



**UNIVERSIDADE DE BRASÍLIA - UnB**  
**Departamento de Geografia - GEA**

# **IDENTIFICAÇÃO DE ÁREAS INUNDÁVEIS NA PORÇÃO SUL DE RORAIMA COM AUXÍLIO DE IMAGENS DE RADAR**

Gustavo Henrique Soares Ferreira

Orientador: Prof. Dr. Osmar Abílio de Carvalho Júnior

Dissertação de Mestrado

**Brasília-DF: Julho / 2018**



**UNIVERSIDADE DE BRASÍLIA - UnB**  
**Departamento de Geografia - GEA**

**IDENTIFICAÇÃO DE ÁREAS INUNDÁVEIS NA PORÇÃO SUL DE RORAIMA  
COM AUXÍLIO DE IMAGENS DE RADAR**

Gustavo Henrique Soares Ferreira

Dissertação de Mestrado submetida ao Departamento de Geografia da Universidade de Brasília, como parte dos requisitos necessários para a obtenção do Grau de Mestre em Geografia, área de concentração Gestão Ambiental e Territorial, opção Acadêmica Geoprocessamento.

Aprovado por:

---

**Prof. Dr. Osmar Abílio de Carvalho Júnior - Orientador**  
Universidade de Brasília

---

**Prof. Dr. Renato Fontes Guimarães**  
Universidade de Brasília

---

**Dr. Fernando Campagnoli**  
Agência Nacional de Energia Elétrica

**Brasília-DF, 20 de Julho de 2018**

## FICHA CATALOGRÁFICA

FERREIRA, GUSTAVO HENRIQUE SOARES.

Identificação de áreas inundáveis na porção sul de Roraima com auxílio de imagens de Radar,75p. (UnB-GEA, Mestre, Gestão Ambiental e Territorial, 2018).

Dissertação de Mestrado - Universidade de Brasília. Departamento de Geografia.

1.Geografia 2. Áreas Inundáveis 3.Sensoriamento Remoto 4. Geoprocessamento.

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação e emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito do autor.

---

Gustavo Henrique Soares Ferreira

## **AGRADECIMENTOS**

Agradeço, de maneira geral aos meus pais Simone e Josafá, por darem a melhor criação que um filho pode receber e por terem me incentivado a sempre seguir meus sonhos e objetivos; a minha amada Natalia por confiar seu coração a mim e me fazer enxergar que a vida pode sim ser repleta de momentos felizes e conquistas importantes; meus amigos de longa data, e irmão, por sempre estarem ao meu lado nestes anos, e colaborarem com o meu desenvolvimento, de modo a possibilitar que eu estivesse aqui, hoje, concluindo uma importante etapa da minha vida; ao professor Osmar, por ter me dado a devida orientação, desde o meu início na Geografia, e ter me mostrado o quão importante é para o Geógrafo saber utilizar corretamente as ferramentas que o circundam, para fazer Geografia. A todos, o meu muito obrigado!

## RESUMO

As áreas úmidas são de extrema importância para o equilíbrio da vida na Terra, compreender o seu comportamento é crucial para a preservação destes ecossistemas. Muitas dessas áreas, como as inseridas em domínio amazônico, são de difícil acesso para um estudo em campo. As técnicas de Sensoriamento Remoto têm evoluído muito, aliadas aos avanços da inteligência artificial, contribuindo para o desenvolvimento de estudos em locais de difícil acesso, possibilitando bons resultados de acordo com o tipo de dado utilizado. O presente estudo utilizou a técnica de aprendizado de máquina *Random Forest*, e limiar de retroespalhamento em imagens SAR do satélite Sentinel 1, da Agência Espacial Europeia, para identificar áreas úmidas no sul do estado de Roraima ao longo do ano de 2017. O trabalho identificou o comportamento típico de áreas inundáveis nas margens dos rios e feições adjacentes ao principal rio do estado (rio Branco). O pico de cheia foi encontrado no mês de Julho, cobrindo mais de 72.000 hectares da área de estudo (11,9% da área total da cena), e o de seca no mês de Dezembro, cobrindo mais de 37.000 hectares (6,1% da área total da cena).

Palavras chave: Áreas úmidas; Sensoriamento Remoto; Sentinel 1; Roraima.

## **ABSTRACT**

Wetlands are of extreme importance for the balance of life on Earth, understanding their behavior is crucial to the preservation of these ecosystems. Many of these areas, such as those in the Amazonian domain, are difficult to access for field study. The techniques of Remote Sensing have evolved a lot, combined with the advances of artificial intelligence, contributing to the development of studies in places of difficult access, allowing good results according to the type of data used. The present study used the Random Forest machine learning technique and backscatter threshold in SAR images of the Sentinel 1 satellite of the European Space Agency to identify wetlands in the south of the state of Roraima throughout 2017. The work identified the typical behavior of flooded areas on the banks of the rivers and features adjacent to the main river of the state (Rio Branco). The flood peak was found in July, covering more than 72,000 hectares of the study area (11.9% of the total area of the scene), and the dry season in December, covering more than 37,000 hectares (6.1 % of the total area of the scene).

**Keywords:** Wetlands; Remote Sensing; Sentinel 1; Roraima.

## SUMÁRIO

LISTA DE FIGURAS

LISTA DE TABELAS

LISTA DE ABREVIATURAS E SIGLAS

<b>1. INTRODUÇÃO .....</b>	<b>13</b>
<b>2. ÁREA DE ESTUDO .....</b>	<b>15</b>
<b>3. REVISÃO TEÓRICA .....</b>	<b>19</b>
3.1 Sensoriamento remoto por radar .....	19
3.2 Aplicações das imagens SAR .....	24
3.3 Classificação de imagens SAR .....	24
<b>4. MATERIAIS E MÉTODOS .....</b>	<b>28</b>
4.1 Imagens Sentinel-1 .....	29
4.2 Dados auxiliares.....	33
4.2 Pré-processamento e tratamento de ruídos .....	40
4.3 Classificação .....	42
4.5 Identificação das áreas inundáveis.....	43
<b>5. RESULTADOS .....</b>	<b>45</b>
5.1 Análise das polarizações VV e VH na detecção de áreas inundáveis.....	45
5.2 Pré-processamento .....	47
5.3 Sazonal.....	48
5.3.1 Tratamento de ruídos .....	48
5.3.2 Classificação .....	50
5.4 Data a data .....	54
5.4.1 Tratamento de ruídos .....	54
5.4.2 Classificação .....	56
<b>6. CONSIDERAÇÕES FINAIS.....</b>	<b>63</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>66</b>

## LISTA DE FIGURAS

<b>Figura 1.</b> Localização da área de estudo, imagem de radar do satélite Sentinel 1. Nota-se em termos visuais, a semelhança de cor entre as Campinaranas e as planícies fluviais dos cursos d'água de menor hierarquia na imagem, evidenciando sua relação direta com ambientes alagáveis. ....	<b>15</b>
<b>Figura 2.</b> Unidades mapeadas pela base contínua cartográfica em escala 1:100.000. ....	<b>18</b>
<b>Figura 3.</b> Demonstração do ângulo de incidência. Henderson & Lewis 1998 (Adaptado). ....	<b>23</b>
<b>Figura 4.</b> Tipos de espalhamento: Especular, Difuso e Reflexão de canto. Ponzoni et al. 2015 (Adaptado). ....	<b>24</b>
<b>Figura 5.</b> Fluxograma básico dos processos executados na metodologia de classificação. ....	<b>28</b>
<b>Figura 6.</b> Modos de aquisição dos diferentes produtos Sentinel (Adaptado de Snoeij et al. 2009). ....	<b>30</b>
<b>Figura 7.</b> Forma como são nomeadas as cenas Sentinel. ....	<b>31</b>
<b>Figura 8.</b> Localização da estação Fluviométrica/Pluviométrica de Santa Maria do Boiaçu. ..	<b>34</b>
<b>Figura 9.</b> Comportamento das cotas altimétricas e precipitação acumulada na estação. Em vermelho a curva isolada com os dados do ano de 2017. ....	<b>35</b>
<b>Figura 10.</b> Variação altimétrica extraída de MDE da missão SRTM, esquerda, e aprimorado com os dados Sentinel, direita. ....	<b>36</b>
<b>Figura 11.</b> Imagens de estatística descritiva do cubo de MDEs, média (A)- desvio padrão (B) e variância (C). ....	<b>38</b>
<b>Figura 12.</b> Composição colorida (Landsat 8) da área de estudo e as curvas espectrais referentes à vegetação (a) Rio Branco (b) e Campinaranas/Brejo (c). ....	<b>39</b>
<b>Figura 13.</b> Demonstração da formação do ruído Speckle. Henderson & Lewis 2008 (Adaptado). ....	<b>41</b>
<b>Figura 14.</b> Diferença espectral entre as duas polarizações ao longo do tempo. ....	<b>45</b>
<b>Figura 15.</b> Diferença visual entre as duas polarizações (a) VV (b) VH. Os pontos destacados com a seta vermelha indicam as áreas com maior diferença entre a resposta das duas polarizações, afetando assim a interpretação correta do fenômeno estudado. ....	<b>46</b>
<b>Figura 16.</b> Composição colorida com a diferença entre as imagens VV e VH. R(VV) G(VH) B(subtração entre VV e VH). ....	<b>47</b>
<b>Figura 17.</b> Localização da nuvem na imagem do dia 22/04/2017. Observa-se que a interferência na imagem não é muito substancial, porém por se localizar acima de uma área de Campinarana, a melhor decisão é retirá-la do conjunto de dados. ....	<b>48</b>
<b>Figura 18.</b> Componentes utilizadas na operação inversa da MNF. ....	<b>49</b>
<b>Figura 19.</b> Resultado do tratamento de ruídos no cubo multitemporal com a transformação MNF. ....	<b>50</b>



<b>Figura 20.</b> Gráficos de média e desvio padrão das amostras coletadas.....	<b>52</b>
<b>Figura 21.</b> Resultado da classificação temporal utilizando <i>Random Forest</i> , em verde a Floresta Ombrófila, em ciano as áreas úmidas/inundáveis e em azul os Rios e corpos d'água menores, bem como as áreas que ficaram totalmente cobertas por água durante todo período estudado. ....	<b>54</b>
<b>Figura 22.</b> Diferença entre os dois tipos de filtro adaptativo utilizado. ....	<b>55</b>
<b>Figura 23.</b> Histograma de frequência e valores escolhidos para limiares de água e alvos com conteúdo hídrico elevado (as duas setas vermelhas indicam onde estão os pixels de água aberta "A" e áreas inundáveis "B") .....	<b>57</b>
<b>Figura 24.</b> Diferença visual entre os limiares -16dB(a), -17dB(b) e -18dB(c).....	<b>58</b>
<b>Figura 25.</b> Mapa com a diferença visual entre a data mais cheia, 27/07/2017, e a mais seca 06/12/2017.....	<b>59</b>
<b>Figura 26.</b> Média dos meses classificados pelo limiar de -17dB. ....	<b>60</b>
<b>Figura 27.</b> Distribuição em gráfico da área coberta pela classe água ao longo dos meses analisados. ....	<b>61</b>
<b>Figura 28.</b> Variação altimétrica da área inundável projetada sobre a média de todos os MDEs aprimorados com as imagens Sentinel.....	<b>63</b>
<b>Figura 29.</b> Distribuição gráfica da área ocupada pela classe inundável separada por cotas altimétricas.....	<b>63</b>

## LISTA DE TABELAS

<b>Tabela 1.</b> Bandas de radar e seus respectivos comprimentos de onda e frequência (Henderson & Lewis, 1998). .....	<b>21</b>
<b>Tabela 2.</b> Modos de imageamento pelo sensor e seus diferentes parâmetros (Adaptado de Snoeij et al. 2009). .....	<b>29</b>
<b>Tabela 3.</b> Imagens Sentinel-1 adquiridas para a área de estudo. ....	<b>32</b>
<b>Tabela 4.</b> Estatística descritiva dos MDEs aprimorados com imagens Sentinel. ....	<b>37</b>
<b>Tabela 5.</b> Média da área coberta pela classe água ao longo de 2017. ....	<b>62</b>

## **LISTA DE ABREVIATURAS E SIGLAS**

ANA - Agência Nacional de Águas.

APC – Análise de Principais Componentes.

ESA - Agência Espacial Européia.

EW - Extra Wide Swath Mode.

FMR – Fração Mínima de Ruído.

FR - Full Resolution.

GRD - Ground Range Detected.

HR - High Resolution.

IW - Interferometric Wide Swath Mode.

MDE - Modelo Digital de Elevação.

MEC - Massa Equatorial Continental.

MNF – Minimal Noise Fraction.

MR – Medium Resolution.

OCN - Ocean

RADAM - Projeto Radar da Amazônia.

RAR - Radar de Abertura Real.

REM - Radiação Eletromagnética.

RF – Random Forests.

RNA - Redes Neurais Artificiais.

S1A -Sentinel 1A

SAR - Radar de Abertura Sintética (Synthetic Aperture Radar).

SNR – Signal to Noise Ratio

SIG - Sistema de Informações Geográficas.

SLAR - Radar de Visada Lateral.

SLC - Single Look Complex

SM - Strip-Map Mode.

SNAP –Sentinel Application Platform.

SPU - Secretaria do Patrimônio da União.

SRTM - Shuttle Radar Topography Mission.

SVM - Support Vector Machine.

WV - Wave Mode.

## 1. INTRODUÇÃO

As áreas inundáveis são de extrema importância para a manutenção da vida terrestre e trazem consigo inúmeras particularidades de um ecossistema único intimamente ligado à dinâmica hidrológica local e regional, carecendo ser preservado e estudado (Townsend & Walsh 2001; Ozesmi & Bauer 2002; Touzi et al. 2007; Bartsch et al. 2009; Moraes Novo 2010; Lin et al. 2013; White et al. 2015). A Convenção Ramsar estabeleceu um marco de conservação das áreas úmidas, atribuindo-lhes valor ecológico mundial, com a finalidade de manter e preservar os recursos provindos deste ambiente sensível (Ramsar Convention 1971).

No Brasil, as áreas inundáveis estão sob domínio da União e seguem uma legislação própria para utilização e gestão. De acordo com a Constituição Federal de 1988, art. 20, a gestão da União se dá sob ilhas fluviais e lacustres nas zonas limítrofes com outros países; praias marítimas; ilhas oceânicas e costeiras (com exceção de capitais e sedes municipais); mar territorial; terrenos de marinha; recursos minerais; sítios arqueológicos e pré-históricos; terras indígenas; e terrenos marginais (BRASIL, 1988). Segundo Decreto de Lei n 9.760/1946, os Terrenos Marginais são áreas banhadas pelas correntes navegáveis, fora do alcance das marés, vão à distância de quinze metros, medidos horizontalmente para a parte da terra, contados desde a linha média das enchentes ordinárias. Ainda, as áreas alagáveis adjacentes aos rios de domínio Federal, contidas na linha média de enchentes ordinárias, estão sob domínio da União.

A identificação de tais áreas é feita em campo, pela equipe técnica da Secretaria do Patrimônio da União (SPU) por mão de suas superintendências nos estados brasileiros, o que demandava alto custo de tempo e recursos financeiros. Muitos dos locais, principalmente na Amazônia, são de difícil acesso para a identificação em campo, o que torna o trabalho ainda mais complexo do ponto de vista técnico e logístico. Estes fatores dificultam o processo de identificação e caracterização das áreas úmidas, que é uma etapa chave de qualquer trabalho que seja desenvolvido em ambientes inundáveis.

No domínio Amazônico, além da cobertura vegetal da Floresta Ombrófila tem-se outras formações que caracterizam o ambiente local como sendo passível de inundações, como as Campinaranas. Ao longo do curso do rio Branco, no Estado de Roraima é comum a presença das Campinaranas, com porte arbustivo médio-baixo e uma fitofisionomia característica de ambientes úmidos, como galhos mais finos e raízes expostas por conta do solo encharcado, gerando escassez de nutrientes essenciais (Carvalho 2015).

O avanço das técnicas de Sensoriamento Remoto e Geoprocessamento, em conjunto com a evolução das técnicas computacionais de processamento de imagens, abre uma nova possibilidade para a identificação das áreas inundáveis com a aquisição de dados periódicos dos locais mais inacessíveis. No domínio Amazônico, as imagens de radar SAR (Radar de Abertura Sintética) são adequadas para a identificação de áreas alagáveis por conseguir atravessar a constante cobertura de nuvens que impede os sensores óticos de imagear a superfície (Hess et al. 1995; Henderson & Lewis 1998; Hess et al. 2003; Woodhouse 2006; Jensen 2009; Moraes Novo 2010; Arnesen et al. 2013; Ponzoni et al. 2015).

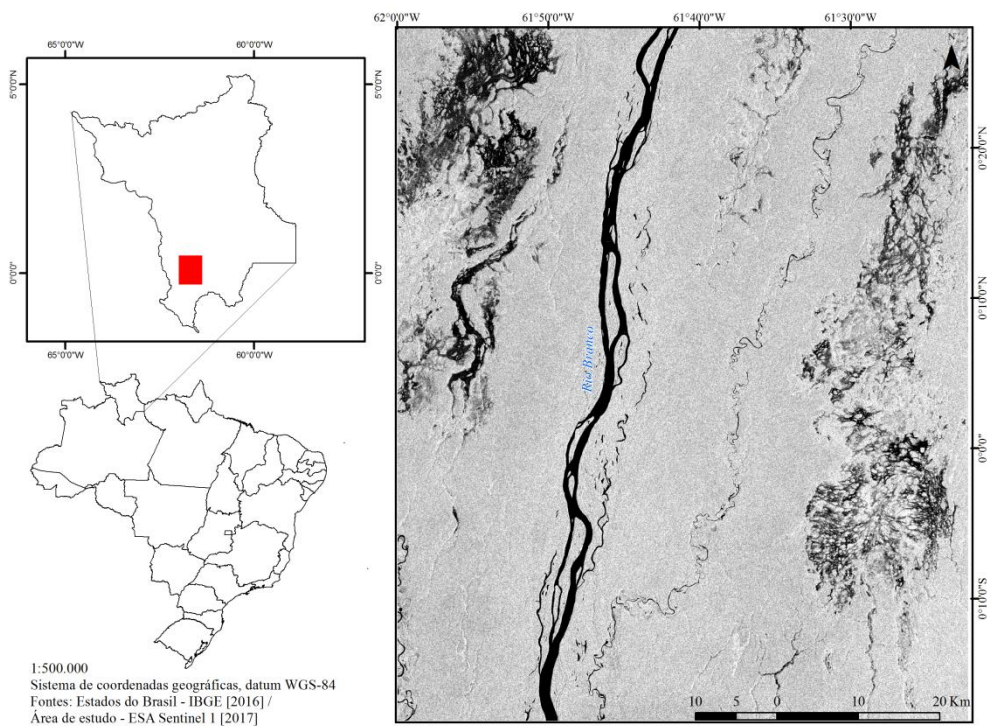
O programa Sentinel 1, da Agência Espacial Europeia (ESA), consiste em uma constelação de dois satélites equipados com sensores radar do tipo SAR, cujos produtos são distribuídos gratuitamente, que operam na banda C da faixa espectral das micro-ondas, sendo utilizados no mapeamento e monitoramento dos seguintes ambientes: ártico; marinho; áreas de riscos de movimentos de massa; ambientes inundáveis; apoio em desastres; entre outros (Snoeijs et al. 2009; Snoeijs et al. 2009b; Malenovsky et al. 2012; Torres et al. 2012; Guccione et al. 2015). Sua resolução temporal de 12 dias para a cobertura de apenas 1 satélite e 6 dias para o uso dos dois, garante uma série temporal robusta, permitindo um bom conjunto de dados sobre a dinâmica espacial na superfície terrestre, como, por exemplo, a dinâmica hídrica em ambientes inundáveis.

Neste contexto, o presente trabalho objetiva identificar as áreas inundáveis nas adjacências do baixo curso do rio Branco, extremo sul do estado de Roraima, por conta das feições adjacentes ao rio Branco nesta porção que possuem características de ecossistemas inundáveis, a partir de séries temporais de imagens de radar do satélite Sentinel 1, escolhidas por causa de sua resolução espacial de 10 metros e disponibilidade gratuita, com técnicas de classificação clássicas de Sensoriamento Remoto e de inteligência artificial, durante o ano de 2017.

Portanto, busca-se traçar o comportamento das áreas úmidas ao longo do tempo, afim de subsidiar trabalhos de caracterização hidrológica nas Campinaranas, formação de vegetação típica de ambientes inundáveis e que se faz presente na área de estudo deste trabalho, visando a celeridade do processo de identificação de tais ambientes, principalmente se tratando do domínio Amazônico, que possui uma extensa área de planícies inundáveis. Além desta introdução, o trabalho possui mais cinco capítulos, quais sejam: área de estudo (capítulo 2); revisão teórica (capítulo 3); materiais e métodos (capítulo 4); resultados (capítulo 5); e considerações finais (capítulo 6).

## 2. ÁREA DE ESTUDO

A área de estudo situa-se na porção sul do estado de Roraima (destaque em vermelho na **Figura 1**), onde se encontra o baixo curso do rio Branco (principal rio do Estado) com cerca de 428km de extensão até desaguar no rio Negro, que por sua vez deságua no rio Amazonas. Essa área é dominada pelas paisagens fluviais, flora e fauna amazônica (BRASIL 2010b; ISA 2012; BRASIL 2013). Na **Figura 1**, as feições relativas às Campinaranas, A formação vegetal considerada como a "caatinga amazônica", por ser uma vegetação baixa sobre um solo arenoso, sua localização em domínio amazônico está ligada ao elevado índice pluviométrico (Araujo Furtado de Mendonça et al. 2015), e outras áreas úmidas ocorrem a leste e oeste do rio Branco (que corta a imagem no sentido Norte/Sul). Todas as feições destacadas na descrição estão em tonalidade mais escura, indicando um acúmulo hídrico considerável. A floresta mantém um tom mais claro, característico da resposta da cobertura vegetal na faixa das micro-ondas.



**Figura 1.** Localização da área de estudo, imagem de radar do satélite Sentinel 1. Nota-se, em termos visuais, a semelhança de cor entre as Campinaranas e as planícies fluviais dos cursos d'água de menor hierarquia na imagem, evidenciando sua relação direta com ambientes alagáveis.

Conforme a classificação climática de Köppen, o clima da região é tropical equatorial chuvoso (Af) com estação seca pouco definida, elevado índice de precipitação anual (acima

de 2000 mm), e pouca variação ao longo dos meses e anos. A variação de temperatura é baixa, não chegando a ultrapassar 5°C dentro das médias mensais (RADAM 1975; Barbosa 1997; BRASIL 2010a; BRASIL 2010b). O período abaixo da média pluviométrica ocorre entre os meses de agosto a outubro. Essa porção do estado sofre forte influência da massa de ar equatorial (mEc), que provoca chuvas fartas em quase todo ano, por conta da presença de forte umidade e da condensação desta massa de ar (Barbosa 1997).

A área se encontra sobre sedimentos aluvionares inconsolidados do período Quaternário, da Formação Içá. A Depressão do Rio Branco – Rio Negro é formada por depósitos de cascalhos, areias quartzosas e argilas nos leitos e terraços dos principais cursos d'água (RADAM 1975; Fraga et al. 1999; BRASIL 2010b; Wankler et al. 2012; Morais & Carvalho 2013; Carvalho 2015). Tais sedimentos foram depositados em decorrência dos processos fluviais, em áreas de planícies de inundação (RADAM 1975; Reis et al. 2003; BRASIL 2010b). A porção sul de Roraima possui extensas áreas inundadas permanentemente ou periodicamente, estando em uma região de depressão com rios majoritariamente de padrão meandrante que cortam planícies alagáveis (RADAM 1975; BRASIL 2010b; Carvalho 2015).

O relevo do sul de Roraima distingue-se por ser aplainado, com baixa variação altimétrica (obtendo cotas entre 100 e 150 metros), e com uma topografia de ondulações pouco acentuadas (RADAM 1975; BRASIL 2010b; Morais & Carvalho 2013). A área está situada nas unidades Morfoestruturais: Depressão do Rio Branco-Rio Negro e Planície Amazônica, que pertencem ao Domínio dos Depósitos Sedimentares Inconsolidados (RADAM 1975; BRASIL 2010b). Uma das principais características dessas unidades é o fato de serem áreas de baixa elevação, que são permanentemente ou periodicamente inundadas. Segundo o projeto RADAM (1975), as áreas de acumulação inundáveis representavam 106.000 km<sup>2</sup> de um total de 195.000 km<sup>2</sup> de área estudada pelo mesmo na depressão do Rio Branco – Rio Negro (RADAM 1975).

A Depressão do Rio Branco-Rio Negro é considerada uma evidência de pediplano antigo que aplainou a área e deixou, como consequência do processo, depressões em que se instauraram cursos d'água e tornaram o ambiente propício ao aparecimento de áreas de inundação. Já a Planície Amazônica, sofreu, basicamente, um aplainamento causado pelas oscilações climáticas no Quaternário (RADAM 1975; BRASIL 2010b).

Os solos do sul de Roraima são predominantemente arenosos Hidromórficos e Neossolos Quartzarênicos, com baixa capacidade de drenagem superficial, pobre em matéria orgânica e pouca aptidão agrícola (RADAM 1975; BRASIL 2010a; BRASIL 2010b; BRASIL 2013; Morais & Carvalho 2013). Esses solos são de baixa fertilidade, arenosos e com



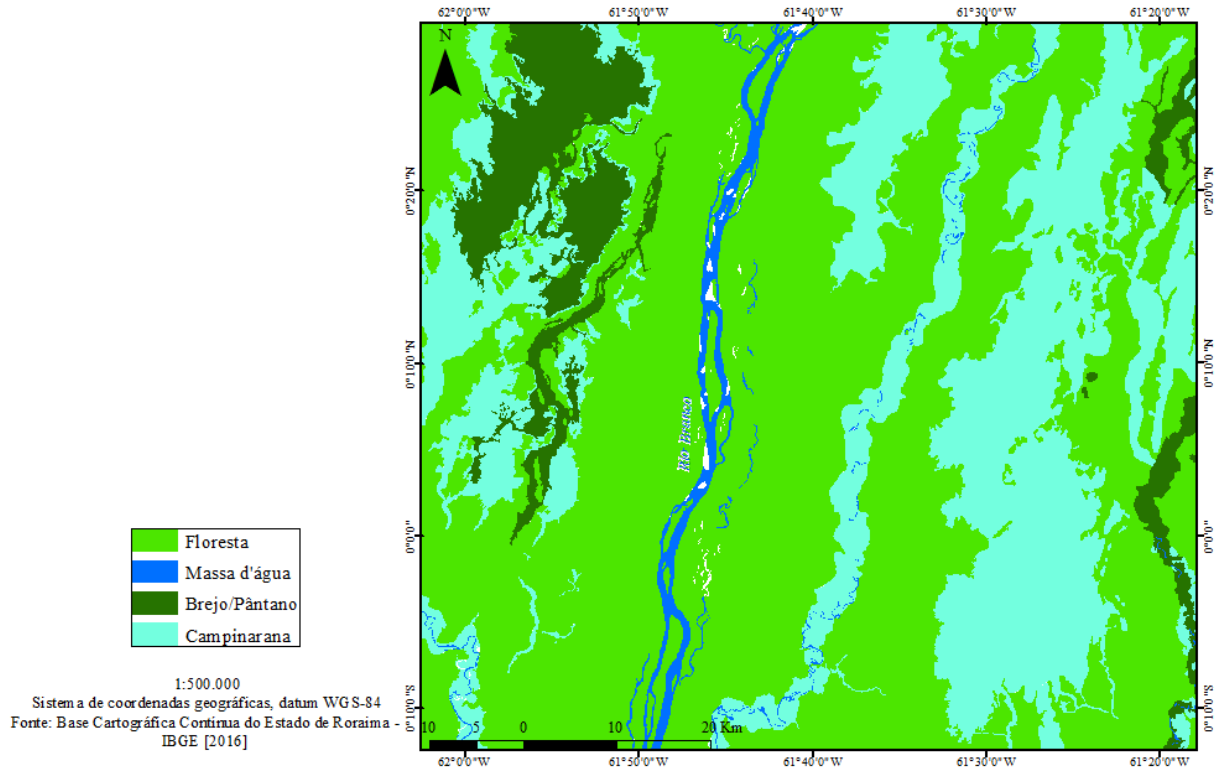
problemas por conta da frequente elevação do nível freático (RADAM 1975). No Domínio da Depressão do Rio Branco-Rio Negro encontra-se o predomínio de solos com B latossólico (Floresta Ombrófila) e solos arenosos hidromórficos, (Campinaranas) (BRASIL 2010b).

A área de estudo, **Figura 2**, possui dois tipos principais de vegetação: Floresta Ombrófila Densa e Campinaranas (RADAM 1975; Barbosa & Fearnside 1999; BRASIL 2010a; BRASIL 2010b; ISA 2012; Conde e Tonini 2013; Morais & Carvalho 2013; BRASIL 2013; Carvalho 2015). As Campinaranas são formações pioneiras de porte arbustivo médio-baixo presentes em planícies fluviais (RADAM 1975; Carvalho 2015; Guimarães & Bueno 2016). As Campinaranas podem ser divididas em: florestada, arborizada, arbustiva e a gramíneo-lenhosa (BRASIL 2010b).

As Campinaranas fazem parte do ecossistema amazônico, cobrindo 7% da conhecida Amazônia Legal. Por estar inserida em um ambiente que sofre com inundações periódicas, as Campinaranas possuem um elevado número de raízes para se adaptar aos períodos de saturação hídrica com escassez de oxigênio, e o próprio porte arbustivo, adaptado ao solo geralmente pobre (IBGE 2012; Guimarães & Bueno 2016).

A Floresta Ombrófila Densa do sul de Roraima é bem estruturada, madura e diversa, porém apresenta poucas espécies raras quando comparada às demais com esse tipo de vegetação (Conde e Tonini 2013). É neste ambiente de vegetação que vem ocorrendo, de forma sistemática, o desmatamento para fins agroindustriais no sul do Estado, que acaba por ocasionar focos de incêndio no local e outros danos ao meio ambiente (Barbosa & Fearnside 1999; ISA 2012; BRASIL 2013). Segundo Freitas et al. (2011), a área plantada no sul de Roraima no ano de 2005 era de 19.900 (ha) e a tendência é o aumento progressivo. O processo de desmatamento também está atrelado à abertura de projetos de assentamento, tendo em vista a boa oferta de terras públicas no estado (De Mello e Théry 2001; Barni et al. 2012)

O mapeamento de vegetação do IBGE (2016), **Figura 2**, referente à base cartográfica contínua do estado de Roraima, demonstra que a área de estudo possui uma predominância das Campinaranas nas áreas adjacentes ao rio Branco. Outra unidade que surge no mapeamento do IBGE corresponde às áreas de brejo ou pântano a depender da localidade, que estão contidas em áreas comuns às Campinaranas.



**Figura 2.** Unidades mapeadas pela base contínua cartográfica em escala 1:100.000.

### 3. REVISÃO TEÓRICA

#### 3.1 Sensoriamento remoto por radar

Os radares são sistemas ativos que trabalham na região espectral das micro-ondas. Os sistemas de sensores ativos são aqueles que emitem seu próprio feixe de radiação eletromagnética e a partir daí recebem a resposta do alvo (Woodhouse 2006; Jensen 2009; Moraes Novo 2009; Moraes Novo 2010; Zhang et al. 2013; Ponzoni et al. 2015). Segundo Moraes Novo (2010), o radar executa cinco funções básicas: transmissão do pulso de micro-ondas em direção ao alvo, recepção da porção refletida pelo alvo (energia retroespalhada), registro da potência, variação temporal e tempo de retorno da energia retroespalhada. Os sensores radares possuem certas vantagens sobre os óticos: (a) o imageamento pode ser no período diurno ou noturno, por conta de não depender da radiação eletromagnética provinda do sol, e (b) opera quase sem interferência de nuvens, precipitação ou neblina, permitindo uma cobertura em condições de tempo adversas (Woodhouse 2006; Henderson & Lewis 2008; Jensen 2009; Moraes Novo 2009; Moraes Novo 2010; Feng et al. 2011; Aytekin et al. 2013; Servello et al. 2015; Ponzoni et al. 2015). No entanto, tal propriedade está diretamente ligada ao comprimento de onda utilizado, onde alguns fenômenos atmosféricos mais extremos podem interferir no imageamento, em linhas gerais naqueles comprimentos de onda que vão de 0,75 a 10 cm como as bandas Ka, K, Ku, X, C, S e P (**Tabela 1**), por conta da interação da onda emitida pelo sensor com as partículas de maior tamanho, geralmente criadas nos fenômenos atmosféricos como moléculas de água e gelo em precipitações de maior volume e/ou tempestades. (Woodhouse 2006; Henderson & Lewis 2008).

Os primeiros instrumentos que funcionavam com o princípio do radar foram utilizados no contexto da segunda guerra mundial, com aparelhos mais rudimentares que detectavam alvos utilizando pulsos de radiação em micro-ondas com um magnetron de cavidade, pois ainda não existiam os transmissores de antena, para detectar alvos inimigos (Woodhouse 2006). Após um certo período, surgiram os primeiros Radares voltados para o imageamento, na década de 1950, os chamados Radares de Visada Lateral (SLAR), que eram do tipo RAR (radar de abertura real) e necessitavam de uma grande infraestrutura (especificamente uma antena de grandes dimensões) para obter imagens com resolução razoável. Então, com a crescente evolução tecnológica, foram introduzidos os Radares de Abertura Sintética (SAR), que simulam digitalmente o tamanho necessário da antena para se chegar à resolução esperada (Woodhouse 2006; Moraes Novo 2009; Moraes Novo 2010; Ponzoni et al. 2015). Os SAR são largamente utilizados em estudos sobre fenômenos na superfície terrestre.

Como o Radar registra a porção de energia retroespalhada pelo alvo iluminado, existe uma limitação prática que diz respeito ao quanto de energia retroespalhada o sistema consegue registrar, para essa quantificação tem-se a equação Radar (Woodhouse 2006), onde:

$$\text{Potência espalhada pelo alvo} = P_t G \frac{\sigma}{4\pi R^2}$$

$P_t$  = Potência que sai da antena;

$G$  = Padrão de sensibilidade da antena (Ganho);

$\sigma$  = Refletividade de uma célula de resolução, dada por: Potência refletida pelo alvo em direção ao Radar / Potência que seria refletida por um alvo isotrópico;

$\frac{\sigma}{4\pi R^2}$  = Área proporcional interceptada pelo alvo para uma superfície com área esférica de raio  $R$ .

Portanto, esta equação não resolve totalmente a questão do radar imageador, pois quanto maior a distância de retorno do alvo, menor será a radiação registrada, então ela pode decair a um fator maior que  $4\pi R^2$ . É preciso determinar a densidade da potência do sinal espalhado para a antena. Por esse motivo, deve-se adicionar uma porção de área efetiva da antena para uma superfície esférica de raio  $R$  (Woodhouse 2006; Oliver & Quegan 2004). Então temos:

$$\text{Sinal recebido} = P_R = \left( P_t G \frac{\sigma}{4\pi R^2} \right) \frac{A_e}{4\pi R^2}$$

$P_r$  = Densidade da potência do sinal espalhado para a antena;

$A_e$  = Área efetiva da antena para uma superfície esférica de raio  $R$ .

$A_e$  pode ser dado por:  $\frac{G\lambda^2}{4\pi}$ , onde  $\lambda$  é o comprimento de onda. Sendo assim, a equação pode ser

descrita da seguinte forma:

$$P_r = \frac{P_t G^2 \lambda^2 \sigma}{(4\pi)^3 R^4}$$

Porém, a equação descrita ainda não leva em conta o ruído do sistema radar, dado por  $N_0$ . Então, para melhor representação usa-se a fração ruído-sinal, *signal-to-noise ratio* SNR, (Woodhouse 2006) dada por:

$$\left( \frac{P_r}{N_0} \right) = \frac{P_t G^2 \lambda^2 \sigma}{(4\pi)^3 R^4 N_0}$$

A equação apresentada acima descreve os sistemas de abertura real. Para um sistema de abertura sintética, a equação não satisfaz por completo, pois, no caso descrito, se aplica para um simples sinal recebido, entretanto os SAR contam com a adição coerente de  $n$  sinais recebidos (Woodhouse 2006). Sendo assim, para os SAR, temos:

$$SNR_{SAR} = \frac{P_t G^2 \lambda^3 \sigma^0 p_r PRF}{(4\pi)^3 R^3 N_0 2V}$$

PRF = Frequência de repetição do pulso (*pulse repetition frequency*);

$\sigma^0$  = Energia retroespalhada.

V = Velocidade.

A classificação dos radares considera parâmetros particulares, que são, em geral, o comprimento de onda/frequência, ângulo de incidência e o tipo de polarização (Henderson & Lewis 1998; Ponzoni et al. 2015). O comprimento de onda está relacionado à banda em que o sistema é capaz de operar, a interação da radiação na faixa das micro-ondas com os alvos em superfície terrestre é dependente da banda utilizada. Devido ao fato do sistema gerar a sua própria energia, raramente se tem plataformas que operem em várias bandas (Ponzoni et al. 2015). A **Tabela 1** elenca as principais bandas utilizadas pelos sistemas SAR, juntamente com os respectivos comprimentos de onda e frequência, cada uma das diferentes bandas permite uma penetração distinta da radiação nos alvos, que aumenta de acordo com o comprimento de onda (Ponzoni et al. 2015).

**Tabela 1.** Bandas de radar e seus respectivos comprimentos de onda e frequência (Henderson & Lewis, 1998).

Banda	Comprimento de onda $\lambda$ (cm)	Frequência $f$ (MHz)
P	136-77	220-390
UHF	100-30	300-1.000
L	30-15	1.000-2.000
S	15-7,5	2.000-4.000
C	7,5-3,75	4.000-8.000
X	3,75-2,40	8.000-12.500
Ku	2,40-1,67	12.500-18.000
K	1,67-1,18	18.000-26.500
Ka	1,18-0,75	26.500-40.000

O ângulo de incidência ( $\Theta$ ) é o ângulo entre o pulso transmitido pelo radar e uma linha perpendicular à superfície. Ele é um dos principais parâmetros que determinam a aparência dos alvos nas imagens (Henderson & Lewis 1998; Woodhouse 2006; Meneses & Sano 2011;

Ponzoni et al. 2015) (**Figura 3**). Assumindo que a radiação eletromagnética (REM) possui campos magnéticos e elétricos que se propagam em direções transversais, a polarização é a trajetória do campo elétrico em um dado plano (Ponzoni et al. 2015). Assim, quando o campo elétrico se desloca paralelo à propagação, ocorre a polarização horizontal (H), quando se desloca perpendicularmente à propagação, tem-se polarização vertical (V) (Henderson & Lewis 1998; Woodhouse 2006; Freitas et al. 2007; Meneses & Sano 2011, Ponzoni et al. 2015).

Os sistemas de radar, por serem ativos, permitem quatro combinações de polarização, que tem relação direta na interação da radiação de micro-ondas com os alvos em superfície, são elas: HH que transmite e recebe o pulso horizontalmente, VV que transmite e recebe verticalmente, VH que transmite verticalmente e recebe horizontalmente e HV, que transmite horizontalmente e recebe verticalmente (Woodhouse 2006; Ponzoni et al. 2015).

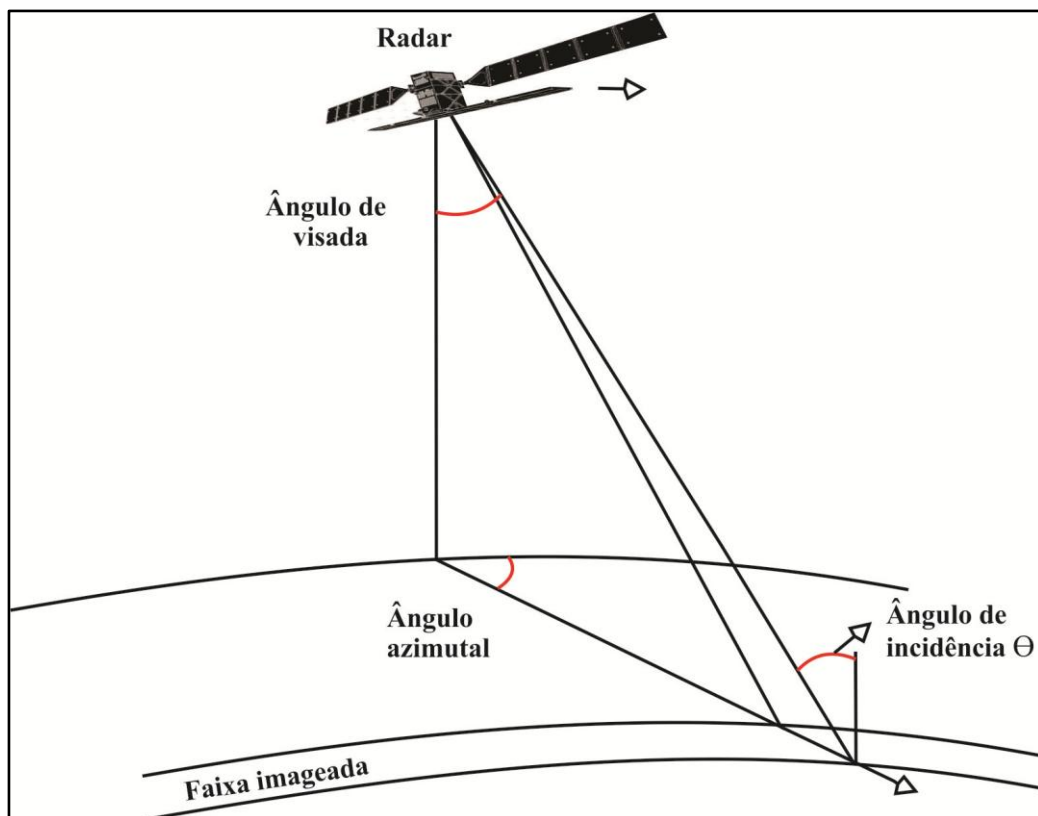
Ao imagear uma área na superfície, o radar capta a amplitude/intensidade da energia retroespalhada pelo alvo após a sua interação com a radiação emitida. Tal energia é descrita pelo coeficiente de retroespalhamento ( $\sigma^{\circ}$ ) (Henderson & Lewis 1998; Woodhouse 2006; Freitas et al. 2007; Jensen 2009; Moraes Novo 2009; Moraes Novo 2010; Ponzoni et al. 2015), que é dado em decibéis (dB) em razão de sua grande variação para diferentes alvos (Waring et al. 1995; Moraes Novo 2010). O retroespalhamento está ligado à rugosidade da superfície terrestre. Onde tiver uma superfície lisa em relação ao comprimento de onda, o espalhamento ocorrerá na direção oposta ao sensor, sendo denominado do tipo especular. Em uma superfície rugosa, o espalhamento ocorrerá em várias direções, denominado do tipo difuso. Um terceiro tipo de espalhamento ocorre quando duas, ou mais, superfícies lisas são adjacentes, sendo denominado como reflexão de canto (Woodhouse 2006; Freitas et al. 2007; Meneses & Sano 2011; Ponzoni et al. 2015) (**Figura 4**).

As características de umidade, que são definidas por meio da constante dielétrica( $\epsilon$ ), também influenciam na intensidade do retroespalhamento, por meio do conteúdo hídrico contido nos alvos (Meneses & Sano 2011; Ponzoni et al. 2015). Quanto maior a quantidade de água do alvo, menor será o espalhamento gerado, resultando em uma atenuação do sinal espalhado (Henderson & Lewis 1998; Moraes Novo 2009; Moraes Novo 2010).

Por imagear em visada lateral, os SAR produzem efeitos geométricos específicos em suas imagens, que são chamados de distorções geométricas (Henderson & Lewis 1998; Oliver & Quegan 2004; Woodhouse 2006; Meneses & Sano 2011). O efeito de encurtamento de rampa, “*foreshortening*”, ocorre quando a imagem possui relevos mais dissecados, onde as encostas que estão a Nadir aparecem mais curtas. O efeito de inversão, “*layover*”, ocorre

quando há o imageamento do topo de uma feição antes de sua base, causando a inversão no terreno. Ou seja, partes baixas mapeadas com altas e vice-versa.


A seguinte distorção geométrica é chamada de sombra do radar, “*Radar shadow*”, que consiste basicamente na sombra gerada por conta do ângulo de incidência do SAR, principalmente em alvos com alta variação altimétrica. Ou seja, a face de um determinado relevo que não recebe o pulso de sinal do SAR, por estar em direção oposta ao imageamento, ficará sem cobertura pelo sensor, causando um efeito de sombra (Henderson & Lewis 1998; Woodhouse 2006; Meneses & Sano 2011). Tais distorções podem ser corrigidas em ambiente computacional, principalmente com a ajuda de modelos digitais de elevação (Henderson & Lewis 1998).



**Figura 3.** Demonstração do ângulo de incidência. Henderson & Lewis 1998 (Adaptado).

Todos os parâmetros mencionados, adquirem aos sistemas SAR um pouco mais de complexidade do que os sistemas óticos. Suas medidas são extremamente sensíveis à resposta do alvo, onde com uma pequena mudança pode-se observar uma grande alteração na imagem, porém os dois sistemas podem, e devem, trabalhar eficientemente em conjunto (Moraes Novo

2009; Moraes Novo 2010; Ponzoni et al. 2015) a depender, é claro, do tipo de estudo a ser realizado.



**Figura 4.** Tipos de espalhamento: Espelhamento, Difuso e Reflexão de canto. Ponzoni et al. 2015 (Adaptado).

### 3.2 Aplicações das imagens SAR

As imagens radar têm sido utilizadas para diversos estudos: mapeamento de uso e cobertura do solo (Ersahin et al. 2010; Kayabol & Zerubia 2013; Jafari et al. 2015; Majedi et al. 2016), monitoramento da cobertura de neve (Rondeau-Genesse et al. 2016), movimentos de massa (Dai et al. 2016), avalanches (Malnes et al. 2015), detecção de embarcações marítimas (Hlaváčová et al. 2016), elaboração de modelos digitais de superfície (Nikolakopoulos & Kyriou 2015), entre outros.

Vários trabalhos adotam imagens SAR para identificar e mensurar áreas úmidas, abertas ou cobertas por vegetação, em diversas regiões do globo (Ozesmi & Bauer 2002; Hess et al. 2003; Alsdorf et al. 2007; Lang et al. 2008; Henderson & Lewis 2008; Rodrigues et al. 2011; Reschke et al. 2012; Betbeder et al. 2015; Na et al. 2015).

### 3.3 Classificação de imagens SAR

Os métodos de classificação de imagens SAR são tão diversos quanto os de classificação de outros tipos de dados, acompanham a evolução tecnológica que sempre incrementa uma nova forma de segmentar os dados, visando a maior acurácia possível para o momento. A seguir lista-se algumas metodologias importantes para extração de feições em imagens SAR, e também outros tipos de imagens, desde que lhe sejam convenientes.

Uma técnica bastante conhecida, e simples a depender dos aspectos apresentados na imagem em que é aplicada, é a classificação por limiar "*Threshold*" (Ozesmi & Bauer 2002; Oliver & Quegan 2004; Costa & Telmer 2006; Deng et al. 2014; White et al. 2015). A classificação por *Threshold* consiste em atribuir a um pixel, ou um grupo deles, uma classe



através de um limiar, selecionado do histograma da imagem, definido, muitas vezes, pelo usuário (Ozesmi & Bauer 2002; White et al. 2015). Para um bom resultado neste método, a imagem precisa estar com seus alvos mais aparentes, sem uma grande variedade Inter pixel (Oliver & Quegan 2004). Em suma, o limiar pode ser definido pela média acrescida do dobro do desvio padrão de cada classe em dB (Costa e Telmer 2006). Este método não se restringe aos sensores ativos, Ozesmi & Bauer (2002) elencam diversos trabalhos utilizando imagens de sensores passivos, Deng et al. (2014) atentam para a escolha de diferentes *Thresholds* para diferentes imagens, em um registro temporal, principalmente no caso dos sensores passivos. O *Threshold* é um método com boa eficácia para se mapear água superficial (White et al. 2015).

Touzi et al. (2007) e Shmitt & Brisco (2013) incorporam à sua classificação de áreas úmidas no Canadá com imagens RADARSAT-2 a decomposição de alvos, que consiste em dissolver a resposta polarimétrica de um espalhador distribuído, evitando a sobreposição de diferentes espalhamentos em um pixel, (Touzi et al. 2007). Em seu trabalho, também com imagens RADARSAT-2, Marechal et al. (2012) utilizam a decomposição polarimétrica pela entropia de Shannon para classificar áreas úmidas na França em um intervalo de um ano de cobertura do sensor.

Ersahin et al. (2010) trabalha com segmentação de imagens, método pelo qual se extrai feições da imagem pelo seu contexto e objetos de forma, e textura, semelhantes, e com um classificador também utilizado por Formont et al. (2011), Ma et al. (2014) e Masjedi et al. (2016), o classificador por distância de Wishart. A distância de Wishart é um classificador estatístico, onde o pixel em consideração, caracterizado pelo vetor alvo  $k$ , é suposto que execute uma média de zero na distribuição Gaussiana descrita por  $CN(0, T)$  sendo  $T$  a matriz de covariância. Considerando uma idêntica e independente distribuição de  $n$ -amostras  $(K_1, \dots, K_n)$  correspondente à vizinhança espacial do pixel  $k$ , a máxima verossimilhança estimada de  $T$  é a conhecida matriz de covariância da amostra, dada por:

$$T_{scm} = \frac{1}{N} \sum_{i=1}^N K_i K_i^H. \text{ Onde } T_{scm} \text{ é a distribuição de Wishart, (Formont et al. 2011).}$$

Os métodos de classificação que estão sendo mais largamente empregados nos últimos anos, são baseados em aprendizado de máquina “*Machine Learning*”, um ramo da área computacional que aborda a inteligência artificial, e que estuda a classificação de dados através de modelos preditivos. O método de aprendizado de máquina mais difundido é o de Redes Neurais Artificiais (RNA), que consiste em um modelo de predição baseado no sistema nervoso central humano, ela possui nós (neurônios) que são unidades de processamento que

recebem e transmitem informações entre si, totalmente interconectados (*Fully connected*), aprendendo e resolvendo problemas de classificação diversos (Civco 1993; Huang et al. 1987; Hepner et al. 1990).

Existem outros métodos bastante relevantes e utilizados em *Machine Learning*, como a máquina de vetores suporte (*Support Vector Machine – SVM*). Sendo empregado com sucesso nos trabalhos de Feng et al. (2011); Tu et al. (2012); Aytekin et al. (2013); Gou et al. (2014); Uhlmann & Kiranyaz (2014); Betbeder et al. (2015); e Masjedi et al. (2016). As SVM são utilizadas na computação desde a década de 1990, porém só na década de 2000 começaram a ser mais difundidas em sensoriamento remoto ótico e em imagens de radar. Trata-se de uma técnica complexa, onde o algoritmo “aprende” aspectos importantes da imagem para então poder classificá-la da melhor maneira, automaticamente. Através do reconhecimento de padrões e regras já descritos antes, como distância, conformidade, textura e contorno, o SVM lista os objetos a serem classificados com precisão, por meio da criação de um “hiperplano” que separa as classes de dados, com base nos padrões observados na fase de treinamento do algoritmo (Gou et al. 2014; Uhlmann & Kiranyaz 2014; Betbeder et al. 2015; Masjedi et al. 2016).

Whitcomb et al. (2009) utilizou o algoritmo *Random Forests* (RF) em seu trabalho, que também foi utilizado em Na et al.(2015) combinado com segmentação de imagem. O RF é um algoritmo de Breiman (2001), derivado do programa CART (*Classification and Regression Trees*) de Breiman et al. (1993), que consiste em um tipo de aprendizado de máquina, também chamado de aprendizado de conjunto, *Ensemble Learning* (Breiman 2001), onde o algoritmo é capaz de criar um modelo preditivo através da indução com base em exemplos previamente considerados.

O RF gera múltiplas árvores de decisão, criadas a partir de uma reamostra aleatória do conjunto de treinamento original, que são utilizadas posteriormente para classificar novos objetos. Em geral, o RF é definido por  $\{h(x, \Theta_k), k = 1, \dots\}$  onde  $\{\Theta_k\}$  são vetores aleatórios distribuídos de forma idêntica e cada árvore gerada lança um voto para a classe mais popular no valor de entrada "x"(Breiman 2001; Whitcomb et al. 2009; Belgiu & Dragut 2016). As árvores geradas pelo algoritmo possuem baixa correlação, para evitar que o classificador fique tendencioso para determinada classe (Breiman 2001).

Para a divisão dos nós de cada árvore o RF seleciona os dados de entrada, fornecidos pelo usuário, de maneira aleatória, podendo ser utilizados várias vezes durante a construção da árvore (Breiman 2001; Whitcomb et al. 2009; Belgiu & Dragut 2016). O método de seleção dos dados de entrada é baseado na metodologia de reamostragem *Bootstrap*, que

consiste em retirar da amostra original uma outra amostra de tamanho  $n$  com reposição, a chamada amostra *Bootstrap* (Da Silva Filho 2015). Entretanto, como se trata de um aprendizado de conjunto, o cerne do RF está no *Bootstrap Aggregating*, ou agregação por *Bootstrap*, de Breiman (1996). O método é chamado por Breiman de *Bagging*, que corresponde ao acrônimo de seu nome original. Em linhas gerais, o *Bagging* é a agregação de dois ou mais modelos de treinamento e/ou métodos de classificação, com a finalidade de prover mais precisão ao processo e reduzir o sobreajuste, chamado de *Overfitting*, quando o algoritmo "decora" apenas as áreas que foram inseridas no conjunto de treinamento, classificando apenas essas áreas de maneira precisa (Breiman 1996).

O RF cria uma série de árvores de decisão através do conjunto de treinamento gerado pela reamostragem em *Bootstrap*, e, ao final, o modelo agrega o resultado de todas as árvores para "decidir" a qual classe pertence o pixel extraído da amostra *Bootstrap* (Breiman 2001).

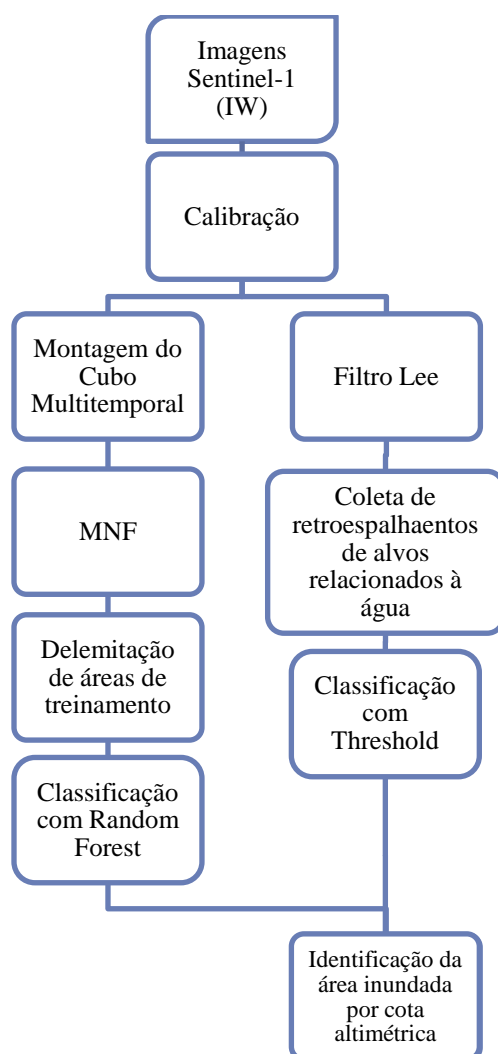
Por ser um algoritmo versátil, pode ser utilizado em outras áreas como diagnósticos médicos e mineração de dados. Whitcomb et al. (2009) e Belgiu & Dragut (2016) fazem uma descrição mais detalhada do algoritmo com o enfoque para trabalhos em sensoriamento remoto, onde explicam que a probabilidade de um pixel nunca ser selecionado como amostra é de  $1 - 1/N$ , onde  $N$  é o número total de pixels de referência. Aproximadamente  $2N/3$  pixels servirão como treinamento e serão colocados como um nó raiz da árvore de decisão. Os pixels que nunca serão selecionados serão utilizados para testar a precisão da classificação, ou seja, o algoritmo divide o conjunto de amostras previamente definidas em dois, sendo 66% do total utilizado para o treinamento e 33% para o teste. Para cada pixel é atribuída uma classe dada pela árvore de decisão. O resultado da classificação é comparado com as classes de referência, para determinar a acurácia (Breiman 2001; Whitcomb et al. 2009; Belgiu & Dragut 2016).

Com a finalidade de minimizar a heterogeneidade das classes em nós subsequentes, o RF utiliza, geralmente, como critério principal de divisão de nós, o índice de impureza de Gini,  $G(n) = 1 - \sum_c p^2 \left(\frac{c}{n}\right)$ , onde  $G(n)$  é o índice de Gini no nó "n",  $p \left(\frac{c}{n}\right)$  é a probabilidade de estar na classe "c" e no nó "n". O nó que possuir um baixo índice será dividido.

Na maioria dos casos em sensoriamento remoto, o número de árvores de decisão construídas é de 150, o que garante uma taxa de erro razoavelmente estável para cada seção da imagem. O número de camadas de entrada utilizadas geralmente é quatro, a depender do tipo de estudo utilizado, pode-se ainda atribuir pesos para cada classe a fim de se equilibrar a classificação, isto pode reduzir os erros para classes menos representadas e aumentar o erro geral de classificação (Whitcomb et al. 2009).

#### 4. MATERIAIS E MÉTODOS

O fluxograma a seguir sintetiza os passos metodológicos seguidos no trabalho. Após o processo de calibração nota-se a bifurcação no que diz respeito à classificação das imagens, um tronco representa a classificação sazonal, aplicada na série temporal (cubo multitemporal) das imagens de 2017, com a finalidade de extrair a dinâmica das unidades de paisagem existentes na área de estudo. O segundo tronco metodológico representa a classificação da imagem por data (uma classificação por imagem adquirida), com o intuito de mapear apenas o comportamento da inundação ao longo do ano. Ao final, a combinação da área coberta pelas feições inundáveis com dados altimétricos.



**Figura 5.** Fluxograma básico dos processos executados na metodologia de classificação.

#### 4.1 Imagens Sentinel-1

A ESA lançou o satélite Sentinel-1A no dia 03 de abril de 2014 e o satélite gêmeo Sentinel 1B após 24 meses. O Sentinel opera na faixa espectral das micro-ondas correspondente a banda C (5.405GHz), sendo capaz de atuar em diversas áreas de monitoramento terrestre e aquático. A resolução temporal é de 12 dias para um satélite e 6 dias para a constelação. Sua resolução espacial depende do modo de aquisição e do tipo de produto gerado por cada um deles, sendo divididos em: *Strip-Map Mode* (SM); *Interferometric Wide Swath Mode* (IW); *Extra Wide Swath Mode* (EW); e *Wave Mode* (WV) (Tabela 2).


**Tabela 2.** Modos de imageamento pelo sensor e seus diferentes parâmetros (Adaptado de Snoeij et al. 2009).

Parâmetro	Strip-Map Mode (SM)	Interferometric Wide Swath Mode (IW)	Extra Wide Swath Mode (EW)	Wave Mode (WV)
<b>Polarização</b>	HH+HV ou VV+VH	HH+HV ou VV+VH	HH+HV ou VV+VH	HH ou VV
<b>Incidência mínima</b>	20° - 45°	25°	20°	23° + 36.5°
<b>Resolução azimutal</b>	<5m	<20m	<40m	<5m
<b>Resolução de terreno</b>	<5m	<5m	<20m	<5m
<b>Faixa imageada</b>	>80km	>250km	>400km	20 x 20km

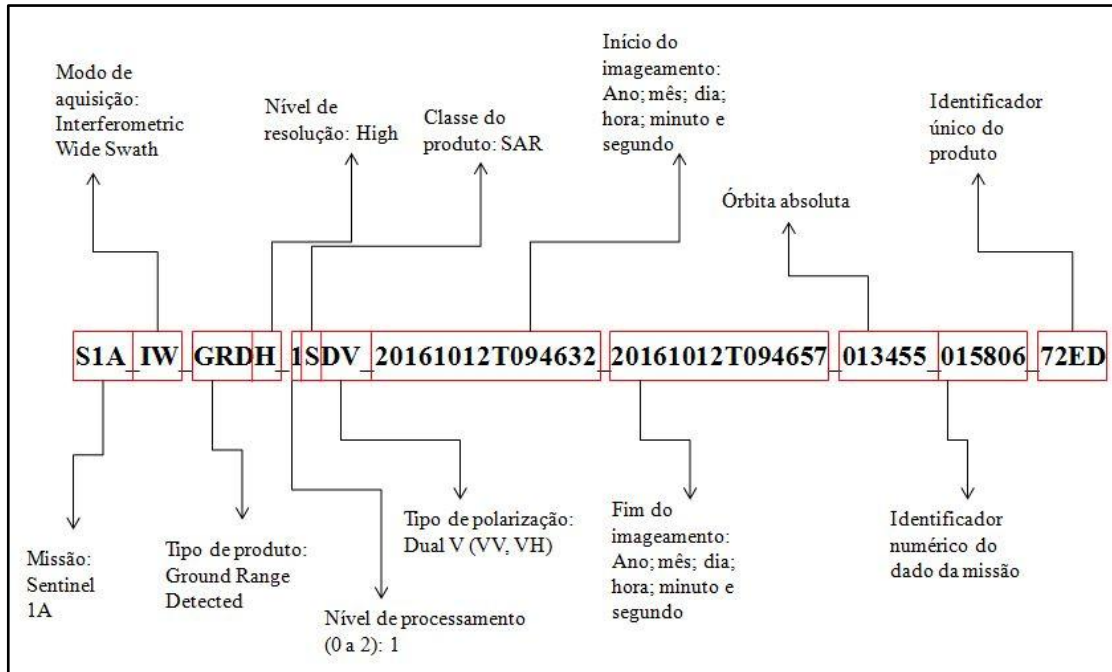
Os produtos disponibilizados estão classificados de acordo com o tipo de aplicação da imagem e o nível de pré-processamento. No tipo de aplicação, os produtos são subdivididos em: SLC; GRD e OCN. Os produtos SLC (*Single Look Complex*) são imagens sem o procedimento de “*Multilooking*”, técnica utilizada para ajudar na eliminação de ruídos e garantir maior precisão radiométrica, em detrimento da resolução espacial, nesse procedimento há uma aproximação de pixels vizinhos, segmentação da antena sintética e segmentação espectral da imagem (Woodhouse 2006). Nas SLC, cada pixel é armazenado como um número complexo em que a parte real é a amplitude do sinal recebido e a parte imaginária é a fase do sinal recebido. Os produtos do tipo GRD (*Ground Range Detected*) consistem em imagens que já receberam o processo de “*MultiLooking*” e foram projetadas

para o DATUM WGS-84, não possuindo informação de fase, e sua resolução está condicionada ao processo de *MultiLooking*, onde quanto mais *Looks* são processados na imagem menor é a sua resolução geométrica. As imagens GRD com base na sua resolução recebem uma segunda nomenclatura: FR (*Full Resolution*) – HR (*High Resolution*) – MR (*Medium Resolution*). Os produtos OCN (*Ocean*) são destinados aos estudos oceanográficos, contendo informações específicas, tais como as informações de ventos de superfície (Torres et al. 2012; Snoeijet al. 2009).

Com relação ao nível de pré-processamento, tem-se os produtos L0 (imagem mais bruta, desfocada, sem pré-processamento), L1 (imagem georreferenciada utilizando parâmetros de órbita e altitude do satélite, focada) e L2 (nível de processamento das imagens do tipo OCN, que inclui informações espectrais e de ventos de superfície) (Torres et al. 2012; Snoeijet al. 2009). A **Figura 6** mostra a operação de cada modo no imageamento. Todos os produtos possuem uma nomenclatura específica estipulado pela ESA (**Figura 7**).



**Figura 6.** Modos de aquisição dos diferentes produtos Sentinel (Adaptado de Snoei et al. 2009).



**Figura 7.** Forma como são nomeadas as cenas Sentinel.

Esses satélites fazem parte do programa *Copernicus* da ESA para a observação e monitoramento dos mais variados fenômenos na superfície terrestre a partir de dados de diferentes faixas espectrais. Além dos sensores radares, fazem parte do programa os satélites Sentinel 2 e 3 que operam na faixa do espectro visível e infravermelho, e futuramente será lançado mais 3 plataformas (Sentinel 4; 5 e 6) com diferentes aplicações. Seus dados são distribuídos gratuitamente e podem ser baixados da internet por qualquer usuário cadastrado, em site específico mantido pela ESA (Torres et al. 2012; Snoeij et al. 2009; Servello et al. 2015).

Ao total, foram adquiridas 30 cenas da área em estudo relativo ao ano de 2017 (**Tabela 3**). As imagens do satélite 1B não estavam disponíveis, bem como os produtos com a polarização dual H (HH, HV). A operação do Sentinel 1B ainda não se encontra em sua totalidade, exceto para algumas áreas pontuais. O modo de imageamento escolhido para o trabalho foi o IW, principalmente por conta da largura da faixa imageada, que consegue comportar um pouco mais de 250 quilômetros com uma resolução espacial de 7x9m sem processamento de correção geométrica. Após o procedimento de correção, a resolução espacial assume o valor de 10x10m, permitindo mapeamentos em escala de até 1:50.000.

O nível do produto escolhido foi o GRDH por possuir um nível de pré-processamento que diminui a demanda computacional e preserva a resolução espacial (*High resolution*). Como o sul de Roraima possui um relevo plano, não foi necessário nenhum procedimento

para a correção das distorções geométricas (encurtamento de rampa, inversão e sombra do Radar). Então, como os produtos GRD já possuem as coordenadas de terreno (*Ground Range*), basta uma correção geométrica simples, menos robusta na imagem, que deixa o produto com uma resolução espacial de 10 metros.

Conforme disposto na **Tabela 3**, as imagens do mês de Dezembro não seguiram a resolução temporal do satélite, que seria de 12 dias, estando disponíveis apenas as cenas dos dias 06 e 30 do referido mês. O produto do dia 18 de Dezembro não foi disponibilizado pela ESA para download por conter problemas técnicos, e por este motivo não passou na triagem que é feita para a disponibilização online.

**Tabela 3.** Imagens Sentinel-1 adquiridas para a área de estudo.

Nome do produto	Data	Órbita Relativa
S1A_IW_GRDH_1SDV_20170104T094629_20170104T094654_014680_017E1E_8737	04/01/2017	83
S1A_IW_GRDH_1SDV_20170116T094629_20170116T094654_014855_018384_F80F	16/01/2017	83
S1A_IW_GRDH_1SDV_20170128T094628_20170128T094653_015030_0188E2_AD92	28/01/2017	83
S1A_IW_GRDH_1SDV_20170209T094628_20170209T094653_015205_018E59_1953	09/02/2017	83
S1A_IW_GRDH_1SDV_20170221T094628_20170221T094653_015380_0193C8_97CD	21/02/2017	83
S1A_IW_GRDH_1SDV_20170305T094628_20170305T094653_015555_019911_63FB	05/03/2017	83
S1A_IW_GRDH_1SDV_20170317T094628_20170317T094653_015730_019E4B_89B9	17/03/2017	83
S1A_IW_GRDH_1SDV_20170329T094628_20170329T094653_015905_01A386_A8B4	29/03/2017	83
S1A_IW_GRDH_1SDV_20170410T094629_20170410T094654_016080_01A8C8_6F75	10/04/2017	83
S1A_IW_GRDH_1SDV_20170422T094630_20170422T094655_016255_01AE23_FAC0	22/04/2017	83
S1A_IW_GRDH_1SDV_20170504T094630_20170504T094655_016430_01B36B_9434	04/05/2017	83
S1A_IW_GRDH_1SDV_20170516T094631_20170516T094656_016605_01B8C5_7235	16/05/2017	83
S1A_IW_GRDH_1SDV_20170528T094631_20170528T094656_016780_01BE28_7D32	28/05/2017	83
S1A_IW_GRDH_1SDV_20170609T094632_20170609T094657_016955_01C394_5E35	09/06/2017	83
S1A_IW_GRDH_1SDV_20170621T094633_20170621T094658_017130_01C8F3_5108	21/06/2017	83
S1A_IW_GRDH_1SDV_20170703T094633_20170703T094658_017305_01CE43_8641	03/07/2017	83
S1A_IW_GRDH_1SDV_20170715T094634_20170715T094659_017480_01D38A_DBA8	15/07/2017	83
S1A_IW_GRDH_1SDV_20170727T094635_20170727T094700_017655_01D8E2_330D	27/07/2017	83
S1A_IW_GRDH_1SDV_20170808T094636_20170808T094701_017830_01DE3E_CCC9	08/08/2017	83



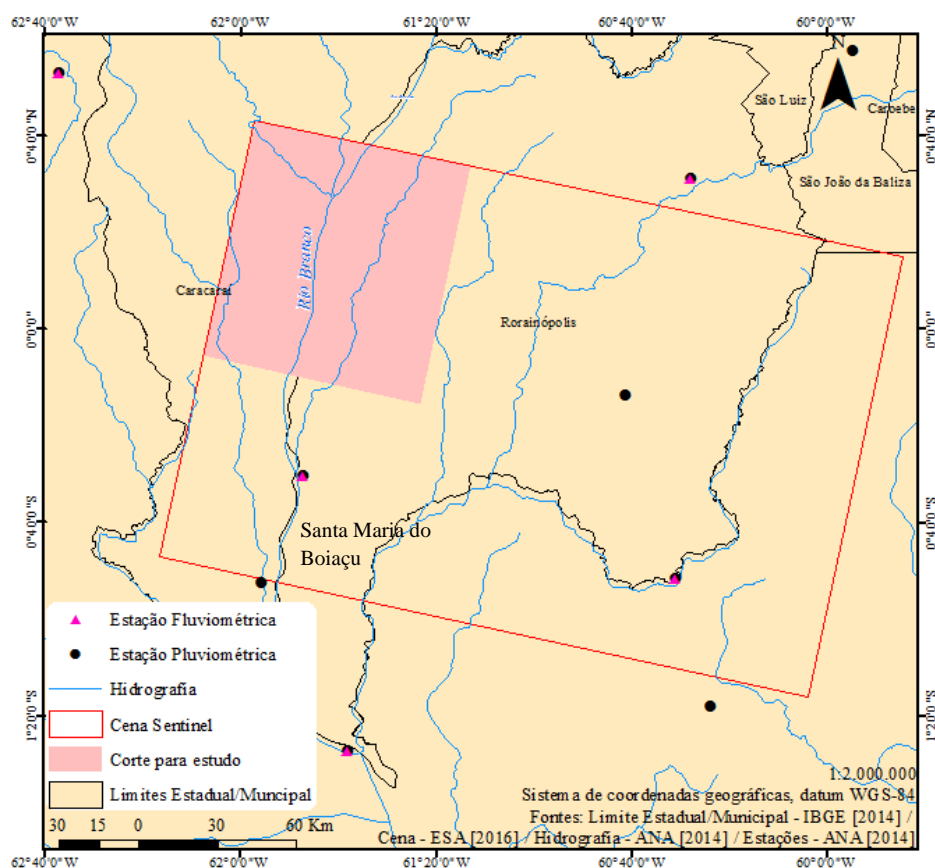
S1A_IW_GRDH_1SDV_20170820T094636_20170820T094701_018005_01E38 9_FAA0	20/08/2017	83
S1A_IW_GRDH_1SDV_20170901T094637_20170901T094702_018180_01E8 CD_F3B6	01/09/2017	83
S1A_IW_GRDH_1SDV_20170913T094637_20170913T094702_018355_01EE 43_6EEA	13/09/2017	83
S1A_IW_GRDH_1SDV_20170925T094637_20170925T094702_018530_01F3 A6_2B14	25/09/2017	83
S1A_IW_GRDH_1SDV_20171007T094638_20171007T094703_018705_01F8F 2_439B	07/10/2017	83
S1A_IW_GRDH_1SDV_20171019T094638_20171019T094703_018880_01FE 53_0264	19/10/2017	83
S1A_IW_GRDH_1SDV_20171031T094638_20171031T094703_019055_0203 A7_DE67	31/10/2017	83
S1A_IW_GRDH_1SDV_20171112T094638_20171112T094703_019230_02091 0_E4E7	12/11/2017	83
S1A_IW_GRDH_1SDV_20171124T094637_20171124T094702_019405_020E9 5_5916	24/11/2017	83
S1A_IW_GRDH_1SDV_20171206T094637_20171206T094702_019580_02141 3_3F4C	06/12/2017	83
S1A_IW_GRDH_1SDV_20171230T094636_20171230T094701_019930_021E EE_C530	30/12/2017	83

#### 4.2 Dados auxiliares

Por conta da complexidade do fenômeno analisado, o uso de dados auxiliares se faz preciso, tais dados amparam a delimitação da área inundável e a sua caracterização quanto à dinâmica hidrológica ao compreender a distribuição pluviométrica, a resposta espectral das unidades de paisagem na banda do visível e infravermelho e a variação altimétrica da área.

Mesmo que os dados de imagens SAR sejam eficazes ao imagear em diferentes condições climáticas, se fazendo necessário o seu uso em domínio amazônico, a complementação com dados auxiliares, vindos de imagens ou não, traz novas dimensões de análise e mostra novas nuances da área em estudo. Os dados complementares também podem reafirmar o comportamento já visto nos dados principais, com o objetivo de dar uma validade primária ao conjunto principal.

Os dados auxiliares na caracterização das áreas inundáveis foram: (a) dados fluviométricos e pluviométricos fornecidos pela Agência Nacional de Águas (ANA), adquiridos na estação de Santa Maria do Boiaçu, localizada ao longo do curso do Rio Branco, logo abaixo das áreas de Campinaranas, delimitadas pelo corte para estudo, (**Figura 8**), (b) imagens óticas da plataforma Landsat 8; e (c) modelos digitais de elevação (MDE) provindos da missão SRTM e aprimorados com as imagens Sentinel adquiridas.

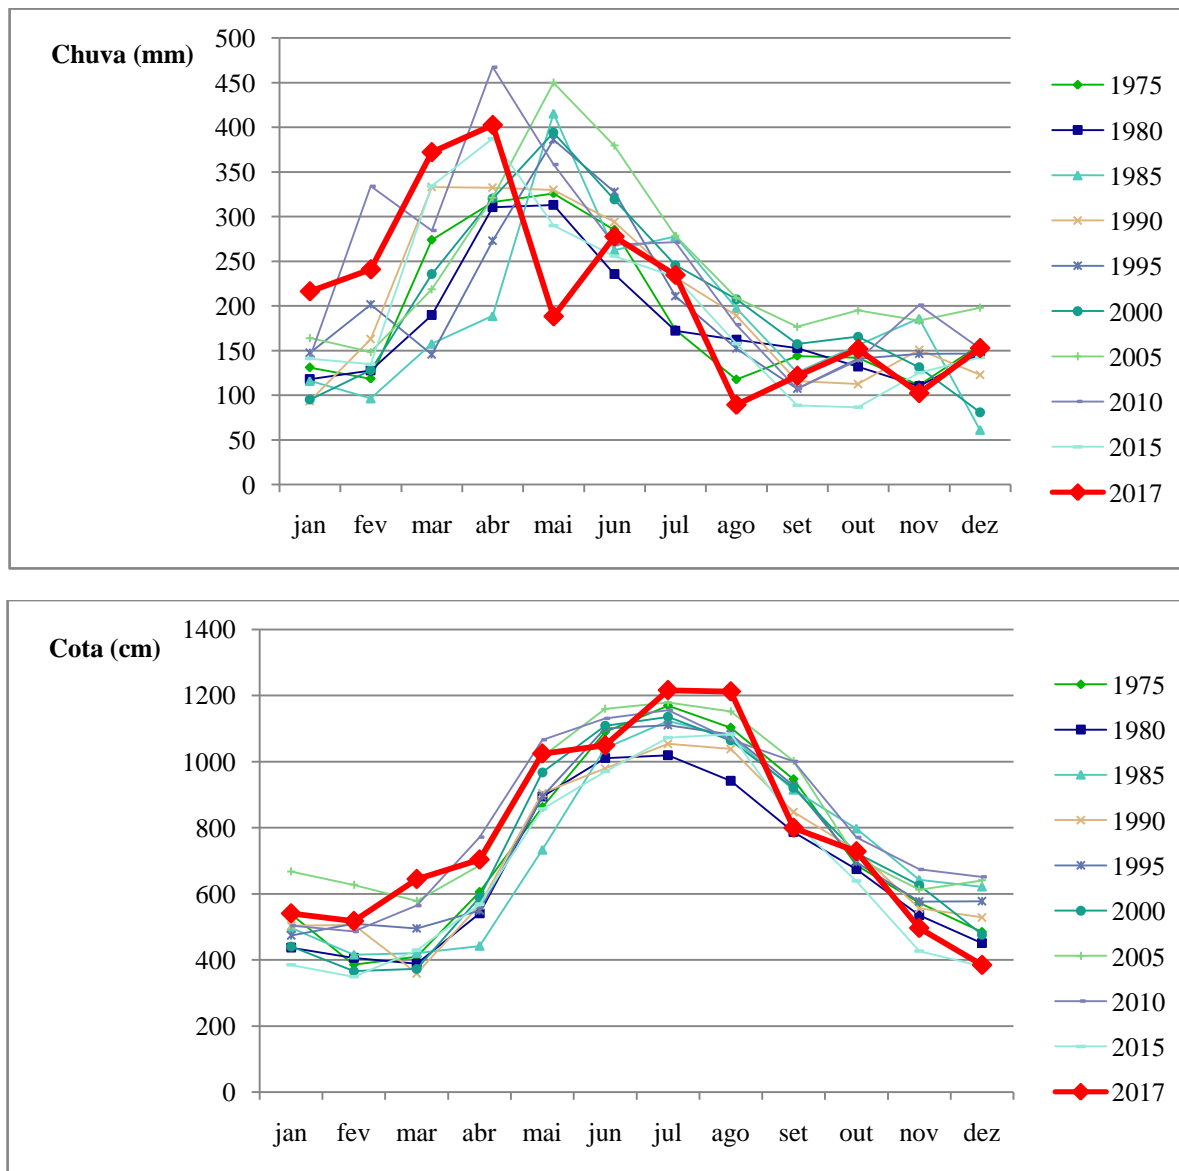


**Figura 8.** Localização da estação Fluviométrica/Pluviométrica de Santa Maria do Boiaçu.

A **Figura 9** demonstra os dados pluviométricos e fluviométricos mensais da estação Santa Maria de Boiaçu durante os anos de 1975-2017 (a estação entrou em operação no ano de 1972, porém decidiu-se desconsiderar os dados dos três primeiros anos e rearranjar os gráficos para representar o valor médio em um intervalo de 5 anos, sendo que o último intervalo representa a média dos três últimos anos, 2015-2017). A estação de Santa Maria do Boiaçu foi escolhida por conta da sua proximidade geográfica da área de estudo e a consistência da série temporal.

Os dados coletados mostram um padrão na cota altimétrica máxima mensal do rio Branco, onde o período de cheia começa no mês de abril e tem seu pico, geralmente, em julho. Tal fato está diretamente correlacionado com a distribuição das chuvas na área e as propriedades do tipo de solo, o pico de cheia ocorre aproximadamente dois meses após o pico de pluviosidade, ou seja, o solo (bastante poroso) demora aproximadamente dois meses para entrar em nível considerável de saturação. É possível ainda, notar uma variação no volume de chuvas entre os anos e sua influência na dinâmica de cheias do rio Branco, resultando e uma variação anual de até 5 metros de sua cota média quinquenal (ANA 2018). Vale ressaltar que

o valor de cota altimétrica está representado em centímetros, pois a estação é nivelada geometricamente com a referência de nível oficial mais próxima.




**Figura 9.** Comportamento das cotas altimétricas e precipitação acumulada na estação. Em vermelho a curva isolada com os dados do ano de 2017.

Um dado auxiliar importante para contextualizar as áreas inundáveis da área em estudo é o MDE. A **Figura 10** demonstra uma comparação entre os MDEs da área de estudo provenientes dos dados da missão *Shuttle Radar Topography Mission (SRTM)* (Bamler 1999; Werner 2001), à esquerda da figura, e à direita o MDE que foi aprimorado com as informações contidas nas imagens Sentinel, pelo procedimento de correlação cruzada realizado no programa SNAP (ESA 2013).

O dado altimétrico em geral oferece a possibilidade de se mensurar e analisar, no caso deste estudo, o limite altimétrico da área de inundação, a extensão espacial que o conteúdo hídrico pode atingir dentro de condições, sobretudo climáticas, ditas normais dentro da área em estudo. O limite altimétrico não necessariamente será atingido pela análise dos dados principais, imagens Sentinel, por levar em consideração o comportamento hidrológico do ano de 2017 apenas.

Na imagem SRTM a elevação é obtida com base nos sistemas de radar (bandas X e C), com resolução espacial de 30 metros. No processamento de correlação cruzada, esses dados são aprimorados com os dados de fase e tempo de retorno do espalhamento das imagens Sentinel, para então assumirem uma resolução espacial de 10 metros.

O MDE possui baixa variação altimétrica, onde os menores valores estão situados no leito e nos afluentes do Rio Branco e nas áreas de Campinarana e Brejo, conforme o mapeamento do IBGE, **Figura 2**. Basicamente, as áreas com baixa elevação estão mais susceptíveis ao acúmulo de água, favorecendo a inundação periódica.



**Figura 10.** Variação altimétrica extraída de MDE da missão SRTM, esquerda, e aprimorado com os dados Sentinel, direita.

Nota-se uma maior variação dos valores altimétricos no MDE aprimorado, porém a extensão das áreas de menor valor altimétrico, mais propensas à acumulação hídrica, é semelhante em ambos os MDEs. Com o aprimoramento do MDE SRTM, cria-se a

possibilidade de confeccionar um cubo multitemporal com um MDE para cada data de imagem Sentinel adquirida.

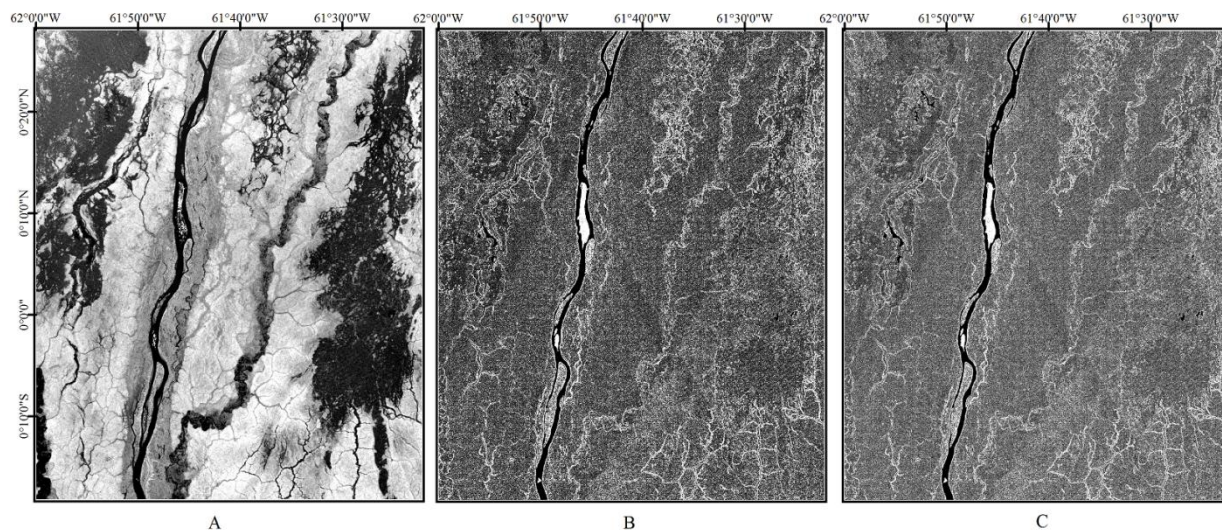
Na **Tabela 4** abaixo pode-se verificar os valores estatísticos basais obtidos de cada MDE aprimorado. A variação dos valores de média, desvio e variância se mostra de maneira mais suave em todos os casos, esta variação pequena se traduz na imagem nas áreas marginais do Rio Branco juntamente com outros corpos d'água e nas Campinaranas/Brejos, onde a variação dos valores de desvio e variância é maior.

**Tabela 4.** Estatística descritiva dos MDEs aprimorados com imagens Sentinel.

Cena	Média	Desvio Padrão	Variância
04/01/2017	35,143679	7,596679	0,362817405
16/01/2017	35,143779	7,596770	0,362815231
28/01/2017	35,144194	7,596384	0,362824449
09/02/2017	35,143862	7,596614	0,362818957
21/02/2017	35,143879	7,596447	0,362822945
05/03/2017	35,144256	7,596357	0,362825094
17/03/2017	35,144079	7,596314	0,362826121
29/03/2017	35,143870	7,596437	0,362823184
10/04/2017	35,143597	7,596814	0,362814181
04/05/2017	35,144274	7,596258	0,362827458
16/05/2017	35,143598	7,596814	0,362814181
28/05/2017	35,143835	7,596669	0,362817643
09/06/2017	35,143726	7,596496	0,362821775
21/06/2017	35,144260	7,596427	0,362823422
03/07/2017	35,144428	7,596423	0,362823518
15/07/2017	35,143815	7,596689	0,362817166
27/07/2017	35,143942	7,596641	0,362818312
08/08/2017	35,143982	7,596388	0,362824354
20/08/2017	35,144176	7,596244	0,362827793
01/09/2017	35,143637	7,596655	0,362817978
13/09/2017	35,143843	7,596551	0,362820461
25/09/2017	35,143937	7,596407	0,362823900
07/10/2017	35,143911	7,596702	0,362816855
19/10/2017	35,143656	7,596835	0,362813679
31/10/2017	35,143903	7,596566	0,362820103
12/11/2017	35,144337	7,596448	0,362822921
06/12/2017	35,144076	7,596425	0,362823470
24/11/2017	35,144167	7,596308	0,362826264
30/12/2017	35,122822	7,445879	0,366473025

A **Figura 11** mostra as imagens de descrição da estatística descritiva básica para todo o cubo multitemporal de MDEs. Pode-se aferir um maior desvio padrão (áreas mais claras) nas bordas de potenciais áreas inundáveis, como nas margens do Rio Branco e nas bordas das


Campinaranas, indicando uma maior variação no valor altimétrico destes alvos ao longo do ano.



**Figura 11.** Imagens de estatística descritiva do cubo de MDEs, média (A)- desvio padrão (B) e variância (C).

As imagens de sensores óticos, como Landsat 8 (OLI), mesmo com a desvantagem em não cobrir os alvos em situações climáticas adversas, permitem auxiliar na identificação dos alvos da área em estudo. Embora o sul do estado de Roraima esteja sob forte cobertura de nuvens durante, praticamente, todo o ano, algumas imagens, com um nível razoável de cobertura de nuvens na cena foram adquiridas.

A **Figura 12** demonstra uma composição colorida feita a partir de uma imagem do satélite Landsat 8 (OLI), banda 6 -infravermelho de ondas curtas- no canal do vermelho, banda 5 -infravermelho próximo- no canal do verde e banda 4 -vermelho- no canal do azul, da data de 06 de outubro de 2017, os espectros dos alvos são distintos entre si. A curva espectral do Rio Branco apresenta uma ligeira diferença em relação às curvas usuais de água aberta, pelo fato de possuir uma grande quantidade de sedimentos em suspensão, como observa-se o tom mais claro do rio Branco em comparação com os demais corpos d'água presentes na imagem, conferindo uma coloração mais clara que os demais corpos d'água presentes na imagem. A curva espectral das Campinaranas apresenta um pequeno pico de refletância na banda no infravermelho próximo, graças à mistura espectral causada pela vegetação e o seu conteúdo hídrico.



**Figura 12.** Composição colorida (Landsat 8) da área de estudo e as curvas espectrais referentes à vegetação (a) Rio Branco (b) e Campinaranas/Brejo (c).

Munido desses dados auxiliares, é possível obter informações mais detalhadas sobre a localização e o comportamento das áreas inundáveis na cena. Essas informações servirão para um balizamento na fase de classificação das imagens SAR, todos os dados auxiliares são de extrema importância para o sucesso do trabalho, porém as imagens SAR, neste caso específico, serão as únicas, dentro dos produtos advindos do sensoriamento remoto, capazes de traçar o comportamento e a dinâmica das Campinaranas, e demais áreas inundáveis, no que diz respeito à periodicidade do alagamento na série temporal analisada, devido à sua boa performance em situações climáticas instáveis, comuns na porção territorial estudada.

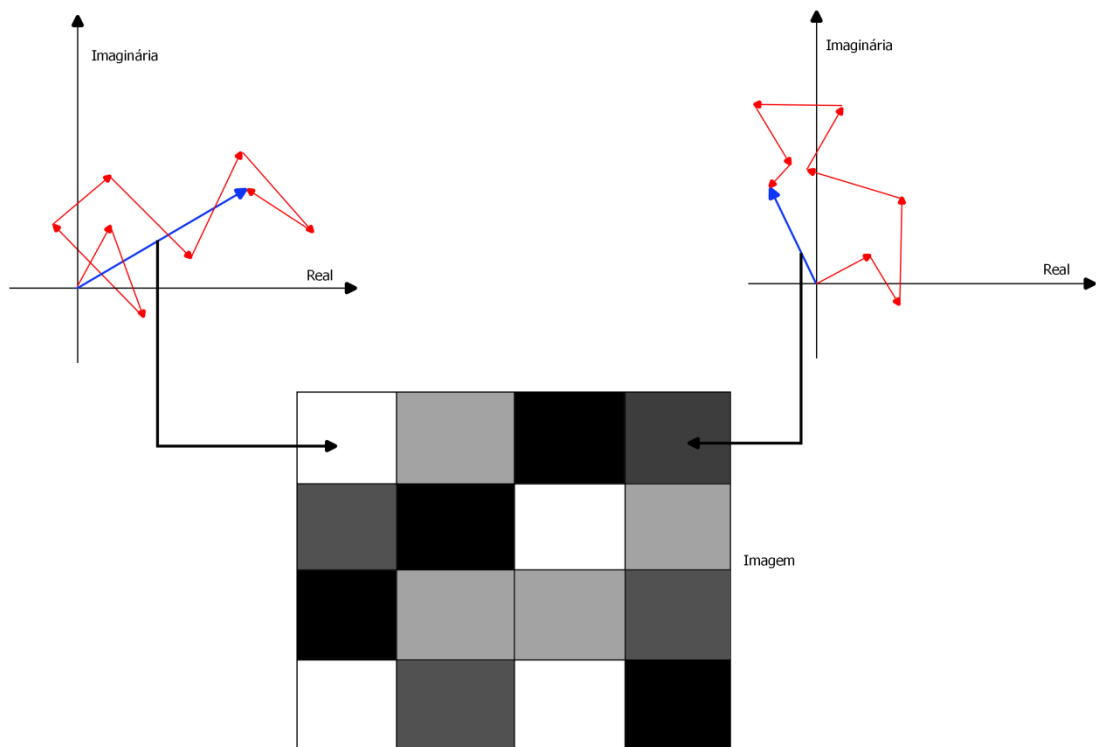
## 4.2 Pré-processamento e tratamento de ruídos

O produto Sentinel adquirido foi o modo IW com as polarizações VH e VV. O pré-processamento consistiu na calibração radiométrica e geométrica e na conversão dos dados para decibéis, utilizando o programa livre *Sentinel Application Platform* (SNAP) da Agência Espacial Europeia (ESA 2013). Na fase de calibração, as imagens foram registradas conforme parâmetros contidos nos pontos de controle, que são buscados automaticamente pelo algoritmo de co-registro para a conversão de números digitais em espalhamento, ou seja, um processo semi-automático de calibração graças aos parâmetros mensurados pelo próprio satélite, e registrados junto aos metadados e informações adicionais da imagem. O algoritmo busca de forma automatizada todos os parâmetros obtidos durante a passagem do satélite para a calibração, parâmetros esses que são gravados junto aos metadados da imagem (Veci 2016).

As imagens SAR são dotadas de ruído do tipo *speckle*, provenientes da propriedade de coerência do sistema SAR, ou seja, pelo fato de emitir sinais de mesma frequência, comprimento de onda e fase (Woodhouse 2006), com características granulares que podem afetar de maneira significativa a interpretação e a análise da imagem (Carvalho Junior et al. 2014). O ruído do tipo *speckle* se origina da interferência gerada entre os feixes propagados pelo sensor, que não tem resolução suficiente para resolver os espalhamentos de maneira individual, que são refletidos pelo alvo em superfície, ou seja, dentro de uma área coberta por um pixel podem existir inúmeros tipos de alvo que irão retroespalhar a energia de maneira diferente. Tal interferência pode ser construtiva ou destrutiva, acarretando em pixels mais claros (construtiva) ou mais escuros (destrutiva), gerando uma complexidade no espalhamento de cada pixel (Henderson & Lewis 1998; Freitas et al. 2007; Meneses & Sano 2011). A **Figura 13** demonstra que a saída final de cada pixel é o resultado de uma soma aleatória de todos os retroespalhamentos em cada célula, por conta da limitação de resolução espacial, distribuídos no plano complexo. Esta interferência pode ser resolvida utilizando técnicas de *Multi-looking* ou filtragem adaptativa (Henderson & Lewis 1998; Shitole et al. 2014; Meneses & Sano 2011; Freitas et al. 2007).

O tratamento de ruído foi diferenciado conforme o procedimento de classificação. A transformação *Minimal Noise Fraction* (MNF) foi aplicada para reduzir o ruído das imagens para classificação das séries temporais, enquanto o filtro adaptativo foi adotado para as imagens classificadas individualmente (data a data).





**Figura 13.** Demonstração da formação do ruído Speckle. Henderson & Lewis 2008 (Adaptado).

O método utilizado para tratar o ruído das imagens no domínio do tempo foi a transformação MNF (*Minimal Noise Fraction*). A transformação MNF (Green et al. 1988) é um procedimento baseado na Análise de Componentes Principais (ACP), porém ao invés de utilizar a variância do dado ela utiliza uma razão sinal-ruído, permitindo reduzir a dimensionalidade dos dados e a remover o ruído. A transformação MNF possui a característica de maximizar a razão sinal/ruído para o ordenamento das imagens de acordo com a qualidade dos dados, e pode ser dividido em quatro etapas: obtenção de uma amostra do ruído e cálculo de sua matriz de covariância; estabelecimento de um índice de fracionamento do ruído; aplicação da função de transformação linear nos moldes da ACP, e a inversão do procedimento do MNF considerando apenas a fração do sinal (Boardman & Kruse 1994; Carvalho Júnior et al, 2002). A transformação MNF foi executada no programa livre ABÍLIO, do Laboratório de Sistemas Espaciais (LSIE) da Universidade de Brasília.

O tratamento de ruídos com filtro adaptativo, técnica mais comum de filtragem de dados SAR, também foi realizado, de forma não temporal (cena por cena). O método empregado é bastante utilizado para o tratamento de imagens do tipo, o filtro de Lee (1980). O filtro Lee é do tipo convolucional, o que reduz o tempo de processamento computacional,

onde o algoritmo considera que a média e o desvio padrão de um dado pixel estará em um intervalo dado pela média e desvio padrão do conjunto total de pixels da imagem. Este tipo de técnica utiliza, basicamente, estatística local com base na vizinhança do pixel (Lee 1980). A maior desvantagem do filtro Lee é que os ruídos em bordas altas não são totalmente filtrados (Lee 1981; Shitole et al. 2014). Para reduzir o *speckle* e preservar a informação de textura, também usa-se a versão refinada do filtro de Lee (*Enhanced Lee*), utilizando os mesmos princípios do Filtro Lee, porém subdividindo o tratamento em três classes de áreas na imagem. Homogêneas, onde o valor do pixel é substituído pela média da janela aplicada; Heterogêneas, onde o valor é substituído por uma média ponderada; E áreas alvo, onde o valor do pixel é preservado (Lee 1981; Lopes et al. 1990). Além do tamanho da janela, como no filtro Lee convencional, o Lee refinado conta com o fator de amortecimento (*Damping factor*), que dita a extensão do efeito de suavização na imagem; O coeficiente de variação para áreas homogêneas, dado por  $C_u$ , e o coeficiente de variação para áreas heterogêneas, dado por  $C_{max}$ . (Lopes et al. 1990). Esse procedimento de filtragem também foi efetuado pelo ABILIO.

### 4.3 Classificação

O procedimento de classificação das imagens foi composto por duas etapas: (a) classificação dos pixels com base em seu comportamento temporal, gerando uma única imagem classificada no período de 12 meses; e (b) classificação individual de cada cena (por cada data) visando observar o comportamento sazonal das áreas inundáveis, usando a técnica de elaboração de uma máscara a partir de valor limite (*Threshold*).

O algoritmo escolhido para a classificação temporal foi o *Random Forests*, por sua boa performance ao trabalhar a partir da análise de múltiplas árvores de decisão, o que dá certa confiabilidade no processo de classificação. O algoritmo *Random Forests* usado está presente, também, na aplicação não comercial ABILIO, implementada pelos docentes do departamento de Geografia da Universidade de Brasília, para uso em pesquisas de Geoprocessamento e Sensoriamento Remoto. O algoritmo foi implementado nos moldes da já consagrada biblioteca de visão computacional “OpenCV”, uma biblioteca de algoritmos de inteligência artificial em linguagem C++ que possibilita a criação de aplicações diversas dentro da área de *Machine Learning* (Bradski & Kaehler 2000).

A partir da coleta de amostras do coeficiente de retroespalhamento relativo às áreas inundáveis, água aberta e floresta, o algoritmo trabalhará no domínio do tempo, classificando cada pixel, de cada data de aquisição das imagens, de acordo com os votos extraídos das

árvores de decisão. Para a validação, o algoritmo utiliza o próprio conjunto de treinamento, que será indicado através de regiões de interesse extraídas da própria imagem, dando confiabilidade dentro do próprio sistema de classificação.

A organização das imagens com base no tempo, cria um cubo multitemporal de dados, onde tem-se o eixo X correspondente às linhas, o eixo Y correspondente às colunas, o terceiro eixo, Z, correspondente à junção das imagens ao longo dos dias e anos coletados. O eixo Z representa o espectro temporal de cada pixel, portanto é possível observar como cada alvo se comporta durante o ano e as mudanças que ocorrem ao longo do tempo, (Carvalho Júnior et al. 2009).

Para a classificação individual, o método por *Threshold* foi escolhido por conta dos alvos referentes às áreas inundáveis estarem bem discriminados na cena. A técnica, apesar de sua simplicidade, pode gerar ótimos resultados na identificação da dinâmica de inundação da área de estudo, e é bastante usual em imagens SAR (Henderson & Lewis 2008).

#### **4.5 Identificação das áreas inundáveis**

Conforme os processos mostrados no fluxograma básico da **Figura 5**, juntamente com o que já foi descrito nos tópicos anteriores, a caracterização das áreas inundáveis se dará nas frentes, temporal (contínua) e data por data (discreta). Espera-se que, na classificação contínua, áreas que margeiam os maiores cursos d'água apareçam como inundáveis, resguardados, é claro, a limitação causada pela resolução espacial do produto (10 metros).

As copas das grandes árvores da floresta amazônica também podem apresentar o comportamento de áreas inundáveis, visto que a banda C não tem penetração muito alta e não consegue ir muito além da porção superior da copa das árvores, por conta do conteúdo hídrico contido no dossel da vegetação. Tal equívoco de classificação pode ser corrigido manualmente, munido de dados auxiliares, em um processo de pós classificação.

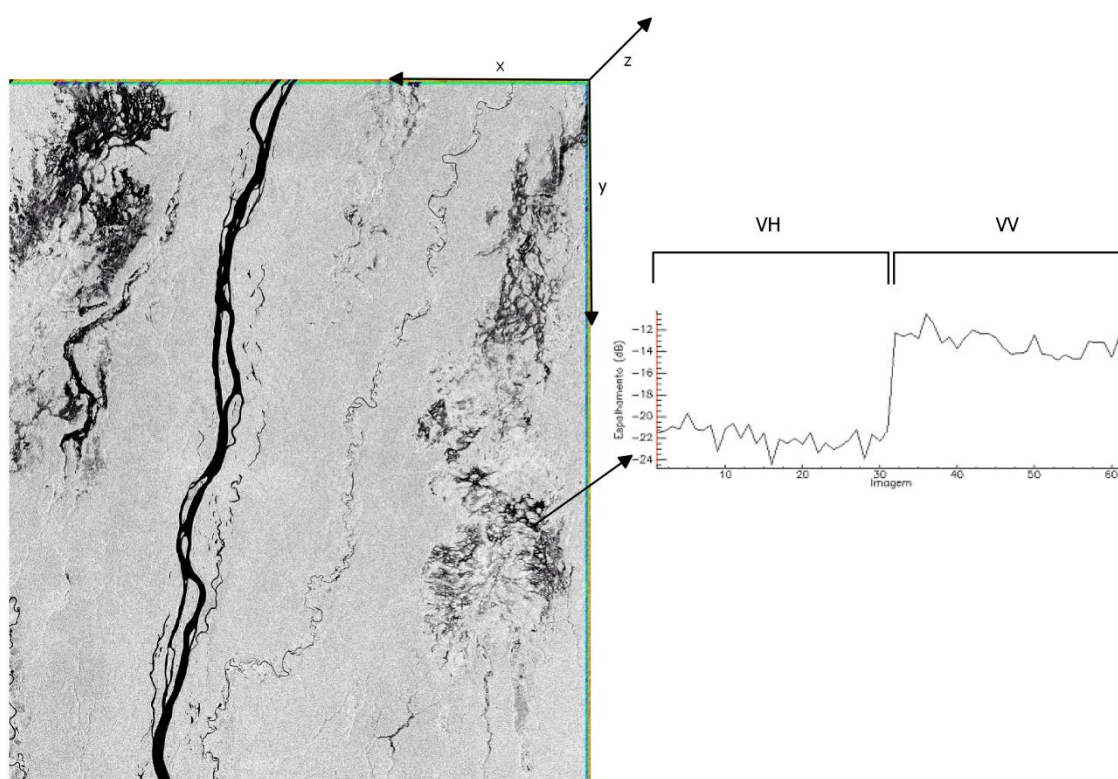
O que vai, de fato, caracterizar a área em estudo como sendo inundável, é o comportamento pulsativo da classe referente aos alvos que contém um conteúdo de água considerável. Este comportamento, ditado, principalmente, pela distribuição pluviométrica, poderá ser observado na imagem como um aumento ou diminuição da "mancha", *footprint*, de água formada nos ambientes inundáveis. Então, conforme os valores de precipitação forem subindo, espera-se um aumento desta mancha, no caso do sul de Roraima entre os meses de Abril, Maio, Junho e Julho, a partir de Agosto espera-se uma diminuição da cobertura desta classe.

Como o procedimento de classificação que indicará esse comportamento pulsativo será por limiar, o sucesso do processo de filtragem do ruído *speckle*, em especial o do tipo destrutivo, pois poderá se assemelhar à um pixel com espalhamento referente à água, será de extrema importância para a delimitação correta do pulso de inundação ocorrente. Contudo, a escolha do tamanho da janela de filtragem a ser utilizada será o elemento chave para a filtragem correta, pois uma janela muito pequena pode não surtir o efeito de eliminação do *speckle*, e uma janela muito grande pode suavizar o dado em demasia, causando perda de informação radiométrica.

## 5. RESULTADOS

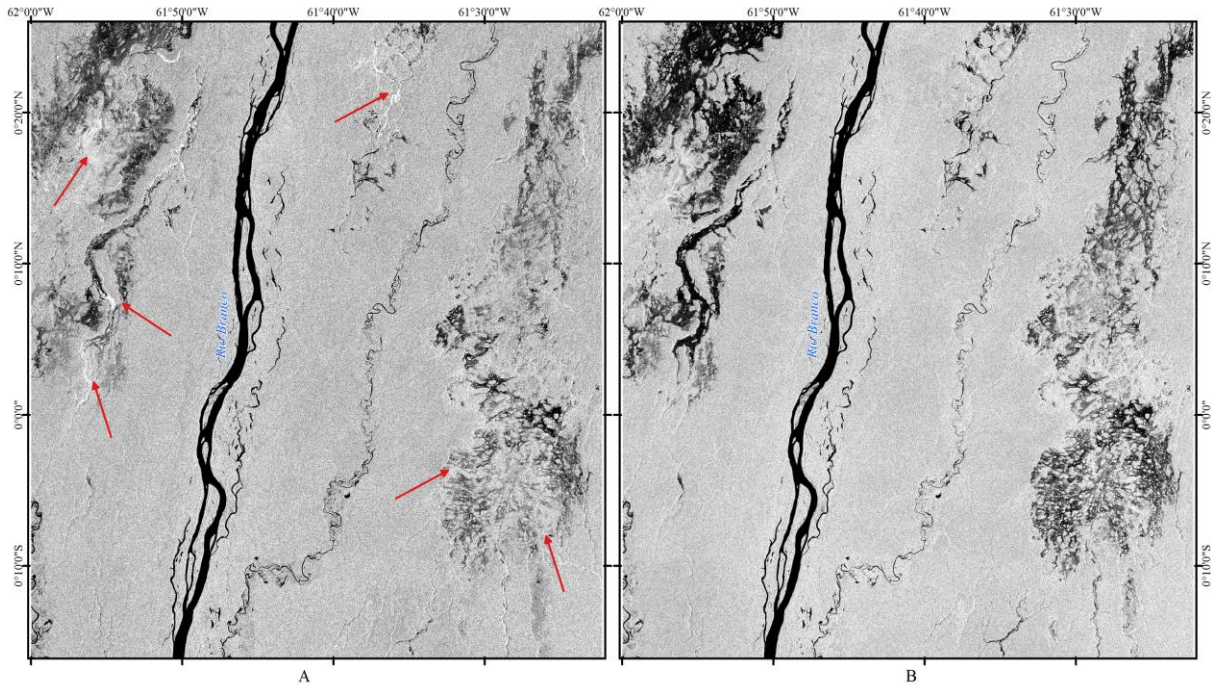
### 5.1 Análise das polarizações VV e VH na detecção de áreas inundáveis

As imagens das polarizações VV e VH apresentam significativas diferenças nas áreas inundáveis/Campinaranas. A **Figura 14** demonstra que a polarização VH permite uma maior distinção das áreas úmidas do que a polarização VV. Quando a polarização de retorno é horizontal, neste caso, ocorre uma maior interação com o conteúdo hídrico que se encontra abaixo das formas de vegetação de Campinarana que possuem baixa estatura e distribuição mais esparsa que a floresta, resultando em uma maior discriminação das feições úmidas.



**Figura 14.** Diferença espectral entre as duas polarizações ao longo do tempo.


A floresta possui uma pequena diferença entre as polarizações VV e VH, permanecendo homogênea em ambas polarizações. Tal fato pode ser explicado pelo grande porte arbóreo da floresta em relação ao comprimento de onda da banda C (aproximadamente 5 cm), que não possui capacidade de penetrar ao longo da árvore, então mesmo que se mude a polarização de retorno, a resposta registrada pelo sensor não se modifica.



**Figura 15.** Diferença visual entre as duas polarizações (a) VV (b) VH. Os pontos destacados com a seta vermelha indicam as áreas com maior diferença entre a resposta das duas polarizações, afetando assim a interpretação correta do fenômeno estudado.

As **Figuras 14 e 15** demonstram que o tipo de polarização causa uma diferença significativa na resposta dos alvos. Como está pronunciado na composição colorida da **Figura 16**, onde fora feita com a primeira imagem da série temporal, do dia 04 de Janeiro de 2017, as cores em tons de azul representam os maiores níveis de dissimilaridade entre as duas polarizações.


No cubo multitemporal, a diferença de espalhamento chega a 10 dB para o mesmo pixel, como se pode notar a diferença espectral retratada no gráfico da **Figura 14**. Portanto, a polarização VV não foi adotada no estudo, visto que não acarretará em nenhum prejuízo para o processo de classificação das áreas úmidas presentes na cena. Outra diferença perceptível na composição colorida, são os bancos de areia ao longo do curso do Rio Branco, que possuem uma afinidade maior com a polarização VH.



**Figura 16.** Composição colorida com a diferença entre as imagens VV e VH. R(VV) G(VH) B(subtração entre VV e VH).

## 5.2 Pré-processamento

Na fase de pré-processamento, foi observado, de forma manual, que a cena do dia 22 de Abril de 2017 sofreu interferência de nuvens densas (**Figura 17**). Esse fato não se caracteriza como uma anormalidade, visto que, a depender do comprimento de onda utilizado, fenômenos atmosféricos mais extremos, como nuvens mais densas, podem interferir no imageamento do sensor. A nuvem está localizada no extremo sudeste da imagem, sobre a Campinarana, justamente no início da época de cheia, onde a presença de nuvens mais densas são comuns. Contudo, para não ocasionar em nenhum prejuízo para o resultado final da classificação, a imagem foi retirada, então a metodologia de calibração e tratamento de ruídos foi aplicada em um conjunto de 29 imagens, ao invés das 30 já listadas.



**Figura 17.** Localização da nuvem na imagem do dia 22/04/2017. Observa-se que a interferência na imagem não é muito substancial, porém por se localizar acima de uma área de Campinarana, a melhor decisão é retirá-la do conjunto de dados.



## 5.3 Sazonal

### 5.3.1 Tratamento de ruídos

Para o tratamento de ruídos no cubo multitemporal, a transformação MNF se fez satisfatória. Pode-se notar o aspecto limpo da imagem, discretizando melhor as feições (**Figura 19**). A operação inversa da transformação, foi feita utilizando as quatro primeiras componentes geradas pela primeira transformação, conforme são mostradas, em ordem, na **Figura 18**.

Segundo pode ser visto na figura, com um recorte de exemplificação para a Campinarana da porção leste, as componentes escolhidas armazenam as características cruciais para a classificação do ambiente, sem o risco de haver uma subestimação dos alvos dem áreas inundáveis nas imagens. Da quarta componente em diante estão os registros ruidosos da primeira transformada.






**Figura 18.** Componentes utilizadas na operação inversa da MNF.

A transformação MNF mostrou uma boa performance em imagens SAR, neste caso em imagens de áreas com topografia plana, onde o espalhamento e, conseqüentemente, o ruído se dão de forma mais homogênea. Desta forma, se torna bastante eficaz o uso da transformação em séries temporais de imagens SAR que se encontram em situação semelhante às utilizadas no presente estudo.

Mesmo com um nível de tratamento prévio à disponibilização para aquisição, as imagens do modo GRD ainda apresentam quantidade considerável de *speckle*, nada comparado às imagens "brutas", mas o ruído ainda encobre muitas feições da imagem, bem como pode ser visto na figura abaixo. Pelo fato de já receber um certo tratamento, não foi necessário um ajuste muito robusto dos parâmetros básicos da MNF, sendo o modo *default* suficiente para gerar o resultado esperado.



**Figura 19.** Resultado do tratamento de ruídos no cubo multitemporal com a transformação MNF.

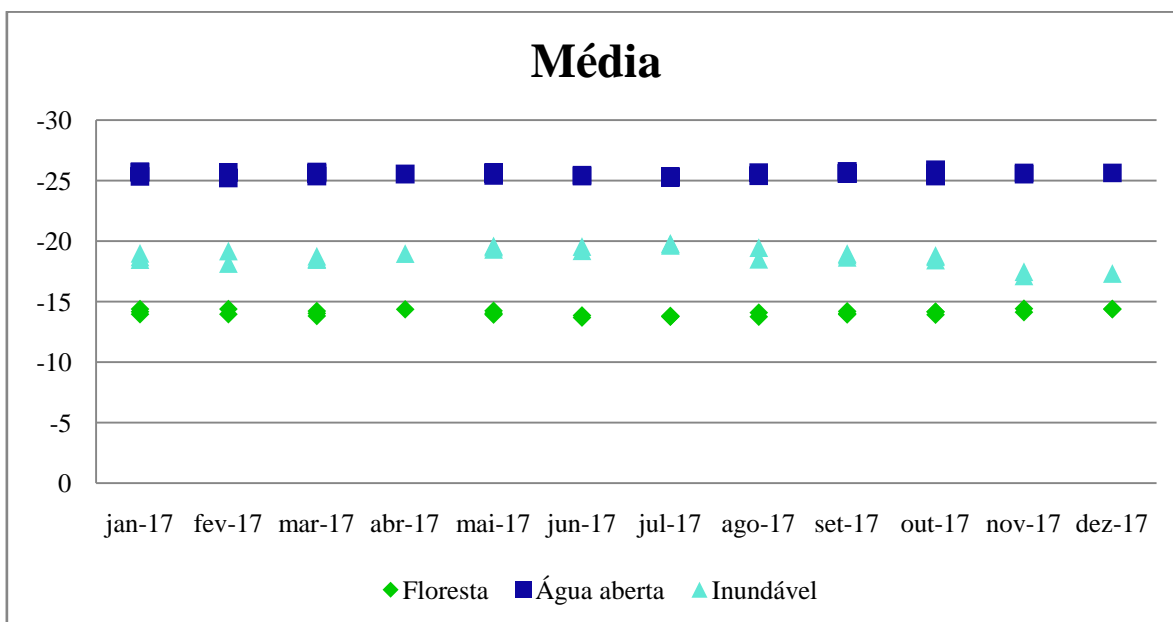
### 5.3.2 Classificação

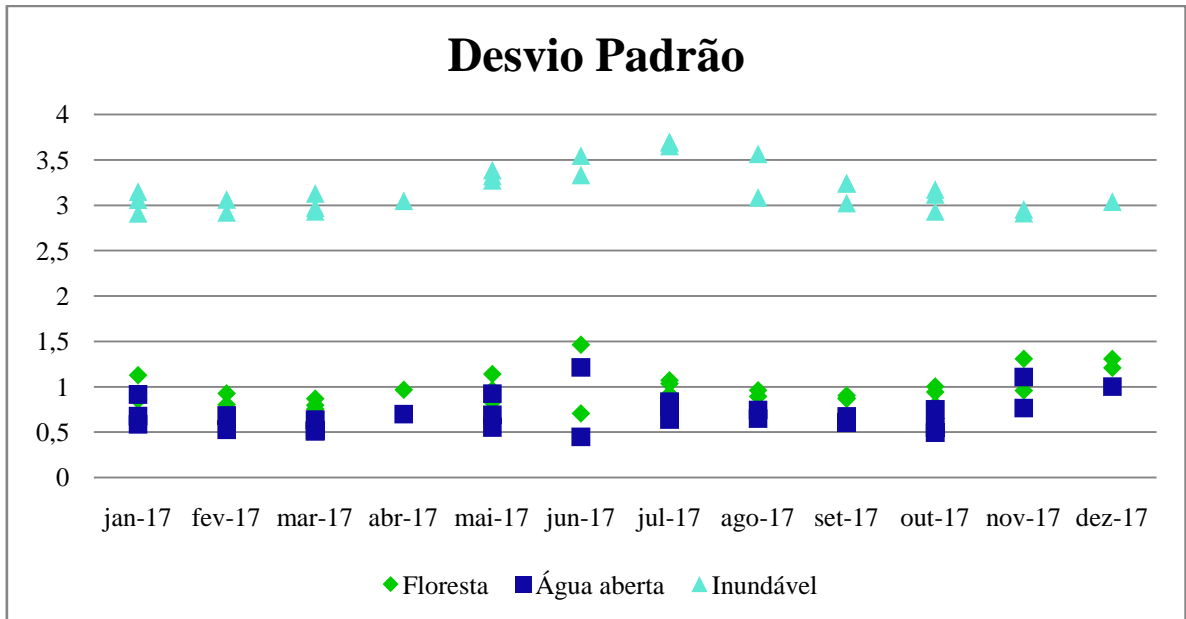
Conforme foi explanado anteriormente, a classificação foi subdividida em duas frentes, contínua e discreta. Para a classificação temporal, com a finalidade de se observar a sazonalidade das unidades de paisagem contidas na cena, foi fornecido um conjunto de treinamento para o algoritmo *Random Forest* em três classes, Água aberta, Áreas inundáveis e Floresta. A soma das três classes do conjunto de treinamento foi de 763.273 pixels, sendo

245.853 para a classe Floresta, 202.542 para Água aberta e 314.842 para Áreas inundáveis. Cada classe foi redefinida para um espaço amostral de 2.500 pixels, com um procedimento de subamostragem aleatória, considerando a união dos polígonos referentes à cada classe, distribuídos pela área de estudo.

A escolha de áreas de treinamento menores foi intencional, afim de se averiguar a performance do algoritmo com um conjunto de treinamento pequeno, em comparação à dimensão da imagem. Assim, ao se replicar o estudo em outras áreas de domínio Amazônico, o usuário não precisa inserir um conjunto muito grande de áreas de treinamento, fazendo com que o processo de classificação seja mais custoso do ponto de vista computacional. A distribuição das áreas, espacialmente homogênea, foi feita pensando-se em evitar o sobreajuste na classificação, ainda que a baixa correlação entre as árvores geradas pelo algoritmo auxiliam de modo eficaz a evitar este problema.

A separação em três classes foi feita visando a verificação do comportamento de alvos que permaneceram com conteúdo hídrico elevado durante todo o ano de 2017. Posteriormente, para cálculo de área, para analisar a extensão total da área alagada, as classes "Água aberta" e "Áreas inundáveis" foram mescladas.





**Figura 20.** Gráficos de média e desvio padrão das amostras coletadas.

Os gráficos da **Figura 20** mostra a média de valores de espalhamento de cada classe do conjunto de treinamento, em cada imagem do cubo multitemporal, bem como o desvio padrão das classes dentro do conjunto. Observa-se um maior desvio na classe de áreas inundáveis, que pode ser explicado por conta do comportamento hidrológico pulsativo das Campinaranas e Brejos, fazendo com que a flutuação do conteúdo hídrico nestes alvos produzam pequenas variações no espalhamento ao longo do tempo.

Os parâmetros do algoritmo RF foram selecionados, em sua maioria, com base na literatura consultada. O parâmetro que diz respeito ao número máximo de árvores construídas para "votar" na classe a qual pertence aquele conjunto analisado, que foi colocado em 150 conforme visto na literatura referente ao uso de *Random Forest* em sensoriamento remoto (Whitcomb et al. 2009; Belgiu & Dragut 2016).

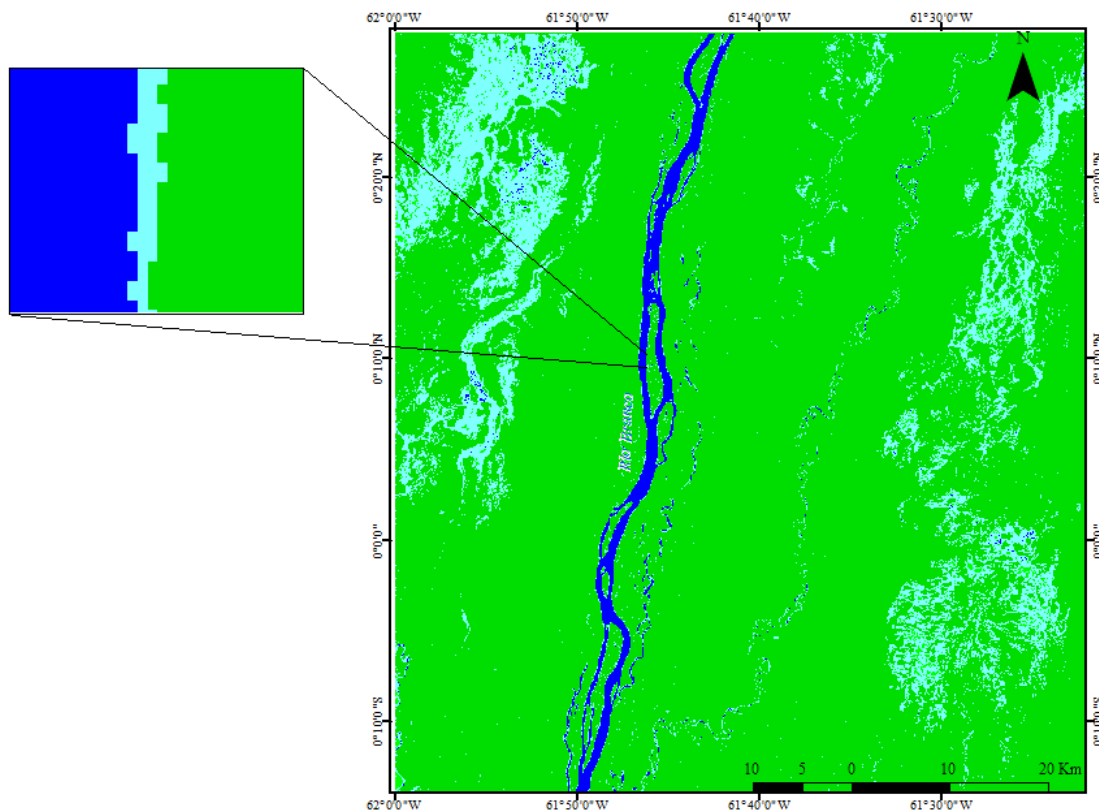
O parâmetro de contagem mínima de amostras fora deixado em 5%, pois segundo a documentação da biblioteca OpenCV (Bradski & Kaehler 2000), um valor razoável para este parâmetro seria uma pequena porcentagem do conjunto total de dados. O último parâmetro modificado foi a precisão suficiente do modelo, ou valor do erro OOB (*Out of bag*), que significa a mensuração do erro de predição em modelos de aprendizado que utilizam o *Bagging* (Breiman 1996), o OOB é o erro médio de previsão para cada amostra de treino  $x_i$ , utilizando apenas as árvores que não possuem  $x_i$  em sua amostra *Bootstrap* (Bradski & Kaehler 2000). Este parâmetro recebeu o valor de 0,1.

Os demais parâmetros, do programa ABILIO, profundidade máxima da árvore, variáveis nativas (o tamanho do subconjunto de feições utilizados aleatoriamente em cada nó, quando definido em zero, o tamanho será a raiz quadrada do número total de feições Bradski & Kaehler 2000) e número máximo de categorias (máximo número de categorias para se dividir um nó da árvore) não sofreram alterações, permanecendo 5, 0 e 10, respectivamente.

Conforme pode-se observar na **Figura 21**, a classe água aberta, que ocupa uma área de 13.338,35 hectares, corresponde aos alvos que permaneceram cobertos por água durante todo o período analisado, como o rio Branco e seus afluentes e algumas áreas de Campinarana e/ou Brejo, conforme o mapeamento contínuo realizado pelo IBGE e já mostrado neste estudo. A classe floresta, que ocupa uma área de 522.137,53 hectares, corresponde à Floresta Ombrófila Densa, característica do domínio Amazônico.

A classe de áreas inundáveis, ocupando 59.889,16 hectares, corresponde às zonas já conhecidas como úmidas (Campinaranas e Brejos) e, também, às margens dos principais cursos d'água presentes na imagem. Como pode-se observar na **Figura 21**, as margens dos rios tiveram um comportamento sazonal referente à classe de áreas inundáveis que varia de 10 a 30 metros medidos horizontalmente em cada margem, 1 a 3 pixels, conforme disposto na aproximação da margem do Rio Branco vista na figura.

Este resultado, de certa maneira, é esperado por conta da dinâmica hidrológica e pluviométrica da região, e pode estar subestimado se levarmos em conta a faixa de água que se estende subsuperficialmente pela faixa de floresta que margeia os rios, fato explicado pela incapacidade do feixe irradiado pelo sensor do satélite Sentinel 1(banda C) em penetrar pelas árvores da floresta.




**Figura 21.** Resultado da classificação temporal utilizando *Random Forest*, em verde a Floresta Ombrófila, em ciano as áreas úmidas/inundáveis e em azul os Rios e corpos d'água menores, bem como as áreas que ficaram totalmente cobertas por água durante todo período estudado.

## 5.4 Data a data

### 5.4.1 Tratamento de ruídos

Quanto ao tratamento de ruídos com filtragem adaptativa, para a classificação data a data, pode-se notar ótimos resultados nos dois métodos utilizados, filtro Lee e Lee refinado, conforme disposto na **Figura 22**. O tamanho da janela foi o mesmo para os dois métodos, 7x7. Para o filtro Lee refinado, os parâmetros adicionais se mantiveram em *default* do programa utilizado, fator de amortecimento em 1,  $C_u$  em 0.5230 e  $C_{max}$  em 1.7320, conforme visto na literatura consultada, aplicada à imagens SAR (Lopes et al. 1990), são os valores mais indicados para este tipo de imagem. Na figura, observa-se uma suavização mais pronunciada na imagem tratada pelo filtro Lee refinado, porém ainda se preserva a textura e as bordas dos principais elementos contidos na imagem.



**Figura 22.** Diferença entre os dois tipos de filtro adaptativo utilizado.

Na imagem em sua totalidade não é possível notar a diferença de suavização entre as duas técnicas, por conta da extensão geográfica da área em consonância com a resolução espacial da imagem, entretanto pode-se analisar, visualmente, tal diferença ao chegar próximo do limite da resolução, conforme visto na figura acima. Nos alvos que contém um volume considerável de conteúdo hídrico, que é o mote do trabalho em questão, o *speckle* se faz mais presente nas imagens tratadas com filtro Lee convencional. O motivo mencionado, aliado à pouca perda de textura, fizeram a escolha do filtro tender para o do tipo Lee refinado, por conta da provável subestimação de áreas inundáveis, que ocorreria com a escolha de um limiar em áreas de ambientes aquáticos com a presença de *speckle*, como ocorre nos produtos do filtro Lee convencional

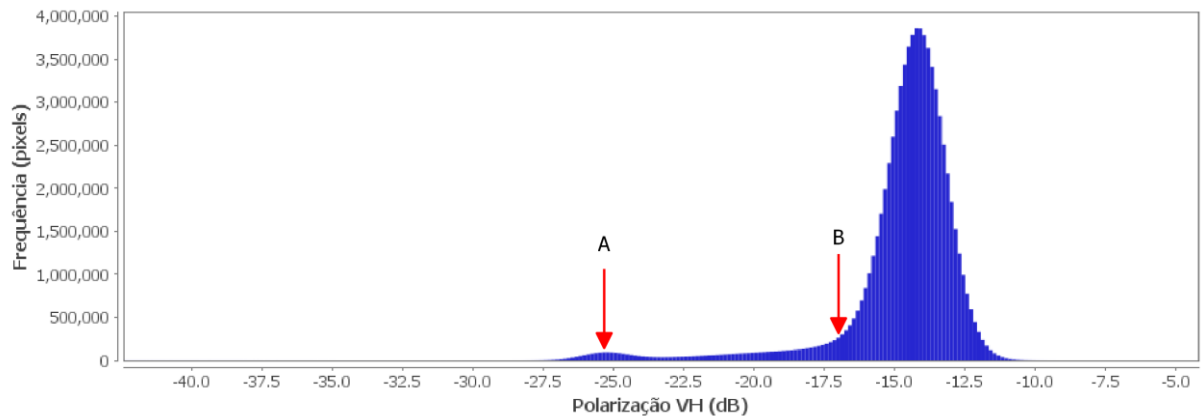
### 5.4.2 Classificação

Para a classificação feita data a data, a escolha do limiar que melhor traduz os alvos com conteúdo hídrico relevante é crucial para o êxito do processo. A escolha foi feita por tentativa e erro, onde buscou-se, primeiramente, identificar o limiar de água aberta, que, segundo a literatura de base consultada (Woodhouse 2006; Henderson & Lewis 2008; Jensen 2009; Moraes Novo 2010) a água aberta possui um retroespalhamento de até -20 dB.

Conforme pode-se notar na **Figura 23**, o histograma de frequência de uma das imagens adquiridas mostra um pequeno pico de espalhamentos de baixo valor, sinalizando o início da distribuição dos pixels referentes à água aberta. Entretanto, de acordo com o objetivo central do trabalho, apenas os pixels de água aberta não são suficientes para identificar as áreas inundáveis na imagem, fora preciso inserir um limiar que conseguisse cobrir, também, outras áreas afetadas pela dinâmica hidrológica, como as Campinaranas e Brejos contidos na área de estudo.

A partir da tentativa e erro, observou-se três limiares que identificavam água aberta e áreas inundáveis, -16dB, -17dB e -18dB, porém estes três limiares apresentam diferenças significativas entre si, que podem ser notadas visualmente na **Figura 24**. Pode-se notar que o maior valor de limiar, -16, superestima as áreas inundáveis, acrescentando à classe parte dos dosséis das árvores da floresta, que possivelmente, estavam encharcados na hora da passagem do sensor. Já o limiar de menor valor, -18, subestima as áreas alagadas, suprimindo parte das Campinaranas e dos Brejos. Diante desta questão, a melhor escolha é o limiar mediano entre os propostos. O limiar de -17dB foi o que melhor representou a classe de áreas inundáveis, que conta com a soma da classe água aberta e áreas alagáveis.



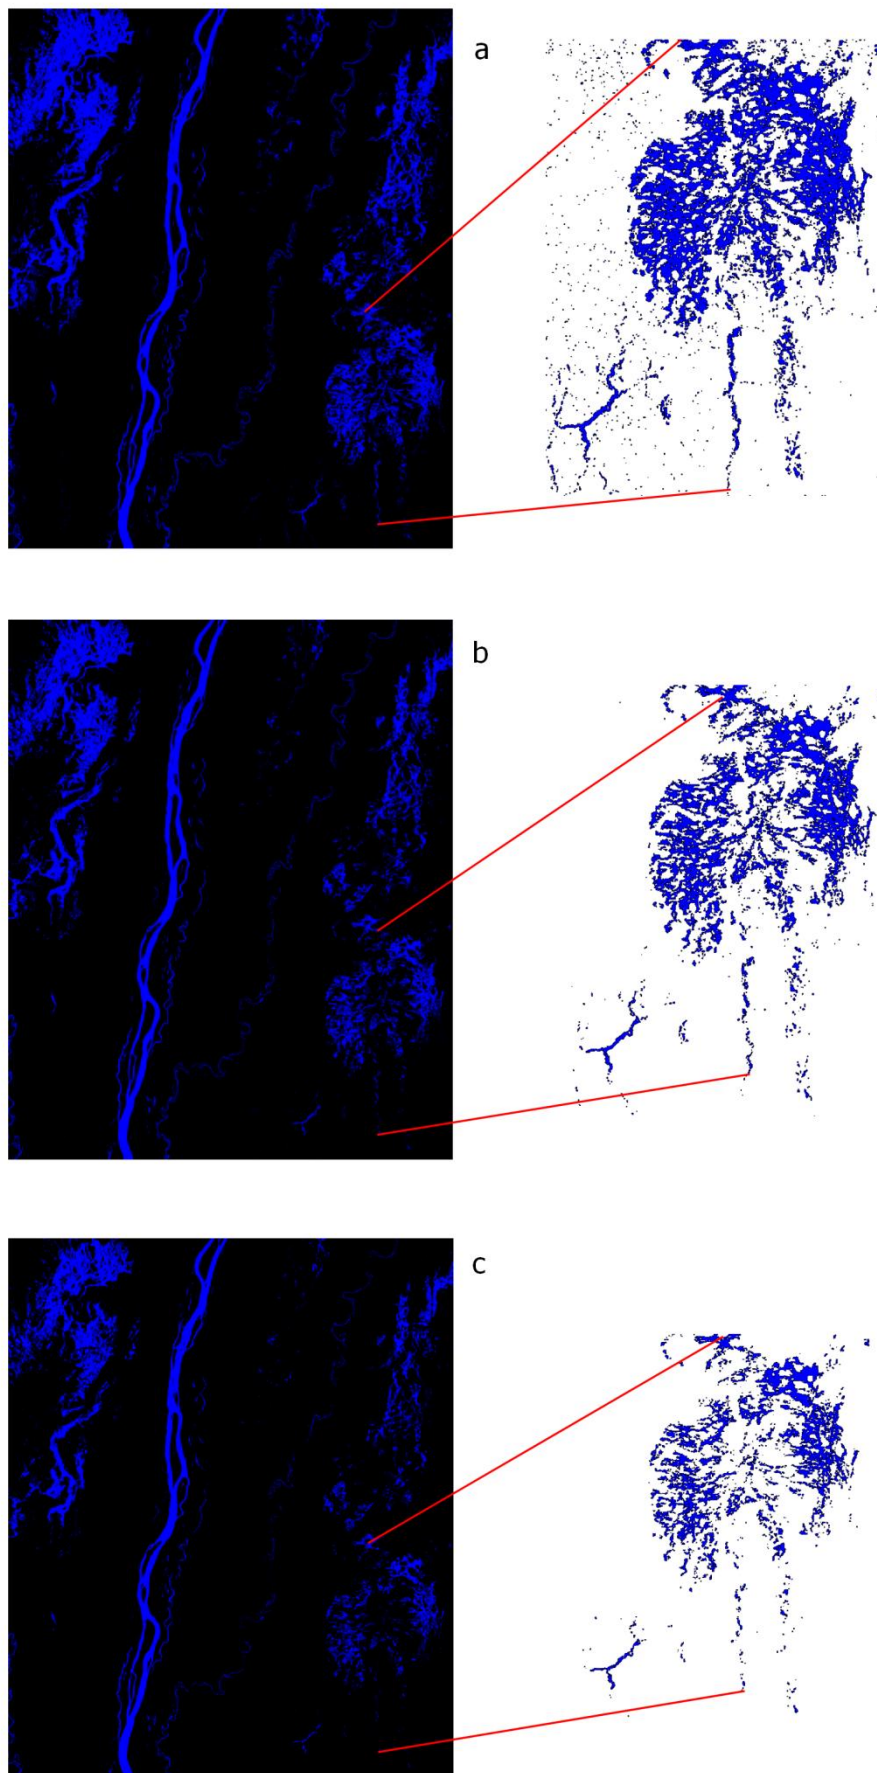


**Figura 23.** Histograma de frequência e valores escolhidos para limiares de água e alvos com conteúdo hídrico elevado (as duas setas vermelhas indicam onde estão os pixels de água aberta "A" e áreas inundáveis "B") .

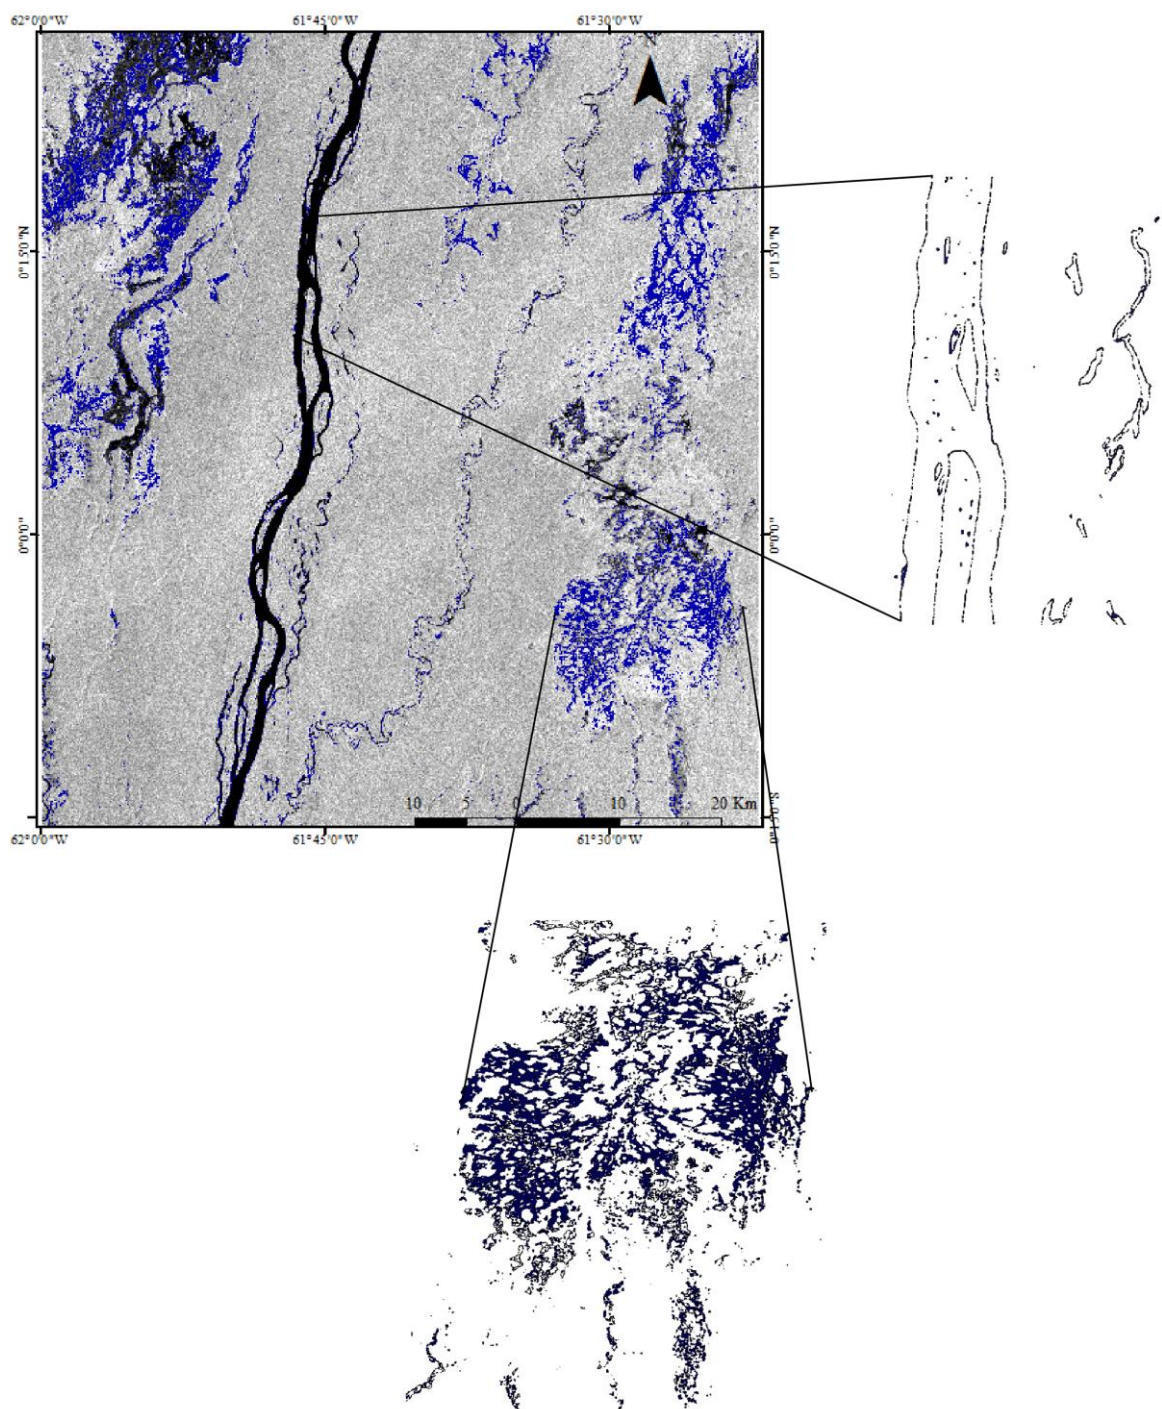
Percebe-se, na **Figura 24**, que o limiar ideal é o de -17dB, o que melhor resguarda os alvos inundáveis. Ao se classificar cena por cena, verificou-se que a data em que ocorreu o maior volume de pixels com elevado conteúdo hídrico foi em 27 de Julho de 2017, pode-se chamar de data de maior cheia. A data de maior seca, por assim dizer, ocorreu em 06 de Dezembro de 2017.

Ainda na **Figura 24**, observa-se a presença de pontos azulados ao redor da Campinarana, indicando que este limiar também classificou como área inundada parte da floresta que foi considerada na classificação sazonal, superestimando assim a área coberta pela classe representativa da área inundada. Tais pontos que podem ser facilmente confundidos com ruídos, forçando o usuário a submeter a imagem a mais um processo de filtragem, degradando ainda mais a resolução espacial e perdendo informações importantes. Nas Campinaranas também pode-se observar tal efeito, com o limiar de -16dB partes da floresta, que está inserida entre os flancos das Campinaranas, também são classificadas como áreas inundáveis, provavelmente pela mistura espectral provinda da proximidade com os pixels de Campinarana, ou ainda o mesmo motivo do caso anterior.

O mapa da **Figura 25** mostra o cálculo da diferença entra a data mais cheia e a data mais seca, espacializado sobre a cena do dia 06 de Dezembro de 2017, ocupando uma área de 39.603 hectares. Nota-se as margens dos rios e as Campinaranas/Brejos bastante evidentes no mapa. Estes resultados vão de acordo com o obtido pela classificação sazonal, que também pontuou as margens dos rios como zonas alagáveis.

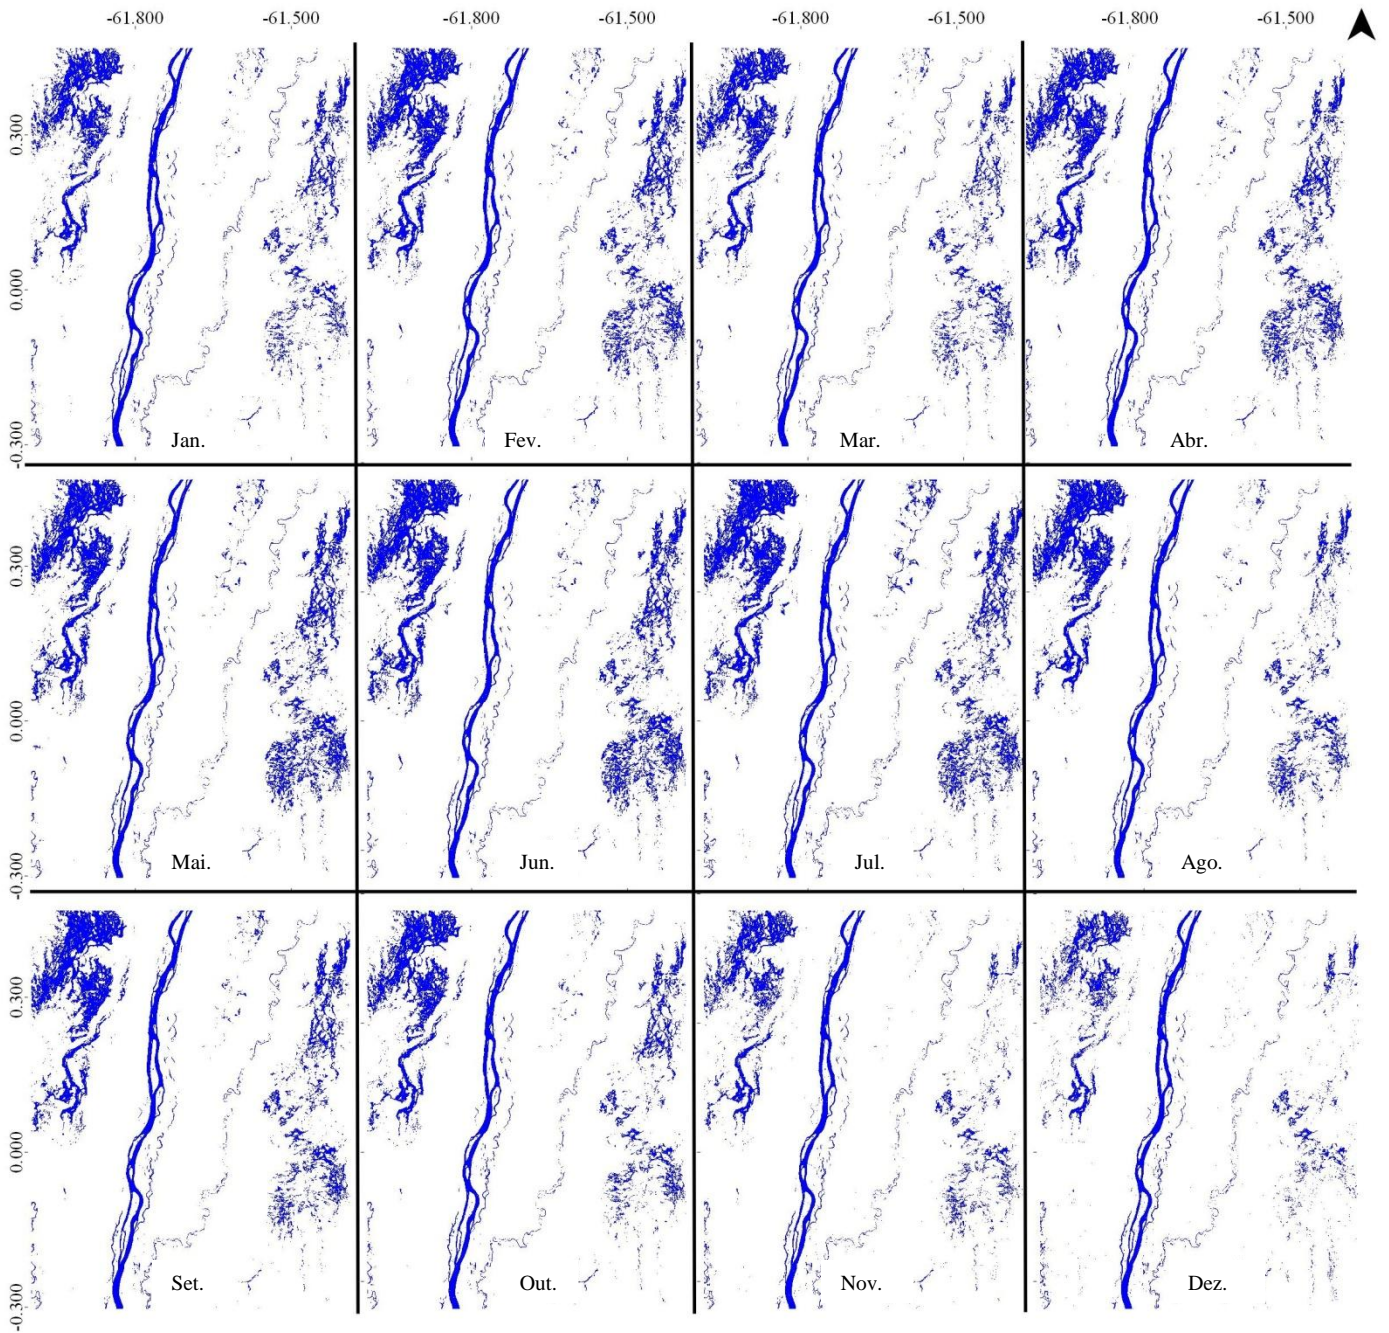


**Figura 24.** Diferença visual entre os limiares -16dB(a), -17dB(b) e -18dB(c).



**Figura 25.** Mapa com a diferença visual entre a data mais cheia, 27/07/2017, e a mais seca 06/12/2017.


A **Figura 26** conta com a imagem das médias simples da área ocupada pela classe água (água aberta + área inundada), em hectares, de cada mês, evidenciando o comportamento pulsante da água sobre a área de estudo, delimitando visualmente a sua extensão ao longo no ano e caracterizando, por fim, esta porção do sul de Roraima como sendo uma área inundável.



**Figura 26.** Média dos meses classificados pelo limiar de -17dB.

A **Figura 27** demonstra o gráfico temporal da classe de água longo do ano, no dia respectivo da passagem do sensor pela área, nele observa-se o comportamento geral comum da região (início da cheia em Abril, com pico em Julho e término em Agosto). Alguns dias registraram valores fora da normalidade, como o verificado no fim do mês de Janeiro e início de Fevereiro. Segundo dados da estação colhidos no repositório da ANA (2018), no mês de Janeiro de 2017 a estação registrou um valor pluviométrico acumulado de 216,3mm, frente à 140,9mm correspondentes à média pluviométrica de Janeiro obtida no intervalo entre 2015 e 2017. Em Fevereiro foram registrados 240,9mm de chuva e a média do mês entre 2015 e 2017 foi de 134,5mm.

Este aumento considerável pode ter sido responsável pelos valores registrados nas imagens de 28 de Janeiro e 09 de Fevereiro, é necessário um estudo mais aprofundado para entender o porquê deste valor pluviométrico fora da média que gerou este evento isolado. Na imagem do dia 31 de Outubro, tem-se o mesmo comportamento diferente do usual, com um valor de precipitação registrado de 151,7mm e a média para o mês de 2015 a 2017 foi de 86,3mm.



**Figura 27.** Distribuição em gráfico da área coberta pela classe água ao longo dos meses analisados.

Ao analisar a média das áreas cobertas pela classe água ao longo do ano, **Tabela 5**, nota-se uma maior aproximação dos gráficos de chuva outrora disposto neste trabalho, **Figura 9**. Importante destacar que no mês de maior cheia, Julho, a classe água cobriu uma área de 72.123 hectares (**Tabela 5**), cerca de 11,9% da área total da imagem. Em consonância com o

dado anteriormente apresentado, a classe Água aberta somada à classe de Áreas inundáveis da classificação temporal cobrem um total de 72.227 hectares (cerca de 11,91% da área total da imagem). O período de seca foi registrado no mês de Dezembro, cobrindo mais de 37.000 hectares (6,1% da área total da cena). A classificação temporal, ou sazonal, das áreas inundáveis, representa o comportamento da classe ao longo do ano, ou seja, o quanto de área total a classe em análise ocupou durante o período estudado. Ao compararmos os dois valores de área, da classificação temporal e da discreta (no mês de cheia), observa-se uma concordância entre elas.


A pequena diferença no valor da classificação temporal pode ser explicada, simplesmente, pela nuance do algoritmo. Tal diferença mínima entre os valores é esperada. Se executarmos outro algoritmo de *Random Forest* com os mesmos parâmetros, sobre o mesmo conjunto de dados, mas que fora programado em linguagem diferente, ou com funções distintas dentro do código, é comum encontrar pequenas diferenças entre os resultados, o que não prejudica nenhuma das duas consequências da metodologia.

**Tabela 5.** Média da área coberta pela classe água ao longo de 2017.

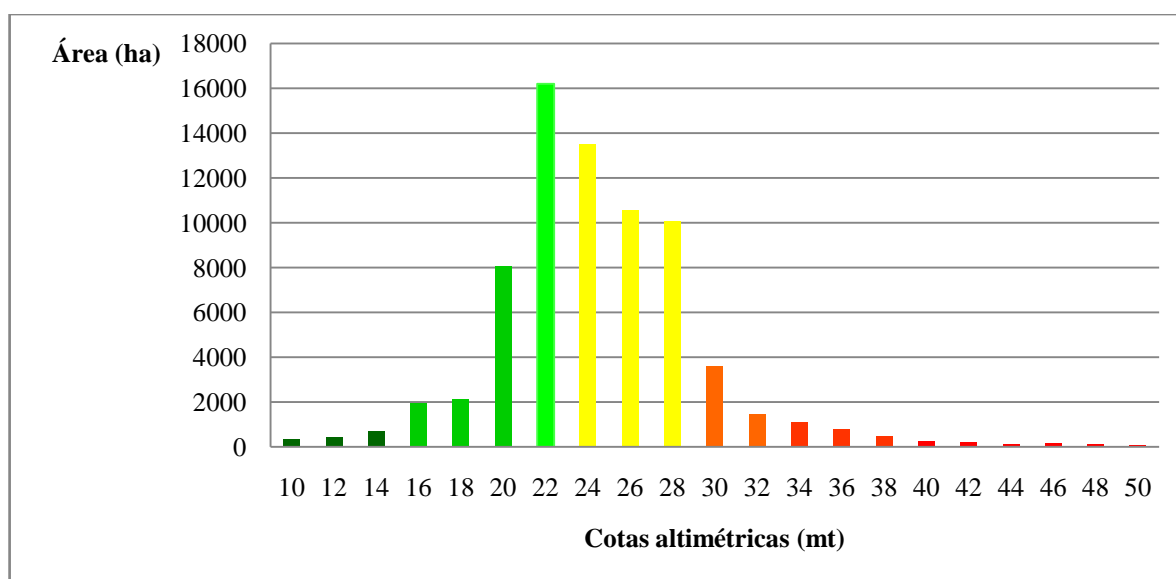
Mês	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
Área (ha)	57.026	56.961	55.234	62.589	68.304	66.808	72.123	61.955	60.010	58.273	43.105	37.425

A **Figura 28** mostra a projeção de toda a área que foi inundada (pico de cheia do local) gerada pela classificação por limiar, sobre a média dos MDEs aprimorados com imagens Sentinel-1. Desta maneira, consegue-se averiguar a distribuição altimétrica ao longo da área inundada, **Figura 29**, apoiando-se na idéia outrora explicitada de que o MDE mostra a capacidade total de inundação da área, e a classificação temporal mostra até onde se estendeu a área inundada no intervalo temporal de estudo.

Ao se estratificar a área inundada em cotas altimétricas, observa-se que as cotas que possuem maior área coberta por água são as medianas, os menores valores de área por cota se encontram na porção mais ao sul do rio Branco e na Campinarana/Brejo à noroeste na imagem, corroborando com a própria topografia da área, onde mais ao norte da imagem as feições de Campinaranas/Brejo e corpos d'água possuem maior valor de altimetria, que vão diminuindo no sentido Norte-Sul.



**Figura 28.** Variação altimétrica da área inundável projetada sobre a média de todos os MDEs aprimorados com as imagens Sentinel.



**Figura 29.** Distribuição gráfica da área ocupada pela classe inundável separada por cotas altimétricas.

## 6. CONSIDERAÇÕES FINAIS

Através dos resultados obtidos no presente trabalho, pode-se concluir que a metodologia conseguiu satisfazer o que fora proposto, no que diz respeito aos objetivos do estudo. Dentro do que foi colocado, os resultados mostraram que a aplicabilidade do método de identificação de ambientes inundáveis, em domínio Amazônico semelhante ao da área de estudo, pode ser incorporada no rol de métodos utilizados para a identificação deste tipo de ambiente. O método utilizado neste estudo também pode contribuir para um mapeamento de ambientes úmidos em escala aproximada de 1:50.000, tendo em vista a resolução espacial das imagens classificadas (10mt).

Importante ressaltar a importância dos dados auxiliares de chuva para a área de estudo. O comportamento hidrológico verificado pelos dois métodos de classificação executados reflete sobre a dinâmica das chuvas no ano de 2017, confirmando o que já havia sido exposto nas séries temporais dos dados de chuva e cota altimétrica do rio Branco, as propriedades do solo arenoso do local causam um certo atraso na inundação da área em relação à data de registro dos maiores valores de precipitação. Esta relação também é evidenciada quando se sobrepõe o resultado da classificação ao Modelo digital de elevação. Nem toda a área considerada de baixa elevação foi ocupada pela água no ano de 2017.

Os procedimentos metodológicos de pré processamento, tratamento de ruídos e classificação se mostraram satisfatórios para o estudo realizado. O aspecto mais importante a ser pontuado é a performance de todos os algoritmos executados na metodologia. Para o conjunto de dados utilizados o tempo de processamento foi relativamente baixo, ao se levar em conta a dimensão da série temporal de imagens Sentinel-1. Para cada imagem, o tempo médio de processamento (englobando todos os algoritmos da metodologia) foi de 3 horas, excetuando-se o tempo gasto para adquirir as imagens e testar outros parâmetros para os algoritmos de processamento, em uma máquina pessoal.

Ainda sobre o aspecto metodológico do trabalho, vale destacar aqui as barreiras, tanto dos dados quanto dos procedimentos. O presente trabalho faz uso de dados com limitações diversas, como, por exemplo, a própria limitação espacial, onde um único pixel de 100m<sup>2</sup> de área armazena uma única informação, radiométrica, altimétrica ou complexa, aliada, claro, com a informação geométrica. A limitação do método caminha, neste caso, ao mesmo passo das tecnologias atuais, principalmente do ramo da inteligência artificial, onde o avanço tecnológico global traz novas possibilidades, principalmente quando se envia pelo campo da precisão, que são incorporadas às metodologias do Sensoriamento Remoto.



Ao se tratar de precisão, cabe destacar a ausência de um conjunto de dados classificados para a validação da metodologia executada, porém, como foi dito em outras sessões do trabalho, foi impossível encontrar dados, livres em termos de disponibilização, com a mesma qualidade das imagens Sentinel, a mesma resolução espacial e, principalmente, temporal. Tal fato é completamente explicado pela particularidade da área, sempre coberta por nuvens e situada em um domínio Morfoclimático delicado para estudos geoespaciais. Por este motivo, a escolha pelos dados auxiliares foi a mais viável, diferentes visões (faixas espectrais distintas) e mapeamentos feitos por órgãos renomados (ainda que em escala inferior à trabalhada neste estudo) trazem mais segurança e balizam melhor o dado utilizado, no caso as imagens SAR Sentinel.

Para estudos futuros, propõe-se o refinamento dos métodos de classificação. Para a classificação temporal pode-se inserir mais parâmetros no algoritmo *Random Forest*, como o valor máximo para a árvore subdividir o nó formado, através do índice de Gini, conforme mostrado na revisão teórica deste trabalho, fazendo com que o usuário possa ter mais opções de refinamento do programa. Outra alternativa é partir para outros métodos em inteligência artificial, como os já utilizados no ramo da visão computacional, de aprendizagem profunda (*Deep Learning*) que podem aumentar consideravelmente a precisão da classificação.

Na classificação discreta, por limiar, propõe-se uma forma de escolha do melhor *Threshold* para os alvos em ambientes aquáticos, talvez uma aplicação que trabalhe com segmentação e estatística, ou funções de mínimo global e local, para encontrar o limiar que melhor traduz os ambientes inundáveis. Para a resolução do problema de validação, sugere-se a aquisição de dados provindos de levantamentos à Laser (Lidar) e/ou Drones e Vants, dependendo da extensão da área de estudo, para conseguir dar validade ao conjunto de dados provindos do Sentinel, que, com o passar dos anos, parece rumar para um programa extremamente robusto de observação contínua e disponibilização de dados em tempo real.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ALSDORF, D, E; BATES, O; MELACK, J; WILSON, M; DUNNE, T. Spatial and temporal complexity of the Amazon flood measured from space. **Geophysical research letters**, v. 34, n. 8, 2007.
- ALSDORF, D, E; HAN, S, C; BATES, P; MELACK, J. Seasonal water storage on the Amazon floodplain measured from satellites. **Remote Sensing of Environment**, v. 114, n. 11, p. 2448-2456, 2010.
- ALSDORF, D.; E. Water storage of the central Amazon floodplain measured with GIS and remote sensing imagery. **Annals of the Association of American Geographers**, v. 93, n. 1, p. 55-66, 2003.
- ALSDORF, D; E.; SMITH, L; C.; MELACK, J; M. Amazon floodplain water level changes measured with interferometric SIR-C radar. **IEEE Transactions on Geoscience and Remote Sensing**, v. 39, n. 2, p. 423-431, 2001b.
- ALSDORF, D; E; BIRKETT, C; DUNNE, T; MELACK, J; HESS, L. Water level changes in a large Amazon lake measured with spaceborne radar interferometry and altimetry. **Geophysical Research Letters**, v. 28, n. 14, p. 2671-2674, 2001a.
- ANA. Dados Fluviométricos e Pluviométricos coletados da estação Santa Maria do Boiaçu dos anos 2010 a 2016. 2018. Disponível em: < <http://www.snirh.gov.br>>. Acesso em: 05.Mai.2018.
- ARAÚJO FURTADO DE MENDONÇA, B., FERNANDES FILHO, E. I., GONÇALVES REYNAUD SCHAEFER, C. E., NOGUEIRA BELLO SIMAS, F., & DAHER DE PAULA, M. Os solos das campinaranas na Amazônia brasileira: ecossistemas arenícolas oligotróficos. **Ciência Florestal**, v. 25, n. 4, 2015.
- ARNESEN, A. S., SILVA, T. S., HESS, L. L., NOVO, E. M., RUDORFF, C. M., CHAPMAN, B. D., & MCDONALD, K. C. Monitoring flood extent in the lower Amazon River floodplain using ALOS/PALSAR ScanSAR images. **Remote Sensing of Environment**, v.130, p.51-61. 2013.
- AYTEKIN, O.; KOC, M.; ULUSOY, I. Local primitive pattern for the classification of SAR images. **IEEE Transactions on Geoscience and Remote Sensing**.v.51, p.2431–2441. 2013.
- BAMLER, Richard. The SRTM Mission-A World-Wide 30 m Resolution DEM from SAR Interferometry in 11 Days. **Photogrammetric Week 1999**, p. 145-154, 1999.
- BARBOSA, R. I. **Distribuição das chuvas em Roraima. Homem. In: ambiente e ecologia no Estado de Roraima**. Manaus: INPA, p.325-335. 1997.
- BARBOSA, R. I., & FEARNSIDE, P. M. Incêndios na Amazônia brasileira: estimativa da emissão de gases do efeito estufa pela queima de diferentes ecossistemas de Roraima na passagem do evento “El Niño”(1997/98).**Acta Amazonica**, v. 29(4), p.513-534. 1999.
- BARNI, P.,E., FEARNSIDE, P., M., GRAÇA P.,M.,L.,A.Desmatamento no Sul do Estado de Roraima: padrões de distribuição em função de projetos de assentamento do INCRA e da distância das principais rodovias (BR-174 e BR-210).**Acta Amazonica**v.42, p.195–204. 2012.
- BARTSCH, A., KIDD, R. A., PATHE, C., SCIPAL, K., WAGNER, W. Satellite radar imagery for monitoring inland wetlands in boreal and sub-arctic environments. **Aquatic Conserv: Mar. Freshw. Ecosyst**. v.17, p. 305–317, 2007.

- BARTSCH, A., WAGNER, W., SCIPAL, K., PATHE, C., SABEL, D., WOLSKI, P. Global monitoring of wetlands – the value of ENVISAT ASAR Global mode. **J. Environ. Manage.** v. 90(7) p.2226-33, 2009.
- BATES, P. D., NEAL, J. C., ALSDORF, D., & SCHUMANN, G. J. P. Observing global surface water flood dynamics. **Surveys in Geophysics**, v.35(3), p.839-852. 2014.
- BELGIU, M; DRĂGUȚ, L. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24-31, 2016.
- BETBEDER, J.; RAPINEL, S.; CORGNE, S.; POTTIER, E.; HUBERT-MOY, L. TerraSAR-X dual-pol time-series for mapping of wetland vegetation. **ISPRS J. Photogramm. Remote Sens.** v.107, p.90–98. 2015.
- BOARDMAN, J. W.; KRUSE, F. A. Automated spectral analysis: a geologic example using AVIRIS data, north Grapevine Mountains, Nevada. **In: Thematic Conference on Geologic Remote Sensing, 10., 1994, Ann Arbor: Environmental Research Institute of Michigan**, p. 407-418. 1994.
- BRADSKI, Gary; KAEHLER, Adrian. OpenCV. **Dr. Dobb's journal of software tools**, v. 3, 2000.
- BRASIL, MDA **Plano Territorial De Desenvolvimento Rural Sustentavel: Propostas De Politicas Publicas Para O Territorio Sul De Roraima**. Rorainopolis/RR: MDA, 2010a.
- BRASIL, MME. **Bacia Hidrográfica do Rio Branco/RR: Estudos de Inventário Hidrelétrico. Tomo 1/4**. MME, Empresa de Pesquisa Energética (EPE), Brasília, DF, Brasil.275 p. 2010b.
- BRASIL, SEPLAN. **Panorama e Vetores de Desenvolvimento de Roraima**. Secretaria de Estado do Planejamento e Desenvolvimento, Roraima. V 1, 2 e 3. 153p.2013.
- BRASIL. Constituição da República Federativa do Brasil de 1988.
- BRASIL. Decreto-Lei nº 9.760, de 5 de setembro de 1946.
- BRASIL. Lei nº 5.173, de 27 de outubro de 1966.
- BREIMAN, L. Bagging predictors. **Machine learning**, v. 24, n. 2, p. 123-140, 1996.
- BREIMAN, L. Random forests. **Machine learning**, v.45(1), p.5-32. 2001.
- BREIMAN, L., FRIEDMAN, J.H., OLSHEN, R.A., and STONE, C.J. **Classification and regression trees**. Chapman and Hall, New York. 1993.
- CARVALHO JÚNIOR O. A; CARVALHO APF, MENESES PR & GUIMARÃES RF. Classificação e eliminação dos ruídos em imagens hiperespectrais pela análise sequencial da transformação por fração de ruído mínima. **Revista Brasileira de Geofísica**, v. 20, n. 1, p. 31–41, 2002.
- CARVALHO JÚNIOR, O. A., MACIEL, L. M. D. M., de CARVALHO, A. P. F., GUIMARÃES, R. F., SILVA, C. R., GOMES, R. A. T., & SILVA, N. C. Probability density components analysis: A new approach totreatment and classification of SAR images. **Remote Sensing**, v.6(4), p.2989-3019. 2014.
- CARVALHO JÚNIOR, O. A.; COUTO JÚNIOR, A. F.; SILVA, N. C.; MARTINS, E. S.; CARVALHO, A. P. F.; GOMES, R. A. T. Avaliação dos Classificadores Espectrais de Mínima Distância Euclidiana e Spectral Correlation Mapper em Séries Temporais NDVI-

MODIS no Campo de Instrução Militar de Formosa (GO). **Revista Brasileira de Cartografia**. v. 61(04). p. 399-412. 2009.

CARVALHO JUNIOR, O. A.; SILVA, N.C.; CARVALHO, A.P.F.; COUTO JUNIOR, A.F.; SILVA, C.R.; SHIMABUKURO, Y.E.; GUIMARÃES, R.F.; GOMES, R.A.T. Combining noise-adjusted principal components transform and median filter techniques for denoising modis temporal signatures. **Revista Brasileira de Geofísica**, v. 30, n. 2, p. 147-157, 2012.

CARVALHO, T., M. **SÍNTESE DOS ASPECTOS HIDROGEOMORFOLÓGICOS DO ESTADO DE RORAIMA, BRASIL**. In: Contribuições à Geologia da Amazônia (Orgs. Gorayeb, P.; Meiguins, A.). Edição Volume 9 (9CGA), Ed. SBG-Norte. p.435-450. 2015.

CIVCO, D., L. Artificial neural networks for land-cover classification and mapping. **International Journal of Geographical Information Science**, v. 7, n. 2, p. 173-186, 1993.

COHEN, J. A. Coeficient of Agreement for Nominal Scales. **Educational and Measurment**. v. XX, No 1, p. 37- 46, 1960.

CONDÉ, T. M., & TONINI, H. Fitossociologia de uma floresta ombrófila densa na Amazônia Setentrional, Roraima, Brasil. **Acta Amazonica**, v.43(3), p.247-260. 2013.

COSTA, M. P., & TELMER, K. H. Utilizing SAR imagery and aquatic vegetation to map fresh and brackish lakes in the Brazilian Pantanal wetland. **Remote sensing of Environment**, v.105(3), p.204-213, 2006.

COUTO JÚNIOR, A. F.; CARVALHO JÚNIOR, O. A.; MARTINS, E. S. Séries temporais MODIS aplicadas em sucessão de culturas de soja (*Glycine Max (L.) Merrill*) e milho (*Zeamays L.*) em sistema de plantio direto. **Revista Brasileira de Cartografia**. v. 64(3). p.405-418, 2012. Disponível em: <<http://repositorio.unb.br/>>. Acesso em: 05.Jun.2016.

DABBOOR, M., COLLINS, M. J., KARATHANASSI, V., BRAUN, A. An Unsupervised Classification Approach for Polarimetric SAR Data Based on the Chernoff Distance for Complex Wishart Distribution. **IEEE Trans. Geosci. Remote Sens.**, v. 51, no. 7, p. 4200–4213, 2013.

DAI, D., YANG, W., SUN, H. Multilevel local pattern histogram for SAR image classification. **IEEE Geoscience and Remote Sensing Letters**, v. 8, n. 2, p. 225–229, 2011.

DAI, K., LI, Z., TOMÁS, R., LIU, G., YU, B., WANG, X., ... & STOCKAMP, J. Monitoring activity at the Daguang bao mega-landslide (China) using Sentinel-1 TOPS time series interferometry. **Remote Sensing of Environment**, v.186, p.501-513. 2016.

DA SILVA FILHO, Augusto Sousa. Inferência em amostras pequenas: Método Bootstrap. **Revista de Ciências exatas e tecnologia**, v. 5, n. 5, p. 115-126, 2015.

DE MELLO, N. A., & THÉRY, H. A armadura do espaço amazônico: eixos e zoneamentos. **Alceu**, v.1, p.181-214. 2001.

DENG, F., WANG, X., CAI, X., LI, E., JIANG, L., LI, H., & YAN, R. Analysis of the relationship between inundation frequency and wetland vegetation in Dongting Lake using remote sensing data. **Ecohydrology**, v.7(2), p.717-726, 2014.

DONG, G., KUANG, G. Target recognition in SAR images via classification on Riemannian manifolds. **IEEE Geosci. Remote Sens. Lett.**, v.12, n.1, p.199–203. 2015.

ERSAHIN, K., CUMMING, I. G., WARD, R. K. Segmentation and classification on polarimetric SAR data using spectral graph partitioning. **IEEE Trans Geosci Remote Sens.** v.48 (1), p.164-74. 2010.

ESA. **Sentinel-1 User Handbook**. ESA, 2013.

FENG, J., JIAO, L., ZHANG, X., YANG, D.: Bag-of-Visual-Words Based on Clonal Selection Algorithm for SAR Image Classification. **IEEE Geoscience and Remote Sensing Letters**. 2011.

FERNANDES FILHO, L. A., PINHEIRO, R. V. L., TRUCKENBRODT, W., & NOGUEIRA, A. C. R. Deformação das rochas silicásticas paleoproterozoicas do Grupo Araí como exemplo das reativações de falhas do embasamento, Serra do Tepequém, Roraima, norte do Brasil. **Revista Brasileira de Geociências**, v.42(4), p.785-798. 2012.

FORMONT, P., PASCAL, T., VASILE, G., ORVALEZ, J. P., FERRO-FAMIL, L. Statistical classification for heterogeneous polarimetric SAR images. **IEEE J. Sel. Top. Sign. Process.** v.5(3), p.567-576. 2011.

FRAGA, L. M., SOUZA, M. M., PINHEIRO, S. S., LARIZZATTI, J. H., ESTEVES, M. A., RIKER, S. R. L., ... & PESSOA, M. R. **Projeto Roraima Central**. Companhia de Pesquisa de Recursos Minerais. 1999.

FRAPPART, F., SEYLER, F., MARTINEZ, J. M., LEON, J. G., & CAZENAVE, A. Floodplain water storage in the Negro River basin estimated from microwave remote sensing of inundation area and water levels. **Remote Sensing of Environment**, v.99(4), p.387-399. 2005.

FREITAS, C. R.; SANT'ANNA, S. J. S.; RENNÓ, C. D.; CORREIA, A. H. **Utilização de imagens de Radar de abertura sintética na classificação de uso e ocupação do solo**. São José dos Campos: INPE, 2007. Disponível em: <<http://urlib.net/sid.inpe.br/mtcm17@80/2007/08.10.18.20>>. Acesso em: 05. jun. 2016.

FREITAS, R. E.; MENDONÇA, M. A. A.; LOPES, G. O. Expansão de área agrícola nas mesorregiões brasileiras. **Revista de Política Agrícola**, ano 20, p. 100-116, 2011.

GENG, J., FAN, J., WANG, H., MA, X., LI, B., CHEN, F. **High-Resolution SAR Image Classification via Deep Convolutional Autoencoders**. *IEEE Geoscience and Remote Sensing Letters*, Vol. 12, no. 11, 2015.

GHANNADI, M. A., SAADATSERESHT, M., & MOTAGH, M. Sentinel-1 Image Matching Using Strong Scatters. **The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v.40(1), p.233. 2015.

GOU, S., QIAO, X., ZHANG, X., WANG, W., DU, F. An Eigenvalue Analysis Based Approach for POL-SAR Image Classification. **IEEE Transaction Geoscience and Remote Sensing**, v.52,No.2, p. 805-818, 2014.

GREEN A.A.; BERMAN M; SWITZER P.; CRAIG M.D. A transformation for ordering multispectral data in terms of images quality with implications for noise removal. **IEEE Transactionson Geoscienceand Remote Sensing**, v.26(1), p.65-74. 1988.

GUIMARÃES, F. S., BUENO, G, T. As campinas e campinaranas amazônicas. Minas Gerais. **Caderno de Geografia**, v.26, n.45, 2016.

HENDERSON, F. M., LEWIS, A. J. **Principles and applications of imaging radar. Manual of remote sensing, volume 2**. John Wiley and sons. 1998.

HENDERSON, F. M., LEWIS, A. J. Radar detection of wetland ecosystems: a review. **International Journal of Remote Sensing**. v. 29, N. 20, p.5809-5835, 2008.

HEPNER, G.; LOGAN, T., RITTER, N., BRYANT, N. Artificial neural network classification using a minimal training set- Comparison to conventional supervised

- classification. **Photogrammetric Engineering and Remote Sensing**, v. 56, n. 4, p. 469-473, 1990.
- HESS, L. L., MELACK, J. M., FILOSO, S., & WANG, Y. Delineation of inundated area and vegetation along the Amazon floodplain with the SIR-C synthetic aperture radar. **IEEE Transactions on Geoscience and Remote Sensing**, v.33(4), p.896-904. 1995.
- HESS, L. L., MELACK, J. M., NOVO, E. M. L. M., BARBOSA, C. C. F., GASTIL, M. Dual-season mapping of wetland inundation and vegetation for the central Amazon Basin. **Remote Sensing of Environment**, v.87, p.404-428. 2003.
- HLAVÁČOVÁ, I., HALOUNOVÁ, L., & STANISLAV, P. SENTINEL-1 Insar Processing of Corner Reflector Information in the Northern-Bohemian Coal Basin. **ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, p.763-767. 2016.
- HUANG, W. Y.; LIPPMANN, R., P. Comparisons between neural net and conventional classifiers. In: **IEEE First International Conference on Neural Networks**. p. 485-493. 1987.
- IBGE. **Base cartográfica contínua do estado de Roraima**. IBGE, Rio de Janeiro, 2016.
- IBGE. Manual técnico da vegetação brasileira. **Manuais Técnicos em Geociências, n° 1, 2ª ed.** Rio de Janeiro, 2012.
- ISA, B. R., ISA, R. R. S., STRAUSS, R., ANDRADE, I., de SOUZA, A., de OLIVEIRA, S., & AGUIAR, P. H. **Diversidade socioambiental de Roraima: Subsídios para debater o futuro sustentável da região**. São Paulo: Instituto Socioambiental, 2011.
- JAFARI, M., MAGHSOUDI, Y., ZOEJ, M. J. V. A new method for land cover characterization and classification of polarimetric SAR data using polarimetric signatures. **IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens.**, v. 8, n. 7, p. 3595-3607, 2015.
- JENSEN, R. J. **Sensoriamento Remoto do Ambiente – Uma Perspectiva em Recursos Terrestres**. São José dos Campos: Parêntese Editora, 598 p. 2009.
- KAYABOL, K. Histogram-based contextual classification of SAR images. **IEEE Geosci. Remote Sens. Lett.** ,v. 12, no. 1, pp. 33–37, 2015.
- KAYABOL, K., GUNSEL, B. Unsupervised classification of SAR images using normalized gamma process mixtures. **Digital Signal Processing**, v.23, n. 5, p.1344–1352, 2013.
- KAYABOL, K., ZERUBIA, J. Unsupervised amplitude and texture classification of SAR images with multinomial latent model. **IEEE Transactions on Image Processing**, v.22(2), p.561–572, 2013.
- KIRANYAZ, S., INCE, T., UHLMANN, S., GABBOUJ, M. Collective Network of Binary Classifier Framework for Polarimetric SAR Image Classification: An Evolutionary Approach. **IEEE Transactions on Systems, Man and Cybernetics**, v. 42, n. 4, 2012.
- LANDIS, J.R.; KOCH, G.G. The measurement of observer agreement for categorical data. **Biometrics**, v.33(1), p.159-174, 1977.
- LANG, M. W., KASISCHKE, E. S., PRINCE, S. D., PITTMAN, K. W. Assessment of C-band synthetic aperture radar data for mapping and monitoring Coastal Plain forested wetlands in the Mid-Atlantic Region, U.S.A. **Remote Sensing of Environment** v.112, p.4120–4130, 2008.

- LEE, J.,S. Digital image enhancement and noise filtering by use of local statistics. **IEEE transactions on pattern analysis and machine intelligence**, n. 2, p. 165-168, 1980.
- LEE, J.,S. Refined filtering of image noise using local statistics. **Computer graphics and image processing**, v. 15, n. 4, p. 380-389, 1981.
- LIN, Y., SHEN, M., LIU, B., & YE, Q. Remote Sensing Classification Method of Wetland Based on AN Improved Svm. **ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v.1(1), p.179-183. 2013.
- LOPES, A; TOUZI, R; NEZRY, E. Adaptive speckle filters and scene heterogeneity. **IEEE transactions on Geoscience and Remote Sensing**, v. 28, n. 6, p. 992-1000, 1990.
- MA, X., SHEN, H., YANG, J., ZHANG, L., LI, P. Polarimetric-spatial classification of SAR images based on the fusion of multiple classifiers. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 3, p. 1064–1074, 2014.
- MALENOVSKÝ, Z., ROTT, H., CIHLAR, J., SCHAEPMAN, M. E., GARCÍA-SANTOS, G., FERNANDES, R., & BERGER, M. Sentinels for science: Potential of Sentinel-1,-2, and-3 missions for scientific observations of ocean, cryosphere, and land. **Remote Sensing of Environment**, v.120, p.91-101. 2012.
- MALNES, E., ECKERSTORFER, M., & VICKERS, H. First Sentinel-1 detections of avalanche debris. **The Cryosphere Discussions**, v.9(2), p.1943-1963. 2015.
- MARECHAL, C., POTTIER, E., HUBERT-MOY, L., RAPINEL, S. One year wetland survey investigations from quad-pol RADARSAT-2 time-series SAR images. **Can. J. Remote Sensing**,v. 38, n. 3, p. 240\_252, 2012.
- MASJEDI, A., ZOEJ, M. J. V., MAGHSOUDI, Y. **Classification of Polarimetric SAR Images Based on Modeling Contextual Information and Using Texture Features**. IEEE Geoscienceand Remote Sensing Letters, Vol. 54, no. 2, 2016.
- MENESES, P., R; SANO, E., E. **Sensor Radar de abertura sintética**. IN: MENESES, P. R.; ALMEIDA, T. **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília, 2011.
- MINISTÉRIO DO PLANEJAMENTO, ORÇAMENTO E GESTÃO – MPOG/SPU. **Orientação Normativa que disciplina a demarcação de terrenos marginais e seus acrescidos (ON-GEADE-003)**. 2001
- MINISTÉRIO DO PLANEJAMENTO, ORÇAMENTO E GESTÃO – MPOG/SPU. **Plano Nacional de Caracterização (PNC)**. 2014.
- MONTGOMERY, G.; SCHUCH, C. **Gis Data Conversion Handbook**. Fort Collins: Gis Word Books. 1993.
- MORAES NOVO, E. M. L. de. **Fundamentos e Aplicações de Radar no Estudo de Áreas Alagáveis**. IN: DE SOUZA, R. B. (Ed.). **Oceanografia por satélites**. Oficina de Textos. 2009.
- MORAES NOVO, E. M. L. de. **Sensoriamento Remoto: Princípios e Aplicações**. 4ª Edição-São Paulo, Blucher, 363p. 2010.
- MORAIS, R. P., & CARVALHO, T. M. Cobertura da terra e parâmetros da paisagem no município de Caracará-Roraima. **Revista Geográfica Acadêmica**, v.7(1), p.46-59. 2013.

- MOREIRA, A., PRATS-IRAOLA, P., YOUNIS, M., KRIEGER, G., HAJNSEK, I., & PAPATHANASSIOU, K. P. A tutorial on synthetic aperture radar. **IEEE Geoscience and remote sensing magazine**, v.1(1), p.6-43.2013.
- NA, X. D., ZANG, S. Y., WU, C. S., LI, W. L. Mapping forested wetlands in the Great Zhan River Basin through integrating optical, radar, and topographical data classification techniques. **IEEE Geoscience and remote sensing Letters**, v. 12, n. 8, 2015.
- NIKOLAKOPOULOS, K., KYRIOU, A. Preliminary results of using Sentinel-1 SAR data for DSM generation. **European Journal of Geography** v.6, n.3, p.52 -68, September 2015.
- OLIVER, C., & QUEGAN, S. **Understanding synthetic aperture radar images**, 1st ed MA: Artech House, Inc. 478 pp. 2004.
- OZESMI, S. L., BAUER, M. E. Satellite remote sensing of wetlands. **Wetlands Ecology and Management** v.10, p.381–402, 2002.
- PANT, T., SINGH, D., SRIVASTAVA, T. Advanced fractal approach for unsupervised classification of SAR images. **Adv. Space Res.**, v.45, p.1338-1349. 2010.
- PONZONI, F. J., SHIMABUKURO, Y. E., & KUPLICH, T. M. **Sensoriamento remoto da vegetação**. São Paulo, Oficina de Textos. 2ª ed. 2015.
- QIN, X., ZOU, H., ZHOU, S., JI, K. Region-Based Classification of SAR Images Using Kullback–Leibler Distance Between Generalized Gamma Distributions. **IEEE Geoscience and Remote Sensing Letters**, v. 12, no. 8, 2015.
- RADAMBRASIL, Projeto. **Folhas NA. 20. Boa Vista e parte das Folhas NA 21 Tumucumaque, NB 20 Roraima e NB 21; Geologia, geomorfologia, pedologia, vegetação e uso potencial da terra**. Rio de Janeiro, 428p. 1975.
- RAMSAR CONVENTION. **Convention on Wetlands of International Importance especially as Waterfowl Habitat (Iran), 2 February 1971. UN Treaty Series n° 14583**. As amended by the Paris Protocol, 3 December 1982, and Regina Amendments, 28 may 1987. 1971.
- RAMSAR CONVENTION. **The List of Wetlands of International Importance**. Rue Mauverney 28, CH-1196 Gland, Switzerland (accessed on at ramsar.org). 2016.
- RAO, B.R.M.; DWIVEDI, R.S.; KUSHWAHA, S.P.S.; BHATTACHARYA, S.N.; ANAD, J.B., DASGUPTA, S. Monitoring the spatial extent of coastal wetlands using ERS-1 SAR data. **International Journal of Remote Sensing**, v.20, p.2509–2517. 1999.
- REIS, N. J., FRAGA, L. M., FARIA, M. D., & ALMEIDA, M. E. Geologia do estado de Roraima, Brasil. **Géologie de la France**, v.2, p.3-4. 2003.
- RESCHKE, J., BARTSCH, A., SCHLAFFER, S., SCHEPASCHENKO, D. Capability of C-Band SAR for Operational Wetland Monitoring at High Latitudes. **Remote Sensing**. v.4, p. 2923-2943. 2012.
- RESEARCH SYSTEMS. **ENVI User Guide**. Research Systems. Inc., 930pp, 1998.
- RODRIGUES, S. W. P., SOUZA-FILHO, P. W. M. Use of Multi-Sensor Data to Identify and Map Tropical Coastal Wetlands in the Amazon of Northern Brazil. **Wetlands** v.31, p.11–23, 2011.
- RONDEAU GENESSE, G., TRUDEL, M., & LECONTE, R. Monitoring snow wetness in an Alpine Basin using combined C-band SAR and MODIS data. **Remote Sensing of Environment**, v.183, p.304-317. 2016.



- ROSSETTI, D., & SAWAKUCHI, A. GEOMORFOLOGIA E GEOCRONOLOGIA DE DEPÓSITOS ALUVIONARES DO BAIXO RIO BRANCO-NORTE DA AMAZÔNIA. **Revista Geonorte**, v.5(17), p.73-78. 2016.
- RUCCI, A., FERRETTI, A., GUARNIERI, A. M., & ROCCA, F. Sentinel 1 SAR interferometry applications: The outlook for sub millimeter measurements. **Remote Sensing of Environment**, v.120, p.156-163. 2012.
- SALVI, S., STRAMONDO, S., FUNNING, G. J., FERRETTI, A., SARTI, F., & MOURATIDIS, A. The Sentinel-1 mission for the improvement of the scientific understanding and the operational monitoring of the seismic cycle. **Remote sensing of environment**, v.120, p.164-174. 2012.
- SANDER, C., WANKLER, F. L., de OLIVEIRA EVANGELISTA, R. A., MORAGA, C. H., & dos SANTOS TEIXEIRA, J. F. CHEIAS DO RIO BRANCO E EVENTOS DE INUNDAÇÃO NA CIDADE DE BOA VISTA, RORAIMA. **Acta Geográfica**, v.6(12), p.41-57. 2012.
- SCHMITT, A., BRISCO, B. Wetland Monitoring Using the Curvelet-Based Change Detection Method on Polarimetric SAR Imagery. **Water**, v.5, p.1036-1051. 2013.
- SCHWERDT, M., SCHMIDT, K., RAMON, N. T., ALFONZO, G. C., DORING, B. J., ZINK, M., & PRATS IRAOLA, P. Independent verification of the Sentinel-1A system calibration. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v.9(3), p.994-1007. 2016.
- SERVELLO, E. L., SANO, E. E., & PANTOJA, N. V. Sentinel-1 SAR:efeito de filtros espaciais no estudo do uso do solo amazônico. **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, João Pessoa-PB, Brasil, INPE, 25 a 29 de abril de 2015.
- SHI, L.; ZHANG, L.; YANG, J. Supervised graph embedding for polarimetric SAR image classification. **IEEE Geosci. Remote Sens. Lett.** v.10, p.216–220. 2013.
- SHITOLE, S., SHARMA, M., De, S., BHATTACHARYA, A., RAO, Y. S., & MOHAN, B. K. Local contrast based adaptive SAR speckle filter. **Journal of the Indian Society of Remote Sensing**, p.1-12. 2014.
- SNOEIJ, P., ATTEMA, E., DAVIDSON, M., DUESMANN, B., FLOURY, N., LEVRINI, G., ...& ROSICH, B. The Sentinel-1 radar mission: Status and performance. In **2009 International Radar Conference "Surveillance for a Safer World" (RADAR 2009)** (pp. 1-6). IEEE. 2009
- SNOEIJ, P., ATTEMA, E., DAVIDSON, M., LEVRINI, G., ROMMEN, B., & FLOURY, N. Sentinel-1 CSAR mission status. In **SPIE Europe Remote Sensing** (pp. 747403-747403). International Society for Optics and Photonics. 2009b.
- SOUZA-FILHO, P.W.M.; PARADELLA, W.R.; RODRIGUES, S.W.P.; COSTA, F.R.; MURA, J.C.; GONÇALVES, F.D. Discrimination of coastal wetland environments in the Amazon region based on multi-polarized L-band airborne Synthetic Aperture Radar imagery. **Estuar. Coast. Shelf Sci.** v.95, p.88–98. 2011.
- TONINI, H., da COSTA, P., & KAMINSKI, P. E. Estrutura, distribuição espacial e produção de sementes de andiroba (*Carapaguianensis* Aubl.) no sul do estado de Roraima. **Ciência Florestal**, v.19(3), p.247-255. 2009.
- TORRES, R., SNOEIJ, P., GEUDTNER, D., BIBBY, D., DAVIDSON, M., ATTEMA, E., ... & TRAVER, I. N. GMES Sentinel-1 mission. **Remote Sensing of Environment**, v.120, p.9-24. 2012.

- TOUZI, R., DESCHAMPS, A., ROTHER, G. Wetland characterization using polarimetric RADARSAT-2 capability. **Can. J. Remote Sensing**, v.33, n.1, p.56-67, 2007.
- TOWNSEND, P. A., & WALSH, S. J. Remote sensing of forested wetlands: application of multitemporal and multispectral satellite imagery to determine plant community composition and structure in southeastern USA. **Plant Ecology**, v.157(2), p.129-149. 2001.
- TOWNSEND, P.A. Mapping seasonal flooding in forested wetlands using multi-temporal radarsat SAR. **Photogrammetric Engineering and Remote Sensing**v.67(7), p.857-864. 2001.
- TOWNSEND, P.A. Relationships between forest structure and the detection of flood inundation in forest wetlands using C-band SAR. **Int. J. Remote Sens.** v.23, p.332–460. 2002.
- TU, S. T., CHEN, J. Y., YANG, W., SUN, H. Laplacian eigenmaps based polarimetric dimensionality reduction for SAR image classification, **IEEE Trans. Geosci. Remote Sens.**, v.50, n. 1, p. 170–179, 2012.
- UHLMANN, S., KIRANYAZ, S. Integrating Color Features in Polarimetric SAR Image Classification. **IEEE Trans. Geosci. Remote Sens.**, v. 52, n. 4, p. 2197-2216, 2014.
- VECI, LUIS. **SENTINEL-1 toolbox: SAR Basics Tutorial**. ESA. 2016
- WANG, H., ZHOU, Z., TURNBULL, J., SONG, Q., QI, F. Pol-SAR Classification Based on Generalized Polar Decomposition of Mueller Matrix. **IEEE Geoscience and Remote Sensing Letters**, v. 13, n. 4, 2016.
- WANG, S., LIU, K., PEI, J., GONG, M., LIU, Y. Unsupervised Classification of Fully Polarimetric SAR Images Based on Scattering Power Entropy and Copolarized Ratio. **IEEE Geoscience and Remote Sensing Letters**, v. 10, n. 3, p. 622-626, 2013.
- WANKLER, F. L., de OLIVEIRA EVANGELISTA, R. A., & SANDER, C. SISTEMA AQUÍFERO BOA VISTA: “ESTADO DE ARTE” DO CONHECIMENTO E PERSPECTIVAS. **Acta Geográfica**, v.6(12). 2012.
- WARING, R. H., WAY, J., HUNT, E. R., MORRISEY, L., RANSON, K. J., WAISHAMPEL, J. F., ... & FRANKLIN, S. E. Imaging radar for ecosystem studies. **Bio Science**, v.45(10), p.715-723. 1995.
- WERNER, Marian. Shuttle radar topography mission (SRTM) mission overview. **Frequenz**, v. 55, n. 3-4, p. 75-79, 2001.
- WHITCOMB, J., MOGHADDAM, M., MCDONALD, K., KELLNDORFER J., PODEST, E. Mapping vegetated wetlands of Alaska using L-band radar satellite imagery. **Can. J. Remote Sensing**, v. 35, n. 1, p. 54–72, 2009.
- WHITE, L., BRISCO, B., DABBOOR, M., SCHMITT, A., & PRATT, A. A collection of SAR methodologies for monitoring wetlands. **Remote Sensing**, v.7(6), p.7615-7645. 2015.
- WOODHOUSE, I.H. **Introduction to Microwave Remote Sensing**; Taylor Francis: Boca Raton, FL, USA, 379p. 2006
- XAUD, M., R; EPIPHANIO, J., C., N. Dinâmica do uso e cobertura da terra no sudeste de Roraima utilizando técnicas de detecção de mudanças. **Acta Amazonica**, v. 44(1), p.107 – 120, 2014.

YAGUE MARTINEZ, N., PRATS IRAOLA, P., GONZALEZ, F. R., BRCIC, R., SHAU, R., GEUDTNER, D., ... & BAMLER, R. Interferometric Processing of Sentinel-1 TOPS Data. **IEEE Transactions on Geoscience and Remote Sensing**, v.54(4), p.2220-2234. 2016.

ZANI; H. ROSSETTI, D.,F; FILHO, C.,O.,A. Análise temporal de imagens Landsat aplicada à extração de canais do megaleque Viruá, Estado de Roraima. **Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, Curitiba, PR, Brasil, 30 de abril a 05 de maio de 2011, INPE p.3522. 2011.

ZHANG, X., QIN, J., LI, Q. G. SAR Target classification using bayesian compressive sensing with scattering centers features. **Progress In Electromagnetics Research**, v. 136, p.385-407, 2013.

ZHAO, L., KUANG, G., ZHOU, X., WANG, N. A novel measure of target scattering randomness with application to polarimetric SAR image classification. **International Journal of Remote Sensing** v. 33, n. 2, p.534–551. 2012.