária; SSI: Sucessão Secundária Inicial.

Fonte: Produção do autor.

4.3 Classificações *Support Vector Machine*

4.3.1 Classificações SVM Fase 1.

A partir da metodologia apresentada na seção 3.6.3, foram obtidos os valores médios do índice Kappa e acurácia global (AC), assim como os Intervalos de Credibilidade (Tabela 4.1) gerados a partir das 1000 simulações para todos os cenários analisados (veja os cenários na Tabela 3.7) com o classificador SVM, na primeira fase da classificação.

Nota-se que os cenários SVM-6 e 7 atingiram o conceito de “Muito bom”, segundo a classificação de Landis e Koch (1977), para a qualidade do mapeamento. Sendo os cenários SVM-2 e SVM-3 os que apresentaram os piores resultados, classificados como “Razoáveis”.

Tabela 4.1 - Acurácia Global (AC), Kappa e Intervalos de Credibilidade a 5% de significância para todos os cenários com o classificador SVM para a Fase 1.

Cenários	AC (%)	Kappa	Intervalos de Credibilidade		Conceito
			AC (%)	Kappa	
SVM-1	68,2	0,49	$67,3 \leq AC \leq 69,0$	$0,48 \leq K \leq 0,51$	Bom
SVM-2	53,2	0,26	$52,1 \leq AC \leq 54,3$	$0,24 \leq K \leq 0,27$	Razoável
SVM-3	60,5	0,38	$59,7 \leq AC \leq 61,2$	$0,37 \leq K \leq 0,39$	Razoável
SVM-4	73,0	0,57	$72,1 \leq AC \leq 73,4$	$0,56 \leq K \leq 0,59$	Bom
SVM-5	71,7	0,56	$70,7 \leq AC \leq 72,7$	$0,55 \leq K \leq 0,58$	Bom
SVM-6	76,6	0,64	$75,6 \leq AC \leq 77,5$	$0,63 \leq K \leq 0,65$	Muito bom
SVM-7	81,6	0,72	$80,7 \leq AC \leq 82,5$	$0,70 \leq K \leq 0,73$	Muito bom

Fonte: Produção do autor.

Nota-se que o cenário SVM-2, que utiliza os atributos provenientes da decomposição polarimétrica (H e α), foi o que apresentou o pior resultado de acurácia global, com uma média igual a 53,2%, enquanto o cenário SVM-7 apresentou o melhor resultado de acurácia global e Kappa, iguais a 81,6% e 0,72, respectivamente, representando uma melhora de 28,5% na acurácia e de 46,0% no valor de Kappa em relação ao cenário SVM-2. Entretanto, quando o cenário SVM-2 é agrupado com os outros atributos, coeficientes de retroespalhamento (SVM-4) e coerências interferométricas (SVM-5), percebe-se uma melhora de 19,8% e 18,5%, respectivamente na sua acurácia global.

Quando são comparados os cenários que utilizaram os atributos individualmente (SVM-1, SVM-2 e SVM-3), nota-se que o cenário SVM-1 apresentou o melhor resultado, representando um valor 15,0% maior de acurácia global em relação ao cenário SVM-2, e de 7,7% em relação ao cenário SVM-3. Desse modo, nota-se que a utilização dos atributos provenientes do coeficiente de retroespalhamento apresenta grande importância para o processo classificatório.

No entanto, quando são analisados os cenários agrupados, nota-se que o cenário SVM-5, que utiliza os atributos da coerência interferométrica e da decomposição polarimétrica, apresentou os menores resultados, com acurácia média igual a 71,7%. Enquanto o cenário SVM-6 que utiliza os coeficientes de retroespalhamento em conjunto com as coerências interferométricas, apresentou uma acurácia de 76,6%, representando um aumento de 4,9% em relação ao cenário SVM-5.

A utilização dos atributos provenientes da coerência interferométrica (γ_{VV} e γ_{VH}) agrupados com os coeficientes de retroespalhamento (SVM-6) e decomposição polarimétrica (SVM-5) representou um ganho de 8,4% e 18,5%, em relação aos cenários SVM-1 e SVM-2, respectivamente.

Analisando-se a acurácia do produtor média (Figura 4.10), nota-se que as classes AG e FL apresentaram bons resultados, com os valores de acurácia do produtor para o cenário SVM-7 iguais a 83,1% e 88,3%, respectivamente. Além disso, nota-se que o cenário SVM-2 apresentou resultados discrepantes dos demais em relação à classe FL, com acurácia do produtor igual a 36,2%.

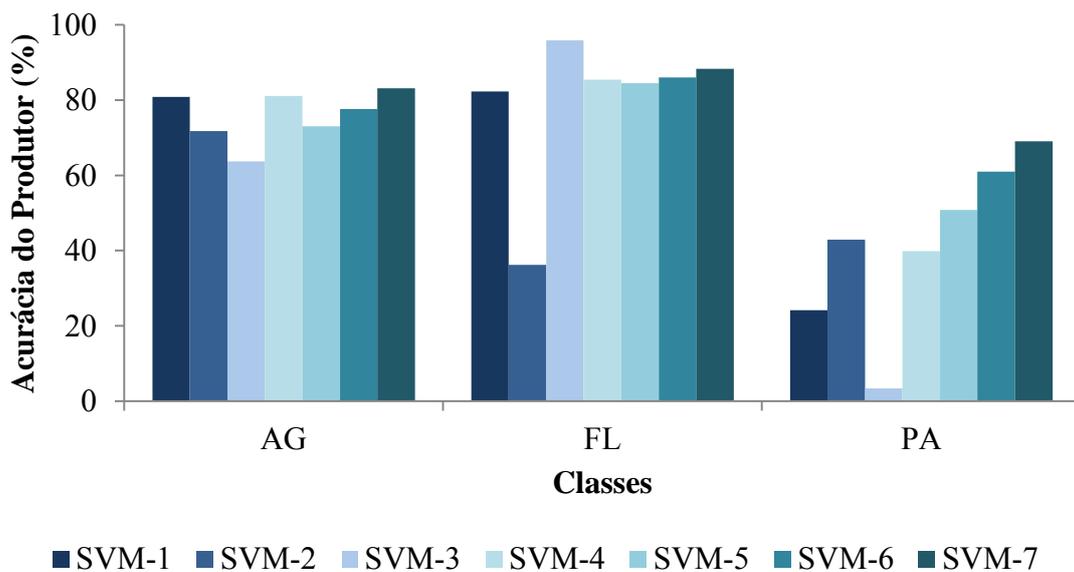
Já a classe pastagem (PA), apresentou os piores resultados de acurácia do produtor, principalmente com o cenário SVM-3 (3,3%), atingindo o melhor desempenho com o cenário SVM-7 (69,1%), o que representou um aumento de 65,8% na acurácia do produtor para esta classe.

Em relação à acurácia do usuário (Figura 4.11), nota-se que a classe AG apresentou os melhores resultados, e o cenário SVM-7 obteve o melhor desempenho em todas as classes, tendo uma pequena diferença no cenário SVM-3 para a classe AG. Nesse caso, nota-se que os cenários que utilizaram a coerência interferométrica apresentaram resultados bastante semelhantes, mostrando que esse atributo foi de grande importância para a classificação dessa classe temática.

Quanto à classe FL, a utilização do cenário SVM-7 (79,7%) apresentou um ganho de 32,3% na acurácia do usuário, em relação ao cenário SVM-3 que apresentou o desempenho mais baixo para essa classe. Nesse caso, a utilização dos coeficientes de retroespalhamento se mostra expressiva para uma melhor acurácia da classificação, representando uma melhora da acurácia do usuário em todos os cenários que utilizaram esse atributo.

Já a classe PA apresentou resultados de acurácia do usuário, no geral, mais baixos, quando comparada com as demais classes. Sendo o cenário SVM-7 o cenário com melhor desempenho (72,5%) representando um aumento de 22,2% em relação ao cenário SVM-2.

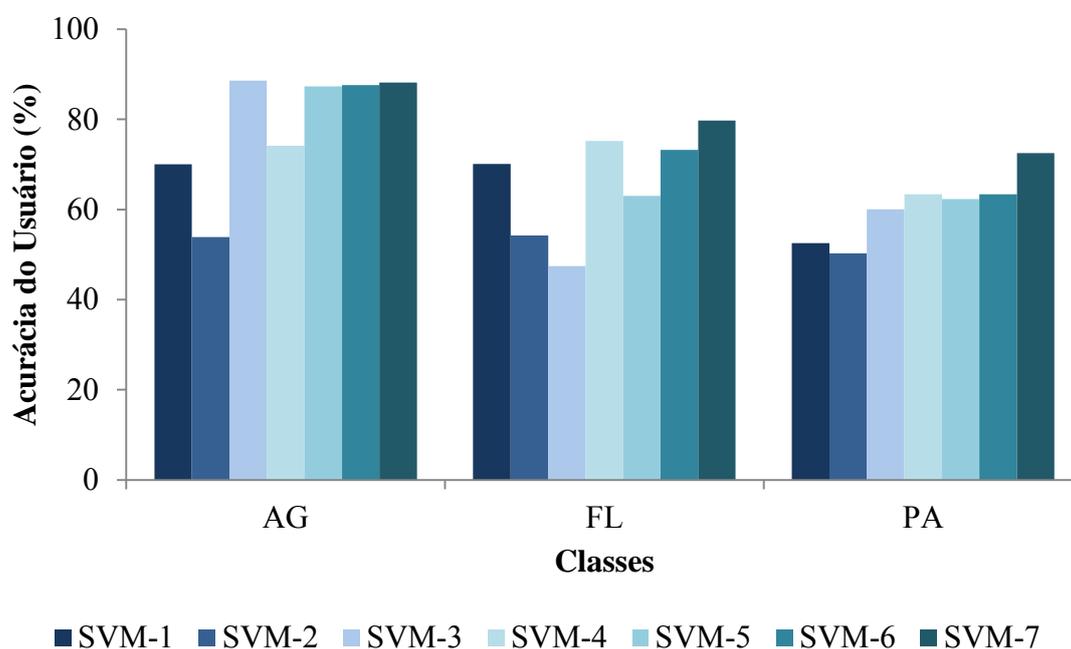
Figura 4.10 - Acurácia do produtor média para cada classe temática nos cenários analisados com o classificador SVM na Fase 1.



Legenda: AG: Agricultura; FL: Floresta; PA: Pastagem.

Fonte: Produção do autor.

Figura 4.11 - Acurácia do usuário média para cada classe temática nos cenários analisados com o classificador SVM na Fase 1.



Legenda: AG: Agricultura; FL: Floresta; PA: Pastagem.

Fonte: Produção do autor.

A partir das 1000 matrizes de confusão obtidas com as simulações, foram calculadas as matrizes de confusão média para cada cenário, que podem ser observadas no Apêndice A. Analisando-se a matriz de confusão média do cenário SVM-7 (Tabela 4.2), que apresentou o melhor desempenho classificatório, pode-se observar como ocorreram as confusões entre as classes temáticas analisadas durante a Fase 1.

Tabela 4.2 - Matriz de confusão média do cenário SVM-7 para a Fase 1.

Mapa	Referência		
	AG	FL	PA
AG	2050	92	183
FL	202	1677	224
PA	215	130	909

Legenda: AG: Agricultura; FL: Floresta; PA: Pastagem.

Fonte: Produção do autor.

Nota-se através da matriz de confusão, que as maiores confusões com a classe Agricultura ocorreram com a classe Pastagem, que representou 66,6% do erro de comissão e 51,5% do erro de omissão da classe AG. De modo geral, a classe AG apresentou baixos erros de omissão e comissão, iguais 16,8% e 11,8%, respectivamente.

Em relação à classe FL, nota-se pouca diferença entre as confusões com as classes AG e PA, sendo que tanto os erros de omissão e quanto de comissão foram um pouco maiores com a classe PA (51,5% e 52,5%, respectivamente dos erros). Assim como a classe AG, a classe FL apresentou altos valores de acurácias do produtor e usuário, com erros de omissão e comissão iguais a 11,7% e 20,2%, respectivamente.

Por fim, quando se analisa a classe PA, nota-se que houve maiores erros de omissão com a classe FL e maior erro de comissão com a classe AG. Do total do erro de omissão (30,9%), a classe FL representou 54,9%, enquanto que do total do erro de comissão (27,5%), a classe AG representou 62,2%.

De modo geral, percebe-se que houve uma boa discriminação das 3 classes temáticas analisadas na Fase 1, permitindo uma separação, principalmente da classe FL que serviu como base para a realização da segunda fase do processo classificatório.

4.3.2 Classificações SVM Fase 2.

A partir do mapeamento da classe FL, foi possível realizar a estratificação das demais classes florestais (FP, FD, SSA, SSInt e SSI). Assim como para a Fase 1, o cenário SVM-7 apresentou o melhor desempenho classificatório (Tabela 4.3), com uma acurácia global igual a 69,6% e Kappa igual a 0,58, sendo classificado com o conceito “Bom” de acordo com a classificação de Landis e Koch (1977). Além disso, foi possível observar que apenas o cenário SVM-7 e SVM-5 atingiram essa classificação, os demais foram classificados como “Ruins” e “Razoáveis”.

Tabela 4.3 - Acurácia Global (AC), Kappa e Intervalos de Credibilidade a 5% de significância para todos os cenários com o classificador SVM para a Fase 2.

Cenários	AC (%)	Kappa	Intervalos de Credibilidade		Conceito
			AC (%)	Kappa	
SVM-1	41,6	0,16	$40,1 \leq AC \leq 43,1$	$0,14 \leq K \leq 0,18$	Ruim
SVM-2	44,8	0,18	$43,6 \leq AC \leq 46,1$	$0,16 \leq K \leq 0,20$	Ruim
SVM-3	42,0	0,16	$40,3 \leq AC \leq 43,6$	$0,14 \leq K \leq 0,19$	Ruim
SVM-4	51,8	0,32	$50,1 \leq AC \leq 53,7$	$0,30 \leq K \leq 0,35$	Razoável
SVM-5	59,3	0,43	$57,4 \leq AC \leq 61,0$	$0,40 \leq K \leq 0,45$	Bom
SVM-6	54,6	0,37	$52,8 \leq AC \leq 56,2$	$0,34 \leq K \leq 0,39$	Razoável
SVM-7	69,6	0,58	$67,8 \leq AC \leq 71,4$	$0,56 \leq K \leq 0,61$	Bom

Fonte: Produção do autor.

De modo geral, nota-se que o cenário SVM-7 apresentou o melhor desempenho obtido nas classificações, representando um valor 27,9% superior em relação ao cenário SVM-1 que obteve o menor desempenho, com um valor de acurácia global igual a 41,6%. Além disso, diferentemente da Fase 1, o cenário SVM-2, dentre os cenários individuais, foi o que apresentou os melhores resultados (44,8%), mostrando que a presença dos atributos H e α são importantes para a discriminação das classes florestais.

Dentre os cenários agregados (SVM-4, SVM-5 e SVM-6), nota-se que o SVM-5 se destacou dos demais, apresentando um aumento na acurácia global de 7,4% e 4,7% em relação aos cenários SVM-4 e SVM-6, respectivamente, enquanto, em relação ao SVM-7, este cenário apresentou uma redução de 10,3% na acurácia global.

Ao se analisar a acurácia média do produtor (Figura 4.12) e do usuário (Figura 4.13) para as classes florestais, observa-se que alguns cenários foram capazes de discriminar melhor algumas classes do que outros.

Para a classe FD se destacaram os cenários SVM-5 (56,1%) e SVM-7 (71,6%) para acurácia do produtor e os cenários SVM-2 (58,2%), SVM-5 (64,8%) e SVM-7 (68,1%) para acurácia do usuário. Nesse caso, nota-se que estes cenários apresentaram em comum a presença dos atributos da decomposição polarimétrica, que melhoraram significativamente ambas as acurácias.

A classe FP também apresentou o melhor desempenho com o cenário SVM-2 para a acurácia do produtor (90,6%), o que representou um aumento de 8,2% em relação ao cenário SVM-5, que apresentou a segunda melhor acurácia. No entanto, quando se

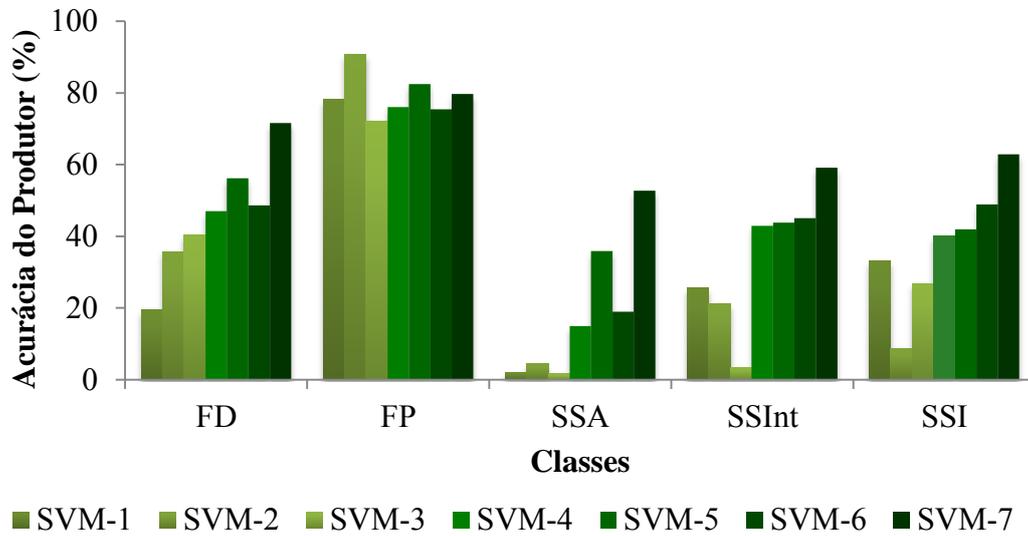
analisa a acurácia do usuário, nota-se, que os cenários SVM-6 e SVM-7, apresentaram os melhores desempenhos, iguais a 54,9% e 66,8%, respectivamente.

Em relação à classe SSA, nota-se que esta apresentou o pior desempenho para a acurácia do produtor em relação às demais classes. O cenário SVM-7 apresentou os melhores resultados para a acurácia do produtor, sendo igual a 52,7%. Já os cenários individuais (SVM-1, SVM-2 e SVM-3) não foram capazes de discriminar bem esta classe, com valores de acurácia do produtor muito baixos ($AP < 5\%$), indicando altos erros de omissão. Para a acurácia do usuário o melhor desempenho também foi observado pelo cenário SVM-7, igual a 72,2%.

Já para a classe SSInt, o cenário SVM-7 também apresentou os melhores valores de acurácia do produtor e usuário, iguais a 59,1% e 76,1%, respectivamente. O cenário SVM-3 apresentou os menores resultados de acurácia do produtor e do usuário, com uma diferença respectivamente de 55,7% e de 40,1% em relação ao SVM-7.

A classe SSI apresentou resultados semelhantes aos observados para a classe SSInt, com o cenário SVM-7 atingindo 62,9% e 75,7% para as acurácias do produtor e usuário, respectivamente. Nota-se também que o cenário SVM-2 apresentou uma baixa acurácia do produtor (8,8%) e se destacou dos demais cenários individuais na acurácia do usuário (54,3%).

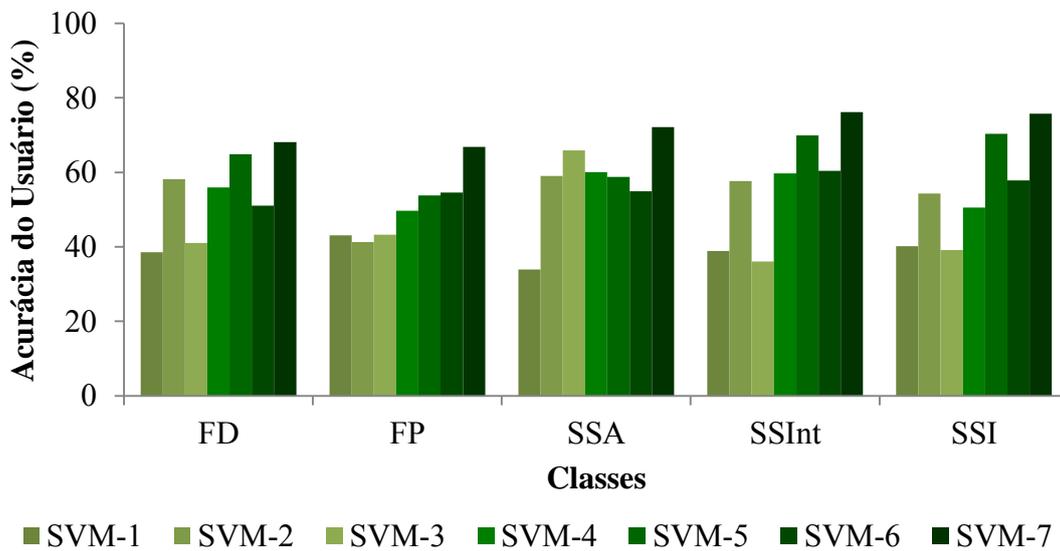
Figura 4.12 - Acurácia do produtor média para cada classe temática nos cenários analisados com o classificador SVM na Fase 2.



Legenda: FD: Floresta Degradada; FP: Floresta Primária; SSA: Sucessão Secundária Avançada; SSInt: Sucessão Secundária Intermediária; SSI: Sucessão Secundária Inicial.

Fonte: Produção do autor.

Figura 4.13 - Acurácia do usuário média para cada classe temática nos cenários analisados com o classificador SVM na Fase 2.



Legenda: FD: Floresta Degradada; FP: Floresta Primária; SSA: Sucessão Secundária Avançada; SSInt: Sucessão Secundária Intermediária; SSI: Sucessão Secundária Inicial.

Fonte: Produção do autor.

A partir da matriz de confusão do cenário SVM-7 (Tabela 4.4), que obteve o melhor desempenho, observa-se que as classes FD e FP apresentaram confusão entre si, sendo estas as responsáveis pelos maiores erros de omissão e comissão de cada. A classe FP foi responsável por 65,4% e 40,4% dos erros de omissão e comissão da classe FD, enquanto a classe FD foi responsável por 47,4% do erro de omissão da classe FP e a classe SSI 35,2% do erro de comissão.

Já entre as classes sucessionais observa-se que também houve confusão com a classe FP e ocorreu uma distribuição dos erros entre as demais classes. Na classe SSA os maiores erros de omissão e comissão ocorreram com a classe FP, correspondentes a 61,2% e 57,7%, respectivamente do total dos erros. Para a classe SSInt, esses erros corresponderam a 60,6% e 40,0%, respectivamente com a classe FP. E para a classe SSI essa proporção foi de 43,7% e 40,9%, respectivamente do total dos erros de omissão e comissão.

Tabela 4.4 - Matriz de confusão média do cenário SVM-7 para a Fase 2.

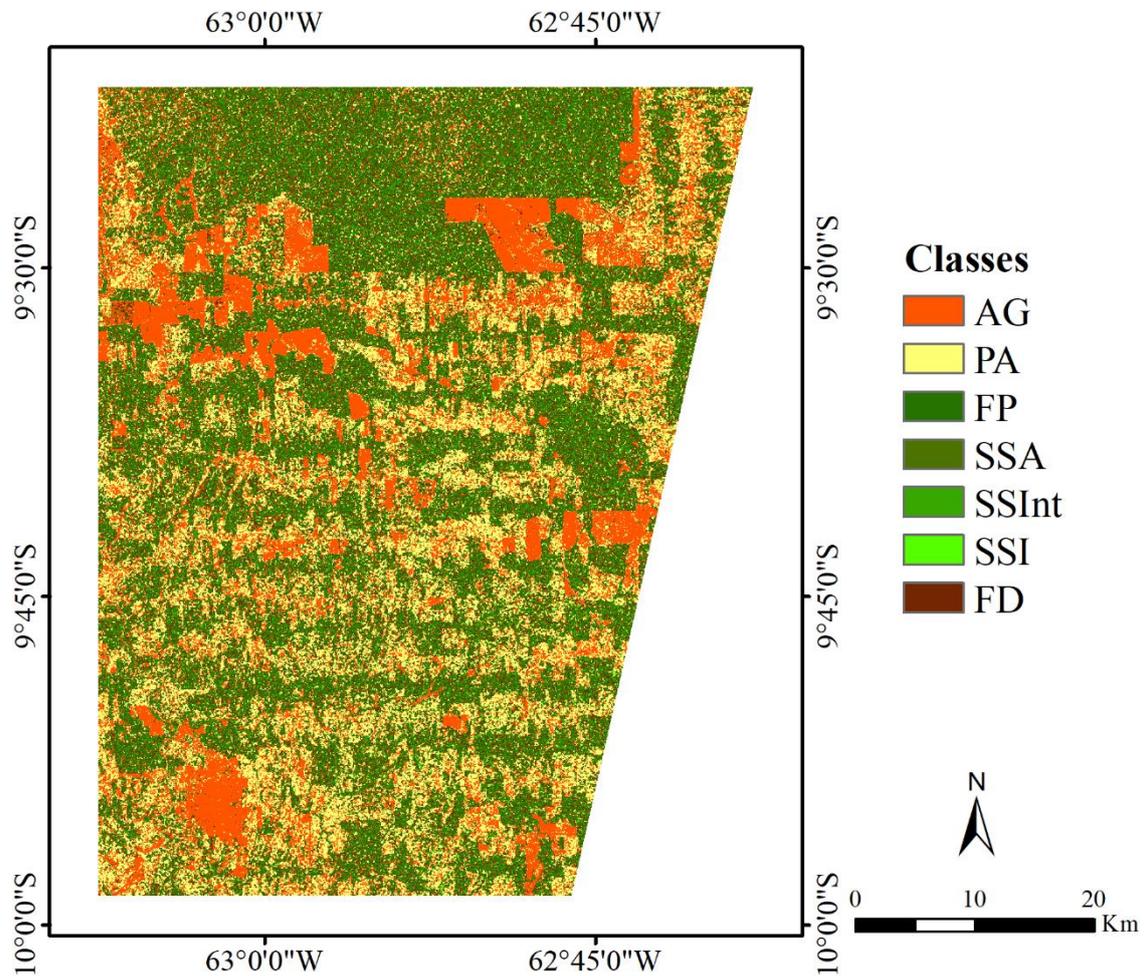
Mapa	Referência				
	FD	FP	SSA	SSInt	SSI
FD	342	65	29	48	19
FP	89	537	63	94	21
SSA	11	26	115	7	1
SSInt	30	37	10	262	7
SSI	6	9	1	6	68

Legenda: FD: Floresta Degradada; FP: Floresta Primária; SSA: Sucessão Secundária Avançada; SSInt: Sucessão Secundária Intermediária; SSI: Sucessão Secundária Inicial.

Fonte: Produção do autor.

A partir das duas fases das classificações realizadas com o cenário SVM-7, foi possível obter o mapa de uso e cobertura da terra da área de estudo (Figura 4.14), onde foi possível observar uma boa discriminação entre as classes Floresta, Agricultura e Pastagem, com uma boa delimitação dos fragmentos florestais. Percebe-se ainda que as classes florestais (FD, FP, SSA, SSInt e SSI) foram classificadas em praticamente todos os segmentos florestais, não observando-se grandes áreas com a predominância de alguma dessas classes.

Figura 4.14 - Mapa do uso e cobertura da terra com o classificador SVM-7 para as duas fases da classificação.



Fonte: Produção do autor.

4.4 Classificações *Random Forest*

4.4.1 Classificações RF Fase 1.

Assim como para as classificações realizadas com o SVM, para o RF foram obtidos os valores médios do índice Kappa e Acurácia Global (AC), assim como os Intervalos de Credibilidade (Tabela 4.5) para todos os cenários analisados na Fase 1. Foi possível perceber que houve um aumento crescente nos valores de Kappa e Acurácia Global à medida que foram incluídos novos atributos aos cenários de classificação, sendo o cenário RF-7 o que apresentou os melhores valores para a classificação, com acurácia

global igual a 85,7% e Kappa igual a 0,78. Esse valor de Kappa é considerado “Muito bom” de acordo com a classificação definida por Landis e Koch (1977). Além disso, nota-se que os intervalos de credibilidade apresentaram baixa variação, com 95% de credibilidade.

Tabela 4.5 - Acurácia Global (AC), Kappa e Intervalos de Credibilidade a 5% de significância para todos os cenários com o classificador RF na Fase 1.

Cenários	AC	Kappa	Intervalos de Credibilidade		Conceito
			AC (%)	Kappa	
RF-1	66,6	0,48	$65,6 \leq AC \leq 67,7$	$0,46 \leq K \leq 0,50$	Bom
RF-2	52,3	0,26	$51,2 \leq AC \leq 53,4$	$0,24 \leq K \leq 0,27$	Razoável
RF-3	59,2	0,37	$58,2 \leq AC \leq 60,2$	$0,35 \leq K \leq 0,38$	Razoável
RF-4	75,9	0,62	$74,9 \leq AC \leq 76,8$	$0,61 \leq K \leq 0,64$	Muito bom
RF-5	76,0	0,63	$75,0 \leq AC \leq 76,9$	$0,61 \leq K \leq 0,64$	Muito bom
RF-6	79,6	0,69	$78,7 \leq AC \leq 80,5$	$0,67 \leq K \leq 0,70$	Muito bom
RF-7	85,7	0,78	$84,9 \leq AC \leq 86,6$	$0,77 \leq K \leq 0,79$	Muito bom

Fonte: Produção do autor.

Analisando-se os cenários que utilizaram os atributos individualmente (RF-1, RF-2 e RF-3), percebe-se que o cenário RF-1, que utilizou os atributos provenientes dos coeficientes de retroespalhamento (σ_{VV}^0 , σ_{VH}^0 e $\sigma_{VH}^0/\sigma_{VV}^0$), apresentou o melhor resultado de acurácia global (66,6%), representando uma melhora de 14,3% em relação ao cenário RF-2 e 7,4% em relação ao cenário RF-3.

Nota-se que o cenário RF-2 apresentou os menores valores de Kappa e acurácia, iguais a 0,26 e 52,3%, respectivamente. Nesse cenário foram utilizados os atributos provenientes da decomposição polarimétrica (H e α), mostrando que a utilização apenas desses atributos não alcança resultados satisfatórios para classificações. No entanto, quando esses atributos são agregados a outros como os coeficientes de retroespalhamento (RF-4) e coerência interferométrica (RF-5) têm-se uma melhora nas classificações de 23,6% e 23,7%, respectivamente.

Quando se analisa o resultado obtido com a inserção de todos os atributos (RF-7), percebe-se que os ganhos mais significativos ocorreram em relação aos cenários individuais RF-1, RF-2 e RF-3, com um ganho na acurácia global de 19,1%, 33,4% e

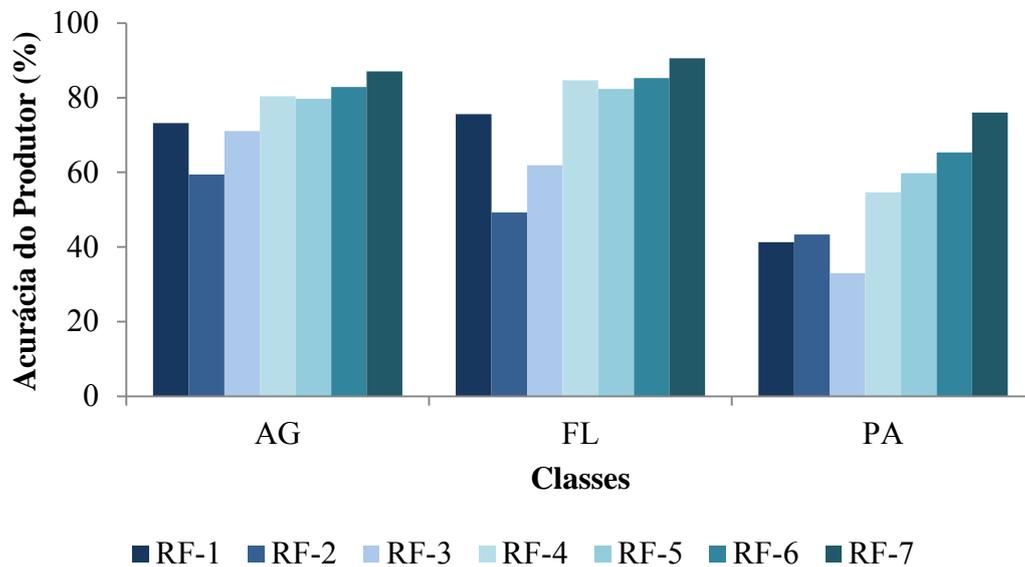
26,5%, respectivamente. O cenário RF-6 foi o que apresentou resultados mais próximos ao RF-7, com uma diferença de 6,1% na acurácia global.

A partir das acurácias médias do produtor (AP) (Figura 4.15) e usuário (AU) (Figura 4.16), nota-se que, assim como na acurácia global, houve um aumento crescente nos valores das acurácias do produtor e usuário à medida que foram acrescentados novos atributos aos cenários de classificação. Em relação à classe AG, percebe-se que a utilização do cenário RF-7 representou um ganho de 27,6% para a AP e 34,2% para a AU, em relação ao cenário RF-2.

Para a classe FL, o ganho obtido com a utilização do cenário RF-7 representou 41,3% e 34,5% para a AP e AU, respectivamente, em relação ao cenário RF-2. Nesse caso, percebe-se que a utilização dos atributos dos coeficientes de retroespalhamento apresentou grande importância para a discriminação dessa classe, o que pode ser observado quando se analisa os cenários individualmente. O cenário RF-1 representou um ganho para a acurácia do produtor de 26,3% e 13,7% em relação aos cenários RF-2 e RF-3, respectivamente, enquanto para a acurácia do usuário esse ganho foi de 22,1% e 19,2%, respectivamente.

Por fim, a classe PA, apresentou os menores resultados de acurácia do produtor e usuário em relação às outras classes, com destaque para o cenário RF-7, que obteve 76,1% de acurácia do produtor e 79,2% de acurácia do usuário, representando um aumento de 43,1% e 39,7% nas acurácias do produtor e do usuário, respectivamente, em relação ao cenário RF-3. Diferente das outras classes, o cenário RF-2 se destacou dentre os cenários individuais para a classe PA, representando um aumento na acurácia do usuário de 0,5% em relação ao cenário RF-1, e de 8,1% em relação ao cenário RF-3, já para a acurácia do produtor, esse aumento foi de 2,0% e 10,4%, em relação aos cenários RF-1 e RF-3, respectivamente.

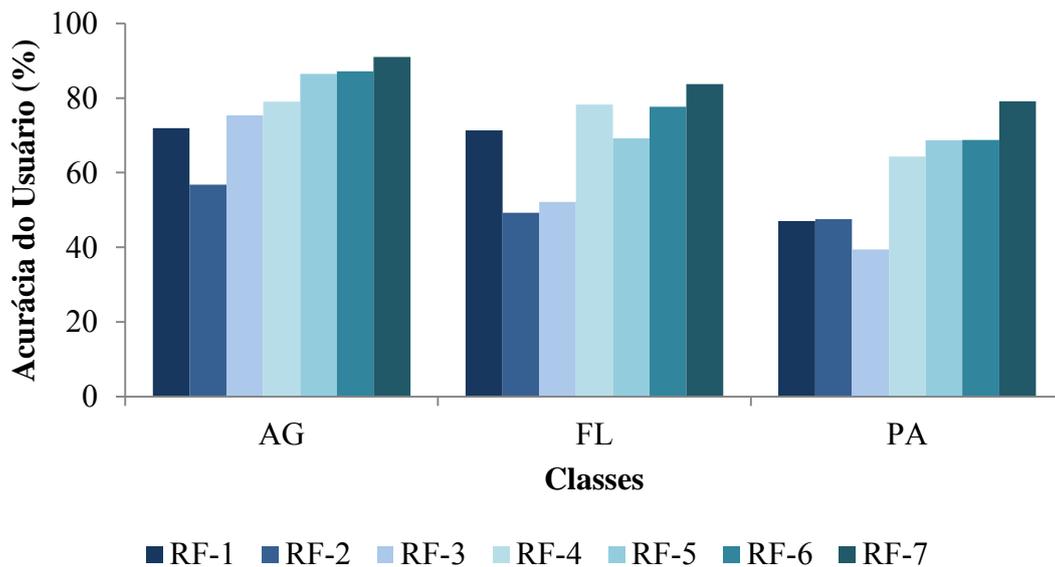
Figura 4.15 - Acurácia do produtor média para cada classe temática nos cenários analisados com o classificador RF na Fase 1.



Legenda: AG: Agricultura; FL: Floresta; PA: Pastagem.

Fonte: Produção do autor.

Figura 4.16 - Acurácia do usuário média para cada classe temática nos cenários analisados com o classificador RF na Fase 1.



Legenda: AG: Agricultura; FL: Floresta; PA: Pastagem.

Fonte: Produção do autor.

A partir da matriz de confusão média obtida com as 1000 simulações para o cenário RF-7 (Tabela 4.6), que apresentou o melhor desempenho classificatório, pode-se observar como ocorreram as confusões entre as classes temáticas analisadas. Nesse caso, nota-se que os erros de omissão e comissão foram baixos entre todas as classes analisadas.

As classes AG e PA apresentaram os maiores erros de comissão entre si, onde a classe PA correspondeu a 66,8% do erro de comissão (9,0%) da classe AG e a classe AG correspondeu a 59,0% do erro de comissão (20,8%) da classe PA. Em relação ao erro de omissão, ambas apresentaram os maiores erros de omissão com a classe FL, que representou 54,8% e 50,9% dos erros de omissão com as classes PA e AG, respectivamente.

Já a classe FL apresentou as maiores confusões com a classe PA, que foi responsável por 60,5% do erro de omissão (9,4%) e 51,6% do erro de comissão (16,3%), ou seja, do erro de comissão a classe FL confundiu praticamente na mesma proporção com as classes AG e PA.

Tabela 4.6 - Matriz de confusão média do cenário RF-M7 para a Fase 1.

Mapa	Referência		
	AG	FL	PA
AG	2148	70	142
FL	162	1721	173
PA	156	108	1001

Legenda: AG: Agricultura; FL: Floresta; PA: Pastagem.

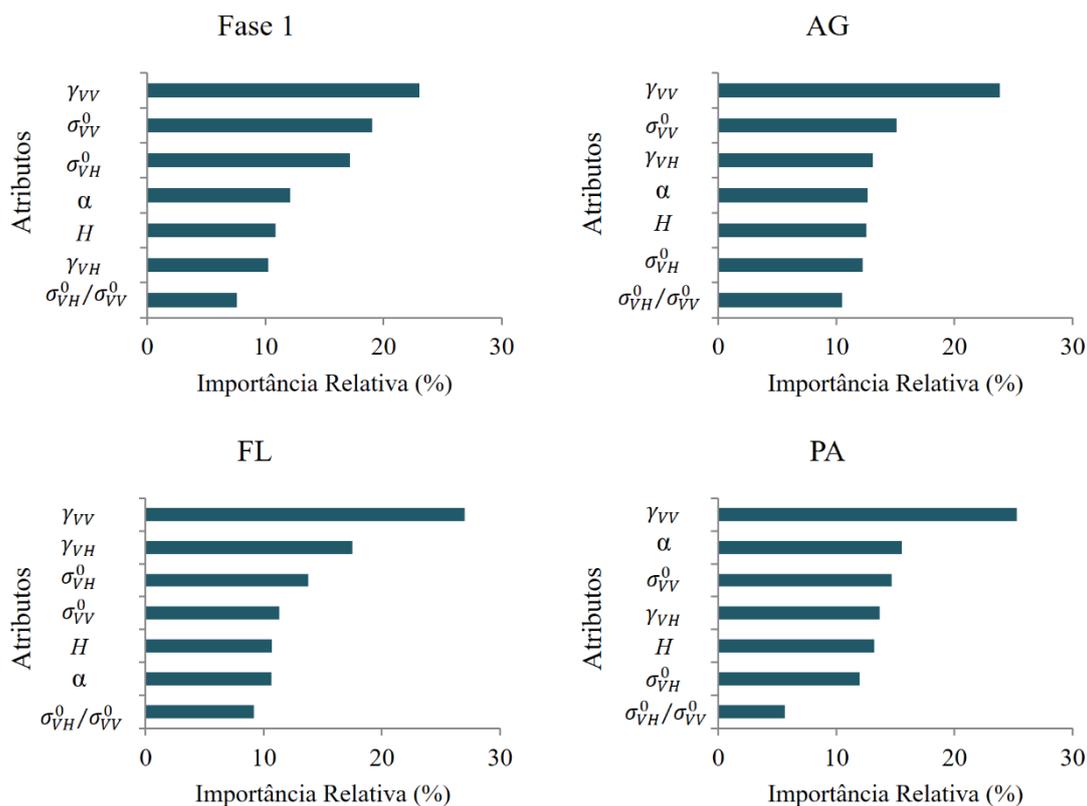
Fonte: Produção do autor.

A partir do classificador RF é possível observar a importância de cada variável para o processo de classificação através do índice de Gini (Figura 4.17). Desse modo, nota-se que a variável γ_{VV} apresentou uma grande importância para o mapeamento da Fase 1, correspondente a 23,0%, seguida pelos coeficientes de retroespalhamento σ_{VV}^0 e σ_{VH}^0 que corresponderam a 19,0% e 17,1%, respectivamente.

Em relação à classe AG, as três variáveis com maior importância foram γ_{VV} , σ_{VV}^0 e γ_{VH} , correspondentes a 23,8%, 15,1% e 13,1%, respectivamente. Já para a classe FL, as variáveis foram γ_{VV} (26,9%), γ_{VH} (17,5%) e σ_{VH}^0 (13,7%). Por fim, para a classe

pastagem destacaram-se as variáveis γ_{VV} , α e σ_{VV}^0 , correspondendo a 25,3%, 15,6% e 14,7%, respectivamente.

Figura 4.17 - Variáveis de Importância pelo índice de Gini para a Fase 1 do mapeamento e para cada classe analisada no Cenário RF-7.



Fonte: Produção do autor.

4.4.2 Classificação RF Fase 2.

Os resultados obtidos com a estratificação da classe FL (Tabela 4.7), mostram que assim como para a Fase 1, o cenário RF-7 apresentou o melhor desempenho, com acurácia global igual a 71,6% e Kappa igual a 0,61, sendo classificado como “Muito bom” de acordo com Landis e Koch (1977). Este cenário apresentou um aumento na acurácia global de 32,3% em relação ao cenário RF-1.

Ao se analisar os cenários individualmente (RF-1, RF-2 e RF-3), nota-se que apenas o cenário RF-2 foi classificado como “Razoável”, os demais foram classificados como “Ruins”. Dentre eles, o cenário RF-2 apresentou um pequeno ganho de 3,2% e 2,2% em relação aos cenários RF-1 e RF-3, respectivamente.

Tabela 4.7 - Acurácia Global (AC), Kappa e Intervalos de Credibilidade a 5% de significância para todos os cenários com o classificador RF na Fase 2.

Cenários	AC (%)	Kappa	Intervalos de Credibilidade		Conceito
			AC (%)	Kappa	
RF-1	39,3	0,17	$37,5 \leq AC \leq 41,1$	$0,15 \leq K \leq 0,20$	Ruim
RF-2	42,5	0,21	$40,8 \leq AC \leq 44,5$	$0,19 \leq K \leq 0,24$	Razoável
RF-3	40,3	0,18	$38,5 \leq AC \leq 42,1$	$0,16 \leq K \leq 0,21$	Ruim
RF-4	55,3	0,39	$53,3 \leq AC \leq 57,1$	$0,36 \leq K \leq 0,41$	Razoável
RF-5	63,0	0,49	$61,0 \leq AC \leq 64,9$	$0,47 \leq K \leq 0,52$	Bom
RF-6	57,7	0,42	$56,0 \leq AC \leq 59,7$	$0,40 \leq K \leq 0,45$	Bom
RF-7	71,6	0,61	$69,8 \leq AC \leq 73,5$	$0,59 \leq K \leq 0,64$	Muito bom

Fonte: Produção do autor.

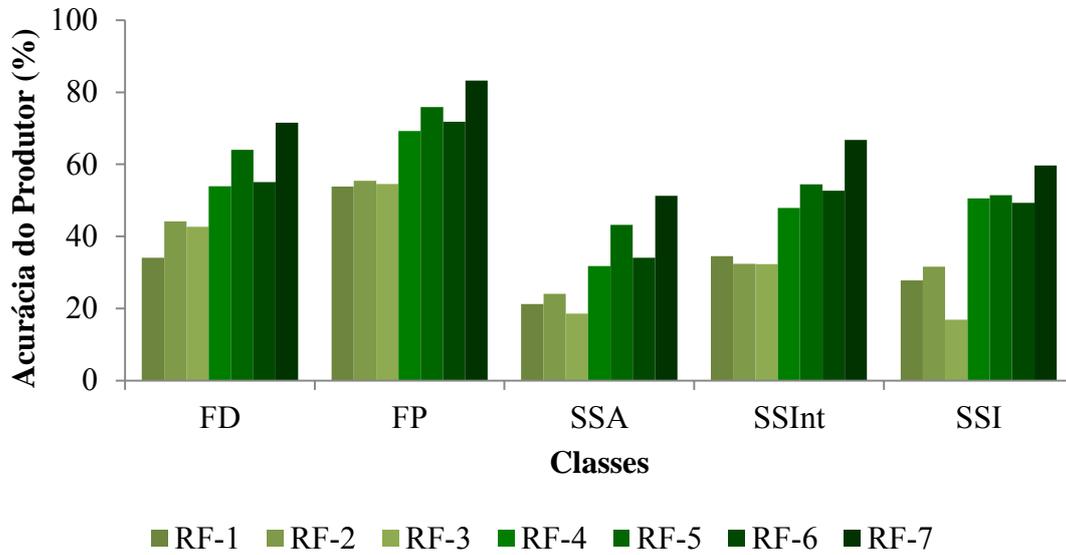
Através das acurácias do produtor (Figura 4.18) e usuário (Figura 4.19) nota-se que a utilização do cenário RF-7 apresentou diferenças com todas as classes, melhorando tanto a acurácia do produtor quanto do usuário.

Para a classe FD, a utilização do cenário RF-7, representou um ganho de 37,5% na acurácia do produtor em relação ao cenário RF-1 e de 36,1% na acurácia do usuário. Percebe-se também que o cenário RF-6, apresentou os menores resultados dentre os cenários agregados, com uma redução de 16,5% e 16,2% nas acurácias do produtor e usuário, respectivamente, em relação ao cenário RF-7.

Em relação à classe FP, o cenário RF-7, representou um ganho de 29,4% e 24,0% para a acurácia do produtor e usuário, respectivamente, em relação ao cenário RF-1. Nota-se que os cenários individuais apresentaram resultados semelhantes para as duas acurácias, variando de 53,8% (RF-1) a 55,4% (RF-2) para a acurácia do produtor e 45,7% (RF-2) a 46,6% (RF-1) para a acurácia do usuário.

As classes sucessoriais SSA, SSInt e SSI, apresentaram comportamento semelhante para ambas as acurácias, com a menor acurácia do produtor observada para a classe SSA (51,3%) e a maior para a classe SSInt (66,8%) enquanto que para a acurácia do usuário, a classe SSI apresentou o melhor desempenho (79,2%) e a SSInt o pior (72,7%).

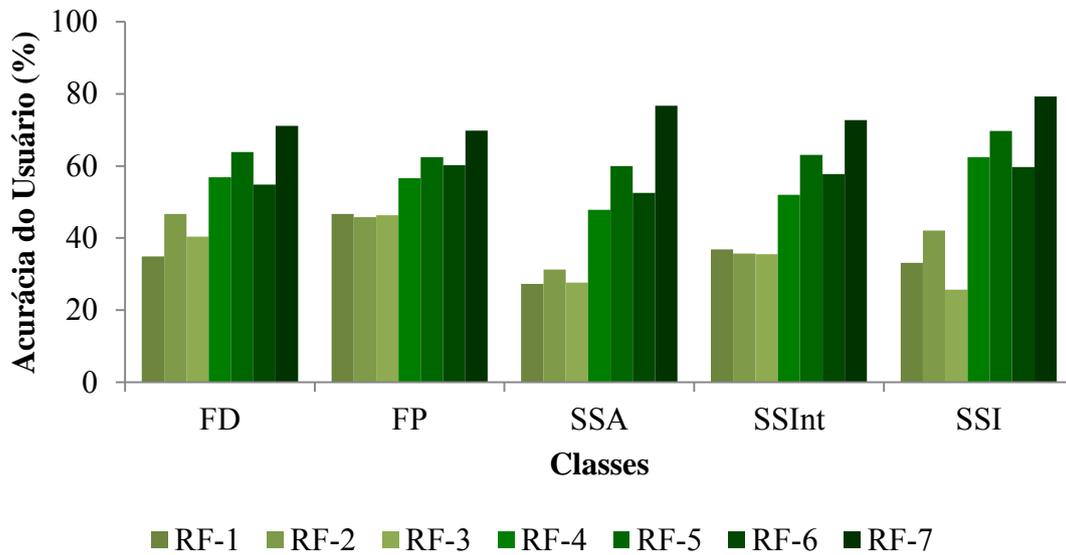
Figura 4.18 - Acurácia do produtor média para cada classe temática nos cenários analisados com o classificador RF na Fase 2.



Legenda: FD: Floresta Degradada; FP: Floresta Primária; SSA: Sucessão Secundária Avançada; SSInt: Sucessão Secundária Intermediária; SSI: Sucessão Secundária Inicial.

Fonte: Produção do autor.

Figura 4.19 - Acurácia do usuário média para cada classe temática nos cenários analisados com o classificador RF na Fase 2.



Legenda: FD: Floresta Degradada; FP: Floresta Primária; SSA: Sucessão Secundária Avançada; SSInt: Sucessão Secundária Intermediária; SSI: Sucessão Secundária Inicial.

Fonte: Produção do autor .

De modo geral, para o classificador RF, nota-se que os cenários apresentaram comportamento semelhante em todas as classes e para as duas acurácias. Observa-se que o cenário RF-5 foi o que apresentou o maior destaque além do RF-7, mostrando que a presença dos atributos provenientes da decomposição polarimétrica (H , α) e dos coeficientes de retroespalhamento (σ_{VH}^0 , σ_{VV}^0 e $\sigma_{VH}^0/\sigma_{VV}^0$) foram importantes para discriminação das classes florestais.

De acordo com a matriz de confusão média para o cenário RF-7 (Tabela 4.8) percebe-se que houve uma distribuição das confusões entre as classes. Em relação à classe FD, a classe FP representou 35,9% do erro de comissão e 61,0% do erro de omissão (28,4%). Já em relação à classe FP, essa proporção foi de 44,2% e 34,1%, respectivamente com a classe FD.

Além disso, nota-se que a classe SSA, apresentou um alto erro de omissão (48,6%), mas um baixo erro de comissão (23,3%), mostrando que poucos pixels das outras classes foram classificados como SSA, sendo a classe FP responsável por 58,5% do erro de omissão e 55,8% do erro de comissão. Já a classe SSInt apresentou os maiores erros de comissão com as classes FP e FD, que corresponderam juntas a 73,0% deste erro, enquanto o erro de omissão ocorreu predominantemente com a classe FP, correspondente a 60,1% deste erro. A classe SSI apresentou os maiores erros de omissão com a classe FP, correspondente a 41,3% do erro, enquanto os erros de comissão se distribuíram entre as classes FD, FP e SSInt.

Tabela 4.8 - Matriz de confusão média para o cenário RF-7 na Fase 2.

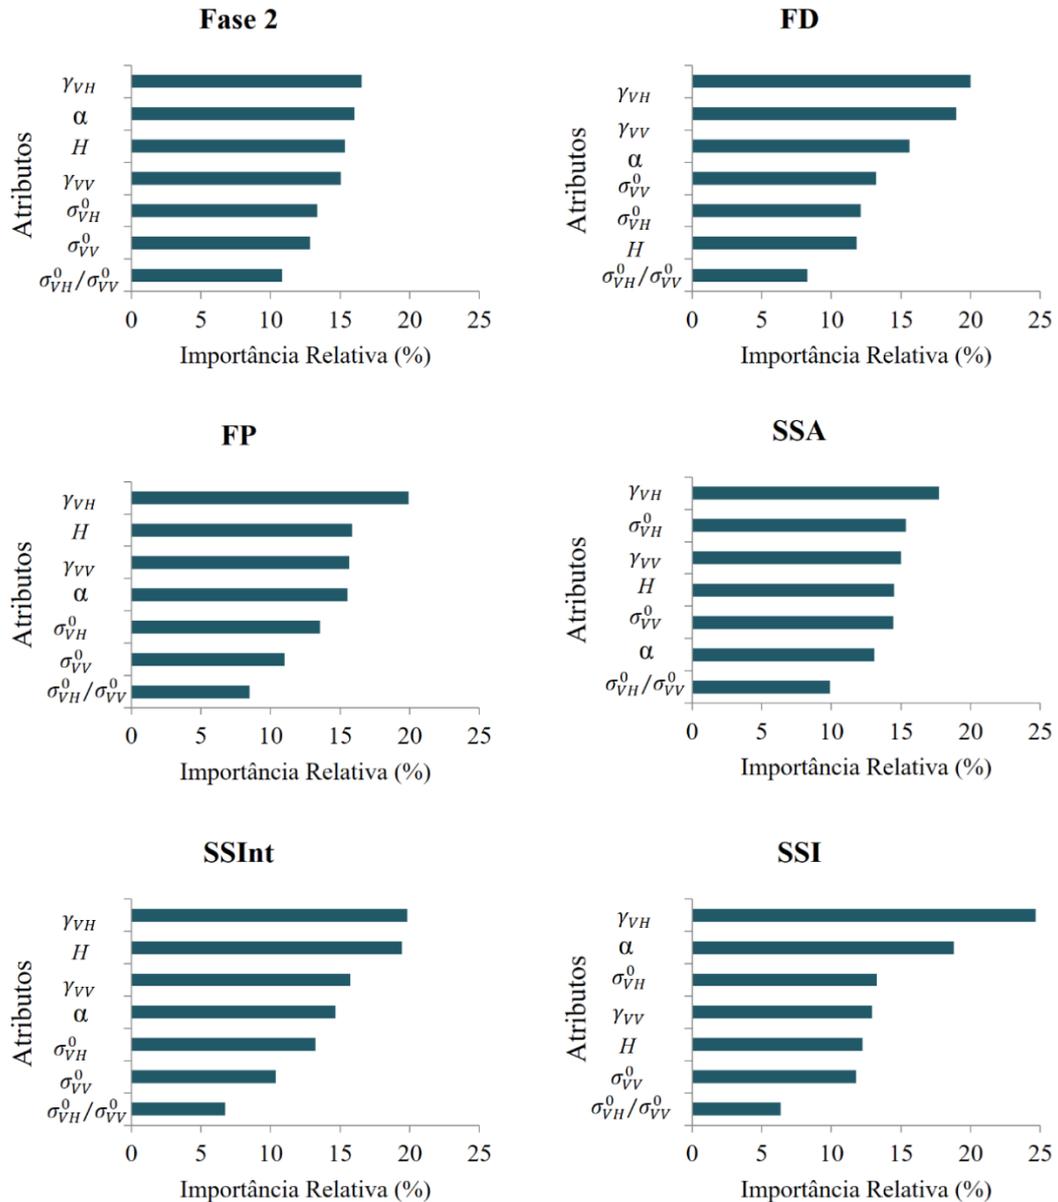
Mapa	Referência				
	FD	FP	SSA	SSInt	SSI
FD	342	50	26	44	19
FP	83	561	62	83	15
SSA	10	19	112	4	1
SSInt	38	38	17	278	11
SSI	5	6	1	7	69

Legenda: FD: Floresta Degradada; FP: Floresta Primária; SSA: Sucessão Secundária Avançada; SSInt: Sucessão Secundária Intermediária; SSI: Sucessão Secundária Inicial.

Fonte: Produção do autor.

Através do índice de Gini foi possível observar a importância dos atributos no processo de classificação (Figura 4.20). Nesse caso, nota-se que o atributo γ_{VH} foi o mais importante tanto para a classificação geral da Fase 2 quanto para a discriminação de todas as classes florestais.

Figura 4.20 - Variáveis de Importância pelo índice de Gini para a Fase 2 do mapeamento e para cada classe analisada no Cenário RF-7.



Fonte: Produção do autor.

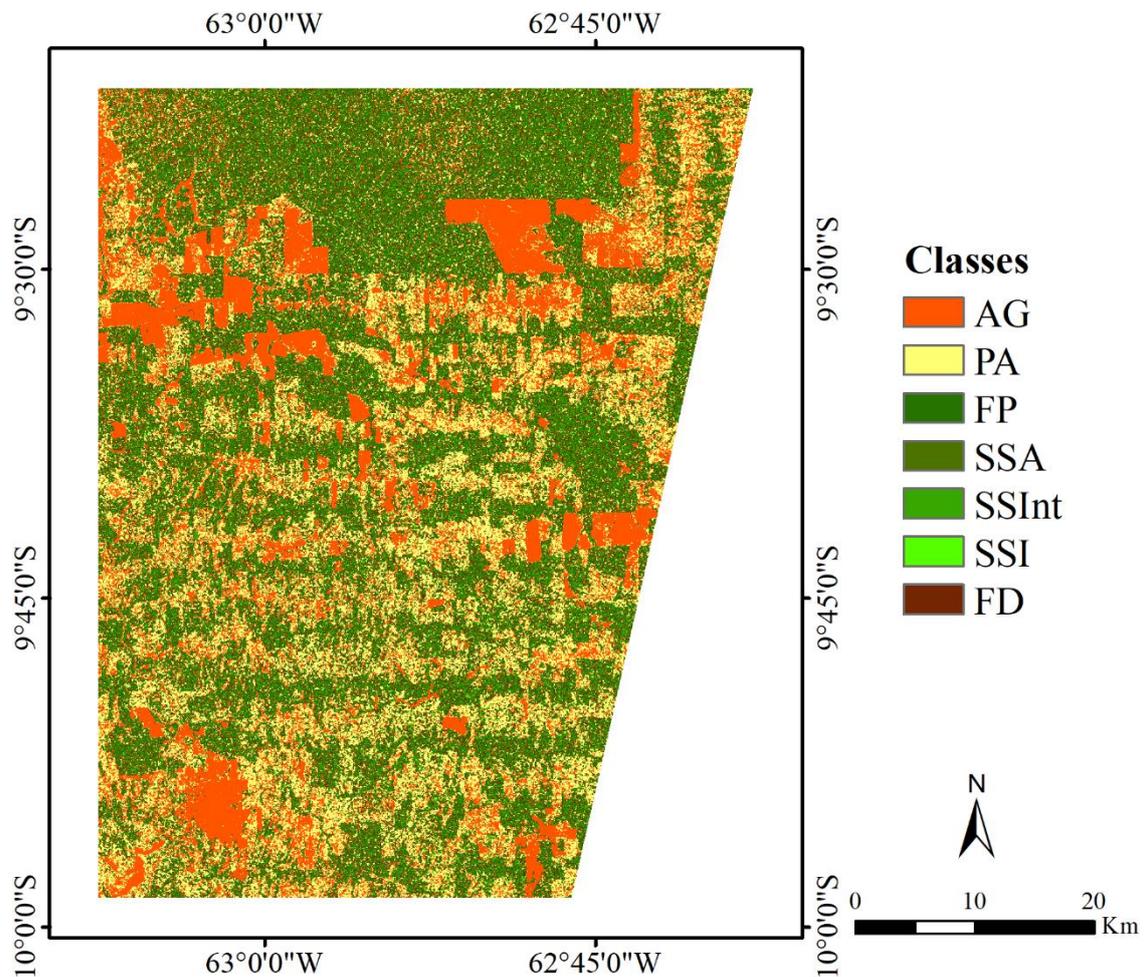
Quando se analisa os valores de importância relativa da Fase 2, nota-se que os três principais atributos apresentaram valores muito próximos de importância, com γ_{VH} igual a 16,5%, α igual a 16,02% e H igual a 15,3%.

Já quando se observa os atributos de importância para cada classe separadamente, verifica-se uma variação a partir dos atributos com segunda maior importância. No caso da classe FD, os três atributos de maior importância foram: γ_{VH} (20,0%), γ_{VV} (18,9%) e α (15,6%). Para a classe FP foram os atributos: γ_{VH} (19,9%), H (15,8%) e γ_{VV} (15,6%). Para as classes sucessionais observa-se que a classe SSA apresentou os atributos γ_{VH} , σ_{VH}^0 e γ_{VV} com os valores de importância relativa iguais a 17,7%, 15,4% e 14,9%, respectivamente. Enquanto para a classe SSInt os atributos foram: γ_{VH} (19,8%), H (19,4%) e γ_{VV} (15,7%) e por fim, para a classe SSI têm-se: γ_{VH} (24,7%), α (18,8%) e σ_{VH}^0 (13,2%).

De modo geral, nota-se que para a discriminação das classes florestais os atributos provenientes da coerência interferométrica (γ_{VH} e γ_{VV}) apresentaram grande importância, assim como os provenientes da decomposição polarimétrica (H e α).

O mapa de uso e cobertura da terra obtido com o classificador RF (Figura 4.21) mostra a espacialização das classes temáticas na área de estudo. É possível observar que grandes áreas foram classificadas como agricultura e que as classes florestais foram classificadas em praticamente todos os fragmentos florestais, o que mostra que há dificuldade em se separar segmentos homogêneos dessas classes.

Figura 4.21 - Mapa de uso e cobertura da terra com o classificador RF para o cenário RF-7.



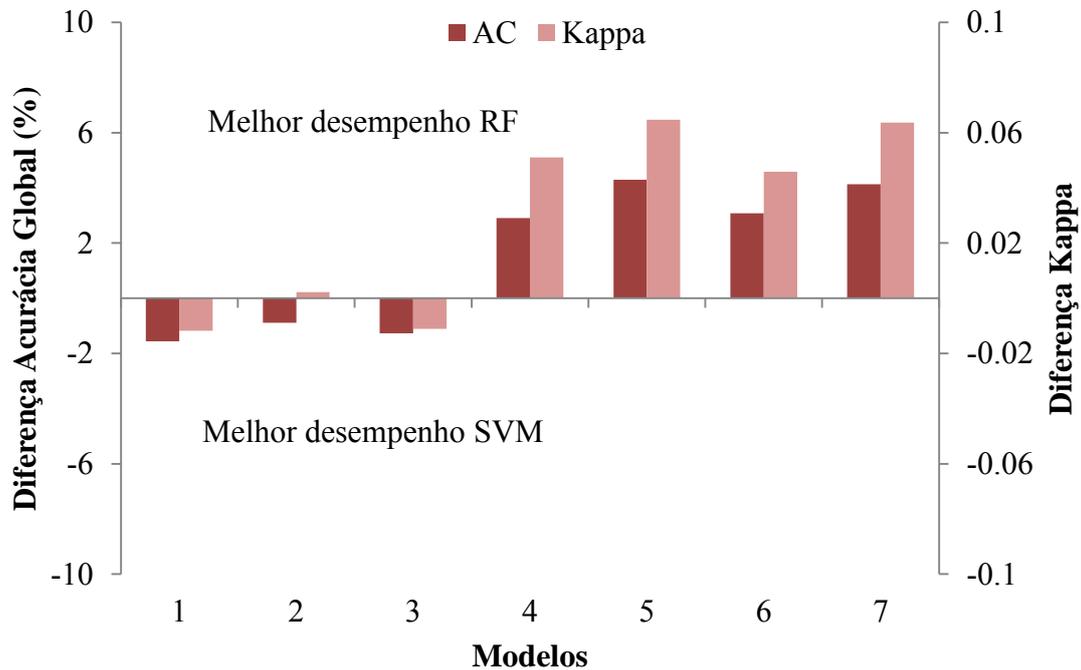
Fonte: Produção do autor.

4.5 Comparação SVM-RF

4.5.1 Comparação SVM-RF Fase 1

A partir dos resultados observados com os classificadores, foi possível obter a diferença entre as classificações, a fim de analisar qual classificador obteve o melhor desempenho. A Figura 4.22 representa a diferença entre o classificador RF pelo SVM na Fase 1, onde os valores negativos indicam melhor desempenho do classificador SVM e os valores positivos do RF.

Figura 4.22 - Diferença entre as classificações do RF pelo SVM na Fase 1.



Fonte: Produção do autor.

Observando a Figura 4.22, nota-se que o classificador SVM apresentou os melhores resultados quando são analisados os cenários individuais (1, 2 e 3), com a maior diferença observada de 1,56% na acurácia global do cenário 1 em relação ao RF.

Para os cenários agrupados, percebe-se que o aumento da acurácia e do índice Kappa foram mais expressivos para o classificador RF. Nesse caso, nota-se que os cenários 5 e 7 apresentaram a maior diferença na acurácia global, com uma melhora de 4,3% e 4,1%, respectivamente em relação ao SVM. Já quando se analisa o índice Kappa, nota-se que essas melhoras foram de 0,064 para ambos os cenários.

A partir do teste de McNemar (Tabela 4.9) observa-se que a um nível de confiança de 95% todos os cenários realizados com o classificador SVM foram diferentes significativamente entre si. Já com o classificador RF, apenas os cenários 4 e 5 não apresentaram diferença significativa. Quando se analisa a diferença existente entre os dois classificadores (SVM e RF), percebe-se que apenas o cenário 3 não apresentou diferença significativa.

Tabela 4.9 - Teste de McNemar comparando os classificadores SVM e RF para cada cenário realizado na Fase 1, com um nível de confiança de 95% (Teste McNemar $\chi^2 > 3,84$).

Comparações	Cenários	1	2	3	4	5	6	7
SVM x RF		6,06*	4,94*	0,06 ^{ns}	23,32*	77,30*	55,35*	76,53*
SVM x SVM	1		270,11*	147,69*	98,88*	24,35*	186,84*	476,60*
	2			37,00*	533,58*	457,53*	611,08*	1062,57*
	3				331,24*	360,49*	577,48*	954,08*
	4					4,54*	28,85*	275,15*
	5						61,90*	352,20*
	6							167,30*
RF x RF	1		279,56*	72,59*	213,56*	156,24*	398,09*	774,40*
	2			68,53*	744,44*	831,51*	967,92*	1430,30*
	3				370,09*	491,16*	679,63*	1084,88*
	4					0,90 ^{ns}	49,91*	361,00*
	5						34,68*	275,25*
	6							182,11*

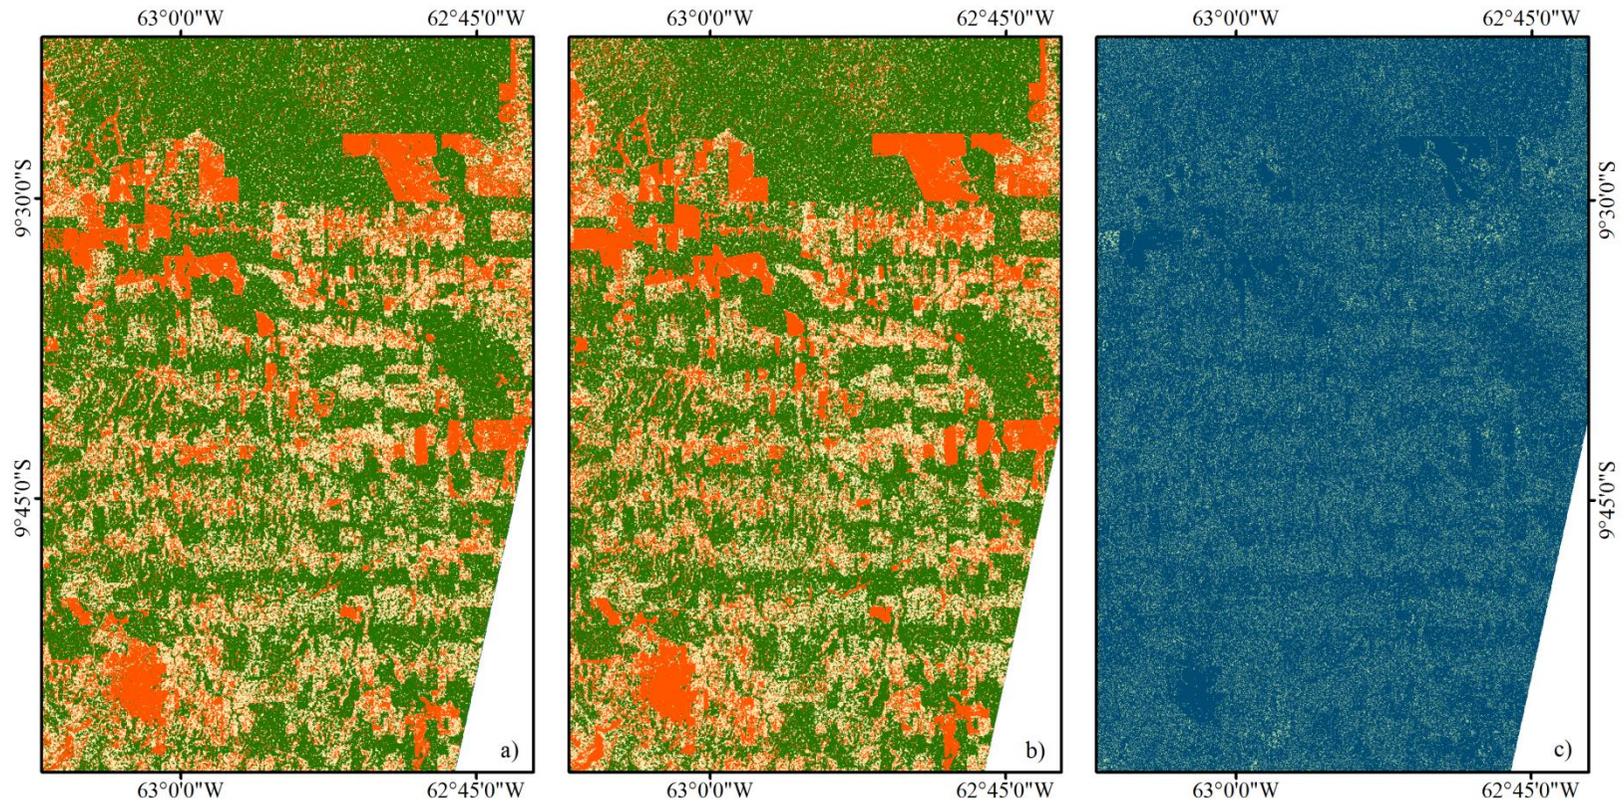
Legenda: *: diferença significativa; ns: diferença não significativa.

Fonte: Produção do autor.

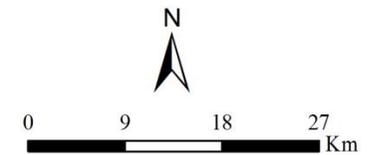
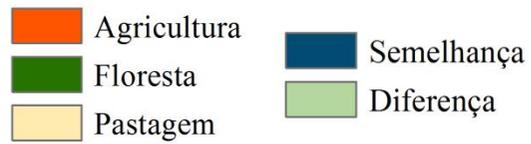
Como pode ser observado pelo teste de McNemar, apresentado na Tabela 4.9, o cenário 7 foi diferente significativamente de todos os demais para os dois classificadores (SVM e RF). Nesse caso, analisando-se os resultados encontrados de Kappa e acurácia global, pode-se considerar o cenário 7 realizado com o classificador RF como o cenário que obteve o melhor desempenho para a Fase 1 do mapeamento, considerando-se os dados analisados.

A Figura 4.23 representa o mapa de diferenças obtido com os mapeamentos realizados com os classificadores SVM e RF para a Fase 1, onde observa-se que houve muitas áreas semelhantes, correspondente a 86,3% entre esses classificadores na área de estudo, enquanto as áreas diferentes corresponderam a 13,7%.

Figura 4.23 - Resultado do mapeamento da Fase 1: a) Mapeamento SVM; b) Mapeamento RF e c) Diferença entre SVM e RF.



Legenda

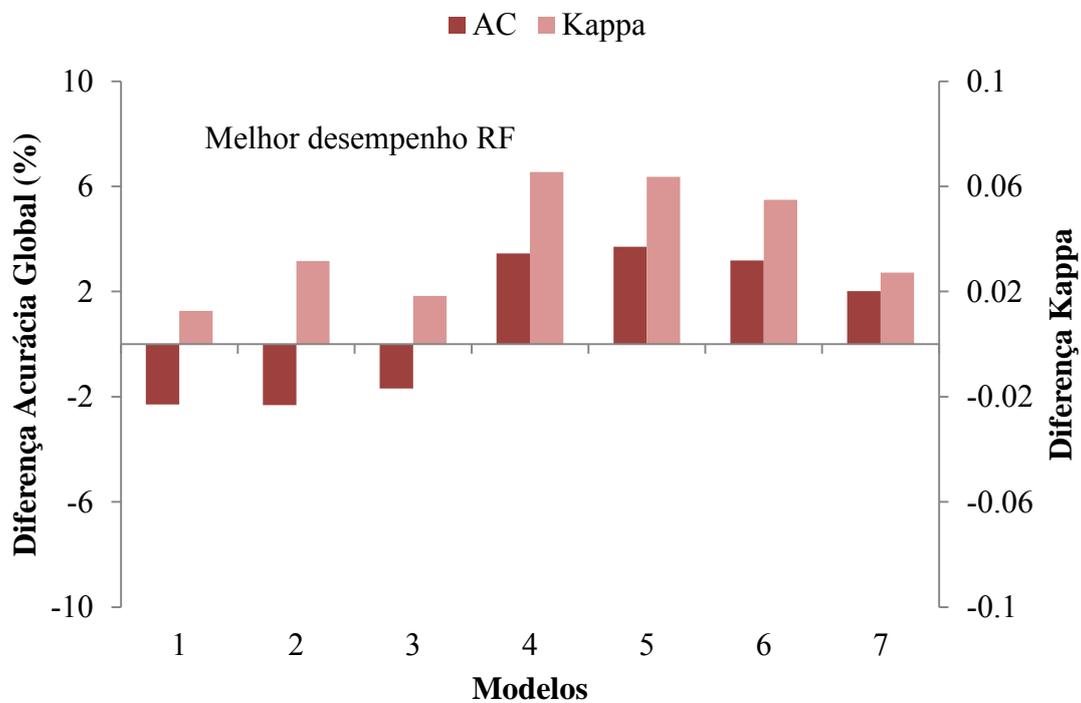


Fonte: Produção do autor.

4.5.2 Comparação SVM-RF Fase 2

Já para a Fase 2 da etapa do mapeamento (Figura 4.24), a diferença existente entre os classificadores foi maior. Em relação aos cenários individuais (1, 2 e 3), nota-se que a maior diferença foi observada na acurácia global do cenário 2, de 2,31%. . No entanto, quando se analisa os valores de Kappa desses cenários, nota-se que houve um aumento com o classificador RF, sendo de 3,16% para o cenário 2 e de 1,26% e 1,83% para os cenários 1 e 3, respectivamente.

Figura 4.24 - Diferença entre as classificações RF e SVM na Fase 2.



Fonte: Produção do autor.

Quando se analisa os cenários agrupados, percebe-se que a utilização do RF também apresentou melhoras para a Fase 2, com um aumento crescente na diferença da acurácia global, atingindo 3,7% para o cenário 5. Além disso, os valores de Kappa apresentaram aumentos ainda maiores, de 2,0% para o cenário 7 até 6,5% para o cenário 4, que apresentou a maior diferença.

A partir do teste de McNemar (Tabela 4.10) observa-se que, a um nível de confiança de 95%, os classificadores SVM e RF foram diferentes significativamente em praticamente todos os cenários exceto o cenário 2, que utilizava apenas os atributos provenientes da decomposição polarimétrica.

Quando se analisa as classificações realizadas pelo SVM nota-se que ocorre diferença significativa entre os cenários quando estes estão agrupados (4, 5, 6 e 7). Para os cenários individuais (1, 2 e 3) não ocorre diferença significativa entre eles. Já com o classificador RF, apenas para os cenários 1 e 3 que não houve diferença significativa.

Tabela 4.10 - Teste de McNemar comparando os classificadores SVM e RF para cada cenário realizado na Fase 2, com um nível de confiança de 95% (Teste McNemar $\chi^2 > 3,84$).

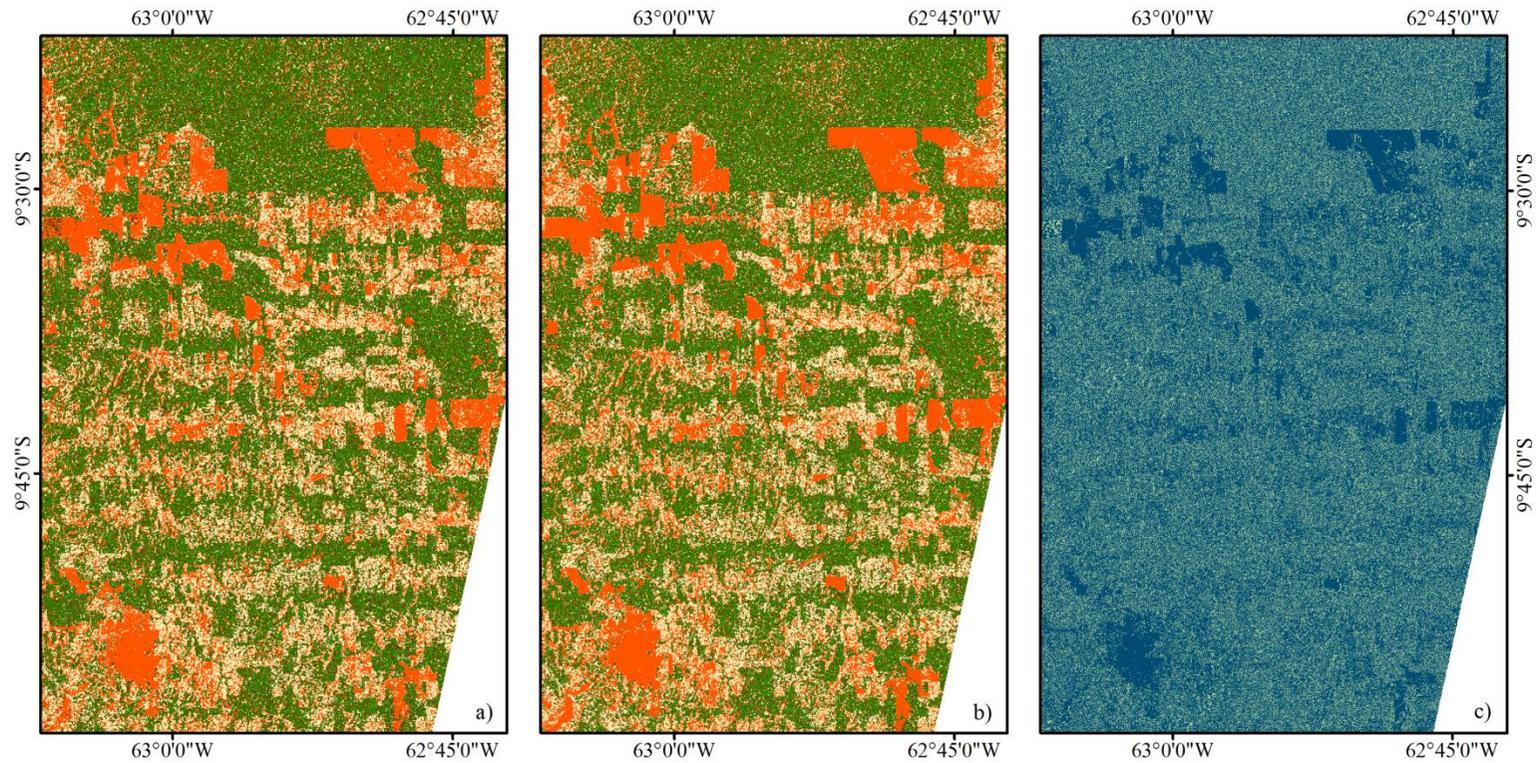
Comparações	Cenários	1	2	3	4	5	6	7
SVM x RF		4,83*	0,05 ^{ns}	4,09*	9,87*	16,64*	11,01*	5,35*
SVM x SVM	1		2,87 ^{ns}	0,78 ^{ns}	76,25*	145,10*	115,18*	359,52*
	2			0,42 ^{ns}	50,75*	176,96*	65,04*	334,70*
	3				37,84*	144,23*	84,23*	328,05*
	4					32,58*	6,65*	203,16*
	5						8,97*	88,30*
	6							151,17*
RF x RF	1		11,55*	1,06 ^{ns}	140,88*	241,66*	199,94*	463,50*
	2			5,97*	63,07*	199,16*	92,81*	341,46*
	3				94,04*	248,52*	165,88*	420,41*
	4					36,94*	6,76*	199,59*
	5						12,40*	58,18*
	6							148,68*

Legenda: *: diferença significativa; ns: diferença não significativa.
 Fonte: Produção do autor.

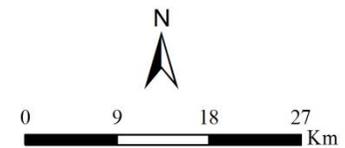
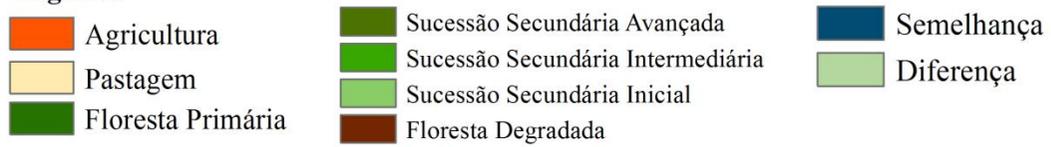
Assim como foi observado para a Fase 1, o cenário 7 com o classificador RF apresentou os melhores resultados de Kappa e acurácia global, sendo considerado estatisticamente diferente dos demais pelo teste de McNemar. Nesse caso, o cenário RF-7 pode ser considerado o melhor para os dados utilizados neste estudo.

A Figura 4.25 mostra o mapa de diferenças entre os mapeamentos realizados com os classificadores SVM e RF para a Fase 2. Nesse caso, as áreas semelhantes representaram 72,1% da área de estudo, ocorrendo principalmente nas áreas agrícolas, enquanto a diferença foi de 27,9%.

Figura 4.25 - Resultado do mapeamento da Fase 2: a) Mapeamento SVM; b) Mapeamento RF e c) Diferença entre SVM e RF.



Legenda



Fonte: Produção do autor.

4.6 Comparação dos mapeamentos com os sensores óptico e radar

4.6.1 Comparação óptico e radar Fase 1.

O mapeamento do uso e cobertura da terra a partir das imagens ópticas do Sentinel-2B, utilizando o classificador RF para a separação de três classes temáticas, possibilitou realizar uma análise sobre as principais diferenças e limitações existentes entre este sensor e o Sentinel-1A. Para esta comparação, foram utilizados os resultados obtidos com o cenário RF-7 que obteve o melhor desempenho classificatório entre os cenários analisados para os dados de radar.

É possível observar na Tabela 4.11 que o desempenho do sensor óptico (Sentinel-2B) apresentou resultados melhores para o mapeamento da Fase 1, com uma melhora de 4,3% na acurácia global e de 7,0% para o Kappa em relação ao mapeamento com radar, sendo classificado como “Excelente” de acordo com Landis e Koch (1977).

Tabela 4.11 - Acurácia Global (AC), Kappa e Intervalos de Credibilidade a 5% de significância para as classificações com os sensores óptico (Sentinel-2B) e radar (Sentinel-1A, cenário RF-7) na Fase 1.

Sensores	AC (%)	Kappa	Intervalos de Credibilidade		Conceito
			AC (%)	Kappa	
Óptico	90,0	0,85	$89,4 \leq AC \leq 90,6$	$0,83 \leq K \leq 0,86$	Excelente
Radar	85,7	0,78	$84,9 \leq AC \leq 86,6$	$0,77 \leq K \leq 0,79$	Muito bom

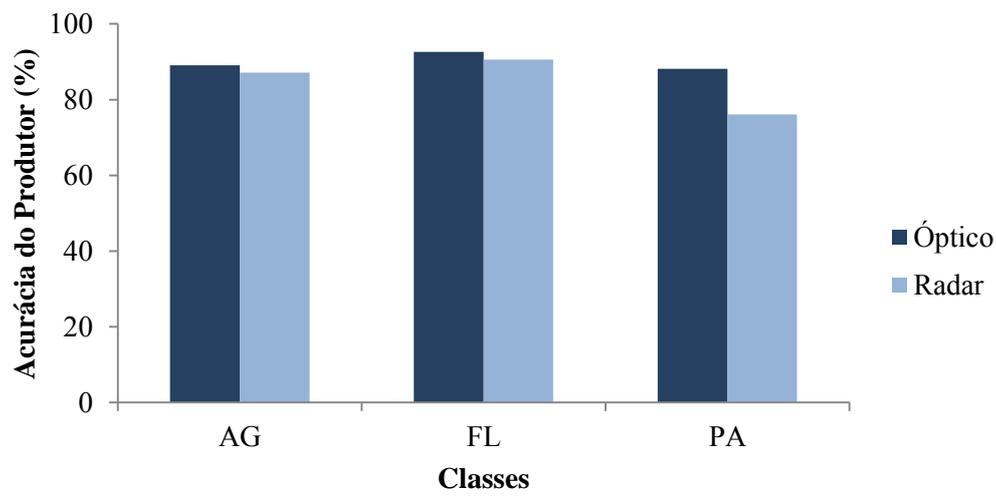
Fonte: Produção do autor.

Quando se analisa a acurácia do produtor para ambos os sensores (Figura 4.26), percebe que na Fase 1 do mapeamento os resultados obtidos com o sensor óptico e radar foram semelhantes, com uma maior diferença na acurácia da classe Pastagem, que apresentou um aumento de 12,1% quando mapeada com o sensor óptico. Enquanto para as classes AG e FP essa diferença foi de 1,91% e 1,99%, respectivamente.

Em relação à acurácia do usuário (Figura 4.27), nota-se o mesmo comportamento, com uma maior diferenciação da classe Pastagem pelo sensor óptico, de 10,4%, enquanto as outras classes não apresentaram grandes diferenças, 4,4% para a classe AG e 1,2% para a classe FL, respectivamente.

A Figura 4.28 mostra o mapeamento realizado com ambos os sensores e a diferença observada entre eles na área de estudo. Nesse caso, nota-se que as áreas de semelhança ocorrem principalmente com a classe Floresta e as diferenças com as classes AG e PA. Do total de pixels classificados, 53,4% foram semelhantes e 46,6% foram classificados como diferentes.

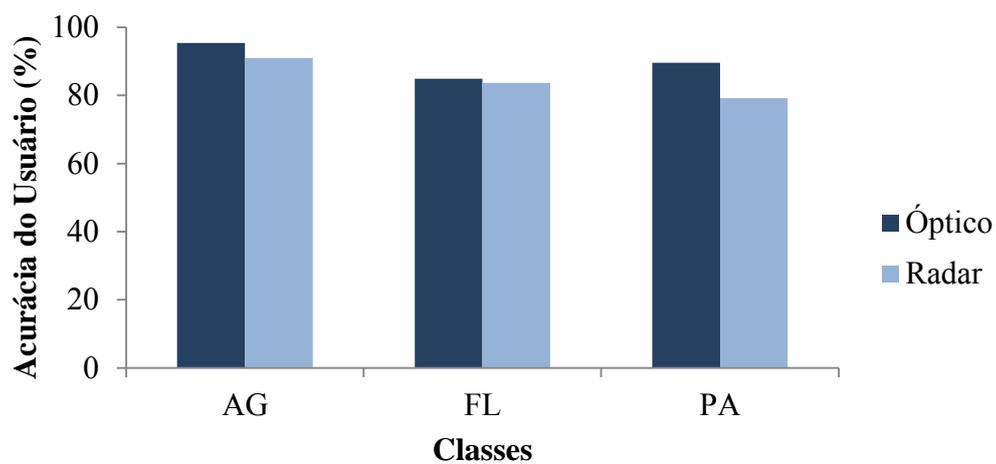
Figura 4.26 - Acurácia do Produtor (%) para os mapeamentos realizados com os sensores óptico e radar (RF-7) na Fase 1.



Legenda: AG: Agricultura; FL: Floresta; PA: Pastagem.

Fonte: Produção do autor.

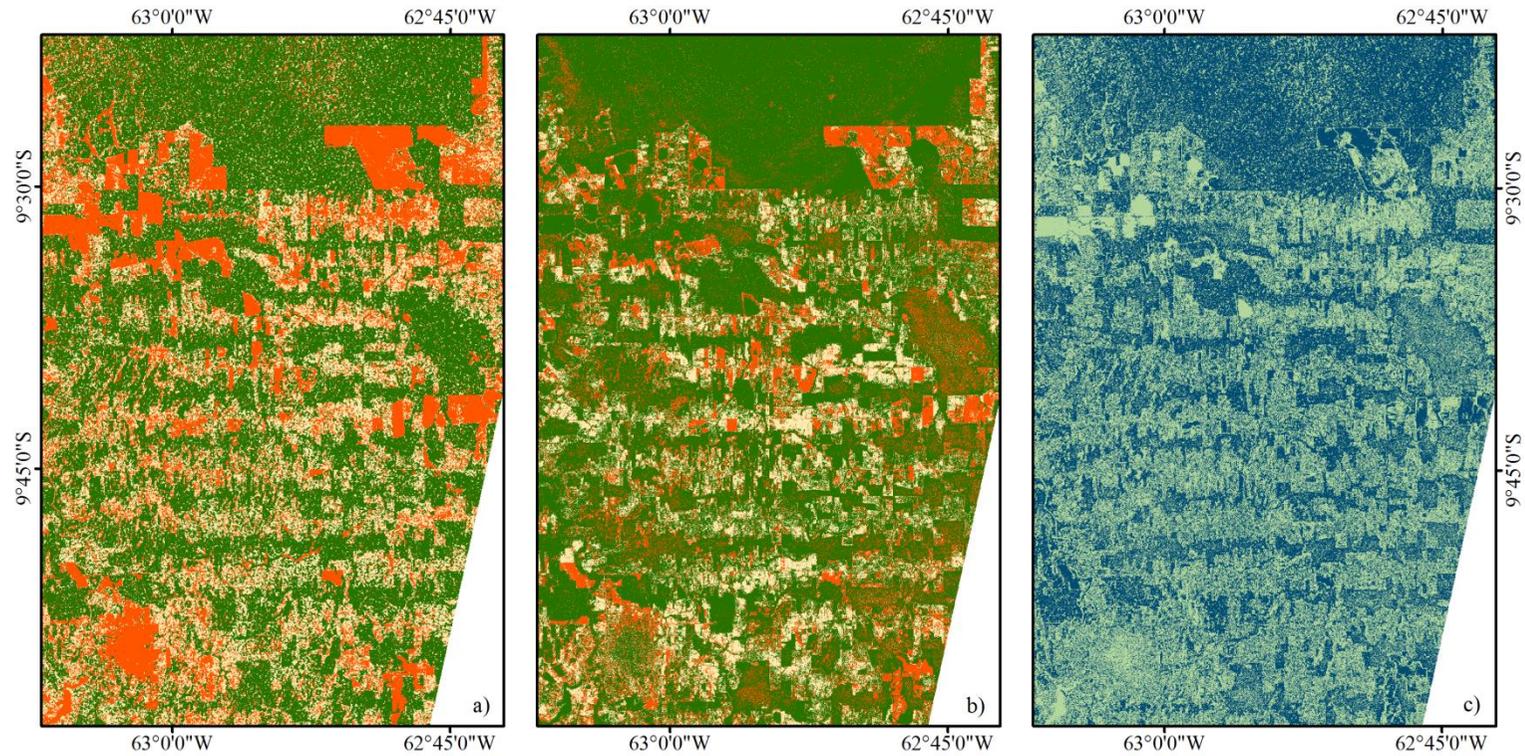
Figura 4.27 - Acurácia do Usuário (%) para os mapeamentos realizados com os sensores óptico e radar (RF-7) na Fase 1.



Legenda: AG: Agricultura; FL: Floresta; PA: Pastagem.

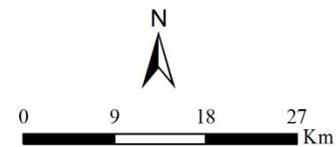
Fonte: Produção do autor.

Figura 4.28 - Comparação dos mapeamentos realizados na Fase 1: a) Mapeamento Sentinel-1A cenário RF-7, b) Imagem Sentinel-2B; c) Mapa de diferenças.



Legenda

- | | |
|---|--|
|  Agricultura |  Semelhança |
|  Floresta |  Diferença |
|  Pastagem | |



Fonte: Produção do autor.

4.6.2 Comparação óptico e radar Fase 2.

Para a Fase 2 (Tabela 4.12), observa-se que a diferença entre os sensores foi mais expressiva, sendo de 13,8% para a acurácia global e de 19% para o Kappa do óptico em relação ao radar. Além disso, o mapeamento com o sensor óptico recebeu o conceito de “Excelente” segundo a classificação de Landis e Koch (1977).

Tabela 4.12 - Acurácia Global (AC), Kappa e Intervalos de Credibilidade a 5% de significância para as classificações com os sensores óptico (Sentintel-2B) e radar (Sentinel-1A, cenário RF-7) na Fase 1.

Sensores	AC (%)	Kappa	Intervalos de Credibilidade		Conceito
			AC (%)	Kappa	
Óptico	85,4	0,80	$84,2 \leq AC \leq 86,5$	$0,78 \leq K \leq 0,81$	Excelente
Radar	71,6	0,61	$69,8 \leq AC \leq 73,5$	$0,59 \leq K \leq 0,64$	Muito bom

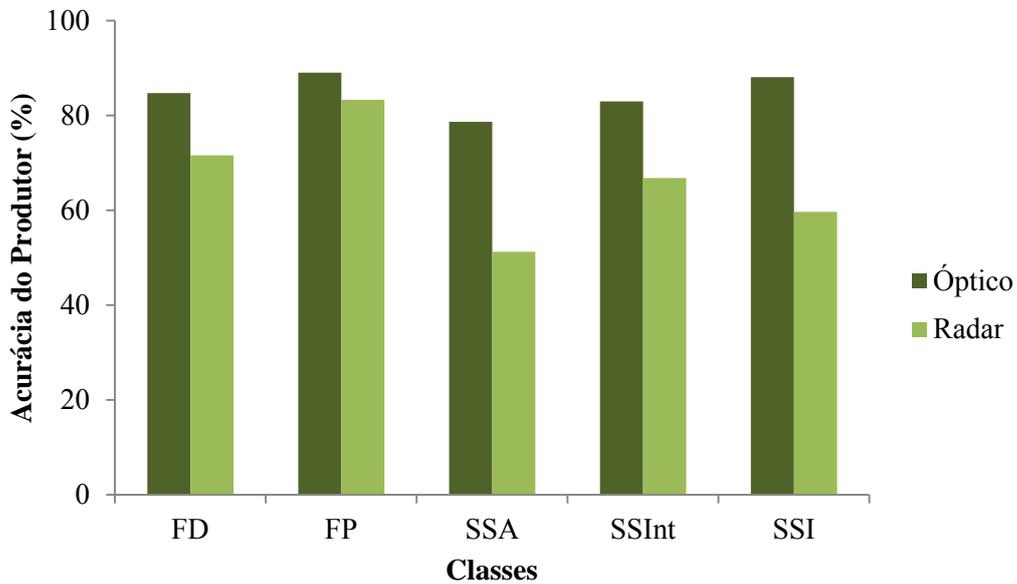
Fonte: Produção do autor.

Quando se analisa a acurácia do produtor obtida para as classes florestais (Figura 4.29), se observa também que o sensor óptico obteve melhores resultados, com a menor diferença observada para a classe FP, igual a 5,7% e a maior com a classe SSI, igual a 28,4%, com uma diferença média entre todas as classes florestais de 18,2%.

Já em relação à acurácia do usuário (Figura 4.30), nota-se que a classe SSI apresentou a menor diferença igual a 5,18%, enquanto para a classe FP, essa diferença foi igual a 15,7%. A acurácia do usuário apresentou uma diferença média entre as classes florestais de 11,8%.

Através da Figura 4.31 é possível observar que houve diferença na classificação em praticamente toda a área de estudo, correspondente a 71,5% do total de pixels, com a semelhança presente em algumas áreas agrícolas (28,5%).

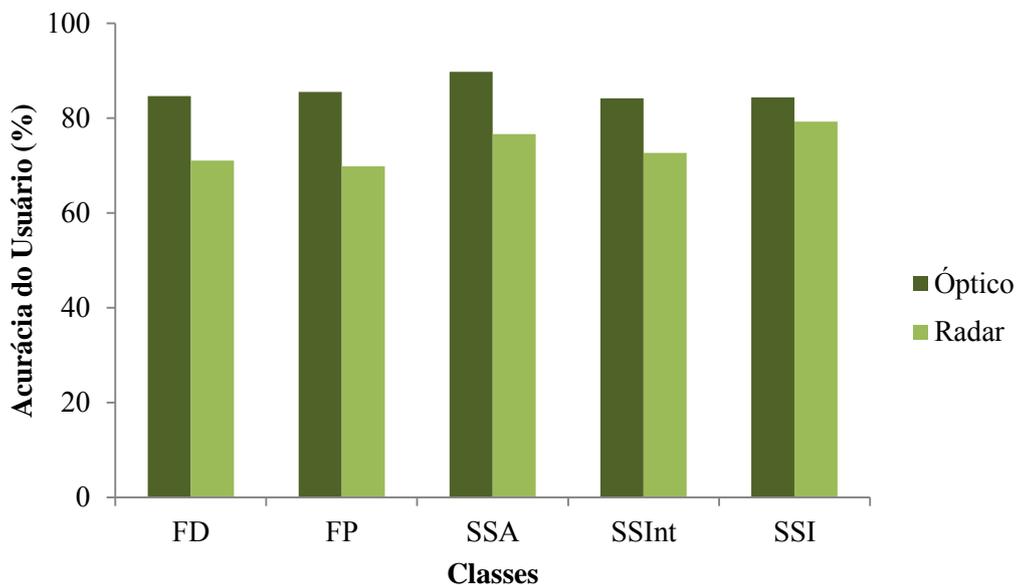
Figura 4.29 - Acurácia do Produtor (%) para os mapeamentos realizados com os sensores óptico e radar na Fase 2.



Legenda: FD: Floresta Degradada; FP: Floresta Primária; SSA: Sucessão Secundária Avançada; SSInt: Sucessão Secundária Intermediária; SSI: Sucessão Secundária Inicial.

Fonte: Produção do autor.

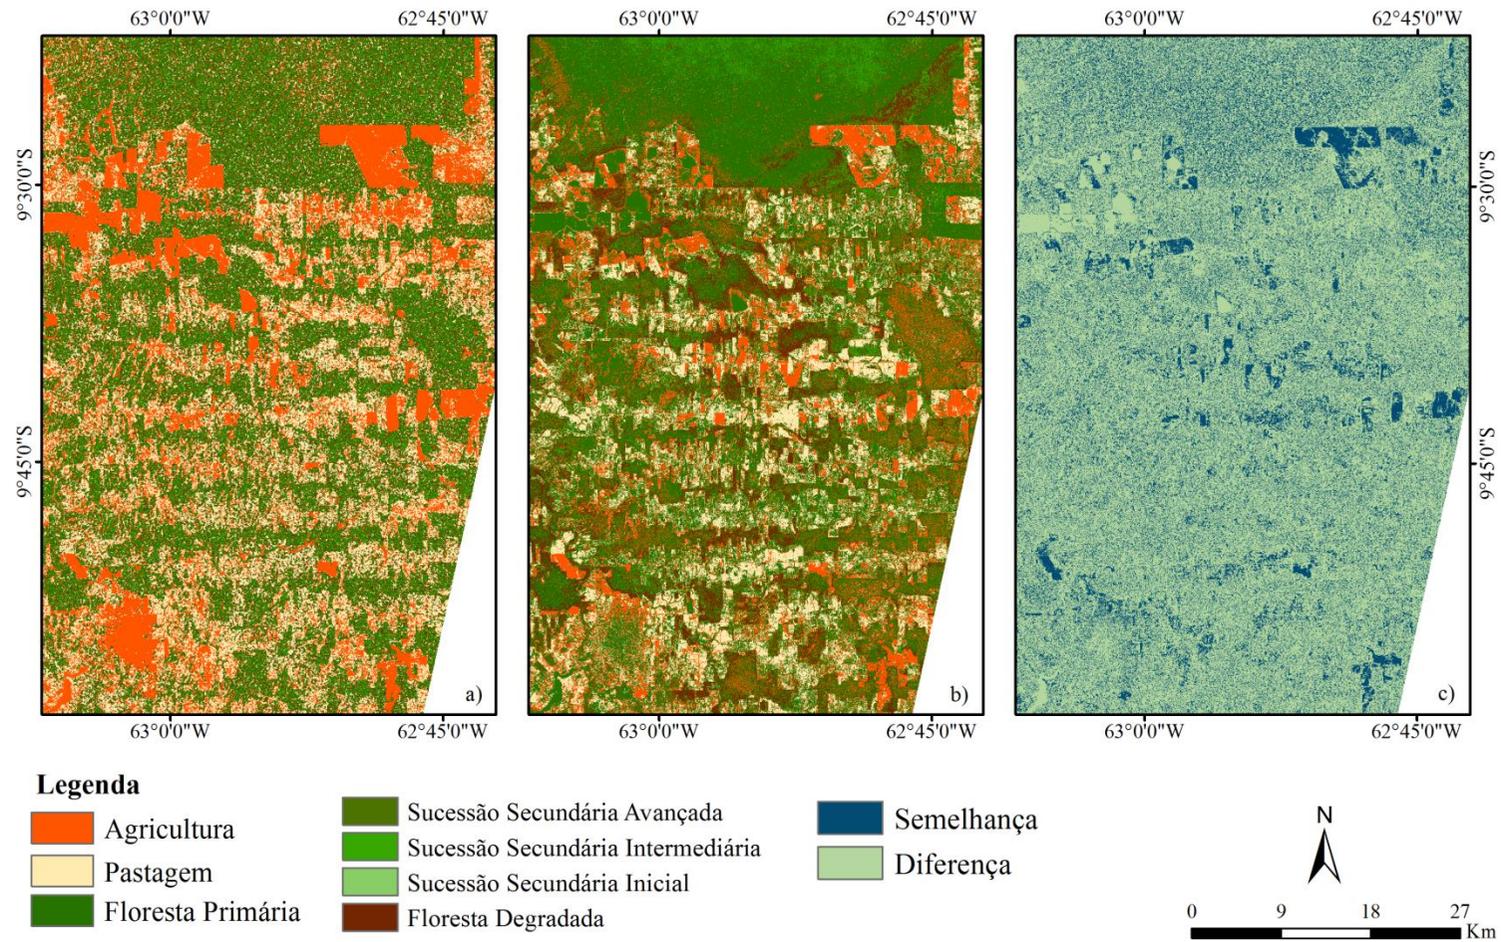
Figura 4.30 - Acurácia do Usuário (%) para os mapeamentos realizados com os sensores óptico e radar na Fase 2.



Legenda: FD: Floresta Degradada; FP: Floresta Primária; SSA: Sucessão Secundária Avançada; SSInt: Sucessão Secundária Intermediária; SSI: Sucessão Secundária Inicial.

Fonte: Produção do autor.

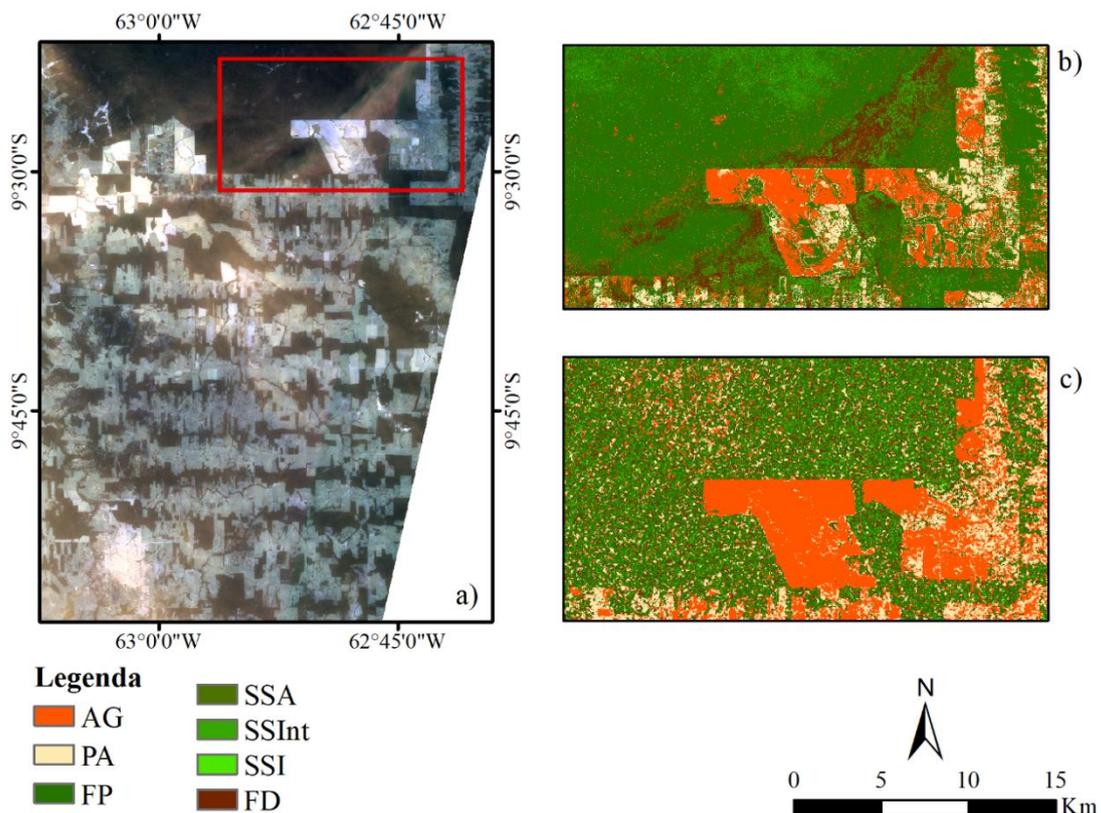
Figura 4.31 - Comparação dos mapeamentos realizados na Fase 2: a) Mapeamento Sentinel-1A, b) Imagem Sentinel-2B; c) Mapa de diferenças.



Fonte: Produção do autor.

Além disso, a Figura 4.32 destaca o efeito da presença da fumaça na classificação do sensor óptico em relação ao radar. Nela é possível observar que a parte influenciada pela fumaça na Floresta Nacional do Jamari (área em destaque) foi classificada como Floresta Degradada e Sucessão Secundária Inicial (Figura 4.32 b). Já na classificação realizada pelo radar (Figura 4.32 **Erro! Fonte de referência não encontrada.** c), apesar de apresentar um maior efeito da classificação pixel-a-pixel, a influência da fumaça não é observada.

Figura 4.32 - Efeito da fumaça sobre o mapeamento: a) Imagem Sentinel-2B na composição verdadeira (RGB: 4, 3, 2); b) Mapeamento com o sensor óptico Sentinel-2B; c) Mapeamento com o radar Sentinel-1A (RF-7).



Fonte: Produção do autor.

5. DISCUSSÃO DOS RESULTADOS

5.1 Classificações com atributos de radar

De acordo com os resultados obtidos para as classificações tanto com os classificadores SVM e RF, nota-se que o cenário 7 foi o que apresentou os melhores resultados, utilizando todos os atributos provenientes dos dados de radar: coeficientes de retroespalhamento (σ_{VH}^0 , σ_{VV}^0 e $\sigma_{VH}^0/\sigma_{VV}^0$), decomposição polarimétrica (H e α) e as coerências interferométricas (γ_{VH} e γ_{VV}).

Ao se observar a importância dos atributos utilizados para as classificações do RF, percebe-se que os atributos provenientes da coerência interferométrica apresentaram a maior importância, sendo o atributo γ_{VV} para a Fase 1 do mapeamento (Figura 4.17) e o γ_{VH} para a Fase 2 (Figura 4.20). O que também pode ser observado na Figura 4.8, que mostra a distribuição dos gráficos *boxplot* para as classes temáticas analisadas onde nota-se que o atributo γ_{VH} apresenta uma melhor distinção entre as classes florestais.

A coerência interferométrica é inversamente correlacionada com o grau de aleatoriedade dos dispersores entre as duas imagens SAR. Nesse caso, áreas de vegetação apresentam baixa correlação, devido aos padrões de vento que podem alterar a orientação das folhas e ramos, enquanto áreas de superfícies rochosas e alvos artificiais apresentam alta correlação (SRIVASTAVA; PATEL, 2006).

Além disso, a coerência interferométrica é influenciada por fatores como a desconexão temporal e volumétrica, gerando valores menores para áreas de florestas maduras e densas e valores maiores para áreas com pequenas vegetações e solos descobertos (WEGMÜLLER; WERNER, 1995; TANASE et al., 2010). Isso também foi observado na Figura 4.9, ao se analisar os valores médios de γ_{VH} e γ_{VV} para a classe agricultura em relação às classes florestais (FD, FP, SSA, SSInt e SSI), onde nota-se que a classe agricultura apresentou maiores valores médios de coerência interferométrica, principalmente com a polarização VV.

Em áreas florestais, a coerência interferométrica será dependente de fatores como incremento de biomassa da vegetação, constante dielétrica, efeitos do terreno e frequência do radar (BORGEAUD; WEGMÜLLER, 1996). De acordo com Wegmüller e Werner (1997), o incremento de biomassa provoca um decréscimo na

coerência interferométrica, o que também foi observado por Gama et al. (2010, 2016) e Pôssa et al. (2018), corroborando com os resultados apresentados na Figura 4.9, onde nota-se que a Floresta Primária foi a classe que apresentou os menores valores médios de coerência interferométrica (γ_{VH} e γ_{VV}), sendo esta, a classe caracterizada por apresentar a maior quantidade de biomassa.

Gaboardi (2003) avaliando o potencial da utilização das imagens de coerência interferométrica da banda C, utilizando dados dos satélites ERS-1/2 para a separação floresta/não floresta e para a classificação da cobertura do solo em áreas de florestas tropicais, observou que a imagem coerência apresentou os melhores resultados nas classificações realizadas. Já Khalil e Saad-ul-Haque (2018), analisaram o potencial de utilização do retroespalhamento médio, da diferença de retroespalhamento e da coerência interferométrica do Sentinel-1A para o mapeamento de diferentes classes de uso e cobertura da terra (solo árido, área urbana, vegetação e água), e observaram que a combinação desses atributos apresentou resultados efetivos para a discriminação das classes analisadas.

Wegmüller et al. (2015), constataram que os valores de coerência da banda C (Sentinel-1) são menores sobre a vegetação após 12 dias de passagem do sensor, se comparado com uma diferença temporal de 1 ou 3 dias, no caso do sensor ERS. Com a diferença das imagens de 12 dias, os autores observaram uma limitação para separação de vegetação baixa, como agricultura e pastagem em relação à vegetação alta (florestas), como também foi observado no caso deste estudo, mostrando que o tempo para aquisição das imagens irá influenciar nos resultados observados.

Em relação aos atributos da decomposição polarimétrica (H e α) nota-se que estes apresentaram grande importância para a Fase 2 do mapeamento, principalmente para a discriminação das classes SSInt e SSI. Apesar de apresentarem distribuição semelhante a outras classes (Figura 4.6), nota-se que as classes SSA e SSI se destacaram das demais, enquanto as classes FP, FD, SSInt e PA apresentaram semelhança na distribuição.

De acordo com Delgado-Aguiar et al. (2017) essa semelhança entre as classes florestais e a pastagem pode acontecer devido à presença de árvores ou arbustos nas áreas de pastagem, que irão aumentar a rugosidade superficial, gerando um sinal SAR

semelhante às áreas de cobertura florestal. Isto foi observado na área de estudo, durante o trabalho de campo, onde observou-se a presença de palmeiras e arbustos nas áreas de pastagem.

Resultados semelhantes foram observados também por Whyte et al. (2018), utilizando dados Sentinel-1A nas polarizações VV e VH, onde os atributos H/α não foram capazes de distinguir as classes Floresta, Arbusto Denso, Pantanal com vegetação elevada e Pastagem. Além disso, o autor concluiu que esses atributos foram efetivos para classificar áreas de baixa vegetação e agricultura, enquanto o comprimento de onda (banda C) pode ser considerado muito curto para discriminar classes de vegetação densas, o que pode explicar a maior confusão e dificuldade de discriminação encontrada na segunda fase do mapeamento. No entanto, para este trabalho estes atributos não apresentaram grande importância para a discriminação das classes agricultura e pastagem (Figura 4.18).

Altos valores de entropia (H) indicam que diferentes mecanismos de espalhamento contribuíram para o retorno do sinal (LEE; POTTIER, 2009; CLOUDE, 2009). A entropia pode ser influenciada por fatores como a heterogeneidade da floresta e teor de umidade, que irão provocar um aumento na dispersão de volume (DICKINSON et al., 2013). Varghese et al. (2016), observou um aumento dos valores da entropia em algumas áreas florestais, relacionado às mudanças de rugosidade da superfície e efeitos da propagação do dossel. Além disso, de acordo com o autor, a cobertura florestal corresponde a valores de entropia variando entre 0,6 e 0,7, relacionada aos dispersores esféricos oblatos (florestas de folhas largas), o que também foi observado nesse trabalho, com os valores de entropia médios para as classes florestais variando entre 0,65 e 0,75 (Figura 4.6).

Já o ângulo alfa (α) pode ser influenciado pela topografia (VAN ZYL, 1993) e pelo ângulo de incidência (SVENDSEN et al., 1998), o que pode modificar o mecanismo de espalhamento dominante exibido pela copa. Áreas que apresentam baixos valores de ângulo alfa são caracterizadas por apresentar espalhamento superficial, enquanto valores de α acima de 45° indicam áreas onde ocorrem múltiplos espalhamentos (CLOUDE; POTTIER, 1996; VARGHESE et al., 2016). Dentre as classes sucessionais analisadas, a

classe SSI apresentou os menores valores de α , o que pode estar relacionado a densidade da vegetação e dos elementos dispersores.

Além disso, verificou-se que a classe agricultura apresentou altos valores de α (Figura 4.6), o que de acordo com Brisco et al. (1991), pode estar relacionado aos diferentes tipos de preparo do solo na região, onde áreas gradeadas apresentam uma maior rugosidade superficial, o que produz um retroespalhamento com maior intensidade e aumenta os valores do ângulo alfa. A realização do trabalho de campo em setembro de 2017, deixou isso evidente, pois nessa época do ano, é realizado o preparo do solo para o plantio.

O comprimento de onda do sensor irá afetar diretamente a interação com os alvos presentes na superfície terrestre (ULABY et al., 1984). A banda C tem como característica ser muito atenuada por copas densas, apresentando valores de espalhamento semelhantes para tipos de vegetação que possuem pequenas diferenças estruturais (GOSSELIN et al., 2013), como é o caso das classes florestais desse estudo, o que dificulta a detecção de diferenças nos mecanismos de retroespalhamento para os atributos da decomposição polarimétrica de Cloude-Pottier (H e α) (FURTADO et al., 2016).

Para sensores que utilizam a banda C, o coeficiente de retroespalhamento será influenciado, principalmente, pelo retroespalhamento do dossel (LANG; KASISCHKE, 2008). De acordo com Bourgeau-Chavez et al. (2005), a interação da radiação eletromagnética com vegetações herbáceas em solo seco, resulta em um espalhamento volumétrico menor, bem como no aumento do espalhamento superficial, provocando um baixo retorno do sinal. Isso é observado na Figura 4.5, analisando os valores médios dos coeficientes de retroespalhamento (σ_{VH}^0 e σ_{VV}^0) para a classe agricultura.

Foi observado também, que houve uma dificuldade para discriminação das classes de sucessão secundária para todos os cenários analisados, apresentando altos valores de erros de omissão e comissão. Nesse caso, deve-se ressaltar que a dificuldade na discriminação entre as classes florestais na Amazônia foi observada em vários estudos (CARREIRAS et al., 2017; CARREIRAS et al., 2006; LUCAS et al., 2000). De acordo com Lucas et al. (2002), as florestas secundárias podem ser confundidas com classes

como agricultura e pastagem, quando estão nas fases iniciais, e, quando estão em estágios mais avançados, podem ser mais semelhantes às florestas maduras.

5.2 Classificadores SVM e RF

Através da comparação das classificações realizadas com os classificadores SVM e RF foi possível observar um melhor desempenho do SVM para os valores de acurácia global e Kappa para os cenários individuais na Fase 1 do mapeamento (Figura 4.22), enquanto o RF apresentou o melhor desempenho para os cenários agregados. Já para a Fase 2 do mapeamento (Figura 4.24), o classificador RF apresentou o melhor desempenho do índice Kappa para todos os cenários e de acurácia global para os cenários agregados, enquanto o SVM apresentou um pequeno incremento em relação à acurácia global dos cenários individuais.

Estatisticamente, pelo teste de McNemar, observou-se que apenas o cenário 3, que utilizou a coerência interferométrica, não apresentou diferença significativa na Fase 1 do mapeamento, enquanto na Fase 2 não houve diferença para o cenário 2, da decomposição polarimétrica.

Em relação à Fase 1 do mapeamento, a Figura 4.23 mostra que os classificadores apresentaram uma grande semelhança na discriminação das classes na área de estudo, o que pode estar relacionado ao baixo número de classes analisadas. No entanto, ainda ocorreram pixels classificados como diferentes, distribuídos em toda a área de estudo, o que pode estar diretamente relacionado ao método de classificação pixel-a-pixel.

Já quando se analisa a Fase 2 do mapeamento (Figura 4.25), nota-se que a diferença entre os mapeamentos de cada classificador ficou ainda maior, com as áreas semelhantes correspondentes à algumas áreas agrícolas presentes na região. Esse fato está relacionado à estratificação da classe Floresta nas classes FD, FP, SSA, SSInt e SSI, tornando a discriminação entre essas classes mais complexa para os classificadores, e também ao método de classificação pixel-a-pixel. Além disso, como já foi mencionado a discriminação das classes florestais na Amazônia apresenta grande dificuldade.

De modo geral, quando se analisa o cenário 7, que apresentou os melhores resultados de acurácia global e Kappa para os mapeamentos das Fases 1 e 2, nota-se que o classificador RF apresentou um destaque em relação ao SVM, com uma melhora na acurácia global de 4,1% para a Fase 1 e de 2,0% para a Fase 2, enquanto para o Kappa, esse aumento foi de 6,4% e 2,7%, respectivamente. Além disso, os classificadores foram diferentes significativamente para esse cenário.

O *Random Forest* apresenta características que o tornam benéfico para a classificação como: ser menos afetado por *outliers* e por dados com ruído; ser não paramétrico e suportar dados com variadas distribuições estatísticas, como os dados SAR; ter uma grande capacidade em processar dados de grande dimensão e com muitas fontes de dados; e apresentar uma maior precisão na classificação quando comparado à outros classificadores como SVM e Máxima Verossimilhança (FURTADO et al., 2016; MAHDIANPARI et al., 2017; NITZE et al., 2012; RODRIGUEZ-GALIANO et al., 2012). Além de possibilitar a análise das variáveis de importância pelo índice de Gini, o que permite uma visão geral do comportamento das variáveis durante o processo classificatório.

Whyte et al. (2018) analisaram a acurácia da classificação com imagens do Sentinel-1 e 2, utilizando os classificadores RF e SVM e observaram uma melhor performance do RF em relação ao SVM em todos os casos analisados, corroborando com o que foi observado nesse estudo para a maioria dos cenários analisados. Os autores explicaram que essa diferença nas acurácias dos classificadores ocorre devido a uma subamostragem dos hiperplanos de separação do SVM. Além disso, os autores observaram que o algoritmo SVM demandou um maior tempo de processamento do que o RF, o que pode afetar estudos em grandes áreas e de longo prazo, o que também foi observado durante a execução deste trabalho.

Vários estudos demonstram a superioridade dos algoritmos de aprendizagem de máquina em relação às abordagens convencionais, como a classificação Maxver (SOTHE et al., 2017). Attarchi e Gloagum (2014) utilizaram os algoritmos SVM, RF, redes neurais e Maxver com imagens Landsat-7 e SAR para discriminar os estágios de sucessão florestal e observaram que os classificadores SVM e RF obtiveram os melhores resultados.

Buscando classificar diferentes classes de uso e cobertura da terra, Adam et al. (2014), utilizaram os classificadores SVM e RF para o mapeamento do uso e cobertura da terra com imagens RapidEye e observaram que apesar de apresentarem desempenhos semelhantes, o RF apresentou maiores valores de acurácia. Sothe et al. (2017) avaliaram metodologias para a classificação sucessional na Mata Atlântica com imagens Landsat e RapidEye, utilizando os algoritmos SVM, RF e Maxver e concluíram que os classificadores tiveram desempenho diferenciado de acordo com o grupo de variáveis utilizadas, sendo o melhor resultado obtido com o RF.

Waske e Braun (2009) utilizaram o algoritmo *Random Forest* em dados multitemporais SAR, banda C em diferentes locais e anos, e observaram que esse classificador apresentou melhor desempenho que os demais utilizados, alcançando uma acurácia de aproximadamente 84% em áreas rurais. Balzter et al. (2015), empregaram o algoritmo *Random Forest* para realizar o mapeamento do uso e cobertura da terra com dados do satélite Sentinel-1A SAR, utilizando as bandas de intensidade, textura, e quatro bandas derivadas do SRTM, e obtiveram uma acurácia de classificação de 68,4%. Já Carreiras et al. (2017), utilizaram o RF no mapeamento dos principais tipos de cobertura e determinação da idade das florestas secundárias na Amazônia combinando dados ópticos e de radares, e obtiveram uma precisão global de 95-96%.

5.3 Comparação óptico e radar

Através da comparação entre os mapeamentos realizados pelos sensores óptico (Sentinel-2B) e radar (Sentinel-1A, cenário RF-7), percebeu-se que para a Fase 1 do mapeamento (Tabela 4.11) houve pouca diferença entre os valores de acurácia global (4,33%) e a classe pastagem obteve a maior diferença entre as acurácias do produtor e usuário (Figura 4.26 e Figura 4.27, respectivamente), apresentando maiores valores para o sensor óptico. Na Figura 4.28 que apresenta o mapa de diferença obtido entre o mapeamento dos dois sensores, é possível observar que para esta fase a classe Floresta apresentou maior semelhança entre os mapeamentos, enquanto as classes AG e PA apresentaram as maiores diferenças, o que evidencia essa diferença nas acurácias do produtor e usuário para a classe PA entre os sensores.

Já para a Fase 2 do mapeamento, a diferença observada entre os dois sensores foi maior de 13,7% na acurácia global, mostrando uma superioridade do sensor óptico em mapear as classes florestais, o que também foi observado analisando-se as acurácias do produtor e usuário (Figura 4.29 e Figura 4.30, respectivamente). Além disso, quando se analisa a Figura 4.30, percebe-se que ocorreram diferenças nas classificações em praticamente toda a área de estudo, com a semelhança presente em algumas áreas agrícolas.

Essa maior diferença observada no mapeamento da área de estudo para a Fase 2, pode estar relacionada à estratificação da classe Floresta em cinco classes, o que dificulta o mapeamento em comparação com a Fase 1, à abordagem pixel-a-pixel utilizada nesse trabalho e ao comprimento de onda (Banda C) utilizado para o mapeamento com o radar, que apresenta uma saturação do retroespalhamento em altos níveis de biomassa, o que resulta em uma estabilidade do sinal da banda C sobre as florestas (WAGNER et al., 2012).

No entanto, apesar do sensor óptico ter apresentado os melhores resultados, deve-se destacar que existem limitações da sua utilização, como a presença de nuvens. Alguns autores demonstraram a dificuldade em se obter imagens livre de nuvens em sensores ópticos (ASNER, 2001; JU; ROY, 2008; HANSEN; LOVELAND, 2012; LEINENKUGEL et al., 2014). De acordo com Evans e Costa (2013) a utilização de imagens ópticas é menor em regiões tropicais, subtropicais e ao Norte, onde existe cobertura permanente de nuvens. Além disso, a sombra das nuvens impede uma detecção clara dos pixels presentes na imagem (ASNER, 2001).

Asner (2001) analisou a obtenção de imagens Landsat na Amazônia brasileira (Anexo A) e observou que a probabilidade de se obter uma cena Landsat com 30% ou menos de cobertura de nuvem na estação chuvosa entre dezembro a maio é mínima. Já durante a estação seca, entre junho e setembro, o autor observou que essa probabilidade aumenta, mas principalmente na parte sul da bacia Amazônica, enquanto o norte é caracterizado por apresentar cobertura de nuvens durante todo o ano, o que também foi observado por Hilker et al. (2012) e Martins et al. (2018). Destaca-se ainda, que o tempo de revisita do Landsat é de 16 dias, enquanto os sensores do Sentinel-2 (A e B) apresentam uma resolução temporal de 10 dias separadamente e de 5 dias quando combinados, o que pode influenciar na obtenção de imagens livre de nuvens na Amazônia.

Além da cobertura de nuvens, o sensor óptico é influenciado pela variabilidade dos constituintes atmosféricos presentes na bacia Amazônica (MARTINS et al., 2018), como o alto teor de aerossóis na estação seca (ZELAZOWSKI et al., 2011) e a concentração de vapor de água e ozônio (GAO et al., 2009), como foi observado na Figura 4.32. As queimadas são práticas frequentes na região Amazônica para o desmatamento direto, por serem rápidas e de baixo custo (ARAGÃO et al., 2007, 2008). As emissões provocadas por essa prática alteram drasticamente as concentrações de aerossóis presentes na atmosfera, principalmente durante a estação das queimadas (REDDINGTON et al., 2015). Martins et al. (2018) observaram que no período em que a cobertura de nuvens é menor, ocorre um aumento na carga de aerossóis rapidamente, impondo desafios para o sensoriamento remoto por sensores ópticos no período seco (sem nuvens) (ASNER; ALENCAR, 2010), devido à grande concentração de fumaça na atmosfera.

Para Vanden Borre et al. (2011), o mapeamento realizado com dados de radar era mais caro do que as pesquisas de campo, necessitando determinar um número ótimo de imagens a serem analisadas. Esse fato vem mudando nos últimos anos, principalmente com a disponibilidade gratuita dos dados da missão Sentinel, permitindo a utilização dos dados de radar de forma mais ampla (ESA, 2018).

Apesar de os dados de radar utilizados neste estudo também apresentarem limitações, tais como o comprimento de onda do Sentinel-1A (banda C), que é caracterizado por apresentar pouca penetração nas áreas florestais, que influencia na discriminação destas classes durante o mapeamento, e por apresentar apenas duas polarizações (VH e VV), limitando a extração de informações presente nas imagens, muitos autores reconheceram e avaliaram o potencial dos dados Sentinel-1 para o mapeamento do uso e cobertura e da terra (THIEL et al., 2009; BALTZER et al., 2015).

6. CONCLUSÕES E RECOMENDAÇÕES

A avaliação do potencial dos dados de radar Sentinel-1A foi realizada através da extração dos atributos dos coeficientes de retroespalhamento, da decomposição polarimétrica e da coerência interferométrica. As suas contribuições para a discriminação das classes temáticas foram observadas através da análise exploratória e da construção de cenários de classificações. A partir da análise exploratória dos dados foi possível verificar que alguns atributos foram capazes de discriminar melhor algumas classes do que outros.

A análise de cenários com os classificadores SVM e RF mostrou que a utilização destes atributos individualmente não alcançou resultados altos de acurácia global. No entanto, quando agrupados, os valores de acurácia global e índice Kappa apresentaram um grande incremento, principalmente, quando todos os atributos foram utilizados conjuntamente, no cenário 7. A partir da análise da variável de importância obtida pelo RF verificou-se que a coerência interferométrica apresentou grande importância para a discriminação das classes temáticas, tanto para a Fase 1 quanto para a Fase 2 do mapeamento.

Ao se analisar o desempenho dos classificadores SVM e RF, verificou-se um melhor desempenho do RF, principalmente com os cenários agrupados. Pela análise dos mapas das diferenças entre os dois classificadores, observou-se que a maior diferença ocorreu durante a Fase 2 do mapeamento, relacionada com a estratificação da classe Floresta e a um maior número de classes durante a análise.

De modo geral, notou-se que os dados de radar utilizados foram capazes de discriminar as classes de uso e cobertura da terra analisadas, apresentando valores de acurácia global e Kappa considerados satisfatórios. Além disso, os dados do Sentinel-1A apresentam como limitações o comprimento de onda do sensor (banda C), e a presença de apenas duas polarizações (VH, VV), limitando a extração de informações da imagem e dificultando o mapeamento, principalmente para a Fase 2, que buscava discriminar as classes Florestais.

Além disso, a comparação do melhor cenário obtido com os dados de radar com o mapeamento realizado com o sensor óptico possibilitou analisar as diferenças e limitações presentes nas duas abordagens. Apesar de o sensor óptico apresentar um

melhor desempenho, deve-se ressaltar a sua limitação para realizar o mapeamento em regiões com grande cobertura de nuvens, o que ocorre na maior parte do ano na região Amazônica. Observou-se ainda, a influência direta dos constituintes atmosféricos, como é o caso da pluma de fumaça, provenientes de queimadas e incêndios, durante o mapeamento com o sensor óptico.

Para estudos futuros sugere-se o incremento de análises temporais utilizando dados do Sentinel-1, que poderão proporcionar um maior entendimento da dinâmica existente na região, auxiliando no mapeamento principalmente, das classes florestais. Recomenda-se também, a avaliação da abordagem da classificação orientada ao objeto para a realização do mapeamento, o que poderá melhorar o efeito *Speckle* observado na abordagem pixel-a-pixel. Indica-se ainda a integração de dados de radar que apresentam um comprimento de onda maior que a banda C e a análise de outras polarizações, que poderão proporcionar uma maior diferenciação das classes florestais, além de testes com outros classificadores de dados SAR como o Wishart.

REFERÊNCIAS BIBLIOGRÁFICAS

- ADAM, E. et al. Land-use/cover classification in a heterogeneous coastal landscape using RapidEye imagery: evaluating the performance of Random Forest and Support Vector Machines classifiers. **International Journal of Remote Sensing**, v.35, n.10, p. 3440-3458, 2014.
- AGRESTI, A. 1996. **An introduction to categorical data analysis**. New York; Wiley, 1996. 312 p.
- AGUIAR, A.P. et al. Spatial statistical analysis of land-use determinants in the Brazilian Amazonia: exploring intra-regional heterogeneity. **Ecological Modelling**, v. 209, p.169-188, 2007.
- ALENCAR, A. et al. **Desmatamento na Amazônia: indo além da emergência crônica**. Manaus: Instituto de Pesquisa Ambiental da Amazônia (IPAM), 2004. 89p.
- ALMEIDA, C. A. et al. Estimativa de área de vegetação secundária na Amazônia Legal Brasileira. **Acta Amazônica**, v. 40, n.2, p.289-302, 2010.
- ALMEIDA, S. A. S. et al. Mapeamento de cobertura da terra utilizando técnicas de processamento de imagens na região de Ariquemes (RO-BR), com ênfase às florestas secundárias. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 1996, Salvador. **Anais...** São José dos Campos: INPE, 1996. p. 479-487.
- ANDERSEN, L. E.; REIS, E. J. **Deforestation, development, and government policy in the brazilian Amazon: an econometric analysis**. Rio de Janeiro: IPEA, 1997. 24p. (Texto para Discussão, 513).
- ARAGÃO, L. E. O. C. et al. Spatial patterns and fire response of recent Amazonian droughts. **Geophysical Research Letters**, v.34, n.7, p. L07701, 2007.
- ARAGÃO, L. E. O. C. et al. Interactions between rainfall, deforestation and fires during recent years in the Brazilian Amazonia. **Philosophical Transactions of the Royal Society B: Biological Sciences**, v.363, n.1498, p.1779–1785, 2008.
- ASKNE, J.; SMITH, G. Forest INSAR decorrelation and classification properties. In: ESA WORKSHOP ON APPLICATIONS OF ERS SAR INTERFEROMETRY, 1996. **Proceedings...** 1996.
- ASNER, G. P. Cloud cover in Landsat observations of the Brazilian Amazon. **International Journal of Remote Sensing**, v. 22, n. 18, p. 3855-3862, 2001.

- ASNER, G. P.; ALENCAR, A. Drought impacts on the Amazon forest: the remote sensing perspective. **New Phytologist**, v.187, n.3, p.569–578, 2010.
- ATTARCHI, S.; GLOAGUEN, R. Classifying complex mountainous forests with L-band SAR and Landsat data integration: a comparison among different machine learning methods in the Hyrcanian Forest. **Remote Sensing**, v.6, p. 3624-3647, 2014.
- BALTZER, H. et al. Mapping CORINE land cover from Sentinel-1A SAR and SRTM digital elevation model data using random forests. **Remote Sensing**, v.7, n.11, p.14876-14898, 2015.
- BANQUÉ, X. et al. **Polarimetry-based land cover classification with Sentinel-1 data**. In: ESA POLINSAR; BIOMASS SCIENCE WORKSHOP, 1., 2015. **Proceeding...** Disponível em: http://tre-altamira.com/uploads/2015_09_Banque_et_al_POLinSAR_Dualpol.pdf. Acesso em: 17 fev. 2018.
- BARONA, E. et al. The role of pasture and soybean in deforestation of the Brazilian Amazon. **Environmental Research Letters**, v.5, p.1-9, 2010.
- BAUDRY, G.; MACHARIS, C.; VALLÉE, T. Range-based multi-actor multi-criteria analysis: a combined method of multi-actor multi-criteria analysis and Monte Carlo simulation to support participatory decision making under uncertainty. **European Journal of Operational Research**, v.264, p. 257-269, 2018.
- BECKER, B.K. Geopolítica da Amazônia. **Estudos Avançados**, v. 19 n. 53, 2005.
- BELGIU, M.; DRAGUT, L. Random forest in remote sensing: a review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.114, p. 24-31, 2016.
- BICKEL U.; DROS J. M. **The impacts of soybean cultivation on brazilian ecosystems** 2003. Disponível em: <http://assets.panda.org/downloads/impactsofsoybean.pdf>. Acesso em: 15 jan. 2018.
- BOERMER, W. M. et al. Polarimetry in radar remote sensing: basic and applied concepts. In: LEWIS, A. J.; HENDERSON, F. M.; RYERSON, R. A. (Eds.). **Principles and applications of imaging radar: manual of remote sensing**. 3.ed. New York: John Wiley & Sons, 1998. v.2, cap.5, p.271-356.
- BORGEAUD, M.; WEGMUELLER, U. **On the use of ERS SAR interferometry for retrieval of geo and biophysical information**. In: ESA WORKSHOP ON APPLICATIONS OF ERS SAR INTERFEROMETRY, 1996, Zurich. **Proceedings...** 1996.

BOURGEAU-CHAVEZ, L. L. et al. Remote sensing of regional inundation patterns and hydroperiod in the greater Everglades using synthetic aperture radar. **Wetlands**, v.25, p. 176-191, 2005.

BRADLEY, J. V. **Distribution-free statistical tests**. Englewood Cliffs, New Jersey: Prentice-Hall, 1968. 388 p.

BREIMAN, L. **Manual on setting up, using, and understanding random forests** v3.1. Berkeley: University of California at Berkeley, 2002. 33p.

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

BRISCO, B. et al. Tillage effects on the radar backscattering coefficient of grain stubble fields. **International Journal of Remote Sensing**, v. 12, n. 11, p. 2283-2298, 1991.

BRITES, R. S. et al. Comparação de desempenho entre três índices de exatidão aplicados a classificações de imagens orbitais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 1996, Salvador, BA. **Anais...** São José dos Campo: INPE, 1996. p. 813-822.

CABLE, J.W. et al. Multi-temporal polarimetric RADARSAT-2 for land cover monitoring in Northeastern Ontario, Canada. **Remote Sensing**. v. 6, p. 2372-2392, 2014.

CALLE, M. L.; URREA, V. Letter to the editor: stability of random forest importance measures. **Briefings in Bioinformatics**, v.12, n. 1, p. 86-89, 2011.

CAMERON, W. L.; LEUNG, L. K. Feature motivated polarization scattering matrix decomposition. In: IEEE INTERNATIONAL RADAR CONFERENCE, 1990, Arlington, VA. **Proceedings...** Arlington, VA, 1990. p. 549-557.

CARREIRAS, J. M. B. et al. Assessing the extent of agriculture/pasture and secondary succession forest in the Brazilian Legal Amazon using SPOT VEGETATION data. **Remote Sensing of Environment**. v. 101, p.283–298, 2006.

CARREIRAS, J. M. B. et al. Mapping major land cover types and retrieving the age of secondary forests in the Brazilian Amazon by combining single-date optical and radar remote sensing data. **Remote Sensing of Environment**, v. 194, p. 16-32, 2017.

CARVALHO, G. O. et al. Frontier expansion in the Amazon: balancing development and sustainability. **Environment: Science and Policy for Sustainable Development**, v.44, p.32–42, 2002.

CARVALHO, R. L. S. et al. Comportamento das séries temporais de temperatura do ar, umidade e precipitação pluviométrica no município de Ariquemes (Rondônia-Brasil). **Revista Brasileira de Climatologia**, v.18, n. 12, p. 123-142, 2016.

CARVALHO, T. S. et al. Desmatamento e a contribuição econômica da floresta na Amazônia. **Estudos Econômicos**, v.46, n.2, p. 499-531, 2016.

CASTRO, E. Dinâmica socioeconômica e desmatamento na Amazônia. **Novos Cadernos NAEA**, v. 8, n. 2, p. 5-39, 2005.

CHANG, C. C.; LIN, C. J. **LIBSVM**: a library for support vector machines. 2001. Disponível em: <https://www.csie.ntu.edu.tw/~cjlin/papers/libsvm.pdf>. Acesso em: 20 abr. 2018.

CHAVEZ JÚNIOR, P. S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, v. 24, p. 459-479, 1988.

CHOMITZ, K. M.; THOMAS, T. S. Geographic patterns of land use and land intensity in the Brazilian Amazon. **Policy Research Working Papers**, p. 50, 2001. Disponível em: <http://documents.worldbank.org/curated/pt/102381468769744789/pdf/multi0page.pdf>. Acesso em: 26 jan. 2018.

CLOUDE, S. R. The dual polarization entropy/alpha decomposition: a PALSAR case study. In: POLINSAR WORKSHOP, 2007, Frascati, Italy. **Abstracts...** Frascati: ESA, 2007. p.19.

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

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

COLDITZ, R. R. An evaluation of different training sample allocation schemes for discrete and continuous land cover classification using decision tree-based algorithms. **Remote Sensing**, v.7, n. 8, p. 9655-9681, 2015.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Lewis Publishers, 1999. 136 p.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. [S.l.]: CRC Press, 2009.

CONGEDO, L. **Semi-automatic classification plugin documentation: release 5.3.2.1.** 272p. 2017. Disponível em: <https://media.readthedocs.org/pdf/semiautomaticclassificationmanual-v3/latest/semiautomaticclassificationmanual-v3.pdf>. Acesso em: 02 maio 2018.

CORDEIRO, M. S. S. Marechais e burareiros: projetos de colonização na Amazônia ocidental. **Textos & Debates**, n. 25, p. 63-78, 2015.

CORTES, C; VAPNIK, V. Support-vector networks. **Machine Learning**, v.20, n. 3, p. 273-297, 1995.

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

CRÓSTA, A. P. **Processamento digital de imagens de sensoriamento remoto.** Campinas: [s.n.], 1992. 170 p.

DELGADO-AGUILAR, M. J. et al. Potential of TerraSAR-X and Sentinel 1 imagery to map deforested areas and derive degradation status in complex rain forests of Ecuador. **International Forestry Review**, v. 19, n.1, p. 102-118, 2017.

DICKINSON, C. et al. Classification of forest composition using polarimetric decomposition in multiple landscapes. **Remote Sensing of Environment**, v.131, p. 206-214, 2013.

DINIZ, J. M. F. S. et al. Avaliação do Sentinel-2, NDVI e MLME para mapeamento do uso e cobertura da terra. **Anuário do Instituto de Geociências**, 2018. Submetido.

DOBSON, M. C. et al. Estimation of forest biophysical characteristics in northern Michigan with SIR-C/X-SAR. **IEEE Transactions on Geoscience and Remote Sensing**, v. 33, n. 4, p. 877–895, 1995.

DONG, Y. et al. Toward edge sharpening: a SAR speckle filtering algorithm. **IEEE Transactions on Geoscience and Remote Sensing**, v. 39, n. 4, p. 851-863, 2001.

DU, P. et al. Random forest and rotation forest for fully polarized SAR image classification using polarimetric and spatial features. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 105, p. 38-53, 2015.

DURO, D. C. et al. A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. **Remote Sensing of Environment**, v.118, p.259–272, 2012.

ENGELBRECHT, J. et al. A simple normalized difference approach to burnt area mapping using multi-polarisation C-band SAR. **Remote Sensing**, v.9, p.764, 2017.

ENVIRONMENTAL SYSTEMS RESEARCH INSTITUTE. 2010. **ArcGIS desktop**: release 10.1. Redlands, CA: ESRI, 2010.

EUROPEAN SPACE AGENCY. **Sentinel-1 SAR technical guide**. 2018a. Disponível em: <https://sentinels.copernicus.eu/web/sentinel/technical-guides/sentinel-1-sar>. Acesso em: 15 jan. 2018.

EUROPEAN SPACE AGENCY. **Sentinel-2 MSI introduction**. 2018b. Disponível em: <https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi>. Acesso em: 15 fev. 2018.

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

EXELIS. HARRIS GEOSPATIAL SOLUTIONS. **Support vector machine background**. 2015. Disponível em: <<https://www.harrisgeospatial.com/docs/BackgroundSVM.html>>. Acesso em: 15 jan. 2018.

FEARNSIDE, P. M. Deforestation in Brazilian Amazonia: history, rates and consequences. **Conservation Biology**, v.19 n. 3, p. 680-688, 2005.

FERREIRA, A. M. M.; SALATI, E. Forças de transformação do ecossistema amazônico. **Estudos Avançados**, v.19, n.54, p. 25-44, 2005.

FOODY, G, M. Thematic map comparison: evaluating the statistical significance of differences in classification accuracy. **Photogrammetric Engineering & Remote Sensing**, v.70, n. 5, p. 627–633, 2004.

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

FU, B. et al. Comparison of object-based and pixel-based Random Forest algorithm for wetland vegetation mapping using high spatial resolution GF-1 and SAR data. **Ecological Indicators**, v.73, p.105-117, 2017

FURTADO L. F. A. et al. Dual-season and full-polarimetric C band SAR assessment for vegetation mapping in the Amazon várzea wetlands. **Remote Sensing of Environment**, v. 174, p. 212-222, 2016.

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

GAMA, F. F. et al. Continuous monitoring of biophysical Eucalyptus sp. parameters using interferometric synthetic aperture radar data in P and X bands. **Journal of Applied Remote Sensing**, v. 10, n. 2, p. 026002, 2016.

GAMA, F. F. et al. Eucalyptus biomass and volume estimation using interferometric and polarimetric SAR data. **Remote Sensing**, v.2, p.939-956, 2010.

GAMA, F. F. et al. Técnicas de interferometria radar na detecção de deformação superficial utilizando dados orbitais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2013. p. 8405-8412.

GAO, B.C. et al. Atmospheric correction algorithms for hyperspectral remote sensing data of land and ocean. **Remote Sensing of Environment**, v.113, n.S17–S24, 2009.

GENS, R.; GENDEREN, V. Review article: SAR interferometry - issues, techniques, applications. **International Journal of Remote Sensing**, 17, n. 10, p. 1803-1835, 1996.

GIBSON, L. et al. Primary forests are irreplaceable for sustaining tropical biodiversity. **Nature**, v.478, n.7369, p.378-381, 2011.

GISLASON, P. O. et al. Random forests for land cover classification. **Pattern Recognition Letters**, v.27, n.4, p.294-300, 2006.

GÓMEZ, C. et al. Optical remotely sensed time series data for land cover classification: a review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.116, p.55-72, 2016.

GOSSELIN, G. et al. Polarimetric Radarsat-2 wetland classification using the Touzi decomposition: case of the Lac Saint-Pierre Ramsar wetland. **Canadian Journal of Remote Sensing**, v.39, n.6, p.491-506, 2013.

GRAHAM, L. C. Synthetic interferometer radar for topographic mapping. **Proceedings of the IEEE**, v.62, n.6, p.763-768, 1974.

GREEN, K. et al. Using remote sensing to detect and monitor land cover and land-use change. **Photogrammetric Engineering and Remote Sensing**, v.60, n.3, p.331-337, 1994.

GUERRA, J. B. et al. Discriminating deforestation increment areas in the Amazon rainforest with L band SAR R99B data. **Acta Amazonica**, v.40, n.3, p.557-566, 2010.

HANSEN, M. C.; DEFRIES, R. S. Detecting long-term global forest change using continuous fields of tree-cover maps from 8-km Advanced Very High Resolution Radiometer (AVHRR) data for the years 1982-99. **Ecosystems**, v. 7, p. 695-716, 2004.

HANSEN, M.C.; LOVELAND, T.R. A review of large area monitoring of land cover dominated by small-scale, complex agriculture as well as frequent cloud change using Landsat data. **Remote Sensing of Environment**, v.122, p.66–74, 2012.

HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001. 900 p.

HELLMANN, M. P. **SAR polarimetry tutorial**. Rennes: University of Rennes, 2001. 109 p.

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

HILKER, T. et al. Remote sensing of tropical ecosystems: atmospheric correction and cloud masking matter. **Remote Sensing of Environment**, v.127, p.370–384, 2012.

HUANG, C., et al. An assessment of support vector machines for land cover classification. **International Journal of Remote Sensing**, v. 23, n. 4, p. 725–749, 2002.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Manuais técnicos em geociências: manual técnico de uso da terra**. 3ed. Rio de Janeiro: IBGE. 2013. 171 p.

INSTITUTO NACIONAL DE METEOROLOGIA (INMET). **Consulta dados da estação automática: Ariquemes (RO)**. Disponível em: http://www.inmet.gov.br/sonabra/pg_dspDadosCodigo_sim.php?Qt0MA==. Acesso em: 25 jan. 2018.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Projeto Terra Class: levantamento de informações de uso e cobertura da terra na Amazônia**. 2010. Disponível em: http://www.inpe.br/cra/projetos_pesquisas/terraclass2010.php. Acesso em: 20 jan. 2018.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **PRODES estima 7989km² de desmatamento por corte raso na Amazônia em 2016**. 2016. Disponível em: http://www.inpe.br/noticias/noticia.php?Cod_Noticia=4344. Acesso em: 23 jan. 2018.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **INPE estima 6.624 km² de desmatamento por corte raso na Amazônia em 2017**. 2017. Disponível em: <http://www.obt.inpe.br/OBT/noticias/INPE-estima-desmatamento-por-corte-raso-na-Amazonia-em-2017>. Acesso em: 23 jan. 2018.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Projeto PRODES: Monitoramento da Floresta Amazônica Brasileira por Satélite**. Disponível em: <http://www.obt.inpe.br/prodes/index.php>. Acesso em: 20 jan. 2018.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **INPE estima 7900 km² de desmatamento por corte raso na Amazônia em 2018**. 2018. Disponível em: <http://www.obt.inpe.br/OBT/noticias/inpe-estima-7-900-km2-de-desmatamento-por-corte-raso-na-amazonia-em-2018>. Acesso em: 02 jan. 2019.

JARAMILLO, C. F.; KELLY, T. **Deforestation and property rights in Latin America**. Washington, D.C.: Inter-American Development Bank, 1999. Disponível em: <<http://idbdocs.iadb.org/wsdocs/getdocument.aspx?docnum=359769>>. Acesso em: 14 jan. 2018.

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

JI, K.; WU, Y. Scattering mechanism extraction by a modified cloude-pottier decomposition for dual polarization SAR. **Remote Sensing**, v. 7, p. 7447-7470, 2015.

JOSHI, N. et al. A review of the application of optical and radar remote sensing data fusion to land use mapping and monitoring. **Remote Sensing**, v. 8, n. 70, p. 23, 2016.

JU, J.; ROY, D.P. The availability of cloud-free Landsat ETM+ data over the conterminous United States and globally. **Remote Sensing of Environment**, v. 112, p.1196-1211, 2008.

KAIMOWITZ, D. et al. **Hamburger connection files Amazon destruction**. Bangon, Indonesia: Center for International Forest Research, 2004.

KASISCHKE, E. S. et al. The use of imaging radars for ecological applications: a review. **Remote Sensing os Environment**, v.57, n. 2, p. 141-156, 1997.

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

KHALIL, R. Z.; SAAD-UL-HAQUE. InSAR coherence-based land cover classification of Okara, Pakistan. **The Egyptian Journal of Remote Sensing and Space Science**, v.21, p. S23-S28, 2018.

- KIM, J. S. et al. Coherence adaptative speckle filter for ultrasound image. In: INTERNATIONAL SYMPOSIUM ON SIGNAL PROCESSING AND ITS APPLICATIONS, 9., 2007, Sharjah, **Proceedings...** Sharjah, 2007. p.1-4.
- KROGAGER, E. A new decomposition of the radar target scattering matrix. **Electronic Letter**, v. 26, n. 18, 1525-1527, 1990.
- LAMBIN, E. F. Modelling and monitoring land-cover change processes in tropical regions. **Progress in Physical Geography**, v.21, n.3, p.375-393, 1997.
- LAMBIN, E. F.; GEIST, H. J. **Land use and land cover change-local processes and global impacts**. [S.l.]: Springer Publication, 2006. 222 p.
- LANDAU, D. P.; BINDER, K. **A guide to Monte-Carlo simulations in statistical physics**. 3.ed. Cambridge: Cambridge University Press, 2009. 500 p.
- LANDIS, J. R.; KOCH, G. G. The measurements of observer agreement for categorical data. **Biometrics**,v. 33, p. 159-174, 1977.
- LANG, M. W.; KASISCHKE, E. S. Using C-band synthetic aperture radar data to monitor forested wetland hydrology in Maryland's coastal plain, USA. **Remote Sensing of Environment**, v.112, p. 3898-3907, 2008.
- LANG, M.W.; KASISCHKE, E. S. Using C-band synthetic aperture radar data to monitor forested wetland hydrology in Maryland's coastal plain, USA. **Remote Sensing of Environment**, v.112, p.3898-3907, 2008.
- LANTZANAKIS, G. et al. Comparison of physically and image based atmospheric correction methods for Sentinel-2 satellite imagery. In: KARACOSTAS T.; BAIS A.; NASTOS P. (Eds.). **Perspectives on atmospheric sciences**. [S.l.]: Springer Atmospheric Sciences, 2017. p.255-261.
- LAURANCE, W.F. et al. Agricultural expansion and its impacts on tropical nature. **Trends in Ecology & Evolution**, v.29, p.107-116, 2014.
- LAWRENCE, R. L. et al. Mapping invasive plants using hyperspectral imagery and Breiman Cutler classifications (random Forest). **Remote Sensing of Environment**, v.100, p. 356-362, 2006.
- LE TOAN, T. et al. On the relationships between radar measurements and forest structure and biomass. In: INTERNATIONAL SYMPOSIUM ON RETRIEVAL OF BIO AND GEOPHYSICAL PARAMETERS FROM SAR DATA FOR LAND APPLICATIONS, 2002, Sheffield. **Proceedings...** 2002. p.3-12.

- LE TOAN, T. et al. Relating forest biomass to SAR data. **IEEE Transactions on Geoscience and Remote Sensing**, v.30, n.2, p.403-411, 1992.
- LECKIE, D. G.; RANSON, K. J. Forestry applications using imaging radar. In: HENDERSON, F. M.; LEWIS, A. J. (Eds.). **Principles and applications of imaging radar**. New York: John Wiley, 1998. p.435-509.
- LEE, J. et al. Speckle reduction in multipolarization, multifrequency SAR imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v.29, n. 4, p.535-544,1991.
- LEE, J.; POTTIER, E. **Polarimetric radar imaging from basics to applications**. New York: CRC Press, 2009. 398 p.
- LEEUW, J. et al. Comparing accuracy assessments to infer superiority of image classification methods. **International Journal of Remote Sensing**, v.27, n.1, p.223-232, 2006.
- LEINENKUGEL, P. et al. Sensitivity analysis for predicting continuous fields of tree-cover and fractional land-cover distributions in cloud-prone areas. **International Journal of Remote Sensing**, v.35, n.8, p.2799-2821, 2014.
- LEWIS, A. J. et al. W. Radar fundamentals: the geoscience perspective. In: LEWIS, A. J.; HENDERSON, F. M.; RYERSON, R. A. (Eds.). **Principles and applications of imaging radar: manual of remote sensing**. 3.ed. New York: John Wiley & Sons, 1998. v.2, cap. 5, p. 271-356.
- LI, W.; DU, Q. 2015. Support vector machine with adaptive composite kernel for hyperspectral image classification. **Proceedings of SPIE**, v.9501, 2015. Disponível em: <http://doi.org/10.1117/12.2178012>.
- LIAW, A.; WIENER, M. Classification and regression by random Forest. **R News**, v.2, n.3, p.18-22, 2002.
- LIN, S. L.; LIU, Z. **Parameter selection in SVM with RBF kernel function**. [S.l.]: J. Zhejiang University of Technology, 2007.
- LOPES, A. et al. Adaptive speckle filters and scene heterogeneity. **IEEE Transactions on Geoscience and Remote Sensing**, v.28, n.28, p.992-1000,1990.
- LORENA, R. B. **Linking spatial patterns of land-use to agents of deforestation in the Brazilian Amazon**. 176 p. Tese (Doutorado em Ciências) – Universidade Católica de Louvain, Louvain-la-Neuve, 2008.

LU, D.; WENG, Q. A survey of image classification methods and techniques for improving classification performance. **International Journal of Remote Sensing**, v. 28, p. 823-870, 2007.

LUCAS, R.M. et al. Forest regeneration on abandoned clearances in central Amazonia. **International Journal of Remote Sensing**, v. 23, p.965–988, 2002.

LUCAS, R.M. et al. Mapping the regional extent of tropical forest regeneration stages in the Brazilian Legal Amazon using NOAA AVHRR data. **International Journal of Remote Sensing**, v.21, p.2855–2881, 2000.

MADANI, K., LUND, J. R. A Monte-Carlo game theoretic approach for multi- criteria decision making under uncertainty. **Advances in Water Resources**, v. 34 , p. 607-616, 2011.

MADSEN, S. N. et al. Topographic mapping using radar interferometry: processing techniques. **IEEE Transactions on Geoscience and Remote Sensing**, v. 31, n. 1, p. 246-256, 1993.

MADSEN, S. N.; ZEBKER, H. A. Imaging radar interferometry. In: RYERSON, R. A. (Ed.). **Principles and applications of imaging radar: manual of remote sensing**. 3.ed. New York, NY: John Wiley & Sons, 1998. v.2, cap.6, p.359-380.

MAHDIANPARI M. et al. Random forest wetland classification using ALOS-2 L-band, RADARSAT-2 C-band, and TerraSAR-X imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 130, p.13-31, 2017.

MARGULIS, S. **Causas do desmatamento da Amazônia brasileira**. [S.l.]: Banco Mundial, 2003.

MARTINS, V. S. et al. Seasonal and interannual assessment of cloud cover and atmospheric constituents across the Amazon (2000–2015): insights for remote sensing and climate analysis. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.145, p.309-327, 2018.

MARUJO, R. F. B. et al. Mapeamento da cultura cafeeira por meio de classificação automática utilizando atributos espectrais, texturais e fator de iluminação. **Coffee Science**, v.12, n. 2, p. 164-175, 2017.

MASSONNETT, D.; FEIGL, K. L. Radar interferometry and its application to changes in the earth's surface. **Reviews of Geophysics**, v.36, n.4, p. 441–500, 1998.

MATHER, P. M. **Computer processing of remotely sensed images: an introduction**. 2. ed. Chichester: John Wiley & Sons, 1999. 292 p.

- MATHER, P.; TSO, B. **Classification methods for remotely sensed data**. Boca Raton: CRC press, 2009.
- MCNEMAR, Q. Note on the sampling error of the difference between correlated proportions or percentages. **Psychometrika**, v.12, p. 153-157, 1947.
- MERTENS, B. et al. Crossing spatial analyses and livestock economics to understand deforestation process in Brazilian Amazon: the case of São Felix do Xingu in South Pará. **Agricultural Economics**, n. 27, p. 269-294, 2002.
- MIRAGAYA, J. Demanda mundial de carne bovina tem provocado o desmatamento na Amazônia. **T&C Amazônia**, v.6, n 14, 2008.
- MORALES-HIDALGO, D. et al. Status and trends in global primary forest, protected areas, and areas designated for conservation of biodiversity from the Global Forest Resources Assessment 2015. **Forest Ecology and Management**, v. 352, p. 68–77, 2015.
- MOREIRA, E. P. et al. Efeito da topografia sobre a classificação do uso e cobertura da terra por análise de imagens baseada em objetos. **Revista Brasileira de Cartografia**, v.68, n.3, p.505-517, 2016.
- MORTON, D. C. et al. Cropland expansion changes deforestation dynamics in the southern Brazilian Amazon. **Proceedings of the National Academy of Sciences of the United States of America**, v. 103 p. 14637–14641, 2006.
- MOSADEGHI, R. et al. Uncertainty analysis in the application of multicriteria decision-making methods in Australian strategic environmental decisions. **Journal of Environmental Planning and Management**, v.58, n. 8, p. 1097-1124, 2013.
- MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing: a review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 3, p. 247-259, 2011.
- MURA, J. C. et al. A phase-offset estimation method for InSAR DEM generation based on phase-offset functions. **Remote Sensing**, v. 4, p. 745-761, 2012.
- NASCIMENTO, T. V. D.; FERNANDES, L. L. Mapeamento de uso e ocupação do solo em uma pequena bacia hidrográfica da Amazônia. **Ciência e Natura**, Santa Maria, v.39, n.1, p. 170-178, 2017.
- NEEFF, T. et al. Area and age of secondary forests in Brazilian Amazonia 1978–2002: an empirical estimate. **Ecosystems**, v.9, n.4, p.609-623, 2006.

NEPSTAD, D. et al. Road paving, fire regime feedbacks, and the future of Amazon forests. **Forest Ecology and Management**, n.154, p.395-407, 2001.

NITZE, I. et al. Comparison of machine learning algorithms random forest, artificial neural network and support vector machine to maximum likelihood for supervised crop type classification. In: GEOBIA, 4., 2012. **Proceedings...** 2012. p.7-9

OLIVEIRA JUNIOR, et al. Análise da área desmatada municipal na Amazônia Brasileira no período 2000 – 2004: uma abordagem com modelos não-lineares, **Economia Aplicada**, v. 14, n. 3, p. 395-411, 2010.

OLIVEIRA, R. S. D. et al. Dinâmica de uso e cobertura da terra das regiões de integração do Araguaia e Tapajós/PA, para os anos de 2008 e 2010. **Revista Brasileira de Cartografia**, v. 68, n.7, p. 1411-1424, 2016.

OOMMEN, T. et al. An objective analysis of support vector machine based classification for remote sensing. **Mathematical Geosciences**, v. 40, n. 4, p. 409-424, 2008.

PAL, M. Random forest classifier for remote sensing classification. **International Journal of Remote Sensing**, v. 26, p. 217-222, 2005.

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

PFAFF, A. S.P. **What drives deforestation in the brazilian Amazon?** evidence from satellite and socioeconomic data. 1997. (Working Paper, 1772). Disponível em: <http://www.wds.worldbank.org/servlet/WDSContentServer/WDSP/IB/1997/05/01/000009265_3980313101835/Rendered/PDF/multi_page.pdf>. Acesso em: 26 jan. 2018.

R CORE TEAM. **R: A language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing, 2018.

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

REDDINGTON, C.L. et al. Air quality and human health improvements from reductions in deforestation-related fire in Brazil. **Nature Geoscience**, v.8, n.10, p.768–771, 2015.

- REIS, E.; MARGULLIS, S. Options for slowing Amazon jungle clearing. IN: DORNBUSCH, R.; POTERBA, J. (Eds.). **Economic policy responses to global warming**. Cambridge, MA: MIT Press, 1991.
- RICHARDS, A. **Remote sensing with imaging radar**. Berlim: Springer, 2009. 361 p.
- RICHARDS, J. A.; JIA, X. **Remote sensing digital image analysis**. 3.ed. Berlin: Springer-Verlag, 1999.
- RIVERO, S. et al. Pecuária e desmatamento: uma análise das principais causas diretas do desmatamento na Amazônia. **Nova Economia**, v. 19, n.1, p. 41-66, 2009.
- RODRIGUEZ-GALIANO, V. F. et al. An assessment of the effectiveness of a random forest classifier for land-cover classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 67, p. 93-104, 2012.
- ROSA, R. G. S. **Filtragem de ruído speckle em imagens clínicas de ecografia**. 99p. Dissertação (Mestrado em Tecnologia Biomédica) - Instituto Politécnico de Bragança, Bragança, Portugal, 2012.
- ROUSE, J. W.; HASS, R. H.; SCHELL, J. A.; DEERING, D. W.; HARLAN, J. C. **Monitoring the vernal advancements and retrogradation (greenwave effect) of natural vegetation**. Washington: NASA/GSFC, 1974. 371p.
- RUBISTEIN, R. Y. **Simulation and the Monte Carlo method**. Canada: John Wiley & Sons, 1981. 282 p.
- SABINS, F. F. **Remote sensing: principles and interpretation**. 3.ed. New York: W. H. Freeman and Company, 1996. 494 p.
- SAITO, E. A.; FONSECA, L. M. G.; ESCADA, M. I. S.; KORTING, T. S. Efeitos da mudança de escala em padrões de desmatamento na Amazônia. **Revista Brasileira de Cartografia**, v.63, n.3, p.401-414, 2011.
- SANT'ANNA, J. S. **Avaliação do desempenho de filtros redutores de "Speckle" em imagens de radar de abertura sintética**. 1995. 209 p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 1995.
- SANT'ANNA, S.J.S.; MASCARENHAS, N.D.A. Comparação do desempenho de filtros redutores de "Speckle". In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 1996, Salvador, BA. **Anais...** São José dos Campos: INPE, 1996. p. 871-877. Disponível em: <<http://marte.dpi.inpe.br/col/sid.inpe.br/deise/1999/02.01.15.54/doc/T122.pdf>>. Acesso em: 7 fev. 2018.

SANTOS, T. C. C.; ANTUNES, M. A. H.; SEOANE, J. C. S.; SOUZA, G. M. Comparação de modelos de correção atmosférica para imagem Worldview-2. **Revista Brasileira de Cartografia**, v. 69, n. 2, p. 229-240, 2016.

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

SERVELLO, E. L. **Dados polarimétricos do Radarsat-2 (banda C) na discriminação de uso e cobertura da terra na região da Floresta Nacional do Tapajós**. 2010. 95p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2010.

SHANG, X.; CHISHOLM, L. A. Classification of Australian native forest species using hyperspectral remote sensing and machine-learning classification algorithms. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v.7, p. 2481-2489, 2014.

SHI, Z.; FUNG, K. B. A. Comparison of digital speckle filters. **International Geoscience and Remote Sensing Symposium**, Pasadena, v.4, p.2129-2133, 1994.

SHIMABUKURO Y. E; SMITH, J. A. The least-squares mixing models to generate fraction images derived from remote sensing multispectral data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 29, p.16-20, 1991.

SMALL, D.; SCHUBERT, A. **Guide to ASAR geocoding**. Paris, France: ESA, 2008.

SOARES-FILHO, B. S. et al. Cenários de desmatamento para a Amazônia. **Estudos Avançados**, v. 19, n. 54, p. 137-152, 2005.

SOLBO, S.; ELSOFT, T. A stationary wavelet-domain wiener filter for correlated speckle. **IEEE Transactions on Geoscience and Remote Sensing**, v. 46, n. 4, p. 1219-1230, 2008.

SOTHE, C. et al. Approaches for classifying successional forest stages in São Joaquim National Park using landsat-8 and rapideye images. **Boletim de Ciências Geodesicas**, v.23, n. 3, p. 389-404, 2017.

SRIVASTAVA, H.; PATEL, P. Application potentials of synthetic aperture radar interferometry for land-cover mapping and crop-height estimation. **Current Science**, v. 91, n.6, p. 783-788, 2006.

STROZZI, T. et al. Mapping deforestation in Amazon with ERS SAR interferometry. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SIMPOSIUM1999, Hamburg. **Proceedings...** 1999.

- SVENDSEN, M. T. Investigation of polarimetric SAR data acquired at multiple incidence angles. **Proceedings International Geoscience and Remote Sensing Symposium (IGARSS)**, v.3, p.1720-1722, 1998.
- TANASE, M. A. et al. Properties of X-, C- and L-band repeat-pass interferometric SAR coherence in Mediterranean pine forests affected by fires. **Remote Sensing of Environment**, v. 114, p. 2182-2194, 2010.
- TEBALDINI, S. et al. P band penetration in tropical and boreal forests: tomographical results. **International Geoscience and Remote Sensing Symposium**, p. 4241-4244, 2011.
- THIEL, C. et al. Analysis of multi-temporal land observation at C-band. **International Geoscience and Remote Sensing Symposium-IGARSS**, v. 9, p.5, 2009.
- TOUZI, R. Target scattering decomposition in terms of roll-invariant target parameters. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, n. 1. p.73-84, 2007.
- TOWNSEND, P. A. Relationships between forest structure and the detection of flood inundation in forested wetlands using C-band SAR. **International Journal of Remote Sensing**, v.23, n. 3, p. 443-460, 2002.
- TURNER, B. L.; LAMBIN, E. F.; REENBERG, A. The emergence of land change science for global environmental change and sustainability. **Proceedings of the National Academy of Sciences of the United States of America**, v.104, p.20666-20671, 2007.
- ULABY, F. T.; BATLIVALA, P. P. Optimum radar parameters for mapping soil moisture. **IEEE Transactions Geoscience Electronics**, v. 14, n. 2, p. 81-93, 1976.
- ULABY, F. T. et al. Relating the microwave backscattering coefficient to leaf area index. **Remote Sensing of Environment**, v.14, p. 113-133, 1984.
- ULABY, F. T.; ELACHI, C. **Radar polarimetry for geoscience applications**. Norwood: Artech House, 1990. 364p.
- VAEZA, R. F. et al. Uso e ocupação do solo em bacia hidrográfica urbana a partir de imagens orbitais de alta resolução. **Floresta e Ambiente**, v. 17, n. 1, p. 23-29, 2010.
- VAN DER SANDEN, J. J. **Radar remote sensing to support tropical forest management**. [S.l.]: Tropenbos-Guyana, 1997. 330 p.
- VAN ZYL, J. J. The effect of topography on radar scattering from vegetated areas. **IEEE Transactions on Geoscience and Remote Sensing**, v.31, n.1, p.153-160, 1993.

- VANDEN BORRE, J. et al. Integrating remote sensing in Natura 2000 habitat monitoring: prospects on the way forward. **Journal for Nature Conservation**, v.19, n.2, p.116-125, 2011.
- VANUCHI, V. C. F. et al. Análise físico-químicas de águas oriundas das principais lagoas e poços do garimpo Bom Futuro – Ariquemes/RO. **Colégio de Aplicação da Universidade Federal do Acre**, v. 1, n. 1, p. 19-28, 2014.
- VARGHESE, A. et al. Analysis of different polarimetric target decomposition methods in forest density classification using C band SAR data. **International Journal of Remote Sensing**, v. 37, n. 3, p. 694-709, 2016.
- VELHO, L. F. et al. Utilização do filtro Lee na redução do *Speckle* em imagens SAR usadas na determinação da velocidade de geleiras. **Revista Brasileira de Cartografia**, n.63/02, p. 253-265, 2011.
- WAGNER, W. et al. Prospects of Sentinel-1 for land applications. **IEEE International Geoscience and Remote Sensing Symposium (IGARSS)**, p.1741–1744, 2012.
- WALKER, R. Theorizing land-cover and land-use change: the case of tropical deforestation. **International Regional Science Review**, v. 27, n.3. p.247-270, 2004.
- WANG, L.; LIU, H. An efficient method for identifying and filling surface depressions in digital elevation models for hydrologic analysis and modelling. **International Journal of Geographical Information Science**, v. 20, n. 2, p.193-213, 2006.
- WANG, P. et al. An improved SAR radiometric terrain correction method and its application in polarimetric SAR terrain effect reduction. **Progress in Electromagnetics Research B**, v.54, p.107-128, 2013.
- WASKE, B.; BRAUN, M. Classifier ensembles for land cover mapping using multitemporal SAR imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.64, n. 5, p. 450-457, 2009.
- WEGMÜLLER, U. et al. On the estimation and interpretation of sentinel-1 TOPS InSAR coherence. **European Space Agency, (Special Publication) ESA SP**, v.731, p. 2-5, 2015.
- WEGMÜLLER, U.; WERNER, C. Retrieval of vegetation parameters with SAR Interferometry. **IEEE Transactions on Geoscience and Remote Sensing**, v. 35, n. 1, p. 18- 24, 1997.
- WEGMÜLLER, U.; WERNER, C. SAR interferometric signatures of forest. **IEEE Transactions on Geoscience and Remote Sensing**, v. 33, n. 5, p. 1153- 1161, 1995.

WHYTE, A. et al. A new synergistic approach for monitoring wetlands using Sentinels -1 and 2 data with object-based machine learning algorithms. **Environmental Modelling and Software**, v.104, p. 40-54, 2018.

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

ZEBKER, H. A.; VILLASENOR, J. Decorrelation in interferometric radar echoes. **IEEE Transactions on Geoscience and Remote Sensing**, v. 30, n. 5, p. 950-959, 1992.

ZELAZOWSKI, P. et al. Reconciling satellite-derived atmospheric properties with fine-resolution land imagery: insights for atmospheric correction. **Journal of Geophysical Research**, v.116, D18308, 2011.

APÊNDICE A – MATRIZES DE CONFUSÃO

A.1 Matrizes de confusão para o classificador SVM

Tabela A. 1- Matriz de confusão média dos cenários com o classificador SVM para a Fase 1. AU: Acurácia do Usuário (%) e AP: Acurácia do Produtor (%).

Cenários		Referência			Total	AU
		AG	FL	PA		
SVM-1	AG	1994	200	652	2846	70.1
	FL	320	1563	346	2229	70.1
	PA	152	136	318	606	52.4
	Total	2466	1899	1316		
	AP	80.9	82.3	24.1		
SVM-2	AG	1770	1020	497	3287	53.8
	FL	328	688	254	1270	54.2
	PA	368	191	565	1124	50.3
	Total	2466	1899	1316		
	AP	71.8	36.2	42.9		
SVM-3	AG	1571	68	135	1773	88.6
	FL	877	1820	1137	3834	47.5
	PA	18	11	44	74	59.7
	Total	2466	1899	1316		
	AP	63.7	95.8	3.4		
SVM-4	AG	1999	178	520	2697	74.1
	FL	263	1621	272	2156	75.2
	PA	204	100	525	829	63.3
	Total	2466	1899	1316		
	AP	81.1	85.4	39.9		
SVM-5	AG	1800	82	180	2062	87.3
	FL	473	1605	468	2545	63.0
	PA	193	212	668	1073	62.3
	Total	2466	1899	1316		
	AP	73.0	84.5	50.8		
SVM-6	AG	1914	69	201	2184	87.6
	FL	284	1634	313	2230	73.2
	PA	268	196	802	1266	63.3
	Total	2466	1899	1316		
	AP	77.6	86.0	60.9		
SVM-7	AG	2050	92	183	2325	88.2
	FL	202	1677	224	2102	79.8
	PA	215	130	909	1254	72.5
	Total	2466	1899	1316		
	AP	83.1	88.3	69.1		

Fonte: Produção do autor.

Tabela A. 2 - Matriz de confusão média dos cenários com o classificador SVM para a Fase 2. AU: Acurácia do Usuário (%) e AP: Acurácia do Produtor (%).

Cenários	Referência						Total	AU
	FD	FP	SSA	SSInt	SSI			
SVM-1	FD	93	53	19	42	36	243	38.2
	FP	267	527	174	222	35	1225	43.0
	SSA	4	1	4	2	2	13	33.2
	SSInt	98	81	16	138	12	344	40.1
	SSI	17	11	5	13	29	76	38.5
	Total	478	674	218	416	115		
	AP	19.4	78.2	1.9	33.1	25.5		
SVM-2	FD	171	41	27	33	23	294	58.1
	FP	287	611	172	342	68	1480	41.3
	SSA	2	3	10	2	0	17	57.9
	SSInt	12	16	4	37	0	68	53.8
	SSI	6	4	6	3	24	43	57.0
	Total	478	674	218	416	115		
	AP	35.8	90.6	4.4	8.8	21.3		
SVM-3	FD	193	118	34	91	36	470	40.9
	FP	229	487	162	209	38	1125	43.2
	SSA	0	3	3	0	0	7	48.9
	SSInt	55	64	18	112	38	287	38.9
	SSI	1	2	0	4	4	12	33.1
	Total	478	674	218	416	115		
	AP	40.3	72.2	1.6	26.8	3.4		
SVM-4	FD	224	68	26	58	25	402	55.9
	FP	171	512	136	181	31	1031	49.7
	SSA	7	10	33	3	2	55	59.5
	SSInt	62	74	21	167	7	330	50.5
	SSI	14	9	3	7	49	83	59.4
	Total	478	674	218	416	115		
	AP	47.0	76.0	14.9	40.1	43.0		
SVM-5	FD	268	58	24	41	23	415	64.7
	FP	165	556	102	178	32	1033	53.8
	SSA	15	23	78	14	4	133	58.6
	SSInt	25	30	12	174	6	248	70.2
	SSI	5	8	1	8	50	72	69.6
	Total	478	674	218	416	115		
	AP	56.1	82.4	35.9	41.9	43.8		
SVM-6	FD	232	81	36	79	27	455	51.0
	FP	165	508	122	117	20	932	54.5
	SSA	14	15	41	5	1	76	54.6
	SSInt	58	59	17	203	16	352	57.7
	SSI	9	11	2	12	52	86	60.2
	Total	478	674	218	416	115		
	AP	48.6	75.4	19.0	48.9	45.1		

continua

Tabela A. 2 - Conclusão.

Cenários	Referência						Total	AU
	FD	FP	SSA	SSInt	SSI			
SVM-7	FD	342	65	29	48	19	502	68.1
	FP	89	537	63	94	21	804	66.8
	SSA	11	26	115	7	1	160	72.0
	SSInt	30	37	10	262	7	346	75.7
	SSI	6	9	1	6	68	90	75.9
	Total	478	674	218	416	115		
	AP	71.6	79.7	52.7	62.9	59.1		

Fonte: Produção do autor.

A.2 Matrizes de confusão para o classificador RF

Tabela A. 3 - Matriz de confusão média dos cenários com o classificador RF para a Fase 1. AU: Acurácia do Usuário e AP: Acurácia do Produtor.

Cenários		Referência				
		AG	FL	PA	Total	AU
RF-1	AG	1806.0	224.5	480.9	2511.4	71.9
	FL	285.8	1435.8	291.1	2012.7	71.3
	PA	374.3	238.7	544.0	1156.9	47.0
	Total	2466.0	1899.0	1316.0		
	AP	73.2	75.6	41.3		
RF-2	AG	1466.6	699.1	415.3	2581.0	56.8
	FL	633.7	935.8	330.3	1899.9	49.3
	PA	365.7	264.1	570.4	1200.2	47.5
	Total	2466.0	1899.0	1316.0		
	AP	59.5	49.3	43.3		
RF-3	AG	1752.8	302.6	271.0	2326.4	75.3
	FL	467.8	1175.7	611.1	2254.7	52.1
	PA	245.4	420.7	433.9	1100.0	39.4
	Total	2466.0	1899.0	1316.0		
	AP	71.1	61.9	33.0		
RF-4	AG	1982.4	153.5	371.4	2507.4	79.1
	FL	221.8	1608.3	224.8	2055.0	78.3
	PA	261.7	137.2	719.7	1118.7	64.3
	Total	2466.0	1899.0	1316.0		
	AP	80.4	84.7	54.7		
RF-5	AG	1966.5	133.8	174.8	2275.1	86.4
	FL	342.4	1563.7	354.3	2260.3	69.2
	PA	157.1	201.6	786.9	1145.6	68.7
	Total	2466.0	1899.0	1316.0		
	AP	79.7	82.3	59.8		
RF-6	AG	2045.0	94.1	206.4	2345.4	87.2
	FL	215.9	1619.3	249.5	2084.7	77.7
	PA	205.2	185.6	860.1	1250.9	68.8
	Total	2466.0	1899.0	1316.0		
	AP	82.9	85.3	65.4		
RF-7	AG	2148.4	70.5	142.2	2361.1	91.0
	FL	161.8	1720.6	172.6	2055.0	83.7
	PA	155.8	108.0	1001.2	1264.9	79.1
	Total	2466.0	1899.0	1316.0		
	AP	87.1	90.6	76.1		

Fonte: Produção do autor.

Tabela A. 4 - Matriz de confusão média dos cenários com o classificador RF para a Fase 2. AU: Acurácia do Usuário (%) e AP: Acurácia do Produtor (%).

Cenários		Referência					Total	AU
		FD	FP	SSA	SSInt	SSI		
RF-1	FD	163	133	48	91	32	467	34.9
	FP	161	363	87	141	26	778	46.7
	SSA	40	52	46	24	7	170	27.2
	SSInt	91	107	30	144	18	390	36.8
	SSI	23	18	7	17	32	97	33.0
	Total	478	674	218	416	115		
	AP	34.1	53.9	21.2	34.6	27.8		
RF-2	FD	211	108	38	70	25	453	46.6
	FP	146	374	88	173	35	816	45.8
	SSA	30	54	52	27	5	168	31.2
	SSInt	73	122	34	135	14	377	35.7
	SSI	18	17	5	11	36	87	41.9
	Total	478	674	218	416	115		
	AP	44.2	55.4	24.0	32.4	100.0		
RF-3	FD	204	139	44	91	29	505	40.4
	FP	153	367	95	147	32	793	46.3
	SSA	27	48	41	26	6	147	27.6
	SSInt	79	102	34	134	30	379	35.5
	SSI	15	18	5	18	19	76	25.6
	Total	478	674	218	416	115		
	AP	42.7	54.5	18.6	32.3	16.9		
RF-4	FD	258	78	30	67	21	454	56.8
	FP	120	467	90	125	23	826	56.6
	SSA	19	39	69	15	2	145	47.8
	SSInt	64	83	26	199	11	383	52.0
	SSI	17	7	3	9	58	93	62.2
	Total	478	674	218	416	115		
	AP	53.9	69.3	31.8	47.9	50.5		
RF-5	FD	306	75	29	49	20	480	63.8
	FP	105	512	68	113	21	820	62.4
	SSA	16	25	94	19	3	157	59.9
	SSInt	43	54	24	226	11	359	63.0
	SSI	7	8	2	8	59	85	69.5
	Total	478	674	218	416	115		
	AP	64.0	75.9	43.2	54.4	51.5		
RF-6	FD	263	84	39	72	22	481	54.8
	FP	121	484	80	101	17	803	60.2
	SSA	23	33	74	11	1	142	52.4
	SSInt	62	60	22	219	17	380	57.7
	SSI	9	13	4	13	57	95	59.5
	Total	478	674	218	416	115	1901	
	AP	55.1	71.8	34.1	52.7	49.3		

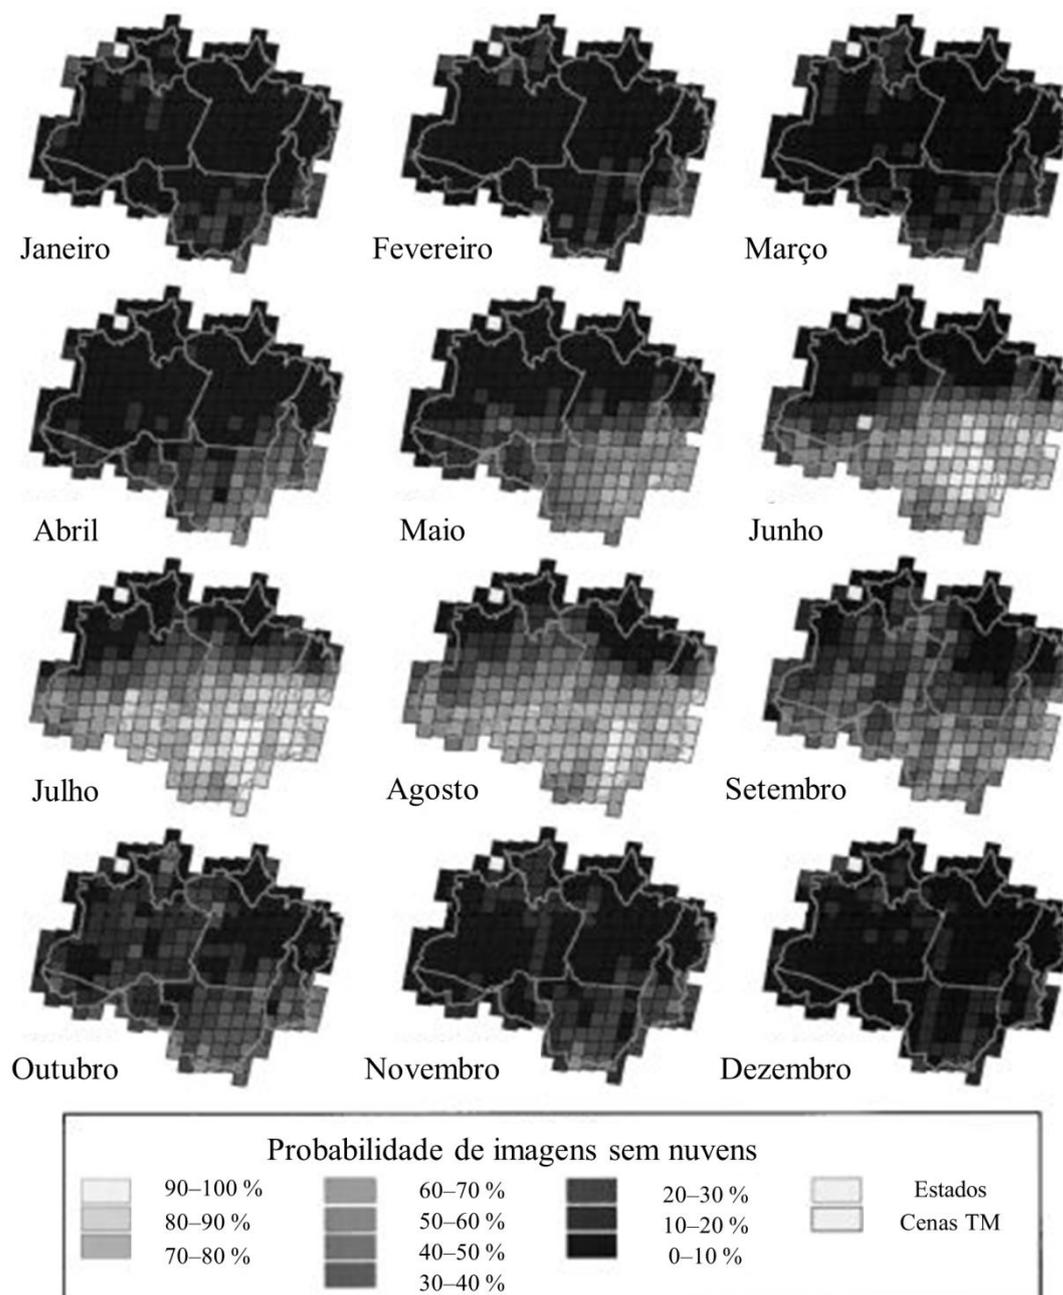
continua

Tabela A. 4 - Conclusão.

Cenários	Referência						Total	AU
	FD	FP	SSA	SSInt	SSI			
RF-7	FD	342	50	26	44	19	482	71.1
	FP	83	561	62	83	15	804	69.8
	SSA	10	19	112	4	1	146	76.6
	SSInt	38	38	17	278	11	383	72.6
	SSI	5	6	1	7	69	87	79.1
	Total	478	674	218	416	115		
	AP	71.6	83.3	51.3	66.8	59.7		

Fonte: Produção do autor.

ANEXO A - PROBABILIDADE DE OBTENÇÃO DE IMAGENS LIVRE DE NUVENS NA BACIA AMAZÔNICA ENTRE 1984 E 1997.



Fonte: Adaptada de Asner (2001).