



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

sid.inpe.br/mtc-m21b/2016/02.26.16.17-TDI

## INTEGRAÇÃO DE DADOS ÓPTICOS E SAR PARA CARACTERIZAÇÃO DA PAISAGEM DE TENSÃO ECOLÓGICA EM RORAIMA

João Arthur Pompeu Pavanelli

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Sensoriamento Remoto, orientada  
pelos Drs. João Roberto dos  
Santos, e Lênio Soares Galvão,  
aprovada em 15 de fevereiro de  
2016.

URL do documento original:

<http://urlib.net/8JMKD3MGP3W34P/3L8M8H5>

INPE  
São José dos Campos  
2016

## **PUBLICADO POR:**

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

Fax: (012) 3208-6919

E-mail: pubtc@inpe.br

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

### **Presidente:**

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

### **Membros:**

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

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

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

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

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

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

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

### **BIBLIOTECA DIGITAL:**

Dr. Gerald Jean Francis Banon

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

### **REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

Simone Angélica Del Ducca Barbedo - Serviço de Informação e Documentação (SID)

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

### **EDITORAÇÃO ELETRÔNICA:**

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

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



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

sid.inpe.br/mtc-m21b/2016/02.26.16.17-TDI

## INTEGRAÇÃO DE DADOS ÓPTICOS E SAR PARA CARACTERIZAÇÃO DA PAISAGEM DE TENSÃO ECOLÓGICA EM RORAIMA

João Arthur Pompeu Pavanelli

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Sensoriamento Remoto, orientada  
pelos Drs. João Roberto dos  
Santos, e Lênio Soares Galvão,  
aprovada em 15 de fevereiro de  
2016.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3L8M8H5>>

INPE  
São José dos Campos  
2016

Dados Internacionais de Catalogação na Publicação (CIP)

---

Pavanelli, João Arthur Pompeu.

P288i      Integração de dados ópticos e SAR para caracterização da paisagem de tensão ecológica em Roraima / João Arthur Pompeu Pavanelli. – São José dos Campos : INPE, 2016.

xvi + 87 p. ; (sid.inpe.br/mtc-m21b/2016/02.26.16.17-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016.

Orientadores : Drs. João Roberto dos Santos, e Lênio Soares Galvão.

1. Random forest. 2. OLI/Landsat-8. 3. PALSAR-2/ALOS-2. 4. Uso e cobertura da Terra. 5. Lavrado. I.Título.

CDU 528.88:502.5(811.4)

---



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

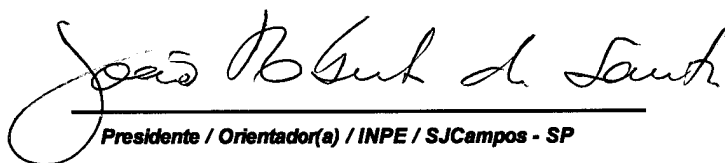
This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): **João Arthur Pompeu Pavanelli**

Título: " INTEGRAÇÃO DE DADOS ÓPTICOS E SAR PARA CARACTERIZAÇÃO DA PAISAGEM DE TENSÃO ECOLÓGICA EM RORAIMA."

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

Dr. João Roberto dos Santos



---

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

Dr. Lênio Soares Galvão



---

Orientador(a) / INPE / SJCampos - SP

Dr. Fábio Furlan Gama



---

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

Dra. Maristela Ramalho Xaud



---

Convidado(a) / EMBRAPA / Boa Vista - RR

Dra. Luciana Spinelli Araujo



---

Convidado(a) / EMBRAPA / Campinas - SP

Este trabalho foi aprovado por:

( ) maioria simples

unanimidade

São José dos Campos, 15 de Fevereiro de 2016



## AGRADECIMENTOS

Gostaria de iniciar esta seção agradecendo a minha professora orientadora de graduação Elza Guimarães, ao professor Luiz Fernando Rolim de Almeida e ao professor Milton Cezar Ribeiro (Miltinho) por todo incentivo ao curso mestrado em Sensoriamento Remoto no INPE.

Por todo o apoio, atenção e tempo dedicados nesses dois anos, fundamentais para o desenvolvimento pessoal e acadêmico, agradeço aos orientadores de mestrado João Roberto dos Santos e Lênio Soares Galvão.

Gratidão especial a toda turma de mestrado e doutorado de 2014 do SERE! Não posso deixar de registrar a valiosa companhia e colaboração dessas pessoas: Evelyn, Hugo, Vanessa, David França, Bruna Neves, Rennan Marujo, Laura, Diogo, Aline, João Felipe, Helô, Omar, Ana, João Bosco, Bru Pechini, Rodolfo, Rani, Sacha, Bruna Braga, David Costa, Anielli, Daniel, Cesare e Eder.

Agradeço à pesquisadora Maristela Xaud e ao pesquisador Haron Xaud, da Embrapa-Roraima, bem como esta unidade da Embrapa, pela infra-estrutura e esforço durante o trabalho de campo (e também depois do campo!).

Ao pessoal de casa: tias, tios, primas, primos e, particularmente, mãe e pai que sempre me incentivaram muito na continuidade dos estudos! E, sobretudo, da “casinha”, Su, por todas as formas de companheirismo no dia-a-dia.

Por fim, agradeço à CAPES, pela concessão de bolsa via INPE, à PGSER, nas pessoas da Vera, Valéria e Elisabete Moraes, coordenadora do curso, e Hajime Zama, da Base Aerofoto pelo auxílio na obtenção da imagem PALSAR-2 junto à JAXA.





## RESUMO

Mapeamentos de uso e cobertura da terra em paisagens tropicais são necessários para fins de manejo, conservação e melhor compreensão dos impactos antropogênicos sobre os ecossistemas naturais. No entanto, a complexidade destas paisagens por conta da transição sutil entre distintas fitofisionomias, a fragmentação da vegetação e o mosaico de áreas ocupadas para fins agropecuários, somada à constante cobertura de nuvens, são fatores limitantes para a caracterização dos territórios a partir de dados de sensoriamento remoto. Nesse sentido, o sinergismo entre sensores ópticos e radares de abertura sintética (SAR) está ganhando evidência, pois geralmente resulta em melhores mapeamentos. Dessa maneira, o objetivo deste trabalho foi analisar o potencial da integração de dados obtidos a partir do sensor óptico OLI/Landsat-8 e SAR PALSAR-2/ALOS-2 para caracterização da paisagem de tensão ecológica entre floresta e savana do estado de Roraima, utilizando o classificador *Random Forest*. A área de estudo no estado de Roraima abrange porções dos municípios de Mucajaí, Boa Vista e Alto Alegre, com área total de 1260 km<sup>2</sup>. A região é caracterizada pelo contato abrupto entre fisionomias florestais e savana (lavrado). Dezesete classes foram levantadas em campo e mapeadas neste estudo. Foi utilizado o produto Landsat CDR, em reflectância de superfície e uma imagem PALSAR-2 dual (HH+HV), Level 1.5 em formato CEOS, com 10 metros de resolução espacial. Do produto OLI foram extraídos os índices NDVI e EVI para auxiliar a classificação. A imagem PALSAR-2 teve o efeito *speckle* reduzido pelo filtro Lee 3x3 pixels e foram extraídas dez métricas GLCM de cada polarização, além de cinco índices espectrais. Ao todo foram utilizadas 35 bandas, 8 bandas ópticas e 27 SAR. As imagens foram corrigidas com base na imagem OLI (ortorretificada) e os pixels reamostrados para 10 metros. A classificação se deu com o algoritmo *Random Forest*, de mineração de dados. Uma etapa prévia de calibração dos parâmetros *n<sub>tree</sub>* (número de árvores na floresta) e *m<sub>try</sub>* (número de variáveis usadas a cada nó das árvores), do *Random Forest*, foi realizada a fim de utilizar os modelos com menor erro para classificação. Foram processados 18 modelos, sendo 6 apenas com dados SAR, 6 apenas com dados ópticos e 6 modelos híbridos, com distintas combinações entre bandas. O melhor modelo SAR atingiu Acurácia Global de 44,6% e Kappa 0,39, enquanto que para o óptico o resultado foi de 76,88% e 0,74, respectivamente. O produto híbrido atingiu Acurácia Global de 82,96% e Kappa 0,81, com diferença estatística significativa em relação aos resultados dos sensores separados, de acordo com o teste Z realizado para comparação entre valores de Kappa. O melhor modelo foi composto apenas com as seis bandas espectrais do OLI e imagens em amplitude HH e HV do PALSAR-2, sendo que a adição de índices espectrais e texturas GLCM do SAR não resultaram em melhorias significativas. Conclui-se, portanto, que o sinergismo entre os sensores óptico e SAR na região de estudo é conveniente para caracterização desta complexa paisagem formada por um mosaico de tipologias de uso e cobertura da terra.

Palavras-chave: Random Forest. OLI/Landsat-8. PALSAR-2/ALOS-2. Uso e cobertura da terra. Mucajaí. Boa Vista. Alto Alegre. Lavrado.



# OPTICAL AND SAR INTEGRATION TO CHARACTERIZE ECOLOGICAL TENSION LANDSCAPE IN THE STATE OF RORAIMA

## ABSTRACT

Land use and cover mapping in tropical landscapes are key for management, conservation and to enhance understanding about anthropogenic impacts over natural ecosystems. However, the natural complexity of these landscapes because of subtle transition between vegetation physiognomies, vegetation fragmentation and the mosaic of land uses for agriculture and pasture lands, in addition to persistent cloud cover, often restricts its characterization by means of remote sensing data. In this sense, optical and SAR synergies is becoming relevant, because it generally results in better land use/cover maps. In light of that, the aim of this study was to analyse the integration of OLI/Landsat-8 optical and PALSAR-2/ALOS-2 SAR sensors to characterize the landscape of ecological tension between forest and savannah in Roraima state, by means of Random Forest classifier. The study site in Roraima state cover portions of the municipalities of Mucajaí, Boa Vista and Alto Alegre, with a total area of 1260 km<sup>2</sup>. The region is characterized by the abrupt contact of forest and savannah physiognomies. Seventeen classes were collected during fieldwork and mapped in this research. Landsat CDR surface reflectance data and PALSAR-2/ALOS-2 dual (HH+HV), Level 1.5, CEOS format (10 metres) were used. From OLI product NDVI and EVI indices were generated. PALSAR-2 image was speckle filtered with a 3x3 Lee filter and GLCM textures were extracted for each polarization, in addition to five spectral indices. In total, 35 bands were used: 8 optical bands and 27 SAR bands. All bands were corregistered based on orthorectified OLI image and pixels were resampled to 10 metres. Classification was made with data mining Random Forest algorithm. A previous calibration step was required to define the parameters *n<sub>tree</sub>* (number of trees in the forest) and *m<sub>try</sub>* (number of variables at each split node). Models whose combination of parameters resulted in minor errors were used for classification. Eighteen models were processed: 6 with only SAR bands, 6 with only optical bands and 6 hybrid models, with distinct band combinations. Best SAR model's Overall Accuracy was 44.6% and Kappa 0.39, while optical better result was 76.88% and 0.74, respectively. Hybrid classification resulted in Overall Accuracy of 82.96% and Kappa 0.81, with significant statistical difference comparing results of classifications using separated sensors, according to Z test between Kappa values. The better model was formed by six OLI spectral bands and HH and HV amplitude images. The addition of spectral indices and SAR GLCM textures did not improved significantly the results. In conclusion, the synergy of OLI and PALSAR-2 in the study site is convenient for characterizing this complex landscape formed by a mosaic of land use and land cover patches.

Keywords: Random Forest. OLI/Landsat-8. PALSAR-2/ALOS-2. Land use and land cover. Mucajaí. Boa Vista. Alto Alegre. Lavrado.



## LISTA DE FIGURAS

	<u>Pág.</u>
3.1 Localização da área de estudo no estado de Roraima. A imagem OLI/Landsat-8 foi adquirida em 06/02/2015 (composição R5G4B6). . . . .	18
3.2 Precipitação diária e datas de imageamento do OLI e PALSAR-2. . . . .	21
3.3 Fluxograma metodológico. . . . .	27
4.1 Importância das bandas no modelo <i>Random Forest</i> 4 - PALSAR-2. O eixo x é a medida de decréscimo médio da acurácia ( <i>mean decrease in accuracy</i> ), normalizada entre 0 e 1. . . . .	37
4.2 Espaço de atributos das duas melhores bandas (HV_Mean e HV_Variance) do modelo 4 com as classes de maior acurácia do produtor (água, campo limpo e silvicultura). . . . .	37
4.3 Classificação do PALSAR-2 com as imagens HH e HV em amplitude e atributos texturais. . . . .	39
4.4 Diagrama de dispersão dos valores amostrais das classes Floresta e Silvicultura nas duas bandas que mais contribuíram para Silvicultura (HV_Correlation e HV_Mean). . . . .	41
4.5 Boxplots com valores em amplitude (HH - amarelo e HV - verde) das amostras de água e campo limpo, comparadas com capoeira inicial (SSI) e floresta. O limite inferior da caixa representa o primeiro quartil, o limite superior é o terceiro quartil. Os pontos representam os valores médios e as linhas pontilhadas os valores máximos e mínimos. . . . .	42
4.6 Importância das bandas no modelo <i>Random Forest</i> 10 - OLI. O eixo x é a medida de decréscimo médio da acurácia ( <i>mean decrease in accuracy</i> ), normalizada entre 0 e 1. . . . .	44
4.7 Espaço de atributos das duas melhores bandas (NIR e SWIR) do modelo 10 com algumas classes de maior contribuição para a exatidão do mapeamento. Valores dos eixos em reflectância de superfície. . . . .	47
4.8 Classificação do OLI com as bandas 2, 3, 4, 5, 6 e 7. Nuvens e sombras de nuvens mascaradas em branco. . . . .	48
4.9 Importância das bandas no modelo <i>Random Forest</i> 15 - OLI+PALSAR-2. O eixo x é a medida de decréscimo médio da acurácia ( <i>mean decrease in accuracy</i> ), normalizada entre 0 e 1. . . . .	50
4.10 Classificação da área de tensão ecológica em Roraima a partir da conjunção de dados OLI e PALSAR-2. . . . .	52

4.11	Ganho de acurácia do produtor (PA) e usuário (UA) em cada classe da integração SAR ao OLI em relação ao OLI. Valores negativos significam perda na acurácia. . . . .	53
4.12	Diagrama de espalhamento das classes com maior ganho com a integração OLI+PALSAR-2 em relação ao OLI. . . . .	54

## LISTA DE TABELAS

	<u>Pág.</u>
2.1 Características das bandas do sensor OLI. . . . .	7
3.1 Descrição e fotografias das classes e levantadas em campo e mapeadas no trabalho. . . . .	22
3.2 Combinação das variáveis (bandas) utilizadas para classificação (modelo RF). Colunas marcadas com X indicam as variáveis presentes em cada modelo de classificação. Modelos 1 a 6 são compostos apenas com produtos SAR. Modelos 7 a 12 são alimentados apenas com bandas ópticas. Modelos 13 a 18 são híbridos. . . . .	30
4.1 Resultados das métricas de avaliação estatística dos modelos classificatórios. . . . .	33
4.2 Teste Z aplicado aos valores de Kappa dos modelos de classificação. *não significativo a 95%. **não significativo a 99%. Demais valores representam diferenças estatísticas significativas entre os modelos de classificação. . . . .	35
4.3 Matriz de confusão do modelo com melhor desempenho classificatório utilizando dados PALSAR-2 (modelo 4). Classes: (1) agricultura, (2) água, (3) campinarana, (4) campo cerrado, (5) campo limpo, (6) campo sujo, (7) capoeira inicial (SS1), (8) capoeira intermediária (SS2), (9) cerrado queimado, (10) cerrado <i>Strictu Sensu</i> (cerrado SS), (11) floresta, (12) pasto limpo, (13) pasto sujo, (14) silvicultura, (15) silvicultura cortada, (16) solo exposto e (17) veredas. . . . .	40
4.4 Matriz de confusão do modelo com melhor desempenho classificatório utilizando dados OLI (modelo 10). Classes: (1) agricultura, (2) água, (3) campinarana, (4) campo cerrado, (5) campo limpo, (6) campo sujo, (7) capoeira inicial (SS1), (8) capoeira intermediária (SS2), (9) cerrado queimado, (10) cerrado <i>Strictu Sensu</i> (cerrado SS), (11) floresta, (12) pasto limpo, (13) pasto sujo, (14) silvicultura, (15) silvicultura cortada, (16) solo exposto e (17) veredas. . . . .	46

4.5 Matriz de confusão do modelo com melhor desempenho classificatório utilizando dados PALSAR-2 e OLI (modelo 15). Classes: (1) agricultura, (2) água, (3) campinarana, (4) campo cerrado, (5) campo limpo, (6) campo sujo, (7) capoeira inicial (SS1), (8) capoeira intermediária (SS2), (9) cerrado queimado, (10) cerrado *Strictu Sensu* (cerrado SS), (11) floresta, (12) pasto limpo, (13) pasto sujo, (14) silvicultura, (15) silvicultura cortada, (16) solo exposto e (17) veredas. . . . . 51



## SUMÁRIO

	<u>Pág.</u>
<b>1 INTRODUÇÃO</b> . . . . .	<b>1</b>
1.1 Objetivos . . . . .	4
1.1.1 Objetivo Geral . . . . .	4
1.1.2 Objetivos específicos . . . . .	4
1.2 Justificativa . . . . .	4
<b>2 FUNDAMENTAÇÃO TEÓRICA</b> . . . . .	<b>7</b>
2.1 O sensor multiespectral OLI/Landsat-8 e o estado da arte para classificação da paisagem . . . . .	7
2.2 O sensor PALSAR-2/ALOS-2 e o estado da arte para a classificação da paisagem . . . . .	9
2.3 Sinergia entre dados SAR e óptico para mapeamento de cobertura e uso da terra usando <i>Random Forest</i> . . . . .	12
<b>3 MATERIAL E MÉTODOS</b> . . . . .	<b>17</b>
3.1 Área de estudo . . . . .	17
3.2 Dados de sensoriamento remoto utilizados . . . . .	19
3.2.1 Landsat CDR . . . . .	19
3.2.2 PALSAR-2/ALOS-2 . . . . .	20
3.3 Dados de campo . . . . .	21
3.4 Procedimentos metodológicos . . . . .	27
3.4.1 Processamento das imagens . . . . .	27
3.4.2 Classificação isolada e em conjunto dos produtos OLI e PALSAR-2 . . . . .	29
<b>4 RESULTADOS E DISCUSSÃO</b> . . . . .	<b>33</b>
4.1 Classificação PALSAR-2/ALOS-2 . . . . .	36
4.2 Classificação OLI/Landsat-8 . . . . .	43
4.3 Integração PALSAR-2/ALOS-2 e OLI/Landsat-8 . . . . .	49
<b>5 CONCLUSÕES</b> . . . . .	<b>57</b>

REFERÊNCIAS BIBLIOGRÁFICAS . . . . .	59
APÊNDICE A - SCRIPT EM R PARA CALIBRAÇÃO DOS MODELOS E CLASSIFICAÇÃO DE USO E COBERTURA DA TERRA COM RANDOM FOREST . . . . .	77
APÊNDICE B - SCRIPT EM R PARA CONFECÇÃO DOS MAPAS DE USO E COBERTURA DA TERRA . . . . .	81
APÊNDICE C - SCRIPT EM R PARA VALIDAÇÃO DOS MAPAS DE USO E COBERTURA DA TERRA . . . . .	83

# 1 INTRODUÇÃO

Apesar da importância de se compreender as mudanças ambientais globais decorrentes de intervenções humanas sobre os ecossistemas, somente nas últimas décadas a preocupação em estudar as mudanças de uso e cobertura da terra ganhou evidência na comunidade científica. Isso ocorre a partir do entendimento de que tais fenômenos de ordem antropogênica na superfície terrestre podem alterar o clima local (LAMBIN et al., 2003), contribuindo para mudanças climáticas em escala global (DENG et al., 2013). Estas mudanças podem levar à impactos socioeconômicos, como insegurança alimentar e vulnerabilidade ambiental (TORRES et al., 2012), perda de biodiversidade, redução da disponibilidade de água, dentre outros efeitos (DEFRIES et al., 2012).

Uma das fontes mais significantes de emissão de gases de efeito estufa (GEE) antropogênicos é a remoção da cobertura vegetal das florestas tropicais (WERF et al., 2009; DENG et al., 2013). O desflorestamento atrai a atenção especial da comunidade científica, pois estas florestas estocam e sequestram mais carbono do que qualquer outro ecossistema terrestre (GIBBS et al., 2007; AVITABILE et al., 2012), além de abrigar quase metade das espécies conhecidas do planeta (MALHI et al., 2008).

A partir de 1850, em torno de 35% do total de CO<sub>2</sub> antropogênico emitido foi derivado de mudanças de uso e cobertura da terra (HOUGHTON; HACKLER, 2001). No ano de 2008, apenas o desflorestamento foi responsável por 12% do montante de CO<sub>2</sub> emitido pela humanidade (QUÉRÉ et al., 2009). Dessa forma, as mudanças de uso e cobertura da terra se configuram como a segunda maior fonte de emissão antropogênica de gás carbônico, atrás somente dos combustíveis fósseis (BODEN et al., 2012).

Ainda que haja incertezas quanto às consequências para a temperatura e ciclo hidrológico decorrentes do aumento da concentração atmosférica dos gases de efeito estufa antropogênicos, em especial o gás carbônico, a conversão de florestas para pastagens ou outros usos podem afetar diretamente o clima regional (CHASE et al., 1999). Esta conversão altera o balanço energético da superfície e o ciclo hidrológico (PIELKE et al., 2002; KALNAY; CAL, 2003).

A conversão de ambientes naturais afeta a biodiversidade, a partir da modificação, perda e fragmentação de habitat que leva ao declínio de espécies animais e vegetais (PIMM; RAVEN, 2000). A perda de habitat é a remoção de ecossistemas

naturais, enquanto a fragmentação é a perda de conectividade entre os ecossistemas naturais que constituem a paisagem (FAHRIG, 1997; FAHRIG, 2003) devido à ação humana.

É estimado que no período de 1850 a 2001 somente a expansão global dos cultivos agrícolas foi responsável pela conversão de 6 milhões de km<sup>2</sup> de florestas e 4,7 milhões de km<sup>2</sup> de savanas, campos e estepes (LAMBIN et al., 2001). Em toda região da América Latina e Caribe foi estimada perda líquida de 179.405 km<sup>2</sup> de vegetação lenhosa (perda total de 541.835 km<sup>2</sup> e ganho total de 362.430 km<sup>2</sup>) entre 2001 e 2010, sendo que 92% do desmatamento ocorreu na América do Sul (particularmente no Brasil, Argentina, Bolívia e Paraguai), devido à expansão de áreas agrícolas (como plantios de soja) e pastagens (AIDE et al., 2013).

Entretanto, ainda há limites e incertezas para compreensão da magnitude e para o monitoramento das mudanças de uso e cobertura da terra e suas consequências (LAURANCE et al., 2011; DENG et al., 2013). Um dos motivos dessa dificuldade é a escassez de dados disponíveis, especialmente sobre a cobertura da terra (FOODY, 2002). Isto evidencia a importância dos mapeamentos contínuos e precisos das regiões tropicais para avançar no entendimento da sucessão de efeitos ambientais nas escalas local, regional e global.

Tais mapeamentos temáticos são gerados, principalmente, a partir de técnicas de sensoriamento remoto orbital no espectro óptico (WERF et al., 2009). Nesse contexto, algumas informações derivadas desses mapeamentos são a quantificação da cobertura vegetal, grau e espacialização de fragmentação da paisagem, discriminação de fitofisionomias e modelos de estimativa de biomassa. Todas essas informações são fundamentais para o monitoramento da paisagem, como também para suporte da escolha de áreas prioritárias para conservação.

Contudo, é de conhecimento geral que há uma série de limitações no uso desses dados orbitais aplicados aos estudos da vegetação, derivados da complexidade das paisagens tropicais. Essa complexidade é atribuída ao nível de fragmentação em pequenas manchas de várias classes de uso e cobertura, ao mosaico formado pela transição natural contínua entre fitofisionomias, às especificações técnicas dos sensores e, um dos mais agravantes, a constante cobertura de nuvens (LU et al., 2007; LAURIN et al., 2013).

Com a crescente disponibilidade de dados coletados por Radares de Abertura Sintética (*Synthetic Aperture Radar* - SAR) orbitais, tal ferramenta se tornou uma importante opção para mapeamento e monitoramento das paisagens tropicais. O SAR opera em certas frequências de micro-ondas que penetram as nuvens, permitindo o sensoriamento remoto sob condições meteorológicas adversas aos sensores ópticos (LU et al., 2012).

Um projeto pioneiro para mapeamento e monitoramento utilizando dados SAR foi o *Global Forest Mapping* (GRFM/GBFM), utilizando informações em banda L do satélite JERS-1 (XIANG-ZHENG et al., 2002; ROSENQVIST et al., 2004). Outra iniciativa global de monitoramento de florestas com SAR em banda L foi o uso do sensor PALSAR, a bordo do satélite ALOS, realizando quatro mapeamentos anuais (2007 - 2010) com produtos de Floresta e Não-Floresta (SHIMADA et al., 2014).

Adicionalmente, muitos trabalhos apontam para o sinergismo entre sensores ópticos e SAR como uma combinação considerada conveniente. Os sensores ópticos permitem inferir sobre parâmetros biofísicos dos objetos na superfície terrestre por meio da reflectância. Os sistemas SAR permitem extrair informações valiosas sobre a geometria dos alvos (LU et al., 2007; SHIMABUKURO et al., 2007; LAURIN et al., 2013).

Dois representantes recentes da geração de dados ópticos e SAR são os sensores OLI/Landsat-8, lançado em 2012, e PALSAR-2/ALOS-2, lançado em 2014. O OLI é um sensor composto de nove bandas multiespectrais, concebido para fins de monitoramento ambiental, mapeamento de uso e cobertura da terra, dentre outros (ROY et al., 2014). Por sua vez, o PALSAR-2 é um radar de abertura sintética que opera em banda L (23 cm) e dá continuidade à aquisição de dados nessa frequência iniciada pelo PALSAR-1, amplamente utilizado para fins de monitoramento de uso e cobertura da terra (ROSENQVIST et al., 2014). Pelo que se sabe, o uso do PALSAR-2 para tal finalidade ainda não foi descrito na literatura.

Dentre as várias técnicas existentes para a classificação de dados ópticos e SAR, ou da integração de ambos, *Random Forest* tem sido recentemente utilizada em vários trabalhos (JHONNERIE et al., 2015). O *Random Forest* é um algoritmo baseado em árvores de decisão e seu emprego para caracterização de uso e cobertura da terra tem se mostrado eficiente e mais preciso do que outros classificadores (RODRIGUEZ-GALIANO et al., 2012), inclusive para integração entre dados ópticos e SAR (FORKUOR et al., 2014). Dentre as características do *Random Forest* pode-se

destacar, principalmente, a capacidade de lidar com grande número de variáveis e estimar a importância das variáveis de entrada para classificação. É um algoritmo adequado para classificação multisensor (Van Beijma et al., 2014), especialmente por se tratar de um método não-paramétrico, ao contrário de classificadores estatísticos, como o MAXVER-ICM (CORREIA et al., 1998), usado para classificação SAR (SILVA; SANTOS, 2011) e integração óptico+SAR (GARCIA et al., 2011).

## 1.1 Objetivos

### 1.1.1 Objetivo Geral

O presente trabalho tem por objetivo analisar o potencial da integração de dados obtidos a partir de sensores orbitais óptico (OLI/Landsat-8) e radar de abertura sintética (PALSAR-2/ALOS-2) para caracterização da paisagem de tensão ecológica entre floresta e savana do estado de Roraima, utilizando o classificador *Random Forest*.

### 1.1.2 Objetivos específicos

O trabalho tem os seguintes objetivos específicos:

- a) Verificar a capacidade de caracterização temática de uso e cobertura da terra obtida por meio do uso dos sensores OLI e PALSAR-2, adicionando nessa comparabilidade a utilização de métricas derivadas das respectivas bandas espectrais e polarizações;
- b) Analisar a potencialidade de discriminação e mapeamento das classes de uso e cobertura da terra a partir da integração dos sensores óptico e SAR;
- c) Determinar quais as classes apresentam maior ganho de desempenho classificatório quando dados OLI e PALSAR-2 são utilizados em conjunto;

## 1.2 Justificativa

Mapear uma região é ação fundamental para iniciativas de planejamento, manejo e monitoramento do território, a fim de reduzir os impactos antrópicos sobre os ecossistemas locais. No entanto, diversos fatores supracitados levam à diminuição da exatidão dos mapeamentos em regiões tropicais. Portanto, este trabalho se

assenta na hipótese de que o sinergismo entre os sensores orbitais ópticos e SAR resultará em mapeamentos com maior exatidão, em comparação aos mapeamentos feitos a partir da extração de atributos independentemente dos sensores.

Assim, busca-se a aplicação de técnicas de sensoriamento remoto, em abordagem multisensorial, para caracterização de uma região bastante heterogênea e de grande interesse e fragilidade ecológica, caracterizada pela transição entre fisionomias florestais e savânicas e que, todavia, sofre pressões de ordem antropogênica que ameaçam a biodiversidade e o funcionamento dos ecossistemas.

Destaca-se, por fim, que este é um estudo pioneiro em ambiente tropical brasileiro ao empregar a integração de dados OLI/Landsat-8 e PALSAR-2/ALOS-2 para mapeamento de uso e cobertura da terra, bem como o uso deste mais recente SAR em banda L para esta finalidade.





## 2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção serão inicialmente descritos os sensores OLI/Landsat-8 e PALSAR-2/ALOS-2, que serão empregados como base primária na citada proposta de caracterização e mapeamento temático. Adicionalmente, são citadas algumas aplicações, fazendo uso da informação óptica e de microondas que vem sendo ultimamente conduzidas para uso e cobertura da terra. Finalmente, discute-se acerca das técnicas de processamento que os especialistas vem desenvolvendo e aplicando para a abordagem integrada multisensor.

### 2.1 O sensor multispectral OLI/Landsat-8 e o estado da arte para classificação da paisagem

Lançado em 11 de fevereiro de 2012, o Landsat-8 carrega a bordo o sensor termal TIRS (*Thermal Infrared Sensor*) e o multispectral OLI (*Operational Land Imager*) (MARKHAM et al., 2014), que será especificamente utilizado neste trabalho.

Os produtos são disponibilizados em 16 *bits* e a resolução espacial é de 30 metros, à exceção da banda pancromática (15 metros). O sensor OLI opera em nove bandas espectrais no intervalo de 0,43  $\mu\text{m}$  a 1,38  $\mu\text{m}$  (ROY et al., 2014), como descrito na Tabela 2.1.

Tabela 2.1 - Características das bandas do sensor OLI.

Banda	Nome da banda	Comprimento de onda ( $\mu\text{m}$ )	Centro da banda ( $\mu\text{m}$ )
1	Aerossol costeiro	0,43 - 0,45	0,443
2	Azul	0,45 - 0,51	0,482
3	Verde	0,53 - 0,59	0,561
4	Vermelho	0,64 - 0,67	0,655
5	Infravermelho Próximo	0,85 - 0,88	0,865
6	Infravermelho Médio	1,57 - 1,65	1,609
7	Infravermelho Médio	2,11 - 2,29	2,201
8	Pancromática	0,50 - 0,68	0,59
9	Cirrus	1,36 - 1,38	1,373

Dadas as melhorias gerais, em especial da resolução radiométrica, o OLI em relação aos seus antecessores (TM e ETM+/Landsat), pode discriminar melhor certas classes de uso e cobertura da terra com respostas espectrais próximas.

Roy et al. (2014) destacam a aplicação do sensor para fins de monitoramentos ambientais e mapeamento de uso e cobertura da terra, com melhor capacidade de separação entre solo exposto e vegetação não fotossinteticamente ativa, bem como entre florestas perenifólias de outras tipologias de florestas sempre-verdes.

As resoluções espacial e temporal do OLI são as mesmas de seus antecessores (30 metros e 16 dias, respectivamente), mas a resolução radiométrica é de 16 bits. Mais um ponto a ser destacado é que a banda do infravermelho próximo do OLI é mais estreita do que a banda correspondente no ETM+, evitando a feição de absorção pelo vapor de água em  $0,825 \mu\text{m}$  (ROY et al., 2014).

O mapeamento de uma região urbana e peri-urbana, com os sensores TM e OLI, em classificação baseada no pixel, resultou em acurácia global de 83,85% com o TM e 86,15% com o OLI (POURSANIDIS et al., 2015). É destacado que a melhor resolução radiométrica do OLI contribuiu para a separação das classes.

Nesse sentido, Pavanelli et al. (2014) também discutem que a resolução radiométrica da imagem OLI (2014) favoreceu uma classificação temática com melhor nível de acurácia, comparada com aquela feita a partir da imagem TM (2010), em estudo na zona de contato entre floresta e savana de Roraima. A classificação pixel a pixel com o OLI resultou em exatidão global de 89,01% e Kappa 0,86, enquanto com o TM a exatidão global foi de 79,93% e Kappa 0,76.

Jia et al. (2014) usaram medidas texturais extraídas de imagens OLI e ETM+ para comparar o desempenho entre os sensores para classificação de uso da terra em Beijing, China. Ambas imagens foram adquiridas em maio de 2013 e foi assumido que não houve drásticas alterações na paisagem entre o período de aquisição (7 dias). Os resultados mostram que a textura do OLI é mais fina na região do visível e infravermelho próximo (VNIR), mas não apresenta melhoria significativa no infravermelho médio (SWIR), em relação a do ETM+. As imagens do VNIR do OLI são mais claras e contém mais informações texturais, especialmente no espectro visível, contribuindo para a melhor classificação.

O uso de atributos derivados das bandas espectrais do OLI, tais como principais componentes multitemporais, conferiram exatidão global de 86,5% e Kappa de 0,8 para classificação de treze temas em uma zona periurbana agrícola no Azerbaijão, com o algoritmo *Random Forest* (EISAVI et al., 2015).

Dessa forma, é notável o potencial do uso do sensor OLI para caracterização de uso e cobertura da terra em diversas paisagens. Entretanto, espera-se classificações com maior exatidão e melhor distinção entre os temas ao se adicionar a informação de retroespalhamento dos objetos, oriundos de dados SAR.

## 2.2 O sensor PALSAR-2/ALOS-2 e o estado da arte para a classificação da paisagem

Em maio de 2014 foi lançado o satélite *Advanced Land Observing Satellite-2* (ALOS-2), carregando a bordo o sensor *Phased Array L-band Synthetic Aperture Radar-2* (PALSAR-2) (ARIKAWA et al., 2014). Esse sensor dá continuidade à aquisição de dados em banda L, após o final da operação do PALSAR 1, em 2011 (ROSENQVIST et al., 2014). O PALSAR-2 deve contribuir com dados para a gestão de territórios locais e em nível internacional, para manejo e exploração de recursos da Terra, gestão de desastres, dentre outras aplicações nesse sentido (KANKAKU et al., 2009).

Este sensor opera em banda L (23 cm) com as possibilidades de selecionar polarizações simples (HH/VV/HV), dual (HH+HV / VV+VH) ou *full* (HH+HV+VH+VV). Há três modos de imageamento: *Spotlight*, *Stripmap* e *ScanSAR* (KANKAKU et al., 2009).

O modo *Spotlight* tem resolução de 3 m em *range* e 1 m em azimute e pode imagear com polarização simples. O *ScanSAR* tem resolução de 44,2 m a 95,1 m, podendo ser disponibilizado ao usuário nas polarizações simples e/ou dual. Já o modo *Stripmap* é um pouco mais diversificado quanto aos produtos, podendo apresentar imagens com resolução de 3 m, de polarizações simples e dual (*Ultra-fine*), imagens com resolução de 6 m de polarizações simples, dual e *full* (*High-sensitive*), ou ainda, imagens com resolução espacial de 10 m, também com as três possibilidades de polarização (*Fine*).

Como até recentemente o sensor PALSAR do satélite ALOS-2 estava numa fase de comissionamento, não há, ainda, registros científicos da qualidade cartográfica e de aplicação temática desse produto-sensor. Contudo, traz-se logo a seguir, as experiências tidas com sensores-radar, sobretudo de banda L, no delineamento temático de uso e cobertura da terra, que ajuda a embasar e dar ciência da

potencialidade que ora se direciona nessa dissertação.

A aplicação de dados em banda L, em variadas combinações de polarizações e modos de imageamento, é descrita na literatura para diversas aplicações florestais, como a caracterização da vegetação, estimativa de biomassa, detecção de desflorestamento e dinâmica de uso da terra.

A análise da correlação entre uma imagem  $\sigma^0$  JERS-1, banda  $L_{HH}$  e imagens-fração vegetação, solo e sombra derivados do Landsat-5/TM, em uma região com diferentes tipologias de uso e cobertura da terra, incluindo florestas, savanas, áreas queimadas e desflorestamento, levaram SHIMABUKURO et al. (2007) e Shimabukuro et al. (2008) à conclusão de que os dados SAR e ópticos são altamente correlacionados. Assim, os trabalhos destacam o potencial da banda L para o mapeamento nessa região amazônica.

A utilização da simulação da banda L do MAPSAR, um radar proposto de uma cooperação entre Brasil e Alemanha, para mapeamento de desflorestamentos recentes na região do Tapajós, PA, indicou o potencial do uso das polarizações HH+HV+VV para detecção de áreas desflorestadas (SANTOS et al., 2008). Segundo estes autores a polarização dual VV+HV apresentou melhores resultados para detecção de desflorestamentos recentes do que a polarização HH+HV.

Por sua vez, Li et al. (2012), utilizando a combinação de bandas C-HH e -HV (RADARSAT-2) e L- HH e -HV (PALSAR/ALOS-1), não alcançaram resultados satisfatórios para estratificação de fisionomias florestais de terra firme e de igapós e sucessões secundárias no Estado do Pará.

Mitchell et al. (2014) compararam também as bandas C (RADARSAT-2) e L (PALSAR/ALOS-1) através do uso de atributos texturais para classificação de florestas naturais e manejadas na Tasmânia. Os resultados evidenciaram a capacidade superior da banda L, em relação à C, na discriminação de tipos e estruturas florestais, tanto nas áreas naturais quanto nas manejadas. A capacidade de discriminação somente entre floresta e não-floresta também foi maior com a banda L, mesmo com a adição de elementos texturais e topográficos à banda C. Isso é devido ao fato de o comprimento de onda da banda L ter maior penetração nos dosséis, resultando em interações da energia com os componentes da floresta (galhos, troncos, etc.) e o solo. Por outro lado, a penetração limitada da banda

C nos dosséis é uma desvantagem para o uso desse comprimento de onda nessa aplicação.

Diferenças na relação entre biomassa e retroespalhamento na banda L (PALSAR/ALOS-1) foram observadas entre florestas, bosques e bosques abertos da Austrália (LUCAS et al., 2010). Tais diferenças são atribuídas às particularidades estruturais de cada fitofisionomia, como densidade e distribuição das classes de diâmetro e de altura das árvores. Sinais mais baixos de retorno dos bosques e bosques abertos foram atribuídos à pouca interação das ondas na banda L com galhos e ramos menores. Além disso, o dossel mais aberto pode ter contribuído para o espalhamento do solo para outras direções que não no sentido do sensor.

Silva e Santos (2011) avaliaram o uso das imagens PALSAR/ALOS-1 no mapeamento de uma região do semi-árido brasileiro. Naquela oportunidade fizeram uso dos algoritmos MaxVer-ICM e Wishart, envolvendo pares e/ou tripletes derivados da matriz de covariância de imagens de amplitude PALSAR HH, HV e de uma imagem sintética HH\*HV. A abordagem Wishart resultou na acurácia global de 59,72% e Kappa de 0,50 para estratificação de classes de caatinga e de uso da terra. Por outro lado, a classificação pelo MaxVer-ICM com o triplete das componentes amplitude HH, HV e HH\*HV, obteve melhores resultados com exatidão global de 66% e Kappa 0,58. Os autores destacam que a abordagem classificatória utilizada se mostra eficiente dentro das limitações apresentadas pelas componentes de base dual em banda L, devido à complexa interação dessa frequência com as sutis variações nas fisionomias de caatinga.

Uma comparação entre algoritmos de classificação foi realizada por Shiraiishi et al. (2014), com a finalidade de investigar quais abordagens resultariam em melhores classificações de uso e cobertura da terra na Indonésia. O estudo foi conduzido baseado em um mosaico de séries temporais de imagens PALSAR com polarizações HH e HV. Os resultados mostram que a classificação com o método *Random Forest* produziu o melhor mapeamento temático, com exatidão global de 64,15%. Entretanto, quando a avaliação era decorrente da discriminação estrita de floresta e não floresta, este método também se destacou como o melhor, com exatidão global de 90,22%. Os autores também indicam o potencial do uso de séries temporais para melhorar a classificação.

Também na região de floresta tropical da Indonésia, Bagan et al. (2010) uti-

lizaram o algoritmo MaxVer sobre as quatro polarizações do PALSAR para classificação de seis categorias genéricas de uso e cobertura da terra. Tal abordagem conferiu-lhes uma exatidão global de 77,69% e Kappa 0,73. No entanto, ao utilizar a abordagem subespaço e adição da matriz de coerência polarimétrica (T3) às quatro bandas iniciais, a exatidão foi de 87,49% e o Kappa 0,84.

Outra abordagem descrita é o uso da classificação, por meio do método Wishart, do atributo entropia (H), originado da decomposição polarimétrica do PALSAR (DICKINSON et al., 2013). Tem-se que a classificação de uma savana arbórea da Austrália atingiu a acurácia global de 79,7%, enquanto para uma floresta boreal e outra de Pinus sp. nos Estados Unidos a exatidão alcançou valores mais baixos, de 47% e 40%, respectivamente.

A adição da coerência interferométrica ao retroespalhamento também se mostrou eficiente para melhorar a classificação de uso e cobertura da terra nos arredores da reserva florestal Tundi, na Índia. Parihar et al. (2014) obtiveram acurácia global de 83,5% e Kappa 0,71 utilizando informações de retroespalhamento e imagens de coerência em dados PALSAR de dezembro de 2007 e fevereiro de 2008. Nesse sentido, a qualidade do mapeamento piorou com o intervalo temporal utilizado no conjunto de dados. Para as informações interferométricas e de retroespalhamento de dezembro de 2007 e março de 2008, a acurácia global foi de 79,1% e Kappa 0,66.

Por fim, destaca-se que é possível explorar as informações obtidas em banda L para fins de caracterização da paisagem florestal e da resultante das atividades antrópicas nela atuante. Isto é possível mesmo com as limitações impostas pela interação entre o sinal-radar e as fitofisionomias em certos ambientes, ou ainda decorrentes do produto em termos de polarizações disponibilizadas operacionalmente ao usuário.

### **2.3 Sinergia entre dados SAR e óptico para mapeamento de cobertura e uso da terra usando *Random Forest***

Dada a heterogeneidade das paisagens tropicais e a frequente cobertura de nuvens, a integração entre dados ópticos e SAR é uma tendência para o mapeamento da vegetação e de uso da terra (LU et al., 2012). Os sensores ópticos permitem inferir sobre parâmetros biofísicos dos objetos na superfície terrestre por meio da

reflectância. Os sensores SAR possibilitam extrair informações valiosas sobre a estrutura dos alvos pelo retroespalhamento (LAURIN et al., 2013).

Segundo Prasad et al. (2011), quando explorados conjuntamente, os dados ópticos e SAR provêm mais informações do que a simples soma da contribuição de cada um dos sensores. Portanto, espera-se que a sinergia de tais dados melhore os mapeamentos em relação ao uso isolado de cada um.

Xaud et al. (2010) destacam que as abordagens multisensor podem ser do tipo substituição, complementação, calibração, intercalibração ou contextualização. No contexto do presente estudo, o interesse principal é que os dados ópticos e SAR se complementem, incorporando informações sobre a reflectância e geometria das tipologias de vegetação e classes de uso da terra.

Muitos trabalhos procedem com a integração multisensorial a partir da fusão de imagens por Análise das Componentes Principais, transformadas Wavelet (PEREIRA et al., 2013; OTUKEI et al., 2015) ou de abordagens híbridas, com mais de um método (LU et al., 2013; HONG et al., 2014). No entanto, tais abordagens requerem a diminuição das variáveis, seja por seleção de atributos, seja por transformações radiométricas, o que, por vezes, requer critérios subjetivos produzindo perda de informação.

Nesse sentido, o *Random Forest* (RF) vem se destacando na comunidade científica para fins de uso e cobertura da terra (GISLASON et al., 2006; RODRIGUEZ-GALIANO et al., 2012). É um classificador robusto capaz de lidar um número grande de variáveis de entrada, sem ter de eliminá-las. Adicionalmente, pode estimar a importância de cada variável para o modelo classificatório.

A classificação pelo *Random Forest* consiste em subdividir aleatoriamente o conjunto de dados em vários subconjuntos (BREIMAN, 2001). Cada subconjunto é criado por uma amostragem com reposição de 2/3 do conjunto de dados, chamada *bootstrap*, que dará origem a uma árvore de decisão. O restante não amostrado (1/3), chamado *out-of-bag*, é usado para avaliação de erros modelo (*Out-Of-Bag Error* - OOB) e para medir a importância de cada variável de entrada. A cada nó da árvore, um subconjunto, de  $m$  atributos, fixado para todos os nós, é selecionado aleatoriamente e avaliado pelo conjunto OOB. O melhor atributo (com menor OOB) é escolhido para dividir o nó. Cada uma das árvores formadas contribui

para a classificação final do objeto, por meio de um voto sobre qual classe o atributo avaliado deve pertencer. Assim, o atributo é classificado de acordo com o maior número de votos que receber.

Permutando, aleatoriamente, os valores de uma variável  $X^j$  dentre as variáveis fora do conjunto amostral (*out-of-bag*) tem-se novas estimativas do erro OOBE. A somatória da diferença entre o erro estimado por permutação e medido, para todas árvores, fornece uma métrica de quanto a ausência de cada variável diminui, em média, a acurácia do modelo (Equação 2.1). Essa métrica se chama decréscimo médio da acurácia (*mean decrease in accuracy*) e é utilizada para medir a importância de cada variável para o modelo, de modo que as variáveis com maior contribuição média para diminuição da acurácia do modelo são as mais importantes.

$$VI(X^j) = \frac{1}{ntree} \sum_t (\widetilde{OOBE}_t^j - OOBE_t^j) \quad (2.1)$$

em que  $VI$  é a importância da variável  $X^j$ ,  $ntree$  é o número de árvores, a somatória é sobre todas as árvores  $t$ ,  $\widetilde{OOBE}_t^j$  é o erro OOBE estimado pela permutação aleatória dos valores da variável  $X^j$  e  $OOBE_t^j$  é o erro OOBE em cada árvore para a variável.

A definição dos parâmetros  $m$  (*mtry*) e quantidade de árvores na floresta (*ntree*) interfere na acurácia do modelo (BREIMAN, 2001). Os valores padrões de *mtry* e *ntree* do pacote *randomForest* são a raiz quadrada do número total de variáveis de entrada ( $\sqrt{N}$ ) e 500 árvores, respectivamente. Breiman (2001) sugere que este valor padrão de *mtry* chega a resultados quase ótimos, sendo utilizado em diversos trabalhos para mapeamento com base em dados de sensoriamento remoto (FORKUOR et al., 2014; MILLARD; RICHARDSON, 2015; AKAR; GÜNGÖR, 2015; SCHULTZ et al., 2015).

Com relação ao parâmetro *ntree*, não há acordo quanto a um número mínimo para alcançar o melhor desempenho (LAWRENCE et al., 2006; AKAR; GÜNGÖR, 2015; MILLARD; RICHARDSON, 2015), mas a importância das variáveis tende a estabilizar com um número maior de árvores (LIAW et al., 2009). Dessa forma, muitos trabalhos assumem o valor de 1000 (Van Beijma et al., 2014; SCHULTZ et al., 2015; BANKS et al., 2015), pois este número de árvores não prejudica o modelo



(BREIMAN, 2001) e florestas maiores não resultam em melhorias significativas na acurácia do *Random Forest* (MILLARD; RICHARDSON, 2013; AKAR; GÜNGÖR, 2015).

Pal (2005) concluiu que o *Random Forest* atinge resultados comparáveis ao algoritmo *Support Vector Machines* (SVM), com a vantagem de que necessita escolher apenas dois parâmetros de entrada. Adam et al. (2014) compararam o RF com SVM para mapeamento com onze classes na África do Sul com imagens RapidEye. A classificação com RF atingiu exatidão global de 93%, enquanto com SVM a exatidão foi de 91,8%.

Assim, muitos trabalhos usam o *Random Forest* para integração entre sensores ópticos e SAR. Jhonnerie et al. (2015) empregaram o RF para classificação de regiões de manguezais em Singapura a partir de dados Landsat-5/TM e PALSAR/ALOS-1. A acurácia global atingiu 81,1% e Kappa 0,76 com as informações espectrais TM e PALSAR HH+HV.

Van Beijma et al. (2014) utilizaram sensores radar aerotransportados polarimétricos em banda S e X e dados ópticos do Landsat-5/TM em uma região costeira no País de Gales. A estratificação temática de cinco classes resultou em acurácia global de 78,2% e Kappa 0,71 quando todas as bandas derivadas dos sensores alimentaram o modelo RF. As classes mapeadas foram areia, vegetação com dominância de *Salicornia sp.*, vegetação com dominância de *Spartina anglica*, sapal e pastagem natural de *Juncus maritimus*.

Dessa forma, para fins de classificação de uso e cobertura da terra em áreas de tensão ecológica, como a existente no estado de Roraima, o uso do classificador Random Forest pode ser bastante interessante. O classificador poderá maximizar o uso das informações extraídas dos sensores OLI e PALSAR-2, indicando quais das variáveis de entrada foram as mais relevantes no processo de classificação.



### 3 MATERIAL E MÉTODOS

#### 3.1 Área de estudo

A região estudada apresenta o contato abrupto entre fisionomias florestais e de savanas, o lavrado, além da ocupação humana para fins agropecuários, propiciando certa dinâmica de uso e conversão de cobertura da terra. Dada a complexidade da paisagem e a constante ocorrência de nuvens, sua caracterização por sensoriamento remoto se torna uma tarefa difícil somente com dados ópticos.

Situada no extremo norte da Amazônia brasileira, no estado de Roraima, a área de estudo é delimitada pelas coordenadas UTM WGS84 20N  $x = 706361,373$ ,  $y = 299450,648$  (superior esquerdo) e  $x = 739667,830$ ,  $y = 265998,627$  (inferior direito) (Figura 3.1). Com área de  $1260 \text{ km}^2$ , compreende uma porção dos municípios de Mucajaí, Alto Alegre e Boa Vista. Os principais cursos d'água são Rio Branco e seu afluente Rio Mucajaí, que faz a divisa de Mucajaí (sudoeste) e Boa Vista (nordeste). Há uma clara separação entre a região florestal (inferior esquerda) e savânica (superior direita), cortadas pelo Rio Mucajaí.

Segundo a classificação de Köppen, a região se encontra sob o domínio Aw (BARBOSA, 1997), caracterizado pelo clima do tipo tropical chuvoso com nítida estação seca entre dezembro e março, época a qual, segundo Silva et al. (2006), é propícia à ocorrência de incêndios florestais. A amplitude térmica entre as médias do mês mais quente e do mês mais frio é inferior a  $5^\circ\text{C}$ , com médias de temperatura e precipitação de  $28^\circ\text{C}$  e  $2000 \text{ mm}$ , respectivamente.

O relevo é predominantemente plano (66%), seguido de suave ondulado (29%) e ondulado (3%). Os solos predominantes na região são do tipo Gleissolo Háplico (48%), Latossolo Vermelho-Amarelo (38%), Latossolo Amarelo (9%) e Argissolo Vermelho-Amarelo (5%) (IBGE-EMBRAPA, 2001).

A vegetação é composta por Floresta Estacional Semidecídua Submontana em contato com Floresta Ombrófila, Floresta Estacional Semidecídua Aluvial, Campinarana Arborizada sem Palmeiras, Vegetação Secundária com e sem Palmeiras em região de Floresta Estacional Semidecídua, Savana Gramíneo-Lenhosa sem floresta de Galeria e Savana Parque com Floresta de Galeria, caracterizando uma região de tensão ecológica (IBGE, 2005).

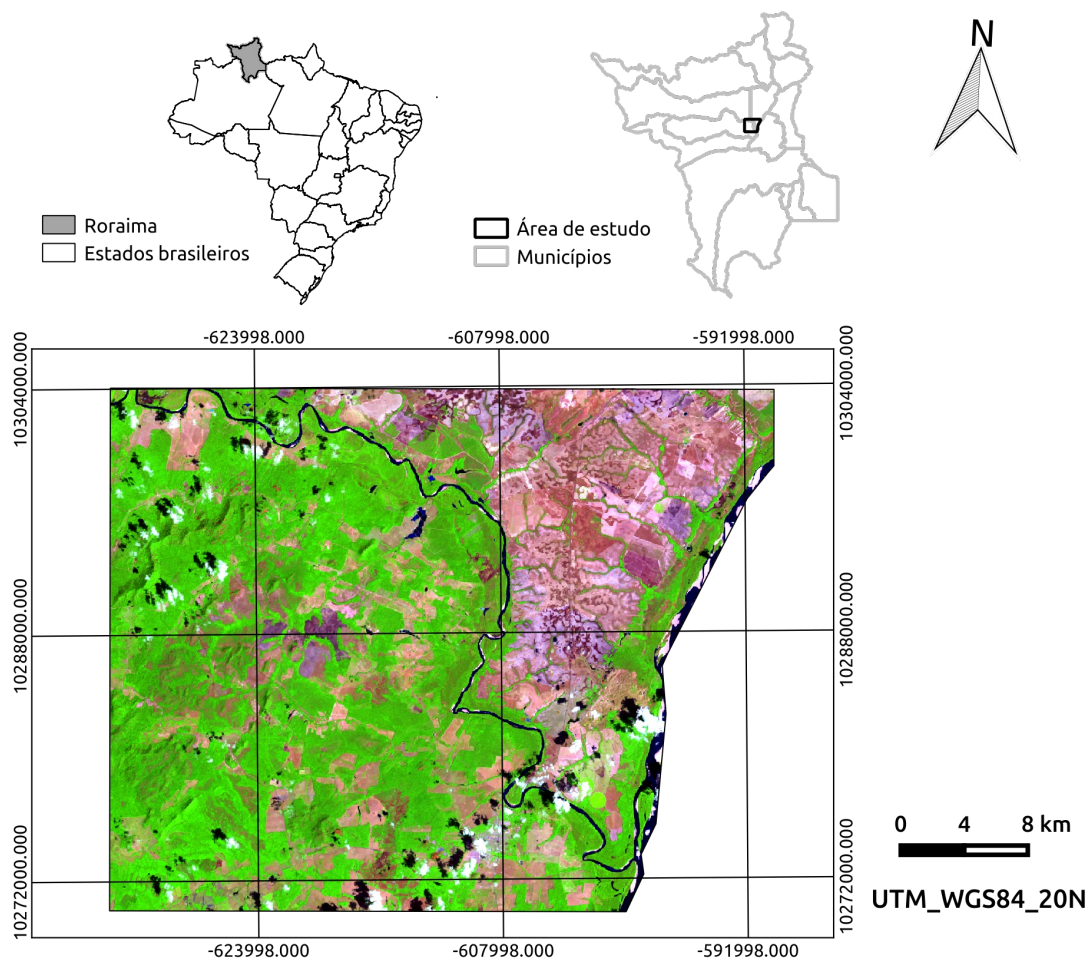


Figura 3.1 - Localização da área de estudo no estado de Roraima. A imagem OLI/Landsat-8 foi adquirida em 06/02/2015 (composição R5G4B6).

A biodiversidade no lavrado é ameaçada pelas grandes extensões de agricultura comercial em expansão (soja, arroz irrigado e silvicultura), fazendo com que as terras indígenas tenham papel fundamental para preservação dos ecossistemas savânicos (BARBOSA et al., 2007). A ocupação do lavrado por fazendas de criação extensiva de gado desde o século XIX levou à implantação dos assentamentos sobre as regiões de floresta, causando uma relação entre o ritmo de chegada de famílias colonas e o desmatamento (BARBOSA, 1993).

Alguns trabalhos destacam que o abandono de lotes pelas famílias beneficiárias é um prática comum, levando a um processo de reconcentração da terra, ainda que de forma ilegal (BARBOSA, 1993; MELO et al., 2008; LACERDA et al., 2015). Apesar disso, tal prática de abandono é uma estratégia de sobrevivência das famílias assentadas que não são assistidas pelos órgãos competentes (BARBOSA,

1993; SANTOS, 2013). O abandono dos lotes, por vezes, resulta em regeneração da vegetação, levando à formação de capoeiras (vegetação secundária).

A agricultura nos assentamentos e colônias da região é baseada na técnica de derrubada e queima, e a subsequente utilização das culturas de arroz, mandioca, feijão, milho, pequena criação de animais e alguns Sistemas Agroflorestais (SAF) (ALMEIDA, 2012). A produção bovina de Mucajaí conta com cerca de 220 pequenos pecuaristas (média de 40 cabeças), 80 médios pecuaristas (média de 216 cabeças) e 23 grandes pecuaristas (média de 1.208 cabeças), sendo que somente 16% do rebanho é mantido pelos pequenos pecuaristas (BENDAHAN et al., 2009).

## 3.2 Dados de sensoriamento remoto utilizados

### 3.2.1 Landsat CDR

Foi utilizado neste trabalho o produto de reflectância de superfície do Landsat *Climate Data Record* (Landsat CDR), que consiste em um produto nível 2A gerado automaticamente pelo Landsat *Ecosystem Disturbance Adaptive Processing System* (LEDAPS) (MASEK et al., 2006), a partir da rotina de correção atmosférica do MODIS, aplicada aos dados Landsat nível 1T (com correção radiométrica e ortorretificados com pontos de controle no terreno).

Para a correção atmosférica do Landsat CDR é utilizado o modelo de transferência radiativa 6S (*Second Simulation of a Satellite Signal in the Solar Spectrum*). O produto CDR acompanha uma máscara de nuvens, sombra de nuvens, água e neve gerada pelo algoritmo "cfmask" (ZHU; WOODCOCK, 2012), que utiliza informações espectrais de todas as bandas ópticas e termais para estimar as áreas a serem mascaradas. Foram utilizadas as máscaras de nuvens e sombra de nuvens nas operações envolvendo apenas os dados ópticos.

Vuolo et al. (2015) compararam o produto CDR com cenas corrigidas pelo método ATCOR-2 em uma região semiárida europeia e concluíram que há consistência entre os valores de reflectância gerados automaticamente e manualmente. O Landsat CDR foi utilizado na Amazônia brasileira para estudos com vegetação secundária na FLONA Tapajós (GALVÃO et al., 2015) e mudanças na cobertura vegetal em várzeas do Baixo Amazonas (FRAGAL et al., 2016).

O produto CDR utilizado neste trabalho foi derivado de uma imagem do sensor *Operational Land Imager* (OLI), a bordo do satélite Landsat-8, órbita 232 e ponto 58, de 06/02/2015, com 30 metros de resolução espacial, obtida da base de dados do USGS. Foram empregadas as bandas 2 (0,45 a 0,515  $\mu\text{m}$ ), 3 (0,525 a 0,60  $\mu\text{m}$ ), 4 (0,63 a 0,68  $\mu\text{m}$ ), 5 (0,845 a 0,885  $\mu\text{m}$ ), 6 (1,56 a 1,66  $\mu\text{m}$ ) e 7 (2,11 a 2,29  $\mu\text{m}$ ). É necessário aplicar um fator de escala de 0,0001 em todas as bandas disponibilizadas no formato tiff pelo USGS, a fim de obter o valor de reflectância de superfície, pois as imagens têm valores entre 0 e 10.000<sup>1</sup>.

### 3.2.2 PALSAR-2/ALOS-2

O satélite ALOS-2 foi lançado em maio de 2014 carregando a bordo o sensor PALSAR-2 (*Phased Array type L-band Synthetic Aperture Radar*) (KANKAKU et al., 2015). A missão dá continuidade à aquisição de dados SAR em banda L, após o final da operação do PALSAR 1, em 2011 (ROSENQVIST et al., 2014).

O PALSAR-2 pode imagear com diferentes configurações em banda L, como modo *Spotlight*, *Stripmap* (*Ultrafine*, *High Sensitive* e *Fine*) e *ScanSAR* (*Normal* e *Wide*), com resolução em azimute de 1 a 100 metros, ângulo de incidência de 8 a 70 graus e em polarização simples (HH ou HV ou VV), dual (HH+HV ou VV+VH) ou completa (HH+HV+VH+VV).

Neste trabalho foi utilizado o produto PALSAR-2, modo *Stripmap Fine*, com polarização dual HH+HV, descendente, ângulo de visada de 32,5° e nível de processamento 1.5 em formato CEOS, obtida pelo serviço de venda de imagens PALSAR-2 da empresa Pasco. Neste nível, as imagens em amplitude já sofreram processamento multi-look (2 *looks*) de modo a obter espaçamento de pixel de 6,25 m, conversão de *slant range* para *ground range* e geocodificação ou georreferenciamento. Optou-se na escolha da imagem pelo produto georreferenciado com sistema de coordenadas UTM datum WGS84 zona 20N, mesma projeção da imagem OLI. O imageamento foi feito no dia 23 de fevereiro de 2015.

---

<sup>1</sup>[http://landsat.usgs.gov/documents/provisional\\_l8sr\\_product\\_guide.pdf](http://landsat.usgs.gov/documents/provisional_l8sr_product_guide.pdf)

### 3.3 Dados de campo

O levantamento das classes temáticas da paisagem foi realizado em duas etapas de campo, realizadas em maio de 2014 e janeiro/fevereiro de 2015. A precipitação diária no período de 06/01/2015 (trinta dias antes do imageamento OLI) até o dia 23/02/2015 (imageamento PALSAR-2) é mostrado na Figura 3.2.

Os dados de chuva foram obtidos na plataforma online do Instituto Nacional de Meteorologia (INMET)<sup>2</sup>, coletados na estação automática de Boa Vista/RR. Os dados do INMET revelam precipitação acumulada de apenas 7,1 mm nesse intervalo de tempo. Esta informação é relevante, pois a presença de umidade na superfície devido às chuvas diminuiria o retroespalhamento dos alvos, resultando em um efeito indesejado para a classificação temática com dados SAR.

Da mesma forma, a ocorrência de chuvas é uma condicionante fisiológica para a vegetação, principalmente para as formações mais abertas de savana (Ex. campos limpos e campos sujos - Tabela 3.1, itens 5 e 6). Isso faz com que, no caso óptico, haja diminuição da reflectância no infravermelho e aumento no vermelho pela menor atividade fotossintética dessas tipologias vegetacionais. A resposta dos solos, mais expostos, tendem a contribuir para a resposta espectral da tipologia vegetal, juntamente com o material fotossinteticamente não ativo do substrato graminóide.




Figura 3.2 - Precipitação diária e datas de imageamento do OLI e PALSAR-2.

Para o levantamento das classes temáticas, foram utilizados um GPS Garmin



<sup>2</sup><http://www.inmet.gov.br/portal/index.php?r=estacoes/estacoesautomaticas>

62sc para coleta das coordenadas das classes, uma câmera Canon t3i para registro fotográfico das classes e anotações de campo para descrever os atributos classificatórios relacionados aos pontos de GPS.

Os pontos de GPS foram importados no Sistema de Informações Geográficas (SIG) livre QGIS para que polígonos representativos de cada classe fossem desenhados para compor um conjunto de amostras de treinamento e de validação (30% dos polígonos). Estes polígonos foram feitos com base nas imagens de alta resolução espacial da base de dados Google Earth. Ao todo, foram coletados 719 pontos das classes no campo e 323 polígonos foram desenhados.

As classes de uso e cobertura da terra levantadas em campo e mapeadas neste trabalho são: (1) agricultura, (2) água, (3) campinarana, (4) campo cerrado, (5) campo limpo, (6) campo sujo, (7) capoeira inicial (SS1), (8) capoeira intermediária (SS2), (9) cerrado queimado, (10) cerrado *Strictu Sensu* (cerrado SS), (11) floresta, (12) pasto limpo, (13) pasto sujo, (14) silvicultura, (15) silvicultura cortada, (16) solo exposto e (17) veredas. Uma breve descrição das fisionomias vegetacionais e caracterização das tipologias de uso da terra são mostradas na Tabela 3.1.





Tabela 3.1 - Descrição e fotografias das classes e levantadas em campo e mapeadas no trabalho.

id	Classe	Descrição	Foto
1	Agricultura	Áreas com monoculturas perenes ou anuais (ex. soja).	
2	Água	Corpos d'água presentes na região (ex. Rio Mucajaí).	

Continua na próxima página



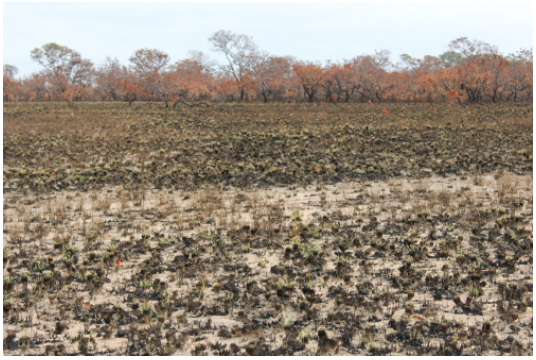


**Tabela 3.1 – continuação da página anterior**

id	Classe	Descrição	Foto
3	Campinarana	Manchas de vegetação arbóreo-arbustivas (max. 2-3m) associadas a áreas limpas de solo arenoso. Formação não florestada dadas limitações edáficas.	
4	Campo Cerrado	Formação savânica com componentes arbustivo-arbóreos esparsos e um componente gramínoide contínuo, sujeita ao fogo anual.	
5	Campo Limpo	Formação estritamente gramínoide, sem presença de árvores ou arbustos.	
6	Campo Sujo	Formação constituída por um estrato gramínoide entremeada por arbustos isolados.	





Continua na próxima página

**Tabela 3.1 – continuação da página anterior**

id	Classe	Descrição	Foto
7	Capoeira Inicial (SS1)	Vegetação em estágio inicial de sucessão secundária, geralmente associado ao abandono de áreas agrícolas ou pastagens. Pode durar de cinco a dez anos, dependendo do grau de degradação do solo e escassez de fonte de propágulos (SALOMÃO et al., 2012).	
8	Capoeira Intermediária (SS2)	Vegetação em estágio de sucessão intermediário entre cinco e vinte anos, com altura média de dossel de 8 m e DAP de 9 cm (SALOMÃO et al., 2012).	
9	Cerrado Queimado	Formação de savana com cicatrizes de queimada no momento do trabalho de campo.	





Continua na próxima página

**Tabela 3.1 – continuação da página anterior**

id	Classe	Descrição	Foto
10	Cerrado Stricto Sensu	Savana arbórea-arbustiva adensada com árvores menores do que 12 m.	
11	Floresta	Formações de Floresta Estacional Semidecídua Submontana em contato com Floresta Ombrófila e de Floresta Estacional Semidecídua Aluvial	
12	Pasto Limpo	Área destinada para pastagem plantada na porção florestal da paisagem.	
13	Pasto Sujo	Pastagem entremeada por espécies invasoras de porte herbáceo-arbustivo e/ou palmeiras (pasto degradado/abandonado).	

Continua na próxima página

Tabela 3.1 – continuação da página anterior

id	Classe	Descrição	Foto
14	Silvicultura	Monoculturas de <i>Acacia mangium</i> Willd degradadas.	
15	Silvicultura Cortada	Áreas de monocultura de <i>Acacia mangium</i> Willd cortada e em processo de rebrota no momento do trabalho de campo.	
16	Solo Ex-posto	Área sem vegetação ou cobertura do solo, geralmente preparada para agricultura ou obras (ex. habitação urbana).	
17	Veredas	Formação do Cerrado que ocorre nas florestas de galeria caracterizada pela presença da palmeira Buriti ( <i>Mauritia flexuosa</i> Mart.) e agrupamentos de espécies arbustivo-herbáceas.	

### 3.4 Procedimentos metodológicos

As etapas de pré-processamento e processamento dos dados utilizados são evidenciadas pelo fluxograma metodológico (Figura 3.3).

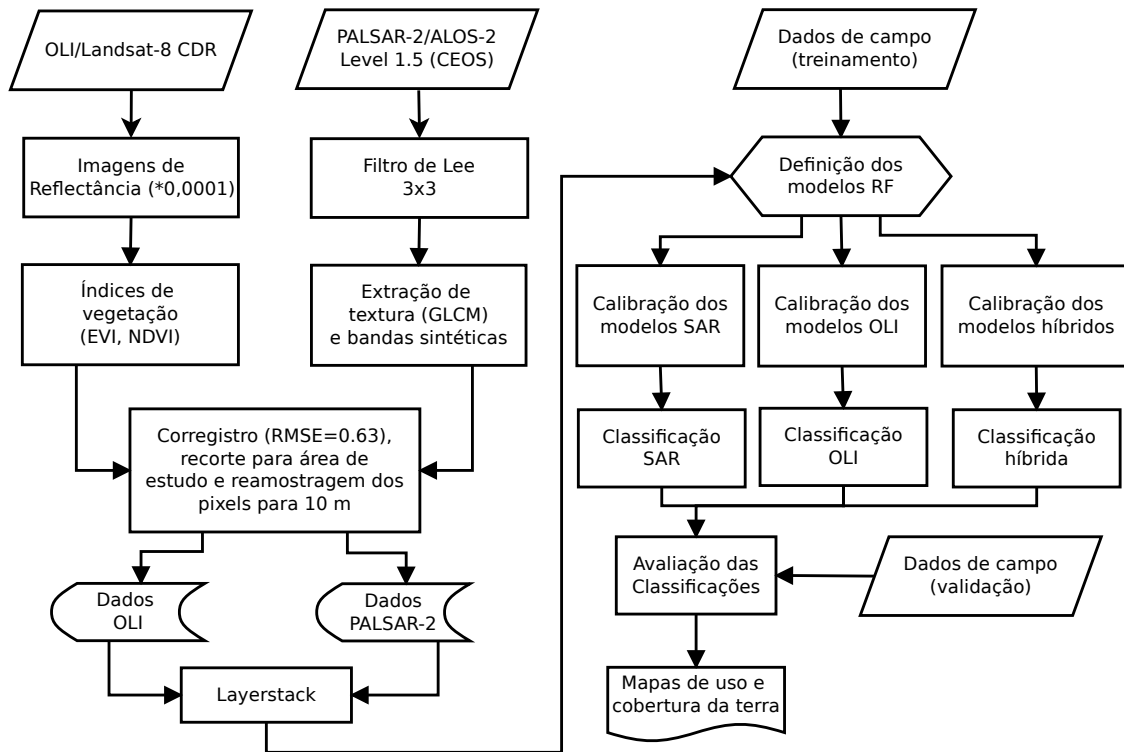


Figura 3.3 - Fluxograma metodológico.

#### 3.4.1 Processamento das imagens

As bandas do OLI/Landsat-8 CDR foram convertidas para imagens de reflectância de superfície pela multiplicação de cada banda pelo fator de escala de 0,0001 em ambiente R. A partir das imagens de reflectância foram calculados os índices de vegetação EVI (Equação 3.1) e NDVI (Equação 3.2), usados também na classificação temática da paisagem.

$$EVI = 2,5 * \frac{\rho_{NIR}(b5OLI) - \rho_{RED}(b4OLI)}{\rho_{NIR}(b5OLI) + 6 * \rho_{RED}(b4OLI) - 7,5 * \rho_{BLUE}(b2OLI) + 1} \quad (3.1)$$

$$NDVI = \frac{\rho_{NIR}(b5OLI) - \rho_{RED}(b4OLI)}{\rho_{NIR}(b5OLI) + \rho_{RED}(b4OLI)} \quad (3.2)$$

em que,  $\rho_{RED}(b4OLI)$  é a reflectância na banda 4 do OLI, correspondente ao vermelho,  $\rho_{NIR}(b5OLI)$  é a reflectância na banda 5 do OLI, correspondente ao infravermelho próximo e  $\rho_{BLUE}(b2OLI)$  é a reflectância na banda 2 do OLI, correspondente ao azul.

Importante observar que em mapeamentos da região dos Cerrados, no oeste do estado da Bahia, séries temporais de produtos de EVI foram usadas para mapeamento de uso e cobertura da terra (BORGES; SANO, 2014). Van Beijma et al. (2014), Jhonnerie et al. (2015) e Akar e Güngör (2015) utilizaram o NDVI, juntamente com valores de reflectância de bandas, métricas texturais e outros índices espectrais para classificação de vegetação pelo algoritmo *Random Forest*, de mineração de dados.

Por sua vez, no presente trabalho, as imagens HH e HV do PALSAR-2 foram processadas com o aplicativo livre Sentinel 1 Toolbox 1.1.1 (STB1), da Agência Espacial Europeia (*European Space Agency* - ESA). Até o momento do processamento dos dados SAR, este era um dos poucos softwares com suporte para dados PALSAR-2 CEOS 1.5 Dual. Como este produto já apresenta certo nível de processamento, as etapas realizadas no STB1 foram a filtragem de efeito *speckle* e extração dos atributos texturais.

Para redução do *speckle* foram testados os filtros de Lee e Frost, com as janelas 3x3, 5x5, 7x7, 9x9, 11x11 e 13x13 pixels. O filtro Lee 3x3 foi escolhido com base na análise do coeficiente de variação e número equivalente de *looks* sobre uma área homogênea de floresta e na avaliação visual de degradação das bordas das fisionomias. Foi também levado em conta, para a escolha de um tamanho de janela mais suave, a transição natural entre classes que ocorrem na paisagem e o reduzido tamanho de alguns fragmentos de classes.

Após a filtragem foram extraídas as métricas texturais de cada polarização baseadas na matriz de co-ocorrência de níveis de cinza (*Gray-level co-occurrence matrix* - GLCM) em uma janela de 5x5. O STB1 permite o cálculo de dez métricas: média, variância, contraste, entropia, energia, dissimilaridade, correlação, homogeneidade, segundo momento angular e máximo coeficiente de correlação.

Diversos trabalhos mostram que o uso de razão, adição ou subtração de bandas, bem como índices a partir das polarizações, auxiliam no mapeamento de uso e cobertura da terra com dados SAR (GUERRA et al., 2010; AVTAR et al., 2012; LI et al., 2012). Entretanto Silva e Santos (2011) não encontraram melhoria estatisticamente significativa na classificação adicionando a multiplicação das imagens amplitude HH\*HV ao conjunto de bandas usados para classificação no semiárido.

A fim de maximizar o uso das duas polarizações, foram geradas novas bandas sintéticas a partir das bandas HH e HV para entrada nos modelos de classificação: HH+HV (GUERRA et al., 2010; LEHMANN et al., 2011), HH-HV (DONG et al., 2012; LONGÉPÉ et al., 2011), HH/HV e HV/HH (AVTAR et al., 2012), além do índice  $NL = (HH*HV)/(HH+HV)$ , utilizado por Lu et al. (2013), chamado aqui de SAR\_IND.

Após realizado os processamentos necessários e geradas as métricas texturais do SAR, bandas sintéticas e índices espectrais, os dados oriundos do OLI e PALSAR-2 foram reamostrados para pixels de 10 metros, corrigidos com base na imagem OLI (RMSE = 0,63 pixel) e recortados para a área de estudo. A reamostragem dos pixels para compatibilizar as imagens foi realizada pelo método vizinho mais próximo e a escolha do tamanho do pixel se deu de modo a não degradar demais a imagem PALSAR-2, e afetar os pixels de 30 m do OLI sem gerar deslocamentos das bordas dos pixels ou criação de novos valores. Com as imagens compatibilizadas pôde-se iniciar as etapas de classificação e avaliação dos mapas temáticos, baseados nas informações coletadas em campo.

### 3.4.2 Classificação isolada e em conjunto dos produtos OLI e PALSAR-2

A partir deste ponto, todas as etapas para classificação, validação, geração dos mapas e gráficos foram executadas em ambiente R (TEAM, 2014), utilizando os pacotes *raster* (HIJMANS et al., 2015), *maptools* (LEWIN-KOH et al., 2012), *GIStools* (BRUNSDON; CHEN, 2014) e *randomForest* (LIAW et al., 2009).

Primeiramente, foi criado um *layer stack* com todas as bandas e, com base nas amostras de treinamento, uma tabela foi gerada com os valores dos pixels de cada classe para cada banda. Esta tabela serviu para alimentar 18 modelos de classificação, assim como feito por Van Beijma et al. (2014), utilizando o minerador

de dados *Random Forest*. Seis modelos foram gerados apenas com dados SAR, seis com dados ópticos e seis com dados ópticos e SAR (Tabela 3.2). Ao todo, foram utilizadas 35 bandas de entrada para classificação temática de uso e cobertura da terra, sendo as seis bandas e dois índices espectrais do OLI e as duas polarizações, cinco bandas sintéticas e vinte métricas de textura do PALSAR-2.

Tabela 3.2 - Combinação das variáveis (bandas) utilizadas para classificação (modelo RF). Colunas marcadas com X indicam as variáveis presentes em cada modelo de classificação. Modelos 1 a 6 são compostos apenas com produtos SAR. Modelos 7 a 12 são alimentados apenas com bandas ópticas. Modelos 13 a 18 são híbridos.

Variáveis de entrada		modelo RF																	
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
SAR	HH_Amplitude	X	X		X		X								X	X	X	X	
	HV_Amplitude	X		X	X		X								X	X	X	X	
	HH_Textura		X		X		X									X	X	X	
	HV_Textura			X	X		X									X	X	X	
	HH+HV					X	X							X				X	
	HH-HV					X	X							X				X	
	HH/HV					X	X							X				X	
	HV/HH					X	X							X				X	
	HH_HV_index					X	X						X	X				X	X
	Óptico	OLI_2						X			X	X				X	X	X	X
OLI_3							X			X	X				X	X	X	X	
OLI_4							X	X	X	X					X	X	X	X	
OLI_5								X	X	X	X				X	X	X	X	
OLI_6								X		X	X				X	X	X	X	
OLI_7									X	X	X				X	X	X	X	
NDVI											X	X	X	X				X	X
EVI											X	X	X	X				X	X
Número de variáveis		2	11	11	22	5	27	3	3	3	6	8	2	3	7	8	28	31	35

O *Random Forest* é dependente de dois parâmetros de entrada: o número de árvores na floresta (*ntree*) e número de variáveis utilizadas em cada nó (*mtry*). Na literatura são descritos alguns esforços buscando otimizar conjuntamente estes dois parâmetros de calibração, a fim de reduzir o erro OOB e produzir melhores resultados (RODRIGUEZ-GALIANO et al., 2012; JHONNERIE et al., 2015; EISAVI et al., 2015).

A abordagem utilizada para calibração dos modelos neste trabalho foi adaptada de Eisavi et al. (2015) e consistiu em aplicar o algoritmo *Random Forest* para cada um dos 18 modelos com 100, 200, 300 ... 1000 árvores e 1, 2, 3 ... N valores de *mtry*, em que N é o número de bandas em cada modelo. Dentre todas as florestas criadas, aquela com o menor erro OOB foi utilizada para classificação. Ex., o RF1, com duas bandas, rodou com 100 a 1000 árvores (de 100 em 100) e *mtry* 1



e 2, totalizando 20 modelos, enquanto o RF18, com 35 bandas, rodou da mesma forma com 100 a 1000 árvores e  $mtry$  de 1 a 35, somando 350 modelos. Portanto, foram testadas todas as combinações de valores de  $mtry$  com 10 tamanhos de floresta.

As classificações foram avaliadas por meio da acurácia global (Equação 3.3) e estatística Kappa (CONGALTON; GREEN, 1999), obtida a partir das matrizes de confusão (Equação 3.4).

$$OA = \frac{\sum_{i=j}^c n_{ij}}{n} \quad (3.3)$$

em que  $c$  é o número de classes,  $n$  o número total de unidades amostrais,  $n_{ij}$  elementos da diagonal da matriz.

$$k = \frac{\theta_1 - \theta_2}{1 - \theta_2} \quad (3.4)$$

em que  $\theta_1$  é a exatidão total observada (Equação 3.3) e  $\theta_2$  é a exatidão calculada aleatoriamente (Equação 3.5).

$$\theta_2 = \frac{\sum_{i=j}^c X_{i+} X_{+j}}{n^2} \quad (3.5)$$

em que  $i+$  é a soma na linha  $i$  e  $+j$  é a soma na coluna  $j$ .

Os valores de Kappa foram comparados pelo teste Z (Equação 3.6) para avaliar se os resultados apresentaram diferenças estatísticas significativas entre si, como realizado por Silva e Santos (2011).

$$Z = \frac{K_2 - K_1}{\sqrt{VarK_1 + VarK_2}} \quad (3.6)$$

em que  $K_1$  e  $K_2$  são valores de kappa e  $VarK_1$  e  $VarK_2$  suas respectivas variâncias, calculadas conforme a Equação 3.7.

$$VarK = \frac{1}{n} \left[ \frac{\theta_1(1 - \theta_1)}{(1 - \theta_2)^2} + \frac{2(1 - \theta_1)(2\theta_1\theta_2 - \theta_3)}{(1 - \theta_2)^3} + \frac{(1 - \theta_1)^2(\theta_4 - 4\theta_2^2)}{(1 - \theta_2)^2} \right] \quad (3.7)$$

em que  $\theta_3$  e  $\theta_4$  são mostrados nas Equações 3.8 e 3.9, respectivamente.

$$\theta_3 = \frac{\sum_{i=j}^c X_{ij}(X_{i+} + X_{+j})}{n^2} \quad (3.8)$$

$$\theta_4 = \frac{\sum_{i=1}^c \sum_{j=1}^c X_{ij}(X_{i+} + X_{+j})^2}{n^3} \quad (3.9)$$

Os *scripts* montados para classificação, confecção dos mapas e validação se encontram nos Apêndices A, B e C.

## 4 RESULTADOS E DISCUSSÃO

Nesta seção são apresentados os resultados gerais dos modelos de classificação e discutidos os resultados dos melhores modelos, quando utilizadas apenas as bandas do sistema óptico e do SAR de forma isolada, bem como a combinação das métricas ou variáveis de entrada desses dois sistemas sensores (Tabela 3.2).

Com relação aos parâmetros de calibração, somente dois modelos obtiveram menor erro OOBE com o padrão de 500 árvores: o 3 e o 17 (não mostrado). Os valores padrões de *mtry* chegaram a resultados ótimos em 7 modelos: 1, 7, 8, 10, 12, 13, 15. Portanto, a combinação de 500 árvores com  $\sqrt{N}$  não produziu nenhum resultado ótimo com menor OOBE, tal como verificado em [Odindi et al. \(2014\)](#), sugerindo a importância de calibração dos parâmetros de entrada para o *Random Forest*.

Na Tabela 4.1 são mostrados os valores da estatística Kappa, variância do Kappa, acurácia global e tempo de processamento em horas dos modelos, evidenciando as melhores classificações de cada conjunto de dados (SAR, óptico e SAR+óptico).

As melhores classificações, em geral, foram obtidas a partir da integração dos

Tabela 4.1 - Resultados das métricas de avaliação estatística dos modelos classificatórios.

	Modelo RF	Acurácia Global (%)	Índice Kappa	Variância do Kappa	Processamento (horas)
SAR	1	30,46	0,238	9,73393e-06	1,6
	2	36,23	0,296	1,063926e-05	17,4
	3	38,88	0,328	1,071825e-05	17,1
	<b>4</b>	<b>44,60</b>	<b>0,390</b>	1,136159e-05	61,1
	5	29,95	0,232	9,649894e-06	7,7
	6	44,54	0,389	1,135425e-05	56,9
OLI	7	57,01	0,527	1,121606e-05	1,2
	8	68,94	0,658	1,002964e-05	1,0
	9	67,89	0,646	1,018479e-05	1,0
	<b>10</b>	<b>76,88</b>	<b>0,744</b>	8,427037e-06	2,1
	11	76,86	0,743	8,451471e-06	3,2
	12	56,57	0,523	1,151954e-05	0,7
SAR+OLI	13	67,29	0,638	1,056907e-05	2,5
	14	67,43	0,639	1,057313e-05	7,6
	<b>15</b>	<b>82,96</b>	<b>0,810</b>	6,854476e-06	4,2
	16	82,61	0,806	6,97785e-06	46,5
	17	82,15	0,801	7,117033e-06	53,9
	18	82,41	0,804	7,046165e-06	69,7

sensores OLI e PALSAR-2, o que está de acordo com a literatura (NA et al., 2015; JHONNERIE et al., 2015) e confirma a hipótese testada, seguidos das classificações usando somente a imagem OLI. O modelo 15 atingiu os melhores resultados estatísticos.

A comparação entre os índices Kappa de cada modelo de classificação, por meio do teste Z, e sua significância estatística são mostradas na Tabela 4.2. Pode-se destacar que, apesar de o modelo 15 (composto pelas bandas espectrais do OLI e imagens em amplitude HH e HV do PALSAR-2) apresentar o melhor desempenho classificatório, os modelos 15, 16, 17 e 18 (estes três últimos formados pelas bandas espectrais inclusas no 15 e demais métricas extraídas dessas bandas) não apresentam diferenças estatísticas significativas de valores Kappa entre si.

A adição de texturas GLCM, razão de bandas e índices espectrais não resultou em melhor desempenho de caracterização de uso e cobertura da terra na região de tensão ecológica de Roraima quando considerada a integração OLI e PALSAR-2. O tempo computacional empreendido no modelo 15 foi de 4,2 horas, enquanto os modelos 16, 17 e 18 gastaram 46, 54 e 69 horas, respectivamente. Assim, um resultado melhor pôde ser atingido com menos informações de entrada garantindo maior eficiência computacional.

Os modelos 13 e 14 (apenas com métricas extraídas do OLI e PALSAR-2) não apresentaram diferenças significativas quando comparados ao modelo 9, composto pelas bandas 4, 5 e 7 do OLI. Dentre os modelos formados apenas pelos dados ópticos, os de número 12 (NDVI e EVI) e 7 (bandas 2, 3 e 4 - visível) não apresentaram diferença significativa entre si, bem como os modelos 10 (todas as 6 bandas espectrais) e 11 (10 + NDVI e EVI).

Quando considerados somente os atributos SAR, os modelos 6 (todas as 22 bandas) e 4 (amplitude e texturas HH e HV) não foram significativamente diferentes, como também ocorreu com os modelos 5 (apenas índices SAR) e 1 (amplitude HH e HV). Zhu et al. (2012) empregaram oito métricas texturais para cada polarização HH e HV do PALSAR/ALOS-1 numa região urbana e periurbana. Ao contrário do encontrado para a região de Roraima, os autores obtiveram uma melhoria significativa na exatidão global, de 31% com as imagens HH e HV em dB para 72% com a adição das texturas.

A adição de índices espectrais ópticos e métricas texturais e índices SAR não

Tabela 4.2 - Teste Z aplicado aos valores de Kappa dos modelos de classificação. \*não significativo a 95%. \*\*não significativo a 99%. Demais valores representam diferenças estatísticas significativas entre os modelos de classificação.

RF	PALSAR-2						OLI						PALSAR-2 + OLI					
	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	
1	12,91	20,06	33,18	-1,24*	33,05	63,12	94,43	91,36	118,85	118,69	61,80	88,87	89,24	140,66	139,16	137,41	138,37	
2	-	7,02	20,06	-14,14	19,94	49,34	79,52	76,58	102,65	102,51	48,15	74,30	74,66	123,04	121,65	120,03	120,93	
3	-	-	13,13	-21,30	13,00	42,32	72,25	69,35	95,02	94,89	41,18	67,13	67,50	115,03	113,67	112,09	112,96	
4	-	-	-	-34,43	-0,12*	28,74	57,82	55,01	79,60	79,48	27,71	52,97	53,33	98,53	97,26	95,77	96,59	
5	-	-	-	-	34,31	64,44	95,86	92,78	120,40	120,25	63,11	90,26	90,64	142,36	140,84	139,08	140,05	
6	-	-	-	-	-	28,87	57,95	55,15	79,75	79,63	27,83	53,10	53,46	98,69	97,41	95,93	96,75	
7	-	-	-	-	-	-	28,39	25,69	49,09	48,98	-0,84*	23,89	24,26	66,81	65,63	64,26	65,03	
8	-	-	-	-	-	-	-	-2,68	20,18	20,09	-29,06	-4,26	-3,89	37,26	36,15	34,84	35,58	
9	-	-	-	-	-	-	-	-	22,88	22,79	-26,37	-1,61*	-1,23*	40,01	38,89	37,58	38,32	
10	-	-	-	-	-	-	-	-	-	-0,08*	-49,61	-24,33	-23,94	16,99	15,90	14,61	15,34	
11	-	-	-	-	-	-	-	-	-	-	-49,51	-24,24	-23,84	17,06	15,97	14,68	15,41	
12	-	-	-	-	-	-	-	-	-	-	-	24,58	24,94	67,19	66,03	64,66	65,42	
13	-	-	-	-	-	-	-	-	-	-	-	-	0,37*	41,32	40,21	38,91	39,64	
14	-	-	-	-	-	-	-	-	-	-	-	-	-	40,90	39,80	38,50	39,23	
15	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-1,08*	-2,37**	-1,64*	
16	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-1,28*	-0,55*	
17	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0,73*	

conferiu melhores resultados quando PALSAR-2 e OLI foram classificados conjuntamente, bem como à classificação das bandas 2 a 7 do OLI. Somente no caso do PALSAR-2 isolado a adição de texturas GLCM contribui para um resultado melhor, ainda assim, aquém do desempenho classificatório OLI e OLI+PALSAR-2.

A seguir serão apresentados os resultados e discussões dos modelos 4 (PALSAR-2), 10 (OLI) e 15 (PALSAR-2 + OLI).

#### 4.1 Classificação PALSAR-2/ALOS-2

Dentre as classificações utilizando somente dados do PALSAR-2 e derivados, o modelo 4 foi o que apresentou maior acurácia global e índice Kappa. Este modelo foi composto pela combinação das imagens em amplitude e atributos texturais, somando 22 variáveis de entrada. Os parâmetros *ntree* e *mtry* que conferiram o menor erro OOB na calibração do modelo foram 900 árvores e 10 variáveis, respectivamente. O tempo computacional exigido para calibração e classificação foi de 61 horas.

A importância das bandas para classificação é mostrada na Figura 4.1. Na Figura 4.2 são plotados os valores das amostras das classes com maior acerto relativo, no espaço de atributos das duas bandas mais importantes. A análise da importância das variáveis sugere que os atributos texturais contribuem mais para o modelo do que as imagens em amplitude, indicando o potencial das imagens-textura para melhorar o desempenho classificatório de imagens SAR.

Os atributos texturais média e variância foram os principais, com diminuição média do erro de 23% e 20%, respectivamente. Essas métricas homogenizam os valores de resposta das diferentes classes, contribuindo para a caracterização das tipologias. A contribuição maior de imagens-textura derivadas da banda HV se dá pela maior interação e capacidade de separabilidade de classes de vegetação nessa polarização.

No trabalho de [Van Beijma et al. \(2014\)](#), as decomposições polarimétricas apresentaram maior importância em relação às imagens de intensidade. Segundo [Xaud \(2013\)](#), as imagens de textura foram muito utilizadas, principalmente antes do uso de imagens polarimétricas, que possibilitam outras alternativas de extração de informações de imagens SAR. Adicionalmente, o autor sugere a geração de texturas quando não é possível a decomposição polarimétrica (com quatro polarizações e fase), a fim de aumentar a separabilidade das classes.




Figura 4.1 - Importância das bandas no modelo *Random Forest 4* - PALSAR-2. O eixo x é a medida de decréscimo médio da acurácia (*mean decrease in accuracy*), normalizada entre 0 e 1.

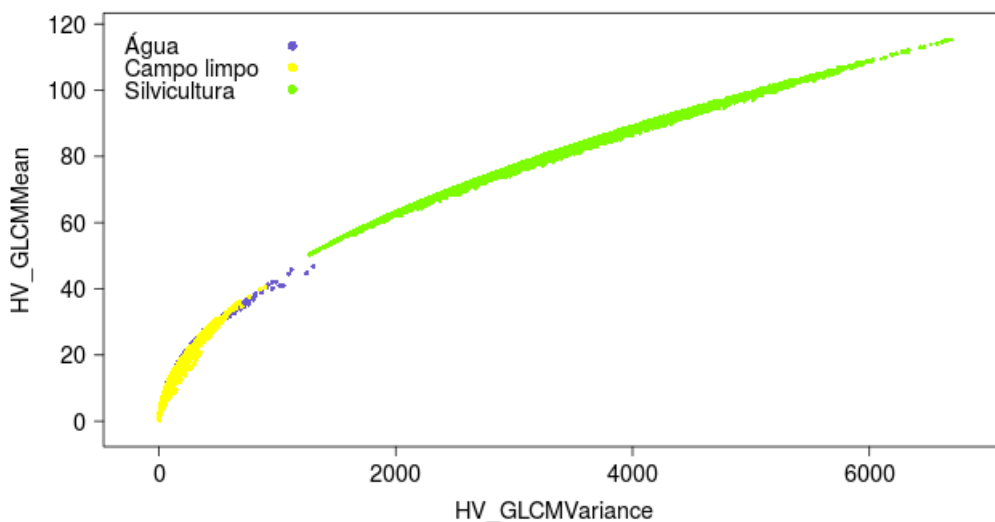


Figura 4.2 - Espaço de atributos das duas melhores bandas (HV\_Mean e HV\_Variance) do modelo 4 com as classes de maior acurácia do produtor (água, campo limpo e silvicultura).

O mapa gerado com essa combinação de bandas é apresentado na Figura 4.3. A matriz de confusão é mostrada na Tabela 4.3 com valores de Kappa = 0,39 e OA = 44,6%.

Quando comparadas às classificações temáticas utilizando dados ópticos, o emprego de dados SAR geralmente resulta em menores índices Kappa e Acurácia Global. No entanto a adição de imagens-textura e índices, como o NL (SAR\_IND), pode melhorar as classificações (LI et al., 2012).

Lu et al. (2013) obtiveram um valor de Kappa de 0.39 e acurácia global de 45% classificando as imagens HH e HV do PALSAR/ALOS-1 com o NL n região da Rodovia Transamazônica (BR-230), entre Altamira e Brasil Novo, PA. Li et al. (2012), na mesma região e sensor, obtiveram valores de kappa entre 0,29 classificando somente a imagem HH e 0,46 quando adicionada a textura ao HH. As classificações com NL ficaram em torno de 0,34. Os valores obtidos neste trabalho estão de acordo com o encontrado na literatura, destacando que a região roraimense se caracteriza pela tensão ecológica, onde há uma complexidade de domínios maior do que as áreas estudadas nos outros trabalhos.

Com base na porcentagem de pixels corretamente classificados, de acordo com a referência (acurácia do produtor - PA), “silvicultura” (95%), “água” (83,72%) e “campo limpo” (82,53%) apresentaram as melhores discriminações temáticas com os dados em banda L. Entretanto, há confusão entre as classes “silvicultura” e “floresta”, bem como entre “campo limpo” e “água”.

As bandas que mais contribuíram para a classe “silvicultura” foram HV\_Mean e HV\_Correlation. Essas métricas texturais obtidas da polarização HV são a medida do valor médio dos pixels em uma vizinhança (neste trabalho adotada como 5x5), no caso da HV\_Mean, e HV\_correlation é uma medida da dependência linear do pixel em relação à vizinhança, onde 1 indica correlação positiva máxima entre os pixels vizinhos, -1 a correlação negativa e 0 sem correlação (FERGUSON, 2007).

Polarizações cruzadas, como HV, são mais sensíveis às fisionomias florestais, especialmente em banda L (SANTOS et al., 2000; LI et al., 2012). Dessa forma, as imagens GLCM de média e correlação são importantes para identificação das áreas de cultivos de acácia. Assim como as florestas naturais, as plantações de acácia também apresentam uma densidade de troncos e galhos de alta resposta






Figura 4.3 - Classificação do PALSAR-2 com as imagens HH e HV em amplitude e atributos texturais.

Tabela 4.3 - Matriz de confusão do modelo com melhor desempenho classificatório utilizando dados PALSAR-2 (modelo 4). Classes: (1) agricultura, (2) água, (3) campinarana, (4) campo cerrado, (5) campo limpo, (6) campo sujo, (7) capoeira inicial (S51), (8) capoeira intermediária (SS2), (9) cerrado queimado, (10) cerrado *Strictu Sensu* (cerrado SS), (11) floresta, (12) pasto limpo, (13) pasto sujo, (14) silvicultura, (15) silvicultura cortada, (16) solo exposto e (17) veredas.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	Total	UA
1 Agricultura	419	11	162	70	39	20	0	0	102	0	0	18	3	0	16	58	0	918	45,64
2 Água	60	535	0	30	120	7	0	0	20	0	0	9	0	0	4	121	0	906	59,05
3 Campinarana	37	1	1597	149	8	114	9	6	52	7	7	53	167	6	217	106	29	2565	62,26
4 Campo cerrado	151	35	147	1004	37	98	7	73	333	0	0	47	227	1	106	85	3	2354	42,65
5 Campo Limpo	25	1	1	80	1432	198	0	0	314	0	0	213	0	0	0	120	0	2384	60,06
6 Campo sujo	24	2	11	116	22	26	0	1	123	1	0	17	6	0	3	32	3	387	6,71
7 Capoeira inicial	0	0	2	0	0	0	0	0	0	0	0	0	4	3	0	0	0	9	0
8 Capoeira intermediária	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
9 Cerrado queimado	11	25	22	164	23	19	0	0	70	0	0	29	62	0	148	3	0	576	12,15
10 Cerrado SS	0	0	1	0	0	0	1	0	0	0	5	0	0	0	1	0	0	8	0
11 Floresta	0	0	80	0	0	0	6	87	0	346	1533	0	0	125	0	0	54	2231	68,71
12 Pasto limpo	182	10	189	619	13	150	2	41	445	0	0	144	343	0	1307	85	0	3530	4,07
13 Pasto sujo	13	0	43	156	0	5	2	14	4	5	0	10	41	1	148	1	2	445	9,21
14 Silvicultura	13	0	1488	29	0	0	100	38	0	139	1137	0	71	2660	0	0	30	5705	46,62
15 Silvicultura cortada	73	12	153	105	7	145	1	38	17	2	0	12	67	0	1440	212	0	2284	63,04
16 Solo exposto	8	7	0	7	34	1	0	0	4	0	0	4	0	0	0	49	0	114	42,98
17 Vereda	2	0	97	0	0	0	0	9	0	0	1	0	23	4	0	0	2	138	1,44
Total	1018	639	3993	2529	1735	783	128	307	1484	500	2683	556	1014	2800	3390	872	123	24554	
PA	41,15	83,72	39,99	39,69	82,53	3,32	0	0	4,71	0	57,13	25,89	4,04	95	42,47	5,61	1,62		
OA (%)	44,60																		
Kappa	0,390																		




Figura 4.4 - Diagrama de dispersão dos valores amostrais das classes Floresta e Silvicultura nas duas bandas que mais contribuíram para Silvicultura (HV\_Correlation e HV\_Mean).

na polarização HV e com certa homogeneidade espacial, resultando em pixels com valores médios altos e pixels correlacionados. As estruturas florestais de formações primárias e de cultivos de acácia podem ser semelhantes nos plantios mais antigos, gerando a confusão espectral nas bandas com maior importância para “silvicultura” (Figura 4.4), como relatado por Rakwatin et al. (2012). Assim, esta monocultura é superestimada frente às áreas de floresta.

Já as classes “água” e “campo limpo” apresentam baixo retroespalhamento em banda L, como ocorre com solos expostos e erodidos (ALMEIDA-FILHO; SHIMABUKURO, 2000). Alguns fatores que fazem com que haja essa resposta espectral são a pouca rugosidade da superfície para a banda L, como a lâmina d’água (BAGHDADI et al., 2008) e a dominância de um estrato graminóide regular, de baixa densidade de biomassa presente nos campos limpos, em comparação com outras fisionomias de savana (SANTOS et al., 2002; SANO et al., 2005). Assim, superfícies mais lisas tendem a apresentar espalhamento especular, diminuindo o sinal que retorna ao sensor (Van der Sanden et al., 1997).

Portanto, a rugosidade da superfície de corpos d’água e de formações de campo limpo, associado à sua quantidade de biomassa, em relação ao comprimento de onda da banda L do PALSAR-2 (aproximadamente 23 cm), confere à essas classes valores baixos de resposta, tanto em HH quanto em HV, como evidenciado na

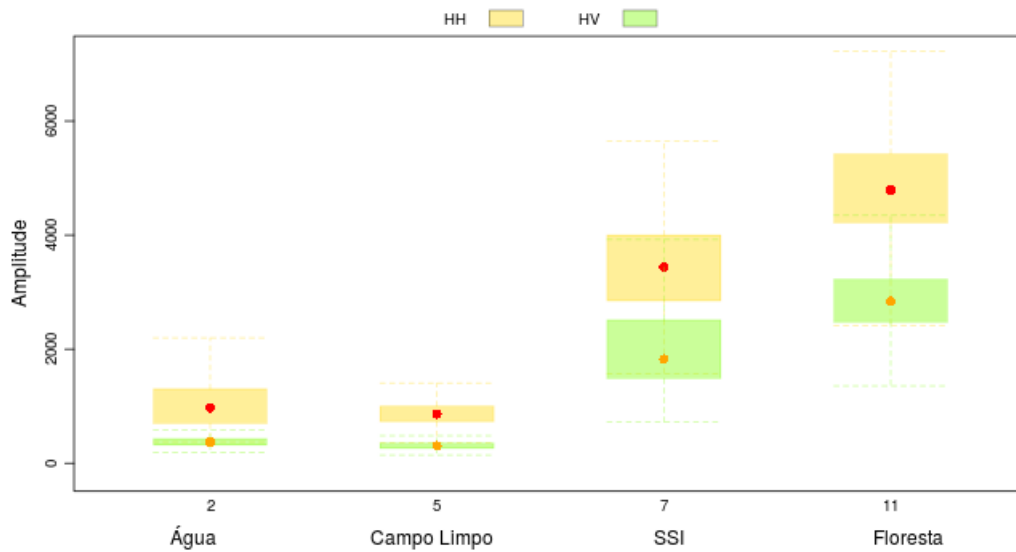


Figura 4.5 - Boxplots com valores em amplitude (HH - amarelo e HV - verde) das amostras de água e campo limpo, comparadas com capoeira inicial (SSI) e floresta. O limite inferior da caixa representa o primeiro quartil, o limite superior é o terceiro quartil. Os pontos representam os valores médios e as linhas pontilhadas os valores máximos e mínimos.

Figura 4.5. Essa característica confere, no espaço de atributos, maior separabilidade em relação às demais classes, preservando contudo, uma certa confusão entre elas próprias, apesar desses dois alvos terem uma constituição totalmente diversa.

Sucessões secundárias, cerrado SS e veredas obtiveram os menores acertos (0 - 1,62%). Tal resultado pode estar relacionado a dois fatores principais: o arranjo estrutural dessas fisionomias e, talvez, às poucas amostras de treinamento nessas áreas (MILLARD; RICHARDSON, 2015). A confusão dessas classes aconteceu, principalmente, com florestas e silvicultura, o que poderia ser esperado. Bitencourt et al. (2007) encontraram valores de biomassa, volume cilíndrico e retroespalhamento em banda L semelhantes entre cerrado SS e cerradão (formação florestal) em um fragmento em São Paulo.

O lavrado apresenta um regime de queima de aproximadamente 2,5 anos, com aproximadamente 38% de sua área queimando anualmente (BARBOSA; FEARNside, 2005b). No entanto, os cerrados queimados apresentaram muita confusão com demais classes de Cerrado na classificação. Ao contrário do efeito do fogo em formações florestais (XAUD et al., 2013; SANTOS et al., 2013), as queimas frequentes pouco alteram o sinal de retroespalhamento das formações savânicas

em banda L. Nesse sentido, [Menges et al. \(2004\)](#) não encontraram diferenças significativas na resposta de áreas de savana australiana queimada, em banda L e P, atribuindo a ligeira diminuição do sinal dessas áreas à perda de umidade do solo.

Apesar do grande número de classes e da complexidade da paisagem, o mapeamento da área de estudo com dados PALSAR-2 pôde distinguir fisionomias de acordo com a biomassa e estrutura, fornecendo informações importantes da paisagem que podem ser úteis, principalmente, na ausência de dados ópticos ([LAURIN et al., 2013](#)). Resultado semelhante foi encontrado por [Simard et al. \(2000\)](#) no mapeamento de dez classes em toda África Central, com JERS-1 (banda L), mostrando que savanas abertas, florestas e vegetação alagada são bem discriminadas pelos valores de resposta em amplitude.

Dessa forma, o uso de dados PALSAR-2 nessa região de tensão ecológica, em que a ocorrência de nuvens é constante, pode auxiliar no monitoramento temporal de ecossistemas florestais e Cerrados abertos, apesar da dificuldade de distinções intra-classes, diretamente relacionada ao nível de estratificação temático, como observado por [Araújo et al. \(1999\)](#).

Esse monitoramento é relevante, pois enquanto o município de Mucajaí apresenta a maior taxa de desmatamento florestal de Roraima ([INPE, 2014](#)), as queimadas nas savanas abertas da região são as que mais contribuem para a liberação bruta de carbono para a atmosfera, em comparação com demais fisionomias do lavrado ([BARBOSA; FEARNSTIDE, 2005a](#)). Apesar da pouca variação no retroespalhamento da vegetação savânica sadia e queimada, transformações radiométricas temporais em banda L podem favorecer a detecção de mudanças sutis na paisagem do lavrado ([ALMEIDA-FILHO; SHIMABUKURO, 2000](#)). Na porção florestal, a análise polarimétrica pode evidenciar distúrbios devido à alteração no mecanismo de espalhamento da vegetação, que varia dentre as tipologias de uso e cobertura da terra ([SANTOS et al., 2009](#)).

## 4.2 Classificação OLI/Landsat-8

Dado o conjunto de bandas OLI e índices espectrais, o modelo que resultou em melhor mapeamento de uso e cobertura da terra foi o 10. Este modelo é composto apenas pelas bandas espectrais do OLI 2, 3, 4, 5, 6 e 7. Os parâmetros de calibração *n<sub>tree</sub>* e *m<sub>try</sub>* utilizados que conferiram o menor erro OOB foram 600 árvores e 2 variáveis.




Figura 4.6 - Importância das bandas no modelo *Random Forest* 10 - OLI. O eixo x é a medida de decréscimo médio da acurácia (*mean decrease in accuracy*), normalizada entre 0 e 1.

O tempo gasto para rodar a calibração e classificação deste modelo foi de duas horas.

Na Figura 4.6 são mostradas as variáveis de entrada em ordem de importância para o modelo. A banda 5 do OLI, de maior importância (54%), é referente ao infravermelho próximo (NIR), seguida pelas bandas 7 (50%), correspondente ao infravermelho de ondas curtas (SWIR), e 4 (45%), posicionada na região espectral do vermelho.

As bandas do NIR e vermelho são amplamente utilizadas para fins de discriminação de tipologias vegetacionais, pois a reflectância da vegetação sadia naquela banda é relativamente alta, enquanto na banda do vermelho é maior a contribuição de solos expostos, vegetações abertas e baixa resposta da vegetação verde de maior biomassa. Já o SWIR fornece informações sobre o conteúdo de água na vegetação.

No entanto, as demais bandas 6 (SWIR), 3 (verde) e 2 (azul) do OLI também apresentaram contribuição relativamente alta, sugerindo o uso conjunto das bandas espectrais do OLI para melhores mapeamentos de uso e cobertura da terra nessa região caracterizada pela sua complexidade de tipologias. Isso pode ser evidenciado ao comparar os resultados das classificações a partir dos modelos que usaram apenas as bandas ópticas. O modelo 10 somente não apresentou melhora significativa no kappa em relação ao 11 (Vide Tabelas 4.1 e 4.2), que além de usar todas as bandas espectrais, incluiu o NDVI e EVI, mas sem contribuição desses índices para maior acurácia do mapeamento.

Chan e Paelinckx (2008) utilizaram dados hiperespectrais HyMap aerotransportados para mapeamento de fisionomias abertas e arbóreas com *Random Forest* em uma paisagem belga. De 25 melhores bandas selecionadas pelo *Random Forest*, 17 se encontravam na região do SWIR, apenas duas no NIR e seis no visível, sendo 4 na região do vermelho.

Sesnie et al. (2008) empregaram o sensor TM e variáveis extraídas do modelo digital de elevação do *Shuttle Radar Topography Mission* (SRTM) para mapeamento de classes de vegetação e usos agrícolas entre Costa Rica e Nicarágua. Dentre o conjunto de dados do TM, as variáveis mais importantes foram a banda 1 (azul), 5 (SWIR) e 7 (SWIR).

Destaca-se, portanto, a contribuição geral do SWIR sobre o NIR para classificação de uso e cobertura da terra, ao contrário do resultado obtido para a paisagem de Roraima. No entanto, Braun e Hochschild (2015) apresentam as bandas OLI\_5 e OLI\_7 com maior importância, respectivamente, em uma região semiárida. Isso sugere a importância do NIR em regiões com fisionomias mais heterogêneas. O diagrama de dispersão nas bandas NIR e SWIR com os valores amostrais de reflectância de algumas classes com maior contribuição para a exatidão da classificação é mostrado na Figura 4.7.

A matriz de confusão é mostrada na Tabela 4.4. O valor de Kappa é 0,744 e a acurácia global 76,88%. O mapa elaborado a partir desse modelo de classificação é mostrado na Figura 4.8. Pavanelli et al. (2014) chegaram ao valor de kappa de 0,86 e exatidão global de 89% com as bandas 2 a 6 do OLI na mesma região de tensão ecológica, porém em uma área menor e com estratificação temática de nove classes, sem distinção de pastagens, estágios sucessionais e de algumas fisionomias de savana, que conferiram maiores taxas de erros.

As classes com maior acerto foram “água”, “agricultura”, “campinarana”, “Cerrado queimado”, “floresta”, “silvicultura” e “silvicultura cortada”. A baixa reflectância da água no infravermelho confere boa separabilidade dessa classe dentre as demais, como evidenciado na Figura 4.7, e a banda de maior importância para sua classificação foi a OLI\_7, em que a reflectância é próxima a zero.

Há três conjuntos de pontos amostrais de agricultura, referentes aos cultivos comerciais de soja em pivôs, milho e arroz irrigado, que foram amostrados

Tabela 4.4 - Matriz de confusão do modelo com melhor desempenho classificatório utilizando dados OLI (modelo 10). Classes: (1) agricultura, (2) água, (3) campinarana, (4) campo cerrado, (5) campo limpo, (6) campo sujo, (7) capoeira inicial (SS1), (8) capoeira intermediária (SS2), (9) cerrado queimado, (10) cerrado *Strictu Sensu* (cerrado SS), (11) floresta, (12) pasto limpo, (13) pasto sujo, (14) silvicultura, (15) silvicultura cortada, (16) solo exposto e (17) veredas.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	Total	UA
1 Agricultura	1016	0	0	46	0	0	0	0	0	0	0	35	55	0	0	228	0	1380	73,62
2 Água	0	674	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	674	100
3 Campinarana	0	0	3610	2	1	0	19	0	0	2	0	0	16	0	9	0	0	3659	98,66
4 Campo cerrado	0	0	9	1555	143	479	0	0	55	0	0	64	27	0	27	22	21	2402	64,73
5 Campo Limpo	0	0	3	282	1154	50	0	0	14	0	0	123	0	0	35	35	0	1696	68,04
6 Campo sujo	0	0	0	107	50	82	0	0	0	0	0	3	0	0	0	22	0	264	31,06
7 Capoeira inicial	0	0	0	0	0	0	19	20	0	27	9	0	0	0	0	0	2	77	24,67
8 Capoeira intermediária	0	0	10	0	0	0	0	16	0	0	30	0	0	0	0	0	0	56	28,57
9 Cerrado queimado	0	0	9	0	0	0	0	0	1297	0	0	0	0	0	34	285	0	1625	79,81
10 Cerrado SS	0	0	91	0	0	0	4	0	0	250	17	0	20	0	0	8	4	394	63,45
11 Floresta	0	0	0	0	0	0	0	62	0	125	2474	0	0	33	0	0	47	2741	90,25
12 Pasto limpo	0	0	79	491	337	125	9	0	60	0	0	162	581	0	0	6	12	1862	8,7
13 Pasto sujo	0	0	59	46	39	44	2	176	0	54	2	56	312	0	0	75	5	870	35,86
14 Silvicultura	0	0	0	0	0	0	45	9	0	7	118	0	3	2736	0	0	10	2991	92,37
15 Silvicultura cortada	0	0	0	0	0	3	0	0	58	0	0	0	0	0	3285	10	0	3446	95,32
16 Solo exposto	2	0	0	0	0	0	0	0	0	0	0	113	0	0	0	181	0	296	38,85
17 Vereda	0	0	9	0	0	0	0	9	24	0	12	33	0	0	4	0	22	113	19,46
Total	1018	634	3993	2529	1736	783	107	307	1484	477	2683	556	1014	2800	3390	872	123	24546	
PA	99,80	100	90,40	61,48	66,47	10,47	17,75	5,21	87,39	52,41	92,21	29,13	30,76	98,67	96,90	20,75	17,88		
OA (%)	76,88																		
Kappa	0,744																		



como uma única classe. No entanto, é notável a separabilidade entre elas dado o desenvolvimento fenológico de cada cultura no momento do trabalho de campo e do período de aquisição do imageamento dos sensores sob investigação (EBERHARDT et al., 2015).

As manchas de agricultura estão presentes majoritariamente na porção savânica. Trinta por cento dos usos antropogênicos do lavrado é para fins agrícolas (BARBOSA; CAMPOS, 2011) que se encontram em expansão na região estudada (SILVA et al., 2015; PAVANELLI et al., 2015).

Da mesma forma, os plantios de acácia na região estão localizados no lavrado e seu monitoramento é importante, dado o potencial invasivo dessa planta nas savanas de Roraima (AGUIAR et al., 2014). A introdução dessa espécie em Roraima se deu em 2002 para produção de celulose (ARCO-VERDE et al., 2005), mas o projeto foi abandonado em 2006. Com isso, os talhões foram abandonados e a falta de manejo fez com que os indivíduos desenvolvessem dosséis bastante heterogêneos, causando confusão das monoculturas com florestas primárias e sucessões secundárias por conta da variação da reflectância do dossel dos talhões. Isso induz ao erro comissionário dos pixels classificados como silvicultura na porção florestal da paisagem.




Figura 4.7 - Espaço de atributos das duas melhores bandas (NIR e SWIR) do modelo 10 com algumas classes de maior contribuição para a exatidão do mapeamento. Valores dos eixos em reflectância de superfície.



Confusões entre savanas abertas com pastagens eram esperadas, uma vez que essas classes apresentam respostas espectrais similares que dificultam sua separabilidade (SANO et al., 2007). Uma das soluções reportadas na literatura para a distinção entre pastagens e savanas é a análise de séries temporais intra anuais, pois a fenologia dessas classes apresenta padrões espaço-temporais distintos (GALFORD et al., 2008; MÜLLER et al., 2015).

Esse comportamento fenológico explica a correta alocação espacial das classes de Cerrado no domínio savânico e de pastagens na porção florestal, distintos em condições edáficas, uma vez que o imageamento com OLI foi feito no período seco, em que o maior verdor das pastagens permite separá-las da vegetação natural (RATANA et al., 2005). A precipitação acumulada nos trinta dias que antecederam o imageamento foi de apenas 6,9 mm, característicos do período seco da região, que se estende de dezembro a março.

A dificuldade de caracterização com maior exatidão dentre as classes de savana com menor biomassa, principalmente quando comparados campo sujo e campo cerrado, se dá pela transição sutil dessas tipologias na paisagem, o que é um fator limitante para classificação com maior nível de estratificação temática em diversas zonas tropicais, conforme também constatado por Laurin et al. (2013).

### 4.3 Integração PALSAR-2/ALOS-2 e OLI/Landsat-8

Os melhores desempenhos classificatórios foram atingidos a partir do uso conjunto do OLI e PALSAR-2. Dentre os modelos que apresentaram maiores índices Kappa e acurácia global, o 15 foi o superior. Este modelo consistiu no emprego das seis bandas espectrais do OLI e imagens HH e HV em amplitude do PALSAR-2. Os parâmetros *ntree* e *mtry* foram 600 árvores e 3 variáveis, respectivamente. Foram gastas 4,2 horas para processar as etapas de calibração e classificação do modelo.

As variáveis de entrada mais importantes para o modelo foram os atributos ópticos, com uma contribuição relativamente baixa das polarizações PALSAR-2 (Figura 4.9). Dentre essas, destaca-se a polarização HV (em torno de 18%) sobre HH (8%). A ordem de importância das bandas ópticas não apresentou grandes diferenças se comparada ao modelo 10 (somente OLI), com maiores contribuições do NIR e SWIR, seguidas pela banda do vermelho.




Figura 4.9 - Importância das bandas no modelo *Random Forest* 15 - OLI+PALSAR-2. O eixo x é a medida de decréscimo médio da acurácia (*mean decrease in accuracy*), normalizada entre 0 e 1.

Esse padrão também pode ser observado em [Braun e Hochschild \(2015\)](#), que empregaram o OLI, o Sentinel-1 (banda C) e SRTM em uma região semiárida usando o *Random Forest*. As seis bandas espectrais do OLI apareceram como as mais importantes, sendo as duas primeiras o NIR e o SWIR, seguidas do SRTM e Sentinel-1. Da mesma forma, a importância das variáveis relatada por [Zhu et al. \(2012\)](#) apresenta as bandas ópticas (ETM+) seguidas do PALSAR/ALOS-1 HV e HH.

A matriz de confusão é mostrada na Tabela 4.5 e o mapa resultante deste modelo na Figura 4.10. A exatidão global da classificação foi de 82,96% e o Kappa de 0,81. Apesar da baixa importância relativa do PALSAR-2, a adição das polarizações HH e HV contribuiu para o aumento da exatidão global em 6% e melhora significativa no Kappa, com relação ao desempenho do modelo com apenas as bandas ópticas.

Portanto, o resultado encontrado está em concordância com a literatura, confirmando a hipótese de que a sinergia entre tais sensores pode resultar em melhores mapeamentos de uso e cobertura da terra.

O ganho na exatidão se deve, principalmente, à melhor distinção das classes de savana aberta (campo limpo e campo cerrado) e pasto sujo, que apresentam pouca biomassa e baixo sinal de retorno.

Campo limpo e campo cerrado obtiveram mais de 20% de incremento na acurácia do produtor, em relação ao OLI, e pasto sujo chegou a 44% de incremento

Tabela 4.5 - Matriz de confusão do modelo com melhor desempenho classificatório utilizando dados PALSAR-2 e OLI (modelo 15). Classes:

(1) agricultura, (2) água, (3) campinarana, (4) campo cerrado, (5) campo limpo, (6) campo sujo, (7) capoeira inicial (SS1), (8) capoeira intermediária (SS2), (9) cerrado queimado, (10) cerrado *Strictu Sensu* (cerrado SS), (11) floresta, (12) pasto limpo, (13) pasto sujo, (14) silvicultura, (15) silvicultura cortada, (16) solo exposto e (17) veredas.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	Total	UA
1 Agricultura	1018	0	0	69	0	0	0	7	0	0	0	32	44	0	0	251	0	1421	71,63
2 Água	0	674	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	674	100
3 Campinarana	0	0	3812	19	0	4	38	14	0	57	13	0	24	0	137	0	6	4124	92,43
4 Campo cerrado	0	0	15	2100	31	502	0	0	72	0	0	104	112	0	26	9	31	3002	69,95
5 Campo Limpo	0	0	0	94	1540	82	0	0	42	0	0	120	0	0	0	43	0	1921	80,16
6 Campo sujo	0	0	0	79	47	79	0	0	4	0	0	1	2	0	0	6	0	218	36,23
7 Capoeira inicial	0	0	16	0	0	0	29	16	0	2	0	0	0	0	0	0	4	67	43,28
8 Capoeira intermediária	0	0	10	0	0	0	3	7	0	6	20	0	0	0	0	0	0	46	15,21
9 Cerrado queimado	0	0	8	17	0	0	0	0	1532	0	0	0	0	0	34	300	0	1711	79,01
10 Cerrado SS	0	0	51	15	0	0	3	0	0	223	13	0	22	0	0	2	4	333	66,96
11 Floresta	0	0	0	0	0	0	0	60	0	133	2498	0	0	32	0	0	49	2772	90,11
12 Pasto limpo	0	0	44	84	101	59	0	0	0	0	0	166	42	0	0	0	4	500	33,20
13 Pasto sujo	0	0	12	45	4	57	10	169	0	69	2	48	765	0	0	84	0	1265	60,47
14 Silvicultura	0	0	6	0	0	0	44	0	0	1	114	0	3	2763	0	0	10	2941	93,94
15 Silvicultura cortada	0	0	18	5	13	0	0	0	14	0	0	0	0	0	3193	9	0	3252	98,67
16 Solo exposto	0	0	0	2	0	0	0	0	0	0	0	85	0	0	0	168	0	255	65,88
17 Vereda	0	0	1	0	0	0	1	34	0	9	23	0	0	5	0	0	15	88	17,04
Total	1018	674	3993	2529	1736	783	128	307	1484	500	2683	556	1014	2800	3390	872	123	24590	
PA	100	100	95,46	83,03	88,70	10,08	22,65	2,28	91,10	44,60	93,10	29,85	75,44	98,67	94,18	19,26	12,19		
OA (%)																		82,96	
Kappa																		0,810	

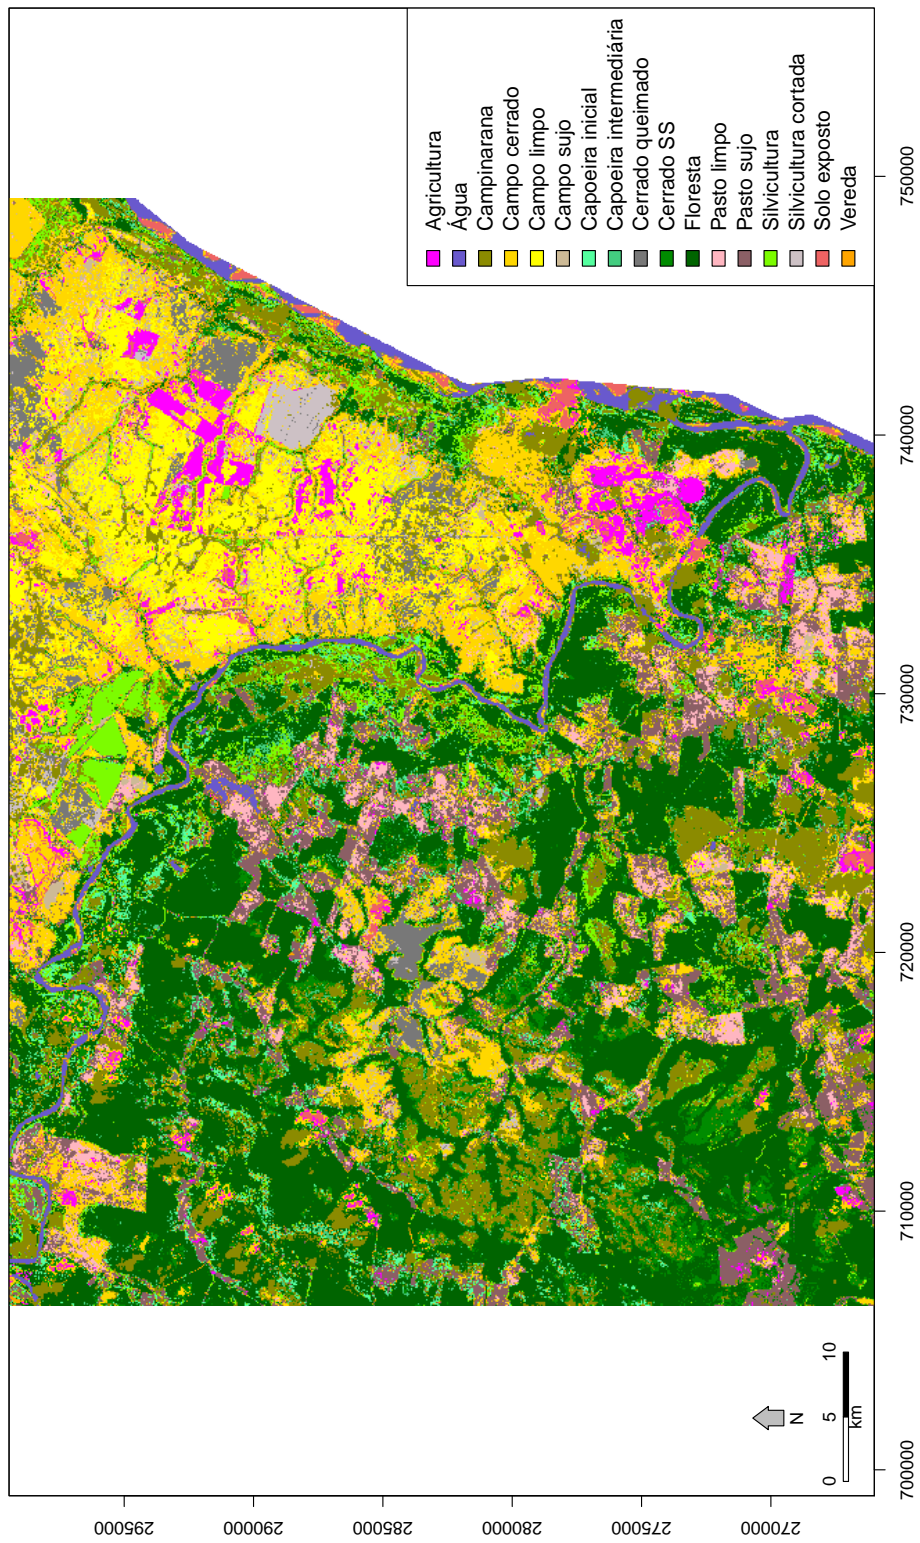


Figura 4.10 - Classificação da área de tensão ecológica em Roraima a partir da conjunção de dados OLI e PALSAR-2.

(Figura 4.11). Capoeira inicial e pasto limpo apresentaram melhorias menores de 5%, mas o acerto relativo (PA) ainda é baixo para essas classes.

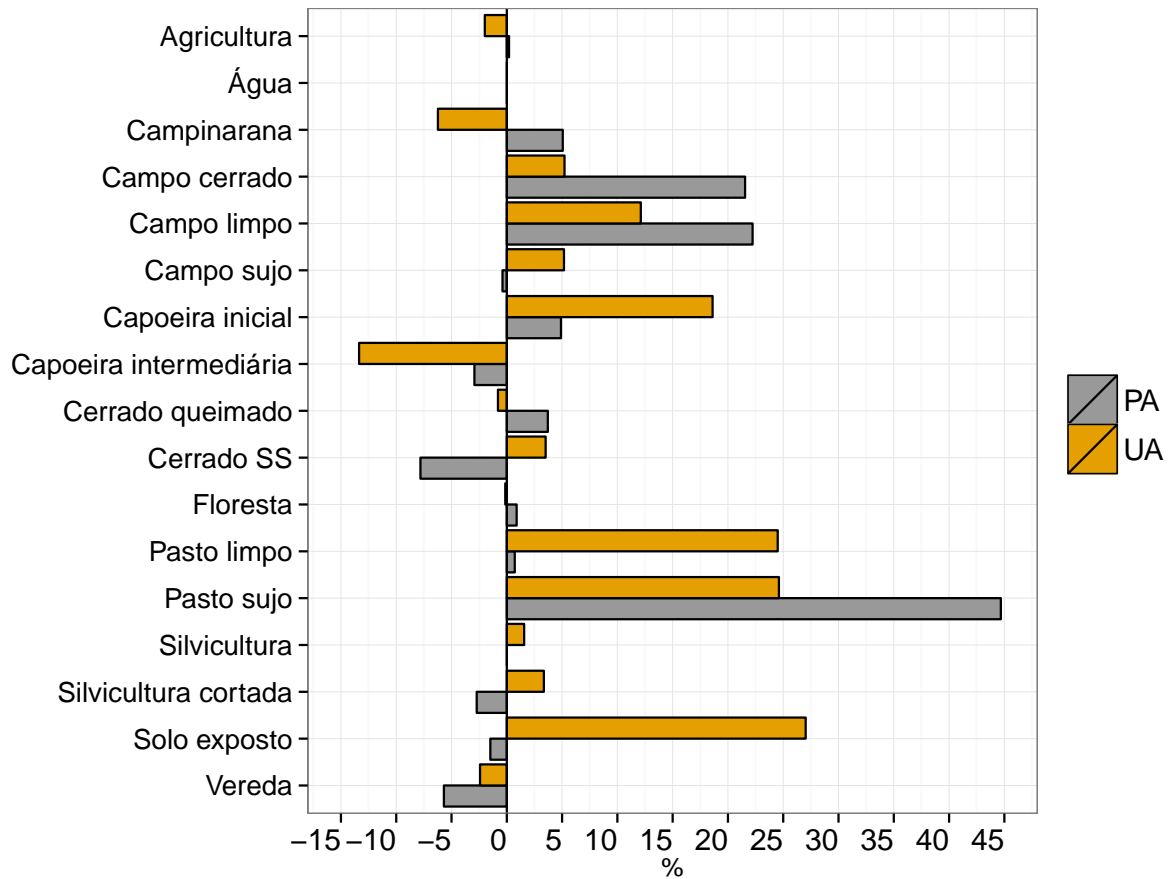
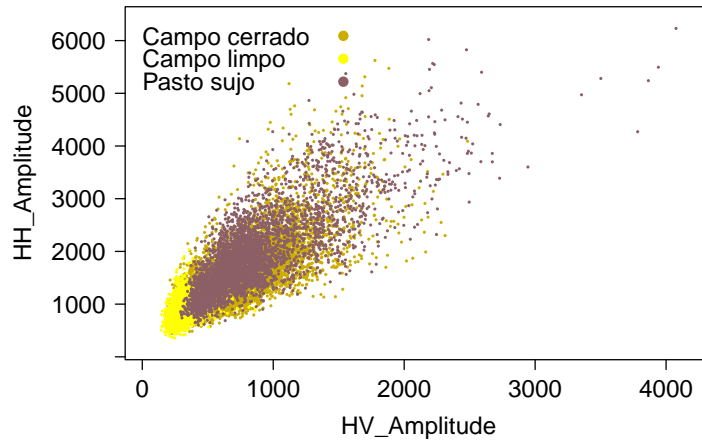



Figura 4.11 - Ganho de acurácia do produtor (PA) e usuário (UA) em cada classe da integração SAR ao OLI em relação ao OLI. Valores negativos significam perda na acurácia.

Na Figura 4.12 são apresentados os diagramas de espalhamento dos valores amostrais das classes de maior ganho. São comparadas as resposta nas bandas amplitude HH e HV, reflectância NIR e SWIR e NIR (a de maior importância para o modelo) com HV (maior importância do PALSAR-2).

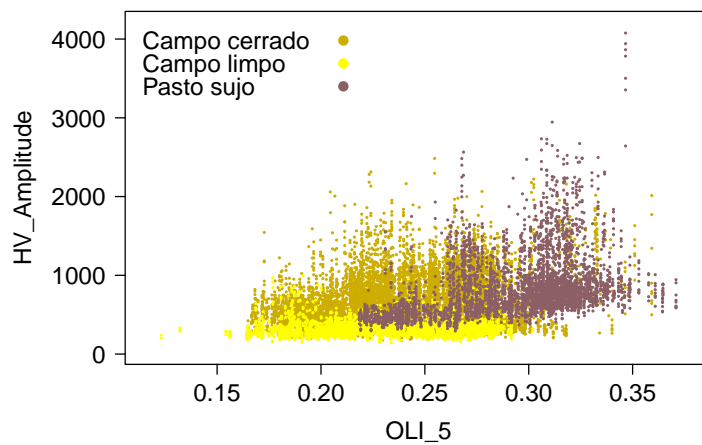
É possível notar a agregação dos pixels de campo limpo com baixos valores nas imagens de amplitude (Figura 4.12a), por conta do baixo retroespalhamento dessa classe na banda L. Já campo cerrado e pasto sujo têm maior contribuição do estrato herbáceo/arbustivo no retorno do sinal, causando a confusão entre elas. No espectro óptico (Figura 4.12b), o pasto sujo distingue dos Cerrados por seus



(a) Diagrama de dispersão das bandas HH e HV.



(b) Diagrama de dispersão das bandas OLI\_5 e OLI\_7.



(c) Diagrama de dispersão das bandas HV e OLI\_5.

Figura 4.12 - Diagrama de espalhamento das classes com maior ganho com a integração OLI+PALSAR-2 em relação ao OLI.



aspectos fisiológicos, como discutido na seção anterior.

Assim, a Figura 4.12c mostra a contribuição do PALSAR-2 para distinção do campo limpo, e do OLI para melhor separação do pasto sujo, confirmando o potencial do uso conjunto dos sensores para essas classes. No entanto, a acurácia dessas classes ainda é comprometida pela sobreposição dos pixels amostrais.

A adição do PALSAR-2 ao OLI não diminuiu a confusão entre campo sujo e campo cerrado, pois o comprimento de onda da banda L não é suficiente para distinguir a estrutura dessas fisionomias. Uma vez que o uso de dados ópticos sazonais na região é comprometido pela cobertura de nuvens, testes com SAR operando em menores comprimentos de onda (ex. TerraSAR-X, em banda X e Sentinel-1, em banda C) podem ser feitos para classificação dessas fisionomias savânicas sem estrato arbóreo (NAIDOO et al., 2015).

No entanto, algumas classes como capoeira intermediária, cerrado SS e vereda, apresentaram certa piora em relação ao modelo 10. As sucessões secundárias podem ser bem discriminadas com dados ópticos, mesmo após trinta anos de regeneração (GALVÃO et al., 2015). Porém, a saturação do sinal em banda L com valores elevados de biomassa e a complexidade estrutural de galhos e troncos não possibilita a separação de florestas e capoeiras intermediárias com essa frequência (ARAÚJO et al., 1999; SANTOS et al., 2002). Isto leva à diminuição do acerto temático, sugerindo-se para minimizar tal problema, o uso de informação de fase de dados full-polarimétricos do PALSAR-2.

Apesar de uma estrutura pouco ramificada, as veredas apresentam alta biomassa devido, principalmente, à altura das palmeiras (GOODMAN et al., 2013). Nesses ecossistemas, a sazonalidade é um fator importante para o retroespalhamento SAR em banda L, atingindo valores próximos aos de florestas nas estações secas e sendo bem discriminadas nas chuvas (EINZMANN et al., 2012). Este comportamento se dá pelo conteúdo de água da hidrografia na qual se localizam as veredas, que favorece o espalhamento *double bounce* entre a superfície lisa da água e os troncos, potencializando o sinal retroespalhado (HORRITT et al., 2003).

Por isso, o imageamento na estação seca não permitiu a correta distinção entre veredas e florestas e piorou a classificação. Ao contrário, Ribeiro (2010) obteve boa separabilidade entre veredas e outras tipologias florestais no lavrado em estação

chuvosa (agosto), com precipitação acumulada de mais de 500 mm nos três meses que antecederam o imageamento.

A confusão de cerrado SS se dá em maior parte com floresta. Hess et al. (1998) encontraram valores de retroespalhamento do JERS-1 (banda L) similares entre essas classes, devido ao arranjo adensado de troncos e galhos do cerrado. As manchas de cerrado SS se encontram na porção florestal da paisagem, formando uma transição sutil entre essas fisionomias que pode ser decorrente da dinâmica dos limites entre floresta e savana ocorridos no Holoceno (DESJARDINS et al., 1997).

## 5 CONCLUSÕES

Neste trabalho foi analisado o potencial dos sensores OLI/Landsat-8 e PALSAR-2/ALOS-2, e seu uso integrado, para o mapeamento das tipologias de uso e cobertura da terra na região de contato entre floresta e savana em Roraima, utilizando o classificador *Random Forest*. Esses sensores foram lançados recentemente e, pelo que se sabe, até o momento o emprego do PALSAR-2 para tal finalidade não foi reportado na literatura.

O sinergismo entre os sensores óptico e SAR se mostrou mais eficaz para classificação nesse estudo com relação à aplicação independente deles. Isso confirma a hipótese que baseou este trabalho e está de acordo com o encontrado na literatura. O uso combinado na região de estudo se mostra conveniente, uma vez que o mosaico de fisionomias de uso e cobertura da terra na região de tensão ecológica confere grande complexidade paisagística.

O processo classificatório das imagens se deu com o algoritmo *Random Forest*, implementado em R. O pacote possui valores padrões de número de árvores (*ntree*) e variáveis utilizadas em cada nó (*mtry*) de 500 árvores e  $\sqrt{N}$ , respectivamente, em que N é o número de bandas de entrada. Foram processados 18 modelos com as combinações das bandas e métricas derivadas do OLI e do PALSAR-2. Nenhum dos modelos produziu o menor erro com os valores padrões de *ntree* e *mtry*. Portanto, considera-se necessária a etapa de calibração do *Random Forest* para otimização desses parâmetros.

As classificações OLI foram superiores às do PALSAR-2. A adição de índices de vegetação não resultou em melhores mapeamentos com o OLI, no entanto, os atributos texturais melhoraram significativamente a classificação do PALSAR-2, em relação ao modelo com apenas as imagens em amplitude. Apesar de não ser eficiente para atingir o grau de estratificação temática desejado, o PALSAR-2 pôde distinguir fisionomias de acordo com a biomassa e estrutura, fornecendo informações relevantes sobre a paisagem para fins de monitoramento, principalmente na ausência de dados ópticos.

A classificação usando conjuntamente as seis bandas espectrais do OLI (2 a 7) e as polarizações HH e HV em amplitude do PALSAR-2 atingiu exatidão global de 83% e Kappa 0,813. Isso representa um aumento de 6% de exatidão e aumento significativo do Kappa frente à classificação com dados OLI apenas. O

uso de métricas texturas ou índices espectrais à integração do OLI e PALSAR-2 não produz resultados melhores, apesar de não serem estatisticamente piores. No entanto, o tempo computacional empregado é muito maior, reduzindo a eficiência da classificação nessa região.

Uma vez que o OLI é eficiente para discriminação de classes de maior biomassa, a principal contribuição do uso integrado OLI+PALSAR-2 se dá em classes com menor biomassa, como campo limpo, campo cerrado e pasto sujo. No entanto, esta imagem óptica com pouca cobertura de nuvens (cobertura de nuvens e sombras de 5,2% da área de estudo) é de difícil obtenção na região, mostrando a importância da sinergia entre sensores para lidar com este problema.

Por fim, o uso integrado de outros sensores SAR operando em menores frequências, como em banda C ou X, podem ser testados futuramente, a fim de aumentar a acurácia dos mapeamentos nessa região caracterizada pelo mosaico heterogêneo de classes de uso e cobertura da terra. Espera-se, com isso, aumentar a capacidade de discriminação das classes de savana aberta, principalmente, que possuem menor biomassa e grande confusão entre si.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ADAM, E.; MUTANGA, O.; ODINDI, J.; ABDEL-RAHMAN, E. M. Land-use/cover classification in a heterogeneous coastal landscape using rapideye imagery: evaluating the performance of random forest and support vector machines classifiers. **International Journal of Remote Sensing**, Taylor & Francis, v. 35, n. 10, p. 3440–3458, 2014. 15
- AGUIAR, A.; BARBOSA, R. I.; BARBOSA, J. B.; JR, M. M. Invasion of acacia mangium in amazonian savannas following planting for forestry. **Plant Ecology & Diversity**, Taylor & Francis, v. 7, n. 1-2, p. 359–369, 2014. 47
- AIDE, T. M.; CLARL, M. L.; GRAU, H. R.; LÓPEZ-CARR, D.; LEVY, M. A.; REDO, D.; BONILLA-MOHENO, M.; RINER, G.; ANDRADE-NÚÑEZ, M. J.; MUÑIZ, M. Deforestation and reforestation of Latin America and the Caribbean (2001–2010). **Biotropica**, v. 45, n. 23, 2013. 2
- AKAR, Ö.; GÜNGÖR, O. Integrating multiple texture methods and ndvi to the random forest classification algorithm to detect tea and hazelnut plantation areas in northeast turkey. **International Journal of Remote Sensing**, Taylor & Francis, v. 36, n. 2, p. 442–464, 2015. 14, 15, 28
- ALMEIDA, C. R. M. **Sistema agroflorestal**: alternativas de produção em áreas de reserva legal: município de Mucajaí, Vicinal Sete, Estado de Roraima. 2012. 107 p. Dissertação (Mestrado Profissional em Economia) — Universidade Federal do Rio Grande do Sul, Faculdade de Ciências Econômicas, Porto Alegre, 2012. 19
- ALMEIDA-FILHO, R.; SHIMABUKURO, Y. E. Detecting areas disturbed by gold mining activities through JERS-1 SAR images, Roraima State, Brazilian Amazon. **International Journal of Remote Sensing**, Taylor & Francis, v. 21, n. 17, p. 3357–3362, 2000. 41, 43
- ARAÚJO, L. S.; SANTOS, J. R. d.; FREITAS, C. D. C.; XAUD, H. A. M. The use of microwave and optical data for estimating aerial biomass of the savanna and forest formations at Roraima state, Brazil. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS'99), 1999, Hamburg, Germany. **Proceedings...** Hamburg: IEEE, 1999. v. 5, p. 2762–2764. 43, 55
- ARCO-VERDE, M.; TONINI, H.; JR, M. M. A silvicultura nas savannas de Roraima. In: BARBOSA, R. I.; XAUD, H. I. M.; SILVA, J. M. Costa e (Ed.).

**Savanas de Roraima: Etnoecologia, Biodiversidade e Potencialidades Agrossilvipastoris.** Boa Vista: FEMACT, 2005. p. 195–200. 47

ARIKAWA, Y.; YAMAMOTO, T.; KONDOH, Y.; AKIYAMA, K.; ITOH, H.; SUZUKI, S. Alos-2 orbit control and determination. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS 2014), 2014, Quebec City, QC. **Proceedings...** Quebec City: IEEE, 2014. p. 3415–3417. 9

AVITABILE, V.; BACCINI, A.; FRIEDL, M. A.; SCHMULLIUS, C. Capabilities and limitations of Landsat and land cover data for aboveground woody biomass estimation of Uganda. **Remote Sensing of Environment**, v. 117, p. 366–380, 2012. 1

AVTAR, R.; SAWADA, H.; TAKEUCHI, W.; SINGH, G. Characterization of forests and deforestation in cambodia using alos/palsar observation. **Geocarto International**, Taylor & Francis, v. 27, n. 2, p. 119–137, 2012. 29

BAGAN, H.; TAKEUCHI, W.; YAMAGATA, Y. Land-Cover Classification in Kalimantan by Polarimetric PALSAR. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science**, v. 38, p. 736–739, 2010. 11

BAGHDADI, N.; ZRIBI, M.; LOUMAGNE, C.; ANSART, P.; ANGUELA, T. P. Analysis of terrasarsar-x data and their sensitivity to soil surface parameters over bare agricultural fields. **Remote Sensing of Environment**, Elsevier, v. 112, n. 12, p. 4370–4379, 2008. 41

BANKS, S.; MILLARD, K.; PASHER, J.; RICHARDSON, M.; WANG, H.; DUFFE, J. Assessing the potential to operationalize shoreline sensitivity mapping: Classifying multiple wide fine quadrature polarized radarsat-2 and landsat 5 scenes with a single random forest model. **Remote Sensing**, Multidisciplinary Digital Publishing Institute, v. 7, n. 10, p. 13528–13563, 2015. 14

BARBOSA, R. I. Ocupação humana em Roraima. II. Uma revisão do equívoco da recente política de desenvolvimento e o crescimento desordenado. **Boletim do Museu Paraense Emilio Goeldi**, v. 9, n. 2, p. 177–197, 1993. 18, 19

\_\_\_\_\_. Distribuição das chuvas em Roraima. In: BARBOSA, R. I.; FERREIRA, E.; CASTELLÓN, E. (Ed.). **Homem, Ambiente e Ecologia no Estado de Roraima**. Manaus: INPA, 1997. p. 325–335. 17

BARBOSA, R. I.; CAMPOS, C. Detection and geographical distribution of clearing areas in the savannas ('lavrado') of Roraima using Google Earth web tool. **Journal of Geography and Regional Planning**, Academic Journals, 73023 Victoria Island Lagos Nigeria, v. 4, n. 3, p. 122–136, 2011. 47

BARBOSA, R. I.; CAMPOS, C.; PINTO, F.; FEARNESIDE, P. M. The Lavrados of Roraima: biodiversity and conservation of Brazil's Amazonian Savannas. **Functional Ecosystems and Communities**, v. 1, n. 1, p. 29–41, 2007. 18

BARBOSA, R. I.; FEARNESIDE, P. M. Above-ground biomass and the fate of carbon after burning in the savannas of Roraima, Brazilian Amazonia. **Forest Ecology and Management**, Elsevier, v. 216, n. 1, p. 295–316, 2005. 43

\_\_\_\_\_. Fire frequency and area burned in the Roraima savannas of Brazilian Amazonia. **Forest ecology and Management**, Elsevier, v. 204, n. 2, p. 371–384, 2005. 42

BENDAHAN, A. B.; MOURÃO JÚNIOR, M.; BRAGA, R. M.; COSTA, N. L.; MATTOS, P. S. R. **Caracterização do rebanho bovino no município de Mucajaí no estado de Roraima**. Boa Vista: EMBRAPA Roraima Documentos, 2009. 19

BITENCOURT, M. D.; MESQUITA JR, H. N. de; KUNTSCHIK, G.; ROCHA, H. R. da; FURLEY, P. A. Cerrado vegetation study using optical and radar remote sensing: two Brazilian case studies. **Canadian Journal of Remote Sensing**, Taylor & Francis, v. 33, n. 6, p. 468–480, 2007. 42

BODEN, T. A.; MARLAND, G.; ANDRES, R. J. **Global, regional, and national fossil-fuel CO<sub>2</sub> emissions**. Oak Ridge, Tennessee, USA: Carbon Dioxide Information Analysis Center (CDIAC), 2012. Oak Ridge National Laboratory, US Department of Energy. 1

BORGES, E. F.; SANO, E. E. Temporal series of evi from modis sensor for land use and land cover mapping of western bahia. **Boletim de Ciências Geodésicas**, SciELO Brasil, v. 20, n. 3, p. 526–547, 2014. 28

BRAUN, A.; HOCHSCHILD, V. Combined use of sar and optical data for environmental assessments around refugee camps in semiarid landscapes. **International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences**, 2015. 45, 50

BREIMAN, L. Random forests. **Machine learning**, Springer, v. 45, n. 1, p. 5–32, 2001. 13, 14, 15

BRUNSDON, C.; CHEN, H. **GISTools: Some further GIS Capabilities for R**. [S.l.]: R package version 0.7-2.\* <http://CRAN.R-project.org/package=GISTools>[Links], 2014. 29

CHAN, J. C.-W.; PAELINCKX, D. Evaluation of random forest and adaboost tree-based ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery. **Remote Sensing of Environment**, Elsevier, v. 112, n. 6, p. 2999–3011, 2008. 45

CHASE, T. N.; PIELKE, R. A.; KITTEL, T. G. F.; NEMANI, R. R.; RUNNING, S. W. Simulated impacts of historical land cover changes on global climate in northern winter. **Climate Dynamics**, v. 16, 1999. 1

CONGALTON, R.; GREEN, K. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. U.S.: CRC/Lewis Press, 1999. 137 p. 31

CORREIA, A. H.; FREITAS, C. C.; FRERY, A. C.; SANTANNA, S. J. S. A user friendly statistical system for polarimetric SAR image classification. **Revista de Teledetección**, v. 6, n. 10, p. 79–93, 1998. 4

DEFRIES, R. S.; ELLIS, E. C.; CHAPIN, F. S.; MATSON, P. A.; TURNER, B. L.; AGRAWAL, A.; CRUTZEN, P. J.; FIELD, C.; GLEICK, P.; KAREIVA, P. M.; LAMBIN, E.; LIVERMAN, D.; OSTROM, E.; SANCHEZ, P. A.; SYVITSK, J. Planetary Opportunities: A social contract for global change science to contribute to a sustainable future. **BioScience**, v. 62, n. 6, p. 603–606, June 2012. 1

DENG, X.; ZHAO, C.; YAN, H. Systematic modeling of impacts of land use and land cover changes on regional climate: A review. **Advances in Meteorology**, v. 2013, p. 11, 2013. 1, 2

DESJARDINS, T.; FILHO, A. C.; CHAUVEL, A. Flutuações do limite floresta-cerrado durante o holoceno em Roraima. In: BARBOSA, R.; FERREIRA, E.; CASTELLON, E. (Ed.). **Homem, ambiente e ecologia no Estado de Roraima**. Manaus: INPA, 1997. 56

DICKINSON, C.; SIQUEIRA, P.; CLEWLEY, D.; LUCAS, R. Classification of forest composition using polarimetric decomposition in multiple landscapes. **Remote Sensing of Environment**, Elsevier, v. 131, p. 206–214, 2013. 12



- DONG, J.; XIAO, X.; SHELDON, S.; BIRADAR, C.; DUONG, N. D.; HAZARIKA, M. A comparison of forest cover maps in mainland southeast asia from multiple sources: Palsar, meris, modis and fra. **Remote Sensing of Environment**, Elsevier, v. 127, p. 60–73, 2012. 29
- EBERHARDT, I. D. R.; LUIZ, A. J. B.; FORMAGGIO, A. R.; SANCHES, I. D. Near real-time detection of crop fields with modis images. **Pesquisa Agropecuária Brasileira**, SciELO Brasil, v. 50, n. 7, p. 605–614, 2015. 47
- EINZMANN, K.; HAARPAINTNER, J.; LARSEN, Y. Forest monitoring in Congo basin with combined use of SAR C-& L-band. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS 2012), 2012, Munich, Germany. **Proceedings...** Munich: IEEE, 2012. p. 6573–6576. 55
- EISAVI, V.; HOMAYOUNI, S.; YAZDI, A. M.; ALIMOHAMMADI, A. Land cover mapping based on random forest classification of multitemporal spectral and thermal images. **Environmental monitoring and assessment**, Springer, v. 187, n. 5, p. 1–14, 2015. 8, 30
- FAHRIG, F. Relative effects of habitat loss and fragmentation on population extinction. **Journal of Wildlife Management**, v. 61, n. 3, 1997. 2
- \_\_\_\_\_. Effects of Habitat Fragmentation on Biodiversity. **Annual Review of Ecology, Evolution, and Systematics**, v. 34, 2003. 2
- FERGUSON, J. R. **Using the grey-level co-occurrence matrix to segment and classify radar imagery**. U.S.: ProQuest, 2007. 38
- FOODY, M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, v. 80, p. 185–201, 2002. 2
- FORKUOR, G.; CONRAD, C.; THIEL, M.; ULLMANN, T.; ZOUNGRANA, E. Integration of optical and synthetic aperture radar imagery for improving crop mapping in northwestern benin, west africa. **Remote Sensing**, Multidisciplinary Digital Publishing Institute, v. 6, n. 7, p. 6472–6499, 2014. 3, 14
- FRAGAL, E. H.; SILVA, T. S. F.; NOVO, E. M. L. d. M. Reconstructing historical forest cover change in the lower amazon floodplains using the landtrendr algorithm. **Acta Amazonica**, SciELO Brasil, v. 46, n. 1, p. 13–24, 2016. 19
- GALFORD, G. L.; MUSTARD, J. F.; MELILLO, J.; GENDRIN, A.; CERRI, C. C.; CERRI, C. E. Wavelet analysis of MODIS time series to detect expansion

and intensification of row-crop agriculture in Brazil. **Remote sensing of environment**, Elsevier, v. 112, n. 2, p. 576–587, 2008. 49

GALVÃO, L. S.; SANTOS, J. R. dos; SILVA, R. D. da; SILVA, C. V. da; MOURA, Y. M.; BREUNIG, F. M. Following a site-specific secondary succession in the amazon using the landsat cdr product and field inventory data. **International Journal of Remote Sensing**, Taylor & Francis, v. 36, n. 2, p. 574–596, 2015. 19, 55

GARCIA, C. E.; CASTILLO, E. M. del; SALGADO, M. P. G. Avaliação do uso e fusão de imagens ALOS/PALSAR e TM/Landsat para identificação e mapeamentos temáticos no município de Mambai - GO. In: XV SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2011, Curitiba, Brasil. **Proceedings...** Curitiba: INPE, 2011. p. 8114–8120. 4

GIBBS, H.; BROWN, S.; NILES, J. O.; FOLEY, J. A. Monitoring and estimating tropical forest carbon stocks: making REDD a reality. **Environ. Res. Lett**, v. 2, p. 1–13, 2007. 1

GISLASON, P. O.; BENEDIKTSSON, J. A.; SVEINSSON, J. R. Random forests for land cover classification. **Pattern Recognition Letters**, Elsevier, v. 27, n. 4, p. 294–300, 2006. 13

GOODMAN, R. C.; PHILLIPS, O. L.; TORRES, D. del C.; FREITAS, L.; CORTESE, S. T.; MONTEAGUDO, A.; BAKER, T. R. Amazon palm biomass and allometry. **Forest Ecology and Management**, Elsevier, v. 310, p. 994–1004, 2013. 55

GUERRA, J. B.; MURA, J. C.; FREITAS, C. d. C. Discriminação de incrementos de desflorestamento na amazônia com dados sar r99b em banda l. **Acta Amazonica**, SciELO Brasil, v. 40, n. 3, p. 557–566, 2010. 29

HESS, L. L.; NOVO, E. M.; VALERIANO, D. M.; HOLT, J. W.; MELACK, J. M. Large-scale vegetation features of the Amazon Basin visible on the JERS-1 low-water Amazon mosaic. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS '98), 1998, Seattle, WA. **Proceedings...** Seattle: IEEE, 1998. v. 2, p. 843–846. 56

HIJMANS, R. J.; ETTEN, J. van; MATTIUZZI, M.; SUMNER, M.; GREENBERG, J. A.; LAMIGUEIRO, O. P.; BEVAN, A.; RACINE, E. B.; SHORTRIDGE, A.; HIJMANS, M. R. J. Package raster. 2015. 29

HONG, G.; ZHANG, A.; ZHOU, F.; BRISCO, B. Integration of optical and synthetic aperture radar (SAR) images to differentiate grassland and alfalfa in Prairie area. **International Journal of Applied Earth Observation and Geoinformation**, Elsevier, v. 28, p. 12–19, 2014. 13

HORRITT, M.; MASON, D.; COBBY, D.; DAVENPORT, I.; BATES, P. Waterline mapping in flooded vegetation from airborne sar imagery. **Remote Sensing of Environment**, Elsevier, v. 85, n. 3, p. 271–281, 2003. 55

HOUGHTON, R. A.; HACKLER, J. L. **Carbon flux to the atmosphere from land-use changes: 1850 to 1990**. Oak Ridge, Tennessee, USA: Carbon Dioxide Information Analysis Center (CDIAC), 2001. Oak Ridge National Laboratory, US Department of Energy. 1

IBGE. **Mapeamento da vegetação do estado de Roraima**. 2005. Disponível em: <[ftp://geoftp.ibge.gov.br/mapas\\_tematicos/vegetacao/unidades\\_federacao/rr\\_vegetacao.pdf](ftp://geoftp.ibge.gov.br/mapas_tematicos/vegetacao/unidades_federacao/rr_vegetacao.pdf)>. Acesso em: 31 de agosto 2015. 17

IBGE-EMBRAPA. **Mapa de Solos do Brasil**. 2001. 17

INPE. **Coordenação Geral de Observação da Terra - OBT**. 2014. Disponível em: <<http://www.obt.inpe.br/prodes/>>. 43

JHONNERIE, R.; SIREGAR, V. P.; NABABAN, B.; PRASETYO, L. B.; WOUTHUYZEN, S. Random forest classification for mangrove land cover mapping using landsat 5 tm and alos palsar imageries. **Procedia Environmental Sciences**, Elsevier, v. 24, p. 215–221, 2015. 3, 15, 28, 30, 34

JIA, K.; WEI, X.; GU, X.; YAO, Y.; XIE, X.; LI, B. Land cover classification using Landsat 8 Operational Land Imager data in Beijing, China. **Geocarto International**, Taylor & Francis, v. 29, n. 8, p. 941–951, 2014. 8

KALNAY, E.; CAL, M. Impact of urbanization and land use change on climate. **Nature**, v. 423, 2003. 1

KANKAKU, Y.; OSAWA, Y.; SUZUKI, S.; WATANABE, T. The overview of the L-band SAR onboard ALOS-2. In: PROGRESS IN ELECTROMAGNETICS RESEARCH SYMPOSIUM, 2014, Moscow, Russia. **Proceedings...** Moscow: PIERS, 2009. p. 735–738. 9

KANKAKU, Y.; SUZUKI, S.; SHIMADA, M. Alos-2 initial results. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS, 2015,

Toulouse, France. **Proceedings...** Toulouse: SPIE Remote Sensing, 2015. p. 96390D–96390D. 20

LACERDA, E. G.; DINIZ, A. M. A.; BORGES, F. A. C. A reforma agrária no contexto de Roraima. In: FONSECA, A. J. da; SILVA, A. Z. B. da (Ed.). **Políticas Públicas, Desenvolvimento e Tecnologias Apropriadas**. Boa Vista: Editora da UFRR, 2015. p. 157–184. 18

LAMBIN, E. F.; GEIST, H. J.; LEPERS, E. Dynamics of land-use and land-cover change in tropical regions. **Annu. Rev. Environ. Resour**, v. 28, p. 205–241, 2003. 1

LAMBIN, E. F.; TURNER, B. L.; GEIST, H. J.; AGBOLA, S. B.; ANGELSEN, A.; BRUCE, J. W.; COOMES, O. T.; DIRZO, R.; FISCHER, G.; FOLKE, C.; GEORGE, P. S.; HOMEWOOD, K.; IMBERNON, J.; LEEMANS, R.; LI, X.; MORAN, E. F.; MORTIMORE, M.; RAMAKRISHNAN, P. S.; RICHARDS, J. F.; SKANES, H.; STEFFEN, W.; STONE, G. D.; SVEDIN, U.; VELDKAMP, T. A.; VOGEL, C.; XU, J. The causes of land-use and land-cover change: moving beyond the myths. **Global Environmental Change**, v. 11, p. 261–269, 2001. 2

LAURANCE, W. F.; USECHE, D. C.; SHOO, L. P.; HERZOG, S. K.; KESSLER, M.; ESCOBAR, F.; BREHM, G.; AXMACHER, J. C.; CHEN, I.-C.; GÁMEZ, L. A.; HIETZ, P.; FIEDLER, K.; PYRCZ, T.; WOLF, J.; MERKORD, C. L.; CARDELUS, C.; MARSHALL, A. R.; AH-PENG, C.; APLET, G. H.; ARIZMENDI, M. del C.; BAKER, W. J.; BARONE, J.; BRÜHL, C. A.; BUSSMANN, R. W.; CICUZZA, D.; EILU, G.; FAVILA, M. E.; HEMP, A.; HEMP, C.; HOMEIER, J.; HURTADO, J.; JANKOWSKI, J.; KATTÁN, G.; KLUGE, J.; KRÖMER, T.; LEES, D. C.; LEHNERT, M.; LONGINO, J. T.; LOVETT, J.; MARTIN, P. H.; PATTERSON, B. D.; PEARSON, R. G.; PEH, K. S.-H.; RICHARDSON, B.; RICHARDSON, M.; SAMWAYS, M. J.; SENBETA, F.; SMITH, T. B.; UTTERIDGE, T. M.; WATKINS, J. E.; WILSON, R.; WILLIAMS, S. E.; THOMAS, C. D. Global warming, elevational ranges and the vulnerability of tropical biota. **Biological Conservation**, v. 144, n. 1, p. 548–557, 2011. ISSN 0006-3207. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0006320710004532>>. 2

LAURIN, G. V.; LIESENBERG, V.; CHEN, Q.; GUERRIERO, L.; FRATE, F. D.; BARTOLINI, A.; COOMES, D.; WILEBORE, B.; LINDSELL, J.; VALENTINI, R. Optical and sar sensor synergies for forest and land cover mapping in a tropical

site in west africa. **International Journal of Applied Earth Observation and Geoinformation**, Elsevier, v. 21, p. 7–16, 2013. [2](#), [3](#), [13](#), [43](#), [49](#)

LAWRENCE, R. L.; WOOD, S. D.; SHELEY, R. L. Mapping invasive plants using hyperspectral imagery and breiman cutler classifications (randomforest). **Remote Sensing of Environment**, Elsevier, v. 100, n. 3, p. 356–362, 2006. [14](#)

LEHMANN, E.; CACCETTA, P.; ZHOU, Z.-S.; MITCHELL, A.; TAPLEY, I.; MILNE, A.; HELD, A.; LOWELL, K.; MCNEILL, S. Forest discrimination analysis of combined landsat and ALOS-PALSAR data. In: INTERNATIONAL SYMPOSIUM FOR REMOTE SENSING OF THE ENVIRONMENT, 2011, Sydney, Australia. **Proceedings...** Sydney, 2011. v. 1015, p. 8114–8120. [29](#)

LEWIN-KOH, N. J.; BIVAND, R.; PEBESMA, J.; ARCHER, E.; BADDELEY, A.; GIRAUDOUX, D. G.; RUBIO, V. G.; HAUSMANN, P.; HUFTHAMMER, K. O.; JAGGER, T. et al. Package mapproj. **R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria**, 2012. [29](#)

LI, G.; LU, D.; MORAN, E.; DUTRA, L.; BATISTELLA, M. A comparative analysis of ALOS PALSAR L-band and RADARSAT-2 C-band data for land-cover classification in a tropical moist region. **ISPRS Journal of Photogrammetry and Remote Sensing**, Elsevier, v. 70, p. 26–38, 2012. [10](#), [29](#), [38](#)

LIAW, A.; WIENER, M.; BREIMAN, L.; CUTLER, A. Package randomForest. **Retrieved December**, v. 12, p. 2009, 2009. [14](#), [29](#)

LONGÉPÉ, N.; RAKWATIN, P.; ISOGUCHI, O.; SHIMADA, M.; URYU, Y.; YULIANTO, K. Assessment of alos palsar 50 m orthorectified fbd data for regional land cover classification by support vector machines. **Geoscience and Remote Sensing, IEEE Transactions on**, IEEE, v. 49, n. 6, p. 2135–2150, 2011. [29](#)

LU, D.; BATISTELLA, M.; GUIYING, M. E.; HETRICK, S. F.; COSTA, C.; DUTRA, L. V.; SANT'ANNA, S. J. S. Land use/cover classification in the Brazilian Amazon using satellite images. **Pesq. Agropec. Bras.**, v. 47, p. 1185–1208, 2012. [3](#), [12](#)

LU, D.; BATISTELLA, M.; MORAN, E. Land-cover classification in the Brazilian Amazon with the integration of Landsat ETM+ and RADARSAT data. **International Journal of Remote Sensing**, v. 28, p. 5447–5459, 2007. [2](#), [3](#)

- LU, D.; LI, G.; MORAN, E.; DUTRA, L.; BATISTELLA, M. A comparison of multisensor integration methods for land cover classification in the Brazilian Amazon. **GIScience & Remote Sensing**, Taylor & Francis, v. 48, n. 3, p. 345–370, 2013. 13, 29, 38
- LUCAS, R.; ARMSTON, J.; FAIRFAX, R.; FENSHAM, R.; ACCAD, A.; CARREIRAS, J.; KELLEY, J.; BUNTING, P.; CLEWLEY, D.; BRAY, S. et al. An evaluation of the ALOS PALSAR L-band backscatter—Above ground biomass relationship Queensland, Australia: Impacts of surface moisture condition and vegetation structure. **Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of**, IEEE, v. 3, n. 4, p. 576–593, 2010. 11
- MALHI, Y.; ROBERTS, J. T.; BETTS, R.; KILLEEN, T. J.; LI, W.; NOBRE, C. A. Climate change, deforestation, and the fate of the Amazon. **Science**, v. 319, p. 169–172, 2008. 1
- MARKHAM, B.; BARSİ, J.; KVARAN, G.; ONG, L.; KAITA, E.; BIGGAR, S.; CZAPLA-MYERS, J.; MISHRA, N.; HELDER, D. Landsat-8 Operational Land Imager radiometric calibration and stability. **Remote Sensing**, Multidisciplinary Digital Publishing Institute, v. 6, n. 12, p. 12275–12308, 2014. 7
- MASEK, J. G.; VERMOTE, E. F.; SALEOUS, N. E.; WOLFE, R.; HALL, F. G.; HUENNRICH, K. F.; GAO, F.; KUTLER, J.; LIM, T.-K. A landsat surface reflectance dataset for north america, 1990-2000. **Geoscience and Remote Sensing Letters, IEEE**, IEEE, v. 3, n. 1, p. 68–72, 2006. 19
- MELO, V. F.; UCHÔA, S. C. P.; SIQUEIRA, R. H. da S.; SILVA, D. F. da; MARTINS, S. A. Impactos Ambientais das Atividades Agrícolas em Roraima. **REVISTA AGRO@ MBIENTE ON-LINE**, v. 2, n. 1, p. 102–106, 2008. 18
- MENGES, C.; BARTOLO, R.; BELL, D.; HILL, G. E. The effect of savanna fires on sar backscatter in northern australia. **International Journal of Remote Sensing**, Taylor & Francis, v. 25, n. 22, p. 4857–4871, 2004. 43
- MILLARD, K.; RICHARDSON, M. Wetland mapping with lidar derivatives, sar polarimetric decompositions, and lidar–sar fusion using a random forest classifier. **Canadian Journal of Remote Sensing**, Taylor & Francis, v. 39, n. 4, p. 290–307, 2013. 15
- \_\_\_\_\_. On the importance of training data sample selection in random forest image classification: A case study in peatland ecosystem mapping. **Remote Sensing**, Multidisciplinary Digital Publishing Institute, v. 7, n. 7, p. 8489–8515, 2015. 14, 42

MITCHELL, A. L.; TAPLEY, I.; MILNE, A. K.; WILLIAMS, M. L.; ZHOU, Z.-S.; LEHMANN, E.; CACCETTA, P.; LOWELL, K.; HELD, A. C-and L-band SAR interoperability: Filling the gaps in continuous forest cover mapping in Tasmania. **Remote Sensing of Environment**, Elsevier, v. 155, p. 58–68, 2014. 10

MÜLLER, H.; RUFIN, P.; GRIFFITHS, P.; SIQUEIRA, A. J. B.; HOSTERT, P. Mining dense landsat time series for separating cropland and pasture in a heterogeneous Brazilian savanna landscape. **Remote Sensing of Environment**, Elsevier, v. 156, p. 490–499, 2015. 49

NA, X.; ZANG, S.; WU, C.; LI, W. Mapping forested wetlands in the great zhan river basin through integrating optical, radar, and topographical data classification techniques. **Environmental monitoring and assessment**, Springer, v. 187, n. 11, p. 1–17, 2015. 34

NAIDOO, L.; MATHIEU, R.; MAIN, R.; KLEYNHANS, W.; WESSELS, K.; ASNER, G.; LEBLON, B. Savannah woody structure modelling and mapping using multi-frequency (x-, c-and l-band) synthetic aperture radar data. **ISPRS Journal of Photogrammetry and Remote Sensing**, Elsevier, v. 105, p. 234–250, 2015. 55

ODINDI, J.; ADAM, E.; NGUBANE, Z.; MUTANGA, O.; SLOTOW, R. Comparison between worldview-2 and spot-5 images in mapping the bracken fern using the random forest algorithm. **Journal of Applied Remote Sensing**, International Society for Optics and Photonics, v. 8, n. 1, p. 083527–083527, 2014. 33

OTUKEI, J. R.; BLASCHKE, T.; COLLINS, M. Fusion of TerraSAR-x and Landsat ETM+ data for protected area mapping in Uganda. **International Journal of Applied Earth Observation and Geoinformation**, Elsevier, v. 38, p. 99–104, 2015. 13

PAL, M. Random forest classifier for remote sensing classification. **International Journal of Remote Sensing**, Taylor & Francis, v. 26, n. 1, p. 217–222, 2005. 15

PARIHAR, N.; DAS, A.; RATHORE, V.; NATHAWAT, M.; MOHAN, S. Analysis of L-band SAR backscatter and coherence for delineation of land-use/land-cover. **International Journal of Remote Sensing**, Taylor & Francis, v. 35, n. 18, p. 6781–6798, 2014. 12

PAVANELLI, J. A. P.; MALDONADO, F. D.; SANTOS, J. R.; GALVÃO, L. S.; XAUD, M. R.; XAUD, H. A. M. Rotação radiométrica para detecção de mudanças

na paisagem de tensão ecológica em Roraima. In: XVII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2015, João Pessoa, Brasil. **Proceedings...** João Pessoa: INPE, 2015. p. 8114–8120. 47

PAVANELLI, J. A. P.; XAUD, M. R.; XAUD, H. A. M.; SANTOS, J. R.; GALVÃO, L. S. Dinâmica do uso e cobertura da terra na região de transição entre floresta e savana no estado de Roraima. In: SEMINÁRIO DE ATUALIZAÇÃO EM SENSORIAMENTO REMOTO E SISTEMAS DE INFORMAÇÕES GEOGRÁFICAS APLICADOS À ENGENHARIA FLORESTAL, 11, 2014, Curitiba, Brasil. **Proceedings...** Curitiba: IEP, 2014. p. 350–357. 8, 45

PEREIRA, L. de O.; FREITAS, C. da C.; Sant´ Anna, S. J. S.; LU, D.; MORAN, E. F. Optical and radar data integration for land use and land cover mapping in the Brazilian Amazon. **GIScience & Remote Sensing**, Taylor & Francis, v. 50, n. 3, p. 301–321, 2013. 13

PIELKE, R. A.; MARLAND, G.; BETTS, R. A.; CHASE, T. N.; EASTMAN, J. L.; NILES, J. O.; NIYOGI, D.; RUNNING, S. W. The influence of land-use change and landscape dynamics on the climate system-relevance to climate change policy beyond the radiative effect of greenhouse gases. **Phil. Trans. A.**, v. 360, n. Special Theme Issue, 2002. 1

PIMM, S. L.; RAVEN, P. Biodiversity: Extinction by numbers. **Nature**, v. 403, n. 843, 2000. 1

POURSANIDIS, D.; CHRYSOULAKIS, N.; MITRAKA, Z. Landsat 8 vs. Landsat 5: A comparison based on urban and peri-urban land cover mapping.

**International Journal of Applied Earth Observation and Geoinformation**, Elsevier, v. 35, p. 259–269, 2015. 8

PRASAD, S.; BRUCE, L.; CHANUSSOT, J. Introduction. In: PRASAD, S.; BRUCE, L. M.; CHANUSSOT, J. (Ed.). **Optical Remote Sensing**. [S.l.]: Springer Berlin Heidelberg, 2011, (Augmented Vision and Reality, v. 3). p. 1–8. ISBN 978-3-642-14211-6. 13

QUÉRÉ, C. L.; RAUPACH, M. R.; CANADELL, J. G.; MARLAND, G. et al. Trends in the sources and sinks of carbon dioxide. **Nature Geoscience**, v. 2, 2009. 1

RAKWATIN, P.; LONGÉPÉ, N.; ISOGUCHI, O.; SHIMADA, M.; URYU, Y.; TAKEUCHI, W. et al. Using multiscale texture information from alos palsar to



map tropical forest. **International Journal of Remote Sensing**, Taylor & Francis, v. 33, n. 24, p. 7727–7746, 2012. 41

RATANA, P.; HUETE, A. R.; FERREIRA, L. Analysis of cerrado physiognomies and conversion in the modis seasonal-temporal domain. **Earth Interactions**, v. 9, n. 3, p. 1–22, 2005. 49

RIBEIRO, A. H. **O buriti na Terra indígena Aracá, Roraima: usos tradicionais, manejo e potencial produtivo**. 2010. 101 p. Dissertação (Mestrado em Ciências de Florestas Tropicais) — Instituto Nacional de Pesquisas da Amazônia, Manaus, 2010. 55

RODRIGUEZ-GALIANO, V. F.; GHIMIRE, B.; ROGAN, J.; CHICA-OLMO, M.; RIGOL-SANCHEZ, J. P. An assessment of the effectiveness of a random forest classifier for land-cover classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, Elsevier, v. 67, p. 93–104, 2012. 3, 13, 30

ROSENQVIST, A.; SHIMADA, M.; CHAPMAN, B.; MCDONALD, K.; GRANDI, G. D.; JONSSON, H.; WILLIAMS, C.; RAUSTE, Y.; NILSSON, M.; SANGO, D. et al. An overview of the JERS-1 SAR global boreal forest mapping (GBFM) project. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS 2004), 2004. **Proceedings...** [S.l.]: IEEE, 2004. v. 2, p. 1033–1036. 3

ROSENQVIST, A.; SHIMADA, M.; SUZUKI, S.; OHGUSHI, F.; TADONO, T.; WATANABE, M.; TSUZUKU, K.; WATANABE, T.; KAMIJO, S.; AOKI, E. Operational performance of the ALOS global systematic acquisition strategy and observation plans for ALOS-2 PALSAR-2. **Remote Sensing of Environment**, Elsevier, v. 155, p. 3–12, 2014. 3, 9, 20

ROY, D.; WULDER, M.; LOVELAND, T.; C.E., W.; ALLEN, R.; ANDERSON, M.; HELDER, D.; IRONS, J.; JOHNSON, D.; KENNEDY, R.; SCAMBOS, T.; SCHAAF, C.; SCHOTT, J.; SHENG, Y.; VERMOTE, E.; BELWARD, A.; BINDSCHADLER, R.; COHEN, W.; GAO, F.; HIPPLE, J.; HOSTERT, P.; HUNTINGTON, J.; JUSTICE, C.; KILIC, A.; KOVALSKYY, V.; LEE, Z.; LYMBURNER, L.; MASEK, J.; MCCORKEL, J.; SHUAI, Y.; TREZZA, R.; VOGELMANN, J.; WYNNE, R.; ZHU, Z. Landsat-8: Science and product vision for terrestrial global change research. **Remote Sensing of Environment**, v. 145, n. 0, p. 154–172, 2014. ISSN 0034-4257. 3, 7, 8

- SALOMÃO, R. de P.; VIEIRA, I. C. G.; JUNIOR, S. B.; AMARAL, D. D. do; SANTANA, A. C. Capoeira class system: a proposal of classification system of successional stages of secondary forests for Pará state. **Bol. Mus. Para. Emílio Goeldi**, Emilio Goeldi, v. 7, n. 3, p. 297–317, 2012. 24
- SANO, E. E.; FERREIRA, L.; ASNER, G.; STEINKE, E. Spatial and temporal probabilities of obtaining cloud-free landsat images over the Brazilian tropical savanna. **International Journal of Remote Sensing**, Taylor & Francis, v. 28, n. 12, p. 2739–2752, 2007. 49
- SANO, E. E.; FERREIRA, L. G.; HUETE, A. R. Synthetic aperture radar (L band) and optical vegetation indices for discriminating the Brazilian savanna physiognomies: A comparative analysis. **Earth Interactions**, v. 9, n. 15, p. 1–15, 2005. 41
- SANTOS, J.; GONCALVES, F.; NARVAES, I.; GRACA, P. Polarimetric responses and scattering mechanisms of tropical forests in the Brazilian Amazon. In: JEDLOVEC, G. (Ed.). **Advances in Geoscience and Remote Sensing**. [S.l.]: INTECH Open Access Publisher, 2009. 43
- SANTOS, J.; LACRUZ, M. P.; ARAUJO, L.; KEIL, M. Savanna and tropical rainforest biomass estimation and spatialization using jers-1 data. **International Journal of Remote Sensing**, Taylor & Francis, v. 23, n. 7, p. 1217–1229, 2002. 41, 55
- SANTOS, J.; MURA, J.; PARADELLA, W.; DUTRA, L.; GONCALVES, F. Mapping recent deforestation in the Brazilian Amazon using simulated L-band MAPSAR images. **International Journal of Remote Sensing**, Taylor & Francis, v. 29, n. 16, p. 4879–4884, 2008. 10
- SANTOS, J. R.; KEIL, M.; ARAUJO, L. S.; LACRUZ, M. S. P.; KRAMER, J. C. M.; KANDLER, O. Biomass estimation of forest and savanna transition vegetation zone by JERS-1 and SIR-C backscatter data. **International Archives of Photogrammetry and Remote Sensing**, IEEE, v. 33, n. 2, p. 341–352, 2000. 38
- SANTOS, J. R.; MARTINS, F. d. S. R. V.; GALVÃO, L. S.; XAUD, H. A. M. Contribution of polarimetric sar attributes for modeling of the tropical forest biomass affected by fire. In: 33RD EARSEL SYMPOSIUM: TOWARDS HORIZON 2020: EARTH OBSERVATION AND SOCIAL PERSPECTIVES, 2013, Matera, Italy. **Proceedings...** Matera: CNR, 2013. p. 219–226. 42

SANTOS, M. J. TECENDO A HISTÓRIA: INDÍCIOS DO SURGIMENTO DA LUTA DOS MOVIMENTOS SOCIAIS DO CAMPO EM RORAIMA. **Textos & Debates**, v. 1, n. 18, 2013. 19

SCHULTZ, B.; IMMITZER, M.; FORMAGGIO, A. R.; SANCHES, I. D.; LUIZ, A. J. B.; ATZBERGER, C. Self-guided segmentation and classification of multi-temporal Landsat-8 images for crop type mapping in Southeastern Brazil. **Remote Sensing**, Multidisciplinary Digital Publishing Institute, v. 7, n. 11, p. 14482–14508, 2015. 14

SESNIE, S. E.; GESSLER, P. E.; FINEGAN, B.; THESSLER, S. Integrating landsat tm and srtm-dem derived variables with decision trees for habitat classification and change detection in complex neotropical environments. **Remote Sensing of Environment**, Elsevier, v. 112, n. 5, p. 2145–2159, 2008. 45

SHIMABUKURO, Y. E.; ALMEIDA-FILHO, A.; KUPLICH, T. M.; DE FREITAS, R. M. Quantifying optical and SAR image relationships for tropical landscape features in the Amazon. **International Journal of Remote Sensing**, v. 28, p. 3831–3840, 2007. 3, 10

SHIMABUKURO, Y. E.; ALMEIDA-FILHO, R.; KUPLICH, T. M.; DE FREITAS, R. M. Use of Landsat TM fraction images to quantify the optical and SAR data relationships for land cover discrimination in the Brazilian Amazon. **International Journal of Geoinformation**, v. 4, n. 1, p. 57–63, 2008. 10

SHIMADA, M.; ITOH, T.; MOTOOKA, T.; WATANABE, M.; SHIRAISHI, T.; THAPA, R.; LUCAS, R. New global forest/non-forest maps from alos palsar data (2007–2010). **Remote Sensing of Environment**, Elsevier, v. 155, p. 13–31, 2014. 3

SHIRAISHI, T.; MOTOHKA, T.; THAPA, R. B.; WATANABE, M.; SHIMADA, M. Comparative assessment of supervised classifiers for land use–land cover classification in a tropical region using time-series palsar mosaic data. **Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of**, IEEE, v. 7, n. 4, p. 1186–1199, 2014. 11

SILVA, F. F. da; SANTOS, J. R. dos. Imagens alos/palsar na classificação da cobertura vegetal da região semi-árida brasileira. **Revista Brasileira de Cartografia**, n. 63, 2011. 4, 11, 29, 31

SILVA, G. F. N.; OLIVEIRA, I. J.; NASCIMENTO, D. T. F. Dinâmica multitemporal do uso e cobertura da terra em áreas de savanas no município de

Boa Vista-RR (2000/2014). In: XVII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2015, João Pessoa, Brasil. **Proceedings...** João Pessoa: INPE, 2015. p. 8114–8120. 47

SILVA, G. F. N.; XAUD, M. R.; OLIVEIRA, M. C. M.; OLIVEIRA, R. A. E.; TAVARES, S. S.; XAUD, H. A. M. **Monitoramento de parâmetros meteorológicos de risco de fogo em ecossistemas florestais na região do Apiaú – Roraima.** [S.l.]: EMBRAPA Boa Vista, 2006. 17 p. 17

SIMARD, M.; SAATCHI, S. S.; GRANDI, G. D. The use of decision tree and multiscale texture for classification of jers-1 sar data over tropical forest. **Geoscience and Remote Sensing, IEEE Transactions on, IEEE**, v. 38, n. 5, p. 2310–2321, 2000. 43

TEAM, R. C. **R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria, 2012.** [S.l.]: ISBN 3-900051-07-0, 2014. 29

TORRES, R. R.; LAPOLA, D. M.; MARENGO, J. A.; LOMBARDO, M. A. Socio-climatic hotspots in Brazil. **Climatic Change**, v. 115, p. 597–609, 2012. 1

Van Beijma, S.; COMBER, A.; LAMB, A. Random forest classification of salt marsh vegetation habitats using quad-polarimetric airborne sar, elevation and optical rs data. **Remote Sensing of Environment**, Elsevier, v. 149, p. 118–129, 2014. 4, 14, 15, 28, 29, 36

Van der Sanden, J. J. et al. **Radar remote sensing to support tropical forest management.** Netherlands: Tropenbos Guyana Series, 1997. 41

VUOLO, F.; MATTIUZZI, M.; ATZBERGER, C. Comparison of the landsat surface reflectance climate data record (cdr) and manually atmospherically corrected data in a semi-arid european study area. **International Journal of Applied Earth Observation and Geoinformation**, Elsevier, v. 42, p. 1–10, 2015. 19

WERF, G. R. V. D.; MORTON, D. C.; DEFRIES, R.; OLIVER, J. G. J.; KASIBHATLA, P. S.; JACKSON, R. B.; COLLATZ, G. J.; RANDERSON, J. CO2 emissions from forest loss. **Nature Geoscience**, v. 2, p. 737–738, 2009. 1, 2

XAUD, H. A. M. **Abordagem multisensor aplicada ao monitoramento de florestas tropicais atingidas for incendios em Roraima.** 2013. 155 p. Tese

(Doutorado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013. 36

XAUD, H. A. M.; MARTINS, F. d. S. R. V.; SANTOS, J. R. dos. Tropical forest degradation by mega-fires in the northern Brazilian Amazon. **Forest Ecology and Management**, Elsevier, v. 294, p. 97–106, 2013. 42

XAUD, H. A. M.; SANTOS, J. R. dos; CAMPOS, S. P. Contribution of the multisensor approach to monitoring tropical forests affected by recurrent fires. In: SEMINÁRIO DE ATUALIZAÇÃO EM SENSORIAMENTO REMOTO E SISTEMAS DE INFORMAÇÕES GEOGRÁFICAS APLICADOS À ENGENHARIA FLORESTAL, 9, 2010, Curitiba, Brasil. **Proceedings...** Curitiba: IEP, 2010. p. 350–357. 13

XIANG-ZHENG, D.; JIN-YAN, Z.; JI-YUAN, L.; DA-FANG, Z. The global rainforest mapping project jers-1: a paradigm of international collaboration for monitoring land cover change. **Journal of Geographical sciences**, Springer, v. 12, n. 1, p. 15–22, 2002. 3

ZHU, Z.; WOODCOCK, C. E. Object-based cloud and cloud shadow detection in Landsat imagery. **Remote Sensing of Environment**, v. 118, p. 83–94, 2012. ISSN 0034-4257. 19

ZHU, Z.; WOODCOCK, C. E.; ROGAN, J.; KELLNDORFER, J. Assessment of spectral, polarimetric, temporal, and spatial dimensions for urban and peri-urban land cover classification using landsat and sar data. **Remote Sensing of Environment**, Elsevier, v. 117, p. 72–82, 2012. 34, 50



## APÊNDICE A - SCRIPT EM R PARA CALIBRAÇÃO DOS MODELOS E CLASSIFICAÇÃO DE USO E COBERTURA DA TERRA COM RANDOM FOREST

```
# preparação das bandas para classificação adaptada do site
# https://geoscripting-wur.github.io/AdvancedRasterAnalysis
# /#supervised-classification-random-forest

library(raster)
library(maptools)
library(GISTools)
library(randomForest)

#Entrada dos dados
setwd("endereço da tabela com amostras de treinamento")
valuetable=read.csv("valuetable.csv") # tabela com valores das
                                     amostras de treinamento
valuetable$class <- factor(valuetable$class, levels = c(1:17)) # 17 classes
#View(valuetable)

#rasterStack
setwd("endereço dos rasters")
dirout1<-getwd()
list <- list.files(dirout1, pattern=glob2rx('*.*tif'), full.names=TRUE)
stack(list)
covs<-stack(list)

#-----#

# Preparando para classificação

setwd("endereço da pasta referente ao modelo x")

names(valuetable)
q=c(1,15) # seleciona as variáveis de entrada de cada modelo
# (neste caso as variáveis 1 e 15 da tabela,
# correspondentes ao HH_Amplitude e HV_Amplitude)
```

```

x=valuetable[,q]
names(x)
z=ncol(x)
z

OOBE=matrix(2, z, 10) # 10 é pra fazer de 100 a 1000 árvores
# cria uma matriz preenchida com valores 2,
# de 10 por z (número de variáveis de entrada)
# para armazenar o menor OOBE. 2 foi escolhido,
# pois os erros OOBE variam entre 0 e 1.

col=c("100","200","300","400","500","600","700","800","900","1000")
# nomes das colunas da tabela OOBE

row=c("1","2","3","4","5","6","7","8","9","10","11","12","13","14",
      "15","16","17","18","19", "20","21","22","23","24","25","26",
      "27","28","29","30","31","32","33","34","35")
# nomes das linhas. 35, pois são 35 variáveis de entrada

colnames(OOBE)=col
rownames(OOBE)=row[1:z]
OOBE # visualiza a matriz criada que será preenchida na próxima etapa

# Calibração de cada modelo

time=system.time({
  for(i in 1:10){
    ntrees=i*100
    for(j in 1:z){
      modelRF=randomForest(x, y=valuetable$class, ntree=ntrees, mtry=j,
        keep.forest = TRUE, importance = TRUE)
      OOBE[j,i]=modelRF$err.rate[ntrees,"OOB"]
      a = modelRF$err.rate[ntrees,"OOB"]
      b = min(OOBE)
      if (a == b) {RF = modelRF} # cria um data frame com o modelo
# de menor OOBE
    }
  }
}

```



```

    }
  })

OOBE_MAT=as.matrix(OOBE)
write.table(OOBE_MAT,"OOBE.csv", sep=",") # salva a matriz de
# OOBDE de cada modelo

inds = which(OOBE == min(OOBE), arr.ind=TRUE)
inds # indica o modelo de menor OOBE usado para classificação

vars=subset(covs, q) # bandas utilizadas para classificação

predLC = predict(vars, model=RF, na.rm=TRUE) # Classificação a partir
# do menor erro

setwd("endereço para salvar a classificação")

writeRaster(predLC, filename="RF1", format="GTiff") # salva o raster
# classificado em GeoTiff

```



## APÊNDICE B - SCRIPT EM R PARA CONFEÇÃO DOS MAPAS DE USO E COBERTURA DA TERRA

```
# MAPA

library(raster)
library(maptools)
library(GISTools)

# cores usadas para as classes

cols = c("magenta", "slateblue3","yellow4", "gold", "yellow", "wheat3",
"seagreen1", "seagreen3","gray47", "green4", "darkgreen",
"lightpink","lightpink4", "lawngreen", "lavenderblush3","indianred2",
"orange")

# para salvar em .png
# tamanho ajustado manualmente

png("Mapa.png", width=1043, height=640)

# legenda do mapa

plot(predLC, col=cols, legend=F)
legend("bottomright",
      legend=c("Agricultura", "Água", "Campinarana", "Campo cerrado",
"Campo limpo", "Campo sujo","Capoeira inicial",
"Capoeira intermediária", "Cerrado queimado", "Cerrado SS",
"Floresta","Pasto limpo", "Pasto sujo","Silvicultura",
"Silvicultura cortada","Solo exposto","Vereda"),
      fill=cols, cex = 1.2, bg="white")

# escala e norte

scalebar(d=5000, xy=c(699550,267000), type="bar", divs=2, below="km",
lonlat=FALSE, label=c("0","5","10"))
```

```
north.arrow(702000,269500,300,lab="N", col='gray')
```

```
# gera o arquivo .png
```

```
dev.off()
```

## APÊNDICE C - SCRIPT EM R PARA VALIDAÇÃO DOS MAPAS DE USO E COBERTURA DA TERRA

```
library(raster)
library(maptools)

##### Matriz de confusão #####

# referencia
setwd("endereço do shape de referência")
ref=readShapePoly("Validacao.shp", delete_null_obj=TRUE) # amostras de validação

ref@data$Code <- as.numeric(ref@data$Classe)

# cria um raster com a extensão do modelo
e=extent(706361.373, 739667.830, 265998.627, 299450.648)

#raster com extensão e crs do modelo pra associar ao shape
s=raster(e,nrows=3345, ncols=4278, crs=predLC@crs)

# rasteriza o shape de referência
ref = rasterize(ref, s, field='Code')

# extrai amostras da classificação
samp = mask(predLC, ref)

ref=as.vector(ref)
obs=as.vector(predLC)

cm=table(obs,ref) # matriz de confusão

# Criação da matriz com nomes das classes
# para cálculo das estatísticas de validação

sum_diag=0
```

```

tabela=matrix(0,ncol=ncol(cm)+1, nrow=nrow(cm)+1)

colnames(tabela)=c("Agricultura", "Água", "Campinarana", "Campo cerrado",
  "Campo Limpo","Campo sujo","Capoeira inicial", "Capoeira
intermediária", "Cerrado queimado","Cerrado SS", "Floresta",
"Pasto limpo", "Pasto sujo","Silvicultura","Silvicultura
cortada","Solo exposto","Vereda", "Total")

rownames(tabela)=c("Agricultura", "Água", "Campinarana", "Campo cerrado",
  "Campo Limpo","Campo sujo","Capoeira inicial", "Capoeira
intermediária", "Cerrado queimado","Cerrado SS", "Floresta",
"Pasto limpo", "Pasto sujo","Silvicultura","Silvicultura
cortada","Solo exposto","Vereda", "Total")

for (i in 1:nrow(cm)){
  for (j in 1:ncol(cm)) {
    tabela[i,j]=cm[i,j]
    if (i==j){
      sum_diag=sum_diag+cm[i,j]
    }
  }
}

for (i in 1:nrow(tabela)){
  tabela[i,ncol(tabela)] = sum(tabela[i,])
  tabela[nrow(tabela),i]=sum(tabela[,i])
}

tabela[nrow(tabela),ncol(tabela)]=tabela[nrow(tabela),ncol(tabela)]/2

# EXATIDÃO GLOBAL
OA = sum_diag/sum(cm)

# PRODUCER'S ACCURACY
PA = array(0,nrow(cm))

# USER'S ACCURACY
UA = array(0,nrow(cm))

```

```

for (i in 1:nrow(cm)){
  PA[i]=tabela[i,i]/tabela[nrow(tabela),i]
  UA[i]=tabela[i,i]/tabela[i,ncol(tabela)]
}

CE = 1-UA #Comission Error
OE = 1-PA #Omission Error

sum_diag_rand=0
rand_matrix=matrix(0,ncol=ncol(cm)+1, nrow=nrow(cm)+1)
colnames(tabela)=c("Agricultura", "Água", "Campinarana", "Campo cerrado",
  "Campo Limpo","Campo sujo","Capoeira inicial", "Capoeira
intermediária", "Cerrado queimado","Cerrado SS", "Floresta",
"Pasto limpo", "Pasto sujo","Silvicultura","Silvicultura
cortada","Solo exposto","Vereda", "Total")

rownames(tabela)=c("Agricultura", "Água", "Campinarana", "Campo cerrado",
  "Campo Limpo","Campo sujo","Capoeira inicial", "Capoeira
intermediária", "Cerrado queimado","Cerrado SS", "Floresta",
"Pasto limpo", "Pasto sujo","Silvicultura","Silvicultura
cortada","Solo exposto","Vereda", "Total")

for (i in 1:nrow(cm)){
  for (j in 1:ncol(cm)) { #com dois for ele vai percorrer a tabela toda
    rand_matrix[i,j]=tabela[i,ncol(tabela)]*tabela[nrow(tabela),j]
    /tabela[nrow(tabela),ncol(tabela)]
  }
  sum_diag_rand=sum_diag_rand+rand_matrix[i,i]
}
tot_rand=sum_diag_rand/sum(cm)

# KAPPA

k = (OA - tot_rand)/(1-tot_rand)
k      # valor Kappa

# Termos necessários para cálculo da variância do Kappa

```

```

theta3<-0
for (i in 1:nrow(cm)){
  theta3 <- theta3 + tabela[i,i]*(tabela[i,ncol(tabela)]+
  tabela[nrow(tabela),i])/(sum(cm)^2)
}

theta4<-0
for (i in 1:nrow(cm)){
  for (j in 1:ncol(cm)) {
    theta4=theta4 + tabela[i,j]*((tabela[i,ncol(tabela)]+
    tabela[nrow(tabela),j])^2)/(sum(cm)^3)
  }
}

theta1=0A
theta2=tot_rand

a=((theta1)*(1-theta1)/(1-theta2)^2)
b=(2*(1-theta1)*((2*theta1*theta2-theta3)/(1-theta2)^3))
c=((1-theta1)^2)*(theta4-4*(theta2^2))/(1-theta2)^4

# VARIÂNCIA DO KAPPA
varK=(a+b+c)/sum(cm)
varK      # valor da variância do kappa

##### TESTE Z #####

# matriz com valores de Kappa e variância do Kappa, em ordem.

mat = matrix(c(0.2377787, 0.2960462, 0.3284839, 0.3901606, 0.2323375,
0.3895695, 0.5267031, 0.6575679, 0.6455286, 0.744257, 0.7439306, 0.5226895,
0.6382118, 0.6399254, 0.8106876, 0.8066576, 0.8018461, 0.8045914,
# a partir daqui são os valores de variância do kappa em ordem
9.73393e-06, 1.063926e-05, 1.071825e-05, 1.136159e-05, 9.649894e-06,

```



```

1.135425e-05, 1.121606e-05, 1.002964e-05, 1.018479e-05, 8.427037e-06,
8.451471e-06,1.151954e-05, 1.056907e-05, 1.057313e-05, 6.854476e-06,
6.97785e-06, 7.117033e-06, 7.046165e-06),
nrow=18, # QUANTIDADE DE CLASSIFICAÇÕES
ncol=2)

colnames(mat)=c("Kappa", "Var_k")
rownames(mat)=c("1","2","3","4","5","6","7","8","9","10","11",
                "12","13","14","15","16","17","18")
mat

# Faz uma matriz com os números dos modelos nas linhas e colunas
tabela=matrix(0,ncol=nrow(mat), nrow=nrow(mat))
colnames(tabela)=c("1","2","3","4","5","6","7","8","9","10","11","12","13",
                  "14","15","16","17","18")
rownames(tabela)=c("1","2","3","4","5","6","7","8","9","10","11","12","13",
                  "14","15","16","17","18")

# cálculo dos valores Z

for (i in 1:nrow(mat)){
  for(j in 1:nrow(mat)){
    z=((mat[i,1])-(mat[j,1]))/(sqrt((mat[i,2])+(mat[j,2])))
    tabela[j,i]=z
  }
}

View(tabela) # Resultado
write.table(tabela, file="endereço para salvar a tabela com valores z",sep=",")

```