


UNIVERSIDADE DE BRASÍLIA
PÓS-GRADUAÇÃO EM GEOGRAFIA

**MAPEAMENTO DA DINÂMICA FLUVIAL NA VOLTA GRANDE DO
XINGU POR MEIO DE IMAGENS MULTITEMPORAIS DO SATÉLITE
SENTINEL-1**

Karina Serra Silvestre

Dissertação de Mestrado

Brasília/DF
2019



UNIVERSIDADE DE BRASÍLIA
PÓS-GRADUAÇÃO EM GEOGRAFIA


**MAPEAMENTO DA DINÂMICA FLUVIAL NA VOLTA GRANDE DO
XINGU POR MEIO DE IMAGENS MULTITEMPORAIS DO SATÉLITE
SENTINEL-1**

KARINA SERRA SILVESTRE

Orientador: Prof. Dr. Renato Fontes Guimarães
Coorientador: Prof. Dr. Osmar Abílio de Carvalho Júnior

Dissertação de Mestrado

Brasília/DF
2019



UNIVERSIDADE DE BRASÍLIA
DEPARTAMENTO DE GEOGRAFIA

**MAPEAMENTO DA DINÂMICA FLUVIAL NA VOLTA GRANDE DO
XINGU POR MEIO DE IMAGENS MULTITEMPORAIS DO SATÉLITE
SENTINEL-1**

KARINA SERRA SILVESTRE

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, linha de pesquisa Geoprocessamento.

Aprovada por:

Prof. Dr. Renato Fontes Guimarães (Orientador)
Universidade de Brasília

Prof. Dr. Osmar Abílio de Carvalho Júnior (Coorientador)
Universidade de Brasília

Dr. Fernando Campagnoli
Agência Nacional de Energia Elétrica

Dr. Thiago Avelar Chaves
Fundação de Empreendimentos Científicos e Tecnológicos

Prof. Dr. Roberto Arnaldo Trancoso Gomes
Universidade de Brasília

Brasília, 06 de dezembro de 2019

FICHA CATALOGRÁFICA

SILVESTRE, KARINA SERRA

Mapeamento da dinâmica fluvial na Volta Grande do Xingu por meio de imagens multitemporais do satélite Sentinel-1, 52p. (UnB-GEA, Mestre, Gestão Ambiental e Territorial, 2019).

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

1. Monitoramento de recursos hídricos; 2. Sentinel-1; 3. Xingu; 4. Sensoriamento remoto; 5. Detecção de mudanças. I. UnB-GEA. II. Título.

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. Esse direito poderá ocorrer somente após a publicação dos artigos contidos no documento. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito do autor.

Karina Serra Silvestre
skarinaserra@gmail.com

RESUMO

As áreas inundáveis na região da Volta Grande do Xingu, Pará, têm sido intensamente pressionadas e degradadas devido às políticas de integração adotadas na região e, mais recentemente, em decorrência da construção da Usina Hidrelétrica de Belo Monte. Para subsidiar o gerenciamento sustentável desses ecossistemas, este estudo visou detectar a dinâmica dos corpos d'água superficiais da Volta Grande do Xingu por meio da análise de imagens multitemporais de radar do satélite Sentinel-1 e o melhor *threshold* da água. Foram analisados o comportamento do retroespalhamento das amostras de água superficiais com os filtros espaciais Frost, Gamma e Lee, nas janelas 5x5, 7x7 e 9x9. A imagem de 26 de julho de 2017 com o filtro Frost 9x9 exibiu maior acurácia na delimitação de corpos d'água ao adotar um *threshold* de -20,71 dB usando a imagem Sentinel-2 de 28 de julho de 2017 como verdade (índice *Kappa* de 0,96 e exatidão global de 98,9%). Esse filtro e *threshold* foram empregados nas 34 imagens multitemporais Sentinel-1. A amplitude máxima do rio foi mapeada com as imagens da menor e maior vazão registrada pelo satélite durante o período de análise, sendo de 29 de setembro de 2016 (449 cm) e 04 de março de 2017 (848 cm), respectivamente. Além de representar a extensão da inundação, o mapa de ocorrência de água no *pixel* também representou o tempo que cada *pixel* ficou coberto por água, fornecendo um panorama do fluxo do rio ao longo do tempo. Isso permite um gerenciamento da vazão remanescente que garanta a manutenção dos ecossistemas aquáticos nos trechos de vazão reduzida, minimizando os impactos sociais, ambientais e econômicos. Os resultados demonstraram um grande potencial metodológico em extrair, de forma rápida, informações sobre a dinâmica de corpos d'água superficiais e em monitorar grandes extensões de áreas inundáveis.

Palavras-chave — Monitoramento de recursos hídricos, Sentinel-1, Xingu, sensoriamento remoto, detecção de mudanças.

ABSTRACT

The flooded areas of the Volta Grande of Xingu have been intensely pressured and degraded due to the integration policies adopted in region and the construction of the Belo Monte Dam complex more recently. Therefore, the management of these ecosystems is crucial. So, this research aims to detect changes in the surface of the open water bodies from Volta Grande do Xingu, using multitemporal SAR images of Sentinel-1 satellite and best thresholding. The performance of Frost, Gamma and Lee filters in open water delineation was analyzed with windows size 5x5, 7x7 and 9x9. The image from July 26 of 2017 with Frost 9x9 filter exhibited greater accuracy in water bodies delineating. Adopting a -20,71 dB threshold, Kappa index result was 0.96 and overall accuracy 98.9%. This *threshold* was employed in 34 multitemporal Sentinel-1 images with Frost 9x9. The maximum amplitude of Xingu river was mapped with images demonstrating the smallest and largest flow during the analysis period, being September 29 of 2016 and March 4 of 2017, respectively. The pixel water map representing the time that each pixel was covered by water and show the extent of the flood, providing a panorama of river flow in the 34 images. This enables remnant flow management that ensures the maintenance of aquatic ecosystems in the reduced flow sections, minimizing social, environmental and economic impacts. The results demonstrated a great methodological potential to quickly extract information about the dynamics of surface water bodies and to monitor large areas of flooded areas.

Keywords: Water body monitoring, Sentinel-1, Xingu, remote sensing, change detection.

SUMÁRIO

LISTA DE FIGURAS	vii
LISTA DE TABELAS	ix
LISTA DE SIGLAS E ABREVIATURAS	x
1. INTRODUÇÃO	1
2. ÁREA DE ESTUDO	3
3. MATERIAIS E MÉTODOS	7
3.1. IMAGENS DE SATÉLITE	7
3.2. DADOS AUXILIARES	9
3.3. PRÉ-PROCESSAMENTO	10
3.4. CLASSIFICAÇÃO	11
3.4.1. Retroespalhamento das amostras de água	12
3.4.2. Melhor <i>threshold</i>	14
3.4.3. Validação	15
3.5. AMPLITUDE MÁXIMA FLUVIAL	15
4. RESULTADOS	16
4.1. COTAS FLUVIOMÉTRICAS	16
4.2. RETROESPALHAMENTO DAS AMOSTRAS DE ÁGUA	16
4.3. MELHOR <i>THRESHOLD</i>	26
4.4. VALIDAÇÃO	36
4.5. AMPLITUDE MÁXIMA FLUVIAL	40
5. CONCLUSÕES	43
REFERÊNCIAS BIBLIOGRÁFICAS	44

LISTA DE FIGURAS

FIGURA 1. Localização da área de estudo	4
FIGURA 2. Situação da região de estudo antes e depois da construção da barragem da UHE Belo Monte e de parte da área do reservatório principal, mostrada pelas imagens Landsat-5 e Landsat-8	6
FIGURA 3. Situação do rio Xingu, na região de Volta Grande, antes e depois da construção da UHE de Belo Monte, mostrada pelas imagens dos satélites Landsat-5 e Landsat-8.....	6
FIGURA 4. Fluxograma dos principais passos metodológicos adotados no mapeamento da dinâmica do rio Xingu em áreas abertas por meio de análise de imagens multitemporais dos satélites Sentinel-1 e Sentinel-2	7
FIGURA 5. Cotas máximas mensais (cm) da Estação Altamira (out. 2016 a out. 2017)	9
FIGURA 6. Cotas fluviométricas registrada pela Estação Altamira nas datas de passagem do satélite Sentinel-1 na área de estudo	16
FIGURA 7. Valores de retroespalhamento das amostras de água nas 34 imagens Sentinel-1 sem filtro	17
FIGURA 8. Valores de retroespalhamento (dB) mínimo, máximo, médio e desvio-padrão das amostras de água nas 34 datas (T) do Sentinel-1, com os filtros Frost, Gamma e Lee, nas janelas 5x5, 7x7 e 9x9	18
FIGURA 9. Diagramas de caixa comparando a distribuição dos valores de σ° (dB) das amostras de água com filtros Frost, Gamma e Lee aplicados nas imagens Sentinel-1 de 29 set. 2016, 10 dez. 2016, 04 mar. 2017, 20 jun. 2017, 26 jul. 2017 e 24 set. 2017	21
FIGURA 10. Área de sobreposição entre as imagens Sentinel-1 e Sentinel-2.....	27
FIGURA 11. Gráfico do melhor <i>threshold</i> para classificar os corpos d'água usando o filtro Frost 5x5. O <i>Kappa</i> atinge o coeficiente máximo no valor de <i>threshold</i> -21,11 dB	28
FIGURA 12. Gráfico do melhor <i>threshold</i> para classificar os corpos d'água usando o filtro Gamma 5x5. O <i>Kappa</i> atinge o coeficiente máximo no valor de <i>threshold</i> -21,11 dB	28
FIGURA 13. Gráfico do melhor <i>threshold</i> para classificar os corpos d'água usando o filtro Lee 5x5. O <i>Kappa</i> atinge seu valor máximo no valor de <i>threshold</i> -21,76 dB	29
FIGURA 14. Gráfico do melhor <i>threshold</i> para classificar os corpos d'água usando o filtro Frost 7x7. O <i>Kappa</i> atinge seu valor máximo no valor de <i>threshold</i> -20,90 dB	29
FIGURA 15. Gráfico do melhor <i>threshold</i> para classificar os corpos d'água usando o filtro Gamma 7x7. O <i>Kappa</i> atinge seu valor máximo no valor de <i>threshold</i> -20,74 dB	30

FIGURA 16. Gráfico do melhor <i>threshold</i> para classificar os corpos d'água usando o filtro Lee 7x7. O <i>Kappa</i> atinge seu valor máximo no valor de <i>threshold</i> -20,17 dB	30
FIGURA 17. Gráfico do melhor <i>threshold</i> para classificar os corpos d'água usando o filtro Frost 9x9. O <i>Kappa</i> atinge seu valor máximo no valor de <i>threshold</i> -20,71 dB	31
FIGURA 18. Gráfico do melhor <i>threshold</i> para classificar os corpos d'água usando o filtro Gamma 9x9. O <i>Kappa</i> atinge seu valor máximo no valor de <i>threshold</i> -20,65 dB	31
FIGURA 19. Gráfico do melhor <i>threshold</i> para classificar os corpos d'água usando o filtro Lee 9x9. O índice <i>Kappa</i> atinge seu valor máximo no valor de <i>threshold</i> -21,21 dB	32
FIGURA 20. Gráfico dos melhores valores de <i>threshold</i> e os respectivos coeficientes <i>Kappa</i>	32
FIGURA 21. Mapeamento dos corpos d'água elaborado a partir das imagens Sentinel-1 de 26 de julho de 2017 com filtros Frost, Gamma e Lee, janelas de filtragem de tamanho 5x5, 7x7 e 9x9, e adotando os respectivos melhores valores de <i>threshold</i>	34
FIGURA 22. Mapeamento da água com os filtros Frost, Gamma e Lee nas janelas 5x5, 7x7 e 9x9	35
FIGURA 23. Vegetação morta que cobria ilhas do rio Xingu, próximos a Altamira, que foram inundadas	36
FIGURA 24. Erros de comissão no mapeamento da água usando o melhor <i>threshold</i>	37
FIGURA 25. Mapeamento dos corpos d'água elaborado filtro Frost, nas janelas 5x5, 7x7 e 9x9	37
FIGURA 26. Acurácia do usuário e do produtor do mapeamento de água elaborado com as imagens Sentinel-1 de 26 de julho de 2017 nos diferentes filtros e tamanhos de janela de filtragem	38
FIGURA 27. Análise de acurácia por meio de índice <i>Kappa</i> e exatidão global	39
FIGURA 28. Detecção da amplitude fluvial na Volta Grande do Xingu.....	40
FIGURA 29. Frequência de água no <i>pixel</i> na Volta Grande do Xingu.....	42

LISTA DE TABELAS

TABELA 1. Data dos menores e maiores valores de σ° (dB) mínimos, máximos, médios, desvio-padrão e amplitude total das amostras de água nas 34 datas, nos filtros Frost, Gamma e Lee nas janelas 5x5, 7x7 e e 9x9	19
TABELA 2. Correlação dos filtros na imagem de 29 de setembro de 2016	24
TABELA 3. Correlação dos filtros na imagem de 10 de dezembro de 2016	24
TABELA 4. Correlação dos filtros na imagem de 04 de março de 2017	24
TABELA 5. Correlação dos filtros na imagem de 20 de junho de 2017.....	25
TABELA 6. Correlação dos filtros na imagem de 26 de julho de 2017.....	25
TABELA 7. Correlação dos filtros na imagem de 24 de setembro de 2017	25

LISTA DE SIGLAS E ABREVIATURAS

AHE – Aproveitamento Hidrelétrico
ANA – Agência Nacional de Águas
ANEEL – Agência Nacional de Energia Elétrica
dB – Decibel
EC – *European Commission*
EIA – Estudo de Impacto Ambiental
ELETROBRÁS – Centrais Elétricas Brasileiras S.A.
ENVI – *Environment for Visualizing Images*
ENVISAT – *Environmental Satellite*
ESA – *European Space Agency*
FUNAI – Fundação Nacional do Índio
GRD – *Ground Range Detected*
IBGE – Instituto Brasileiro de Geografia e Estatística
IW – *Interferometric Wide-swath*
MW – Megawatt
MDE - Modelo Digital de Elevação
NASA – *National Aeronautics and Space Administration*
PA – Projetos de Assentamento
PDI – Processamento Digital de Imagens
Q – Quartil
RADAR – *Radio Detection and Ranging*
RIMA – Relatório de Impacto Ambiental
ROI – *Region Of Interest*
SAR – *Synthetic Aperture Radar*
SNAP – *Sentinel Application Platform*
SRTM – *Shuttle Radar Topographic Mission*
TVR – Trecho de Vazão Reduzida
UHE – Usina Hidrelétrica
UTM – *Universal Transversa de Mercator*
WGS-84 – *World Geodetic System 1984*

1. INTRODUÇÃO

O rio Xingu é um dos maiores afluentes do rio Amazonas e possui diversos trechos susceptíveis à inundação. A flutuação natural do rio promove maior heterogeneidade do habitat e complexidade de espécies. Os ecossistemas inundáveis desempenham um papel fundamental na manutenção da qualidade ambiental e no desenvolvimento social e econômico na região de Volta Grande do Xingu, no estado do Pará. Essas áreas periodicamente inundadas fornecem alimento e abrigo para muitas espécies (incluindo as ameaçadas e as endêmicas) e servem de amortecimento contra efeitos extremos de enchentes ao absorver o excesso de água (WHITE et al., 2008; ARNESEN et al., 2013). Entretanto, essa região passou por diversos processos de ocupação, provocando intensa degradação e pressão sobre os recursos naturais. Dentre eles, destacam-se o ciclo da borracha, a exploração de ouro e a construção da rodovia BR-230 (Rodovia Transamazônica), onde extensas formações florestais foram desmatadas segundo o padrão de “espinha de peixe” (MPEG, 2008; BECKER, 2013). Milhares de pessoas migraram para a região visando a produção agropecuária (MORAN, 2016) e centenas de madeireiras e garimpos ilegais foram instalados (ROSCOCHE & VALLERIUS, 2014). Em especial, a construção da Usina Hidrelétrica (UHE) Belo Monte na região de Volta Grande do Xingu remodelou drasticamente um dos maiores afluentes do rio Amazonas, alterando profundamente a dinâmica fluvial e social (JIANG et al., 2018).

A UHE Belo Monte começou a operar comercialmente em abril de 2016 (ELETROBRÁS, 2019) e tornou-se a maior hidrelétrica 100% nacional em junho de 2019. É a terceira maior UHE do mundo (JIANG et al., 2018) possuindo uma capacidade instalada de 11.233 MW e dois reservatórios ligados por um canal de derivação de 20 km, o principal com 359 km² e o intermediário com 119 km² (NORTE ENERGIA, 2019). A potência máxima só poderá ser obtida durante o período de cheia, sendo assegurada uma energia média de 4,5 mil MW durante outras épocas do ano, podendo chegar a menos de mil MW na seca. As obras da construção iniciaram-se em 2011, alterando a dinâmica social e ambiental da região. Os ambientes aquáticos da Volta Grande do Xingu foram diretamente impactados, acarretando mudanças na dinâmica fluvial e comprometendo seriamente o ecossistema, a vida e a cultura de populações tradicionais. Essas áreas forneciam diversos recursos para as comunidades indígenas e ribeirinhas da região, como pesca, agricultura de subsistência e meio de transporte. Podem-se ressaltar ainda a perda de micro-habitats que dependem do ciclo de cheia e seca para

prover alimentos e ambientes de reprodução de peixes; a restrição à navegação pelas comunidades tradicionais; a redução da capacidade de aeração e eutrofização; e as alterações na vegetação e nos padrões de pesca (MAGALHÃES et al., 2016).

Destarte, o mapeamento e o monitoramento da dinâmica fluvial são imprescindíveis em estudos de avaliação da biodiversidade (FENG et al., 2016) e no gerenciamento sustentável desses ecossistemas (ADAM et al., 2010; HIND et al., 2017), podendo fornecer ainda soluções de melhorias no uso do reservatório. Todavia, a grande área de abrangência do empreendimento e o difícil acesso em algumas áreas tornam o monitoramento complexo.

Nesse propósito, o sensoriamento remoto tem sido amplamente usado como uma ferramenta eficiente no monitoramento hidrológico dos rios em escalas locais e globais (PAZ ET AL., 2010; FENG et al., 2012; MANJUSREE, 2012; CHIGNELL et al., 2015; CLEMENT, 2017; DEVRIES et al., 2017; JIN, 2017; OLTHOF, 2017; TIAN et al., 2017; HARDY et al., 2019) devido à capacidade de obtenção de dados de forma rápida e periódica. Os recentes avanços tecnológicos na obtenção de dados de satélite, sua disponibilização e o crescente uso de algoritmos de aprendizado de máquina têm facilitado a automatização de mapeamentos de áreas inundáveis, permitindo avaliar sua extensão e sua variabilidade espaço-temporal da inundação (SOUZA FILHO et al., 2006; MATGEN et al., 2011; MANJUSREE et al., 2012; HUANG et al., 2014; OGILVIE et al., 2015; WHITE, 2015; MUELLER et al., 2016; PEKEL et al., 2016; BRISCO et al., 2017; CLEMENT, 2017; HIRD et al. 2017; MOHAMMADI et al., 2017). Todavia, a incidência de nuvens é um fator limitante para o mapeamento de áreas inundáveis por meio de sensores óticos (VANDERBILT et al., 2002; MARTINEZ et al., 2015; TIAN et al., 2017; BIORESITA et al., 2018), principalmente na região Amazônica que apresenta elevados índices de pluviosidade e evapotranspiração. Neste sentido, cabe ressaltar a potencialidade dos dados oriundos de sensores de abertura sintética (SAR).

O radar é um sensor ativo que emite sua própria fonte de radiação na faixa do micro-ondas, captando o sinal retroespalhado pelo alvo (MENESES et al., 2012). Os dados de radar possuem a vantagem de não depender das condições climáticas e de iluminação solar no horário de imageamento. Os sensores de radar, por atuarem na faixa espectral de micro-ondas, sofrem pouca interferência das partículas sólidas e moléculas presentes na atmosfera. Por isso, as imagens provenientes de satélites de radar têm sido amplamente empregadas em mapeamentos de diversos campos do conhecimento (VREUGDENHIL et al., 2018; CHOI et al., 2019), sendo muito adotadas em fiscalizações e monitoramento de desastres (LÊ et al., 2015).

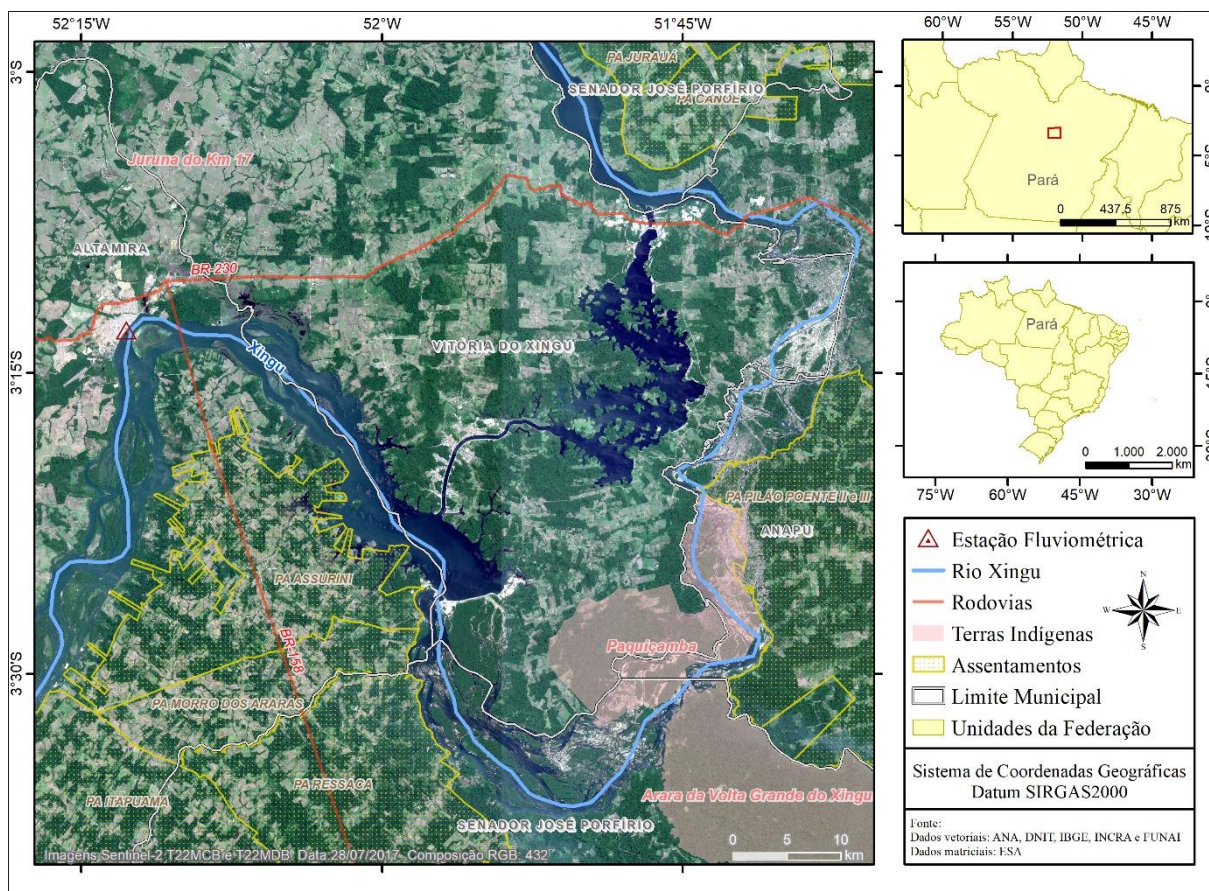
Existem diversas propostas de automatização do mapeamento das áreas inundáveis (HARDY et al., 2019). Entre elas, destaca-se a associação de imagens SAR à técnica de classificação automática por meio do uso de limiares (*thresholding*) de coeficientes de retroespalhamento (σ° , unidade de medida em decibéis - dB) relativos a corpos d'água em várias partes do mundo, visando detectar mudanças nos corpos d'água (MANJUSREE et al., 2012; LONG et al., 2014; HONG et al., 2015; CAZALS et al., 2016; CLEMENT et al., 2017; TIAN et al., 2017; BIORRESITA et al., 2018; HARDY et al., 2019), especialmente em áreas remotas e de difícil obtenção de dados *in situ*. O *thresholding* é amplamente empregado na literatura para classificar corpos d'água de forma rápida e eficaz (MANJUSREE et al., 2012), principalmente em áreas não-florestadas (SOLBØ & SOLHEIM, 2005). Devido ao baixo coeficiente de retroespalhamento da água, é possível mapear corpos d'água superficiais por meio da técnica *thresholding*.

O satélite de radar Sentinel-1 é capaz de fornecer dados contínuos com alta resolução espacial (10 m) e temporal (6 dias) (VREUGDENHIL et al., 2018), além de serem disponibilizados rapidamente e gratuitamente, representando um grande potencial no monitoramento das dinâmicas fluviais (TIAN et al., 2017; BIORRESITA et al., 2018) e nas atividades de fiscalização e gestão do território. Dentro desse contexto, este estudo objetiva mapear a dinâmica fluvial em áreas abertas da região de Volta Grande do Xingu, entre 2016 e 2017, baseadas no processamento de imagens do satélite Sentinel-1.

2. ÁREA DE ESTUDO

Com mais de 2.000 km de extensão, o rio Xingu é um dos maiores afluentes do rio Amazonas. A bacia hidrográfica do rio Xingu possui área aproximada de 509.000 km² e está limitada a oeste pela bacia hidrográfica do rio Tapajós e a leste pela bacia dos rios Araguaia-Tocantins (NASCIMENTO & DRUMMOND, 2003). A área de estudo abrange o rio Xingu no trecho onde ocorre uma acentuada deflexão, na mesorregião do Sudoeste Paraense, chamada de Volta Grande do Xingu, no estado do Pará, Brasil (**Figura 1**). A área de estudo ocupa parte dos municípios de Altamira, Anapu, Senador José Porfírio e Vitória do Xingu, situando-se aproximadamente entre as latitudes 3°01'S e 3°44'S e entre as longitudes 51°35'W e 52°28'W.

Figura 1. Localização da área de estudo.



De acordo com a classificação de Köppen, o clima da bacia é do tipo Tropical de Monção (Am), sendo quente, úmido, e com baixa amplitude térmica anual. As condições climáticas e geomorfológicas da bacia do rio Xingu apresentam diferenças que variam no sentido norte/sul. A precipitação média anual é de 1.800 mm, aumentando no sentido de nascente (1.500 mm) para jusante (2.600 mm) (ELETROBRÁS, 2009a). O período mais seco ocorre geralmente entre julho e novembro e com chuvas mais intensas entre dezembro e junho. As chuvas podem sofrer atraso de até dois meses entre as cabeceiras e o baixo curso, provocando grandes deflúvios no médio e baixo curso do rio (ELETROBRÁS, 2009a). Na área de estudo, esses deflúvios costumam ocorrer entre março e maio. Os índices de evaporação demonstram uma situação inversa aos da precipitação, ou seja, os menores valores ocorrem no período mais chuvoso e os maiores no período mais seco (ELETROBRÁS, 2009c).

O rio Xingu e seus afluentes cortam rochas do embasamento cristalino, rochas sedimentares do Paleozoico, Mesozoico e Cenozoico (ELETROBRÁS, 2009a). De acordo com o Estudo de Impacto Ambiental (EIA) da UHE Belo Monte, a geomorfologia da região possui uma variação altimétrica de 50 m a 750 m, abrangendo a Depressão da Amazônia Meridional,

os Planaltos Residuais do Sul da Amazônia, o Planalto Marginal do Amazonas, a Depressão do Amazonas, a Planície Fluvialagunar do Amazonas e as Planícies Fluviais. As áreas inundáveis da Volta Grande do Xingu localizam-se na Planície Fluvial, Planície Fluvialagunar do Amazonas, e na Depressão da Amazônia Meridional, com presença de ilhas aluviais e rochosas (ELETROBRÁS, 2009c). Na região, predominam a floresta de terra firme, a floresta aluvial e a vegetação de pedrais (ELETROBRÁS, 2009b). Os ambientes inundáveis estão associados à floresta ombrófila aluvial e à vegetação de pedrais (SALOMÃO et al., 2007; ELETROBRÁS, 2009b).

A UHE de Belo Monte ocasionou uma intensa intervenção ambiental, tornando parte das áreas da Volta Grande do Xingu permanentemente inundadas pelo reservatório principal com o desaparecimento de ilhas e praias (ROSCOCHE & VALLERIUS, 2013) (**Figura 2**). A vegetação inundada na área do reservatório, ao apodrecer, emite quantidade considerável de gases do efeito estufa como o metano, dióxido de carbono e óxido nitroso (FEARNSIDE, 2015). Além disso, em um trecho de 100 km do rio Xingu, entre a barragem principal (Sítio Pimental) e a casa de força principal (Sítio Belo Monte), a vazão foi reduzida em decorrência do desvio das águas para a formação do Reservatório Intermediário (ELETROBRÁS, 2009b). Nesse trecho, denominado Trecho de Vazão Reduzida (TVR), localizado à jusante do reservatório principal (barragem Sítio Pimental), houve uma redução de mais de 80% da vazão da água, causando a perda de alimentos, habitats naturais e locais de reprodução da ictiofauna, ocasionando a mortandade de peixes (inclusive endêmicos), alteração da temperatura da água, piora da qualidade da água, profundas alterações no modo de vida e cultura de populações indígenas (ISA, 2017). As Terras Indígenas Paquiçamba e Arara da Volta Grande do Xingu estão localizadas as margens do TVR, e foram diretamente afetadas com a redução das águas do Xingu. Cabe ressaltar que o impacto aumenta conforme aumenta o tamanho do trecho de vazão reduzida e a potência instalada (SOUZA-CRUZ-BUENAGA et al., 2017). Ademais, a perda das planícies de inundação ocasiona perdas de guildas associadas àquele ecossistema (WELCOMME et al., 2006).

As imagens dos sensores Landsat-5 de 04 de maio de 2011 e Landsat-8 de 11 de agosto de 2019 mostram as mudanças na fisionomia do rio Xingu após a construção da UHE Belo Monte (**Figuras 2 e 3**). Fica evidente a intensidade das alterações dos corpos d'água na Volta Grande do Xingu, principalmente na área dos reservatórios e a drástica redução da vazão do rio Xingu no Trecho de Vazão Reduzida.

Figura 2. Situação da região de estudo antes e depois da construção da barragem da UHE Belo Monte e de parte da área do reservatório principal, mostrada pelas imagens Landsat-5 e Landsat-8.

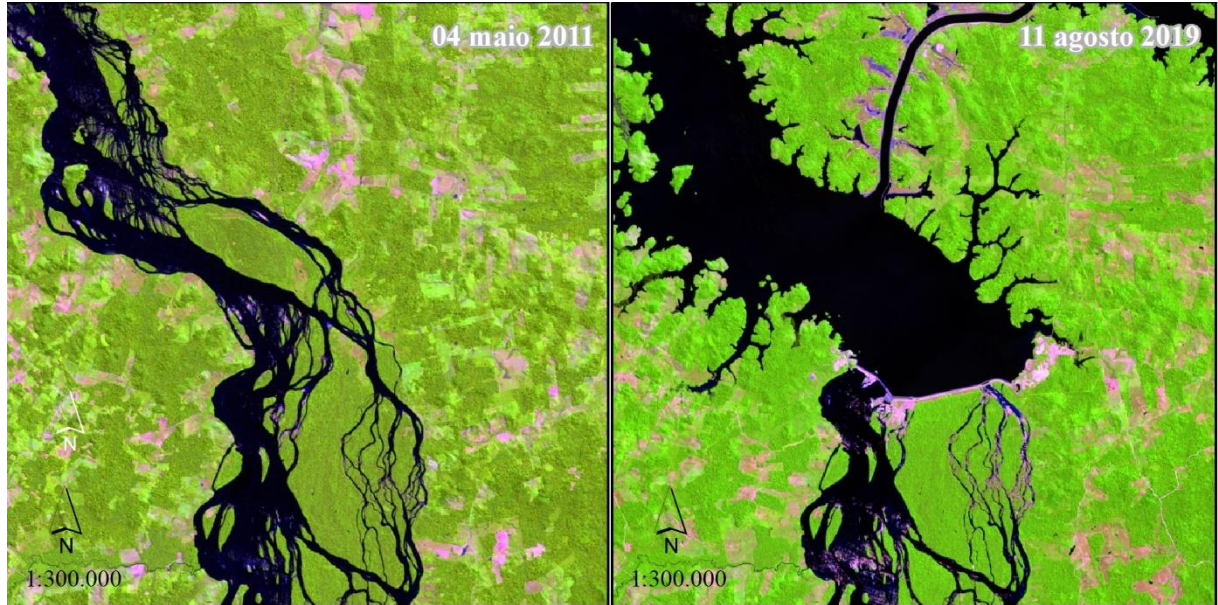



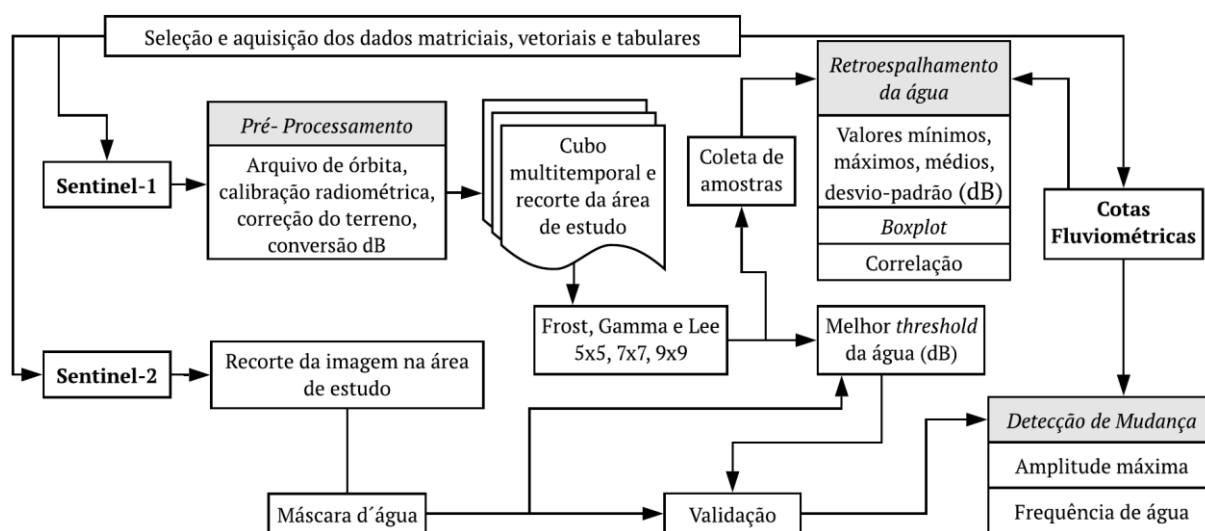
Figura 3. Situação do rio Xingu, na região de Volta Grande, antes e depois da construção da UHE de Belo Monte, mostrada pelas imagens dos satélites Landsat-5 e Landsat-8.



3. MATERIAIS E MÉTODOS

Esse estudo integrou dados de imagens multitemporais do satélite Sentinel-1, cotas fluviais e técnicas de processamento digital de imagens (PDI) para mapear a dinâmica espacial e temporal das inundações em áreas abertas da Volta Grande do Xingu. A **Figura 4** ilustra os principais passos metodológicos adotados.

Figura 4. Fluxograma dos principais passos metodológicos adotados no mapeamento da dinâmica do rio Xingu em áreas abertas por meio de análise de imagens multitemporais do satélite Sentinel-1.



3.1. IMAGENS DE SATÉLITE

As imagens utilizadas para mapear as áreas inundáveis foram provenientes do satélite Sentinel-1 que transporta um sensor de abertura sintética (SAR) desenvolvido pela Agência Espacial Europeia (ESA) e pela Comissão Europeia. O sensor opera na frequência de 5.405 GHz, isto é, na faixa espectral do micro-ondas, comprimento de onda de aproximadamente 5 cm (banda C) (ESA, 2013). Dados oriundos da banda C não são capazes de detectar água abaixo do dossel de densas florestas tropicais, pois o comprimento de onda não é suficientemente longo para permitir penetração nas copas de árvores altas e densas (O'LOUGHLIN et al., 2016; ETTRITCH et al., 2018; HARDY et al., 2019).

As imagens Sentinel-1 permitem a obtenção de informações da cobertura terrestre em áreas com alta incidência de nuvens e à noite, podendo ser usadas em situações de emergências como inundações, erupções vulcânicas, terremotos e deslizamentos de terra (ESA, 2015). Neste estudo, foram empregadas todas as imagens do satélite Sentinel-1A disponibilizadas entre 29 de setembro de 2016 e 31 de outubro de 2017, totalizando 34 imagens. O sensor passou a imagear periodicamente a região a cada 12 dias a partir de 29 de setembro de 2016.

As imagens da área de estudo foram obtidas no nível 1 de processamento (GRD, *Ground Range Detected*), modo de imageamento *Interferometric Wide* (IW), faixa de imageamento de 250 km, resolução espacial de 7,67 m x 9,97 m e ângulo de incidência variando de 29,1° a 46° (ESA, 2019). As imagens GRD são disponibilizadas com pré-processamento *multilook*, o que reduz o efeito do ruído *speckle* nas imagens.


O satélite Sentinel-1, no modo interferométrico de imageamento, disponibiliza imagens nas polarizações VH e VV. Neste sentido, Solbø & Solheim (2005) compararam diferentes polarizações na análise de um lago usando três imagens SAR do satélite Envisat e concluíram que as polarizações VH e HH apresentaram melhor desempenho para mapear massas d'água em áreas abertas do que a polarização VV. Manjusree et al. (2012), em seu estudo de mapeamento de corpos d'água de parte da sub-bacia do Kosi na Índia, compararam o comportamento da água em áreas abertas nas polarizações HH, HV, VH e VV, associando a técnica *thresholding* às imagens SAR do satélite Radarsat-2. O mapeamento na polarização HH apresentou o melhor desempenho, embora as polarizações HV e VH também mostraram-se adequadas para mapear inundações. A maior perda de informação dos corpos d'água ocorreu na polarização VV. Destarte, nesse trabalho foram adotadas as imagens na polarização VH.

A imagem ótica do sensor Sentinel-2 de 28 de julho de 2017 (órbita-ponto T22MCB) foi selecionada para identificar o melhor *threshold* da água e analisar a acurácia, sendo a única imagem do sensor sem incidência de nuvens na área de estudo durante o período analisado. O mapeamento da área coberta por água na Volta Grande do Xingu pela imagem Sentinel-2 foi elaborado a partir da interpretação visual da composição colorida das bandas 4, 3, 2 nos canais RGB, respectivamente, com resolução espacial de 10 m. O mapeamento resultante dessa imagem foi empregado como verdade terrestre. A imagem Sentinel-2 também foi empregada no mapeamento dos corpos d'água elaborado com as imagens Sentinel-1 de 26 de julho de 2016. As imagens Sentinel-1 e Sentinel-2 foram obtidas do sítio da ESA.

3.2. DADOS AUXILIARES

Dados de campo são fundamentais para a compreensão da dinâmica dos corpos d'água. Os dados fluviométricos da estação Altamira (código 18850000) foram obtidos em formato tabular na Agência Nacional de Águas (ANA) com o intuito de verificar as cotas mínimas e máximas mensais no período analisado e identificar as cotas do rio nas datas das imagens Sentinel. Esses dados foram usados na elaboração do mapa de amplitude fluviométrica, representando a maior e a menor vazão estimada pelo Sentinel-1. Os picos de inundação foram definidos pelas cotas mínima e máxima registradas durante a passagem do satélite. A **Figura 5** ilustra as cotas máximas mensais registradas pela estação entre 29 de setembro de 2016 e 31 de outubro de 2017. Cabe ressaltar que a Estação Altamira está localizada na área urbana de Almira, às margens do reservatório principal (**Figura 1**).

Figura 5. Cotas máximas mensais (cm) da Estação Altamira (out. 2016 a out. 2017).



Fonte: Estação Altamira-PA, Agência Nacional de Águas.

Também foram adquiridos os dados vetoriais da cota máxima maximorum e do Trecho de Vazão Reduzida disponibilizados pela Agência Nacional de Energia (ANEEL) e pela Norte Energia, respectivamente.

3.3. PRÉ-PROCESSAMENTO

O pré-processamento das imagens é essencial para correção dos erros e distorções nas imagens em decorrência de ruídos, interferências da atmosfera e distorções geométricas (MENESES et al., 2012; BIORESITA et al., 2018). A etapa de pré-processamento foi aplicada nas imagens Sentinel-1 (SAR) com o auxílio dos *softwares* de processamento digital de imagens: (a) Sentinel Application Platform (SNAP), disponibilizado pela ESA, e (b) Environment for Visualizing Images (ENVI). No SNAP, foi gerada uma rotina de pré-processamentos em cada imagem SAR, abrangendo quatro etapas: aplicação do arquivo de órbita, calibração radiométrica, correção do terreno e conversão dos valores lineares para coeficientes de retroespalhamento em decibéis ($\sigma^{\circ}\text{dB}$).

Os vetores contendo metadados da órbita do satélite de um produto SAR podem ser imprecisos. Esses dados podem ser refinados com a aplicação dos arquivos de órbita contendo informações sobre acurácia da posição, trajetória e velocidade do satélite (ESA, 2011). A calibração radiométrica das imagens de radar é fundamental em mapeamentos de uma série multitemporal de imagens do mesmo sensor ou de sensores diferentes. O conjunto de dados de calibração contendo dados de valores digitais, β° , γ° , *look up table* (LUT) são usados para uma calibração eficiente (ESA, 2019). Os dados de σ° foram adotados pela capacidade de discriminar melhor a água de outros alvos de uso e cobertura da terra (BIORESITA et al., 2018).

Os sensores de radar medem as distâncias dos alvos considerando-se o intervalo de tempo entre a emissão e a recepção do sinal. Ademais, os sensores de radar operam com visada lateral, implicando em presença de distorções geométricas dos alvos nas imagens (NAGASHREE e RAO, 2016). A distorção está diretamente relacionada com a topografia da região e o ângulo de incidência do sensor (OGRADI et al., 2014). Essas distorções implicam na deformação e no deslocamento dos alvos, reduzindo as formas dos objetos que estão mais próximos à antena (alcance próximo), provocando alterações nas medidas de distância e no posicionamento dos alvos (MENESES et al., 2012; CHAPMAN et al., 2015). Portanto, a correção do terreno visa amenizar as distorções geométricas (inversão de relevo e encurtamento de rampa) dos alvos.

A correção topográfica foi efetuada utilizando o modelo digital de elevação (MDE) do Shuttle Radar Topography Mission (SRTM) de 3 arc/seg disponibilizado pelo SNAP, no sistema de projeção Universal Transversa de Mercator (UTM), fuso UTM 22 Sul e datum WGS

1984. Posteriormente, os valores digitais das imagens de amplitude foram convertidos para σ^0 usando uma equação logarítmica de base 10 (TIAN et al., 2017). Um cubo temporal da área de estudo foi gerado contendo 34 imagens em ordem cronológica.

Alguns problemas são inerentes ao radar, dificultando a interpretação das imagens. Em um *pixel* podem existir muitos alvos dispersores que estão distribuídos aleatoriamente no terreno, que influenciam uns aos outros, fazendo aparecer variações súbitas na intensidade da imagem, conhecido como ruído *speckle* (MENESES, 2012). O *speckle* é um ruído que degrada a qualidade visual da imagem de textura granulada com aparência de “sal e pimenta”, causando perda da informação (CHOI et al., 2019). É possível reduzir esse ruído por meio do processamento *multilook* e por meio de processos de filtragens espaciais. Os filtros usualmente descritos e aplicados na literatura são os adaptativos, pois eles visam preservar a textura e a borda enquanto reduzem o ruído. Dentre eles, cabe destacar os filtros Frost, Gamma e Lee, que realizam a filtragem bidimensional por convolução espacial (x, y). Esse processamento realiza o cálculo da intensidade de um *pixel* em detrimento da intensidade dos *pixels* adjacentes. Destarte, foram processados os filtros adaptativos Frost, Gamma e Lee, com janelas de 5x5, 7x7 e 9x9 no cubo temporal de 34 imagens Sentinel-1, na polarização VH, no software ENVI.

3.4. CLASSIFICAÇÃO

As classificações de imagens de radar possuem algumas características peculiares. A energia refletida retroespalhada que retorna ao sensor é mensurada através do coeficiente de retroespalhamento (σ^0). A rugosidade (SHEN et al. 2019), a constante dielétrica e a geometria dos alvos da superfície terrestre influenciam no sinal de retorno do retroespalhamento (*backscattering*) (FORD, 1998; LEWIS & HENDERSON 1998; PONZONI et al., 2012). Devido à alta constante dielétrica, à superfície lisa e homogênea, os corpos d'água apresentam reflexão especular, com baixo sinal de retorno após a absorção (BIORESITA et al., 2018), sendo representada por áreas pretas ou muito escuras (SOLBØ & SOLHEIM, 2005; TIAN et al., 2017). Em contrapartida, os corpos d'água com vegetação oferecem uma característica oposta, em que os valores de retroespalhamento são elevados e caracterizados por *pixels* mais claros, devido à presença de rugosidade oriunda da vegetação (HARDY et al., 2019). Em áreas não-florestadas, os corpos d'água possuem baixo retroespalhamento e podem ser detectados com a técnica de *thresholding* (eg. HONG et al., 2015; eg. HARDY et al. 2019).

As superfícies lisas e homogêneas do asfalto e solo exposto possuem uma reflexão especular, que podem não diferir muito dos coeficientes de retroespalhamento dos corpos d'água (SOLBØ & SOLHEIM, 2005; TIAN et al., 2017, SHEN et al., 2019). Sombras de relevo também apresentam baixos valores de retroespalhamento, semelhante à água. Essas peculiaridades podem ocasionar confusões na classificação desses alvos, gerando “falsos positivos”.

Além das Terras Indígenas Paquiçamba e Arara da Volta Grande do Xingu, circunjacente ao rio Xingu na Volta Grande, é encontrada a área urbana de Altamira, a rodovia Transamazônica e os projetos de assentamentos. Em decorrência disso, podem ocorrer erros de comissão no mapeamento da dinâmica do rio Xingu ao classificar alvos de áreas urbanas e agropastoris como água. Devido ao objeto de estudo ser a calha principal do rio Xingu na Volta Grande e visando minimizar esses erros, foi elaborada uma máscara da cota máxima maximorum do reservatório, do Trecho de Vazão Reduzida e um raio de 500m dessas áreas. Os polígonos de água elaborados com as imagens Sentinel-1 e que se encontravam fora dessa máscara foram desconsiderados do mapeamento.

O comportamento da água nas imagens Sentinel-1 com os filtros Frost, Gamma e Lee – nas janelas de tamanho 5x5, 7x7 e 9x9 – foi comparado por intermédio da análise dos valores de retroespalhamento de amostras de água. Além disso, visando a obtenção de uma melhor acurácia no mapeamento da dinâmica dos corpos d'água da Volta Grande do Xingu, foi avaliado o desempenho dos filtros Frost, Gamma e Lee, com janelas de 5x5, 7x7 e 9x9 para classificar a água em áreas abertas nas imagens Sentinel-1 através da análise de acurácia.

3.4.1. Retroespalhamento das amostras de água

A dispersão dos valores de retroespalhamento dos corpos d'água do Xingu foram comparados nas imagens Sentinel-1 com os filtros Frost, Gamma e Lee, nas janelas de 5x5, 7x7 e 9x9. Essa análise foi realizada mediante a seleção de 50 regiões de interesse (ROIs) de água na área de estudo. Cada ROI foi constituído por 145 *pixels*, totalizando 7.250 *pixels*. A imagem Sentinel-2 de 28 de julho de 2017 auxiliou na coleta. Foram certificados que todos os *pixels* amostrais representassem alvos de corpos d'água abertos em todas as datas das imagens Sentinel-1. Para isso, a imagem Sentinel-1 na data com a menor cota do rio durante o período analisado foi usada na coleta de amostras.

As amostras de água foram usadas na comparação dos valores mínimos, máximos, médios e de desvios-padrões nos filtros e janelas supracitados, nas 34 imagens multitemporais. Posteriormente, foram empregadas na análise da distribuição dos valores de retroespalhamento da água nos diferentes filtros e janelas usando as imagens Sentinel-1 dos dias 29 de setembro de 2016 (T1), 10 de dezembro de 2016 (T7), 04 de março de 2017 (T14), 20 de junho de 2017 (T23), 26 de julho de 2017 (B26) e 24/09/2017 (T31), por meio de gráfico *boxplot*. As imagens dessas datas também foram adotadas para avaliar a correlação dos valores de retroespalhamento das amostras de água com os diferentes filtros. Foram contempladas imagens trimestrais, abarcando as datas com menor e maior vazão medida pela estação Altamira durante o período em análise, além de datas com cotas intermediárias. A imagem do dia 26 de julho de 2017 foi selecionada devido a essa data ser a mais próxima da imagem óptica Sentinel-2.

Em estatística descritiva, o *boxplot* é uma ferramenta usada para avaliar a distribuição dos dados observados de uma variável numérica por meio de quartis. O gráfico representa cinco medidas de distribuição dos valores: o limite inferior, o primeiro quartil (Q1), a mediana (Q2), o terceiro quartil (Q3) e o limite superior. O primeiro, segundo e terceiro quartil representam os percentis 25, 50 e 75, respectivamente. Sendo assim, o segundo quartil representa a mediana. Por conseguinte, pelo menos 50% dos *pixels* de água possuem valores acima dele e 50% abaixo.

A parte central do *boxplot* representa os valores centrais do gráfico, o terceiro quartil e o primeiro quartil. Metade das amostras possuem os valores de retroespalhamento nesse intervalo. O intervalo interquartil é uma medida robusta de dispersão por não sofrer influência dos *outliers*. Valores fora desse limite estão mais distantes da mediana e são denominados *outliers*. Dessa forma, os *outliers* demonstram os valores de retroespalhamento discrepantes do limite superior e inferior. Os limites inferior e superior foram calculados através das seguintes equações:

$$\text{Limite Inferior} = Q1 - 1,5 (Q3 - Q1)$$

$$\text{Limite Superior} = Q3 + 1,5 (Q3 - Q1)$$

O grau e a direção da correlação dos retroespalhamentos das amostras de água entre as imagens com os diferentes filtros foram avaliados pelo coeficiente de correlação de Pearson. Essa correlação é uma medida adimensional que mensura o grau de correlação linear entre duas variáveis, variando de -1 a 1. Quanto mais próximo desses valores mais forte é a correlação, negativa e positiva, respectivamente. Uma correlação positiva ($r > 0$) indica o aumento do valor

da variável y , conforme aumenta o valor da variável x . Uma correlação negativa ($r < 0$) indica que os valores de uma variável aumentam à medida que os valores da outra variável diminuem. Quanto mais próximo de zero, menos uma variável depende linearmente da outra, demonstrando correlação fraca ou ausência de correlação.

3.4.2. Melhor *threshold*

O valor de retroespalhamento pode variar de acordo com a composição química do alvo, o ângulo de incidência do imageamento, o comprimento de onda e a polarização (MANJUSREE et al., 2012). Dessa forma, encontrar um ótimo *threshold* para mapear a água pode demandar bastante tempo (HONG et al., 2015). Vários estudos foram elaborados visando identificar o melhor *threshold* da água. Colditz et al. (2018) avaliaram o melhor *threshold* para mapear corpos d'água abertos a partir dos dados de omissão e comissão.

No presente trabalho, a identificação do melhor *threshold* para classificar a água utilizou um método automático presente no *software* Abilius (CARVALHO JÚNIOR et al., 2011), permitindo maior acurácia na análise estatística e otimização do tempo. Esse método calcula o coeficiente *Kappa* entre o mapa verdade e os resultados do emprego de 100 sucessivos limiares (*threshold*) espaçados em intervalos regulares de tempo e estabelece como o melhor *threshold* o que alcançou o maior valor de coeficiente *Kappa*. O método foi aplicado nas imagens Sentinel-1 com os filtros Frost, Gamma e Lee com janelas de tamanho 5x5, 7x7 e 9x9.

O índice *Kappa* é um método estatístico que mensura o grau de concordância entre dois conjuntos de dados e é largamente empregado em análises de acurácia de classificações dos corpos d'água a partir de imagens de sensores remotos (HUANG et al., 2014; MONTGOMERY et al., 2019). Para Landis e Koch (1977), os valores do índice *Kappa* < 0 demonstram que não há concordância entre os dados; de 0 a 0,2 fraca concordância; de 0,21 a 0,4 razoável concordância; de 0,41 a 0,6 moderada concordância; de 0,61 a 0,8 forte concordância; e de 0,81 a 1 quase perfeita.

O mapeamento dos corpos d'água elaborado com a imagem Sentinel-2 de 28 de julho de 2017 (cota 668 cm) por meio de interpretação visual foi utilizado como verdade terrestre. A imagem Sentinel-1 do dia 26 de julho de 2017 (cota 672 cm) foi selecionada por ser a data e a cota mais próxima da imagem Sentinel-2 durante o período avaliado. Com esse intuito, foi

então delimitado um recorte abrangendo a área de sobreposição entre as imagens Sentinel-1 e Sentinel-2.

3.4.3. Validação

A combinação da análise estatística dos índices *Kappa* e acurácia de exatidão global foram empregados para avaliar a acurácia do mapeamento da água usando as imagens Sentinel-1 com os diferentes filtros e janelas. Além disso, também foi usada para discriminar o filtro e janela com o melhor desempenho no mapeamento dos corpos d'água usando a imagem Sentinel-1. Ambas as análises foram realizadas no *software* ENVI.

A análise de acurácia de exatidão global foi mensurada por meio da razão entre os *pixels* classificados corretamente e o número total de *pixels* da classe, variando de 0 a 100%. Também foi aferida a acurácia do produtor e do usuário, que demonstram o grau de sensibilidade e confiabilidade do mapeamento. A sensibilidade está relacionada com os erros de omissão e a confiabilidade com os erros de comissão. Quanto menor for a taxa de omissão e comissão, maior será a acurácia do produtor e do usuário. Os erros de omissão representam a porcentagem de *pixels* que deveriam ter sido classificados como inundados, mas não foram classificados. A comissão representa os *pixels* que não estavam inundados, mas foram classificados como *pixels* com água. O melhor *threshold* foi aplicado nas imagens do filtro e *kernel* com o melhor desempenho nas 34 imagens multitemporais Sentinel-1.

3.5. AMPLITUDE MÁXIMA FLUVIAL


A dinâmica dos corpos d'água superficiais da Volta Grande do Xingu entre 29 de setembro de 2016 a 31 de outubro de 2017 foi mapeada a partir da aplicação do melhor valor de *threshold* nas 34 imagens com o filtro e janela com o melhor desempenho. No mapeamento da amplitude máxima do Volta Grande do Xingu, foram usados, como insumos, as cotas mínima e máxima da vazão do rio. Ademais, foi calculada a porcentagem da ocorrência de água no *pixel* durante o período analisado (eg. HUANG et al., 2014; eg. MOHAMMADI et al., 2017) a partir das máscaras de água nas 34 imagens Sentinel-1. Esse dado fornece informações sobre o comportamento sazonal dos corpos d'água da Volta Grande do Xingu.

4. RESULTADOS

4.1. COTAS FLUVIOMÉTRICAS

A cota máxima registrada pela estação fluviométrica, entre 29 de setembro de 2016 e 31 de outubro de 2017, foi de 851 cm no dia 10 de março de 2017, e a mínima foi de 449 cm no dia 01 de outubro de 2016. Não houve passagem do satélite Sentinel-1 sobre a área de estudo nessas datas. Em decorrência disso, os registros das cotas foram filtrados, sendo selecionadas apenas as cotas referentes às datas de passagem do satélite Sentinel-1 (**Figura 6**).

Figura 6. Cotas fluviométricas registrada pela Estação Altamira nas datas de passagem do satélite Sentinel-1 na área de estudo. Os dados em preto representam as cotas das imagens.



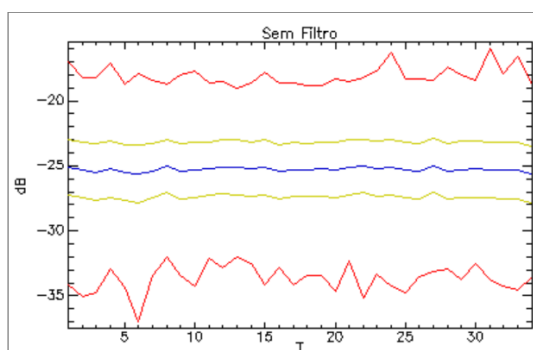
A maior cota registrada nas datas das imagens Sentinel-1 durante o período de análise foi no dia 04 de março de 2017 (848 cm) e a menor no dia 29/09/2016 (449 cm).

4.2. RETROESPALHAMENTO DAS AMOSTRAS DE ÁGUA

Os valores de retroespalhamento dos 7.250 *pixels* de treinamento de água foram avaliados e comparados nas imagens das 34 datas. Os sinais das amostras nas imagens sem filtro variaram de -16,02 dB (24/09/2017 - T31) a -37,01 dB (28/11/2016 - T6) (**Figura 7**).

Ambas as datas eram do período com baixa precipitação. A maior amplitude registrada foi no dia 28 de novembro de 2016 (T6), com valores de *pixels* de água variando entre -37,01 dB e -17,86 dB. A menor foi no dia 20 de fevereiro de 2017 (T13), com valores entre -32,01 dB e -18,97 dB. O maior desvio-padrão foi registrado na imagem do dia 28 de novembro de 2016 (T6), enquanto o menor, na imagem do dia 22 de dezembro de 2016 (T8). Os valores médios das amostras das diferentes datas variaram de -25,65 dB (28/11/2016 - T6) a -24,99 dB (07/08/2017 - T27).

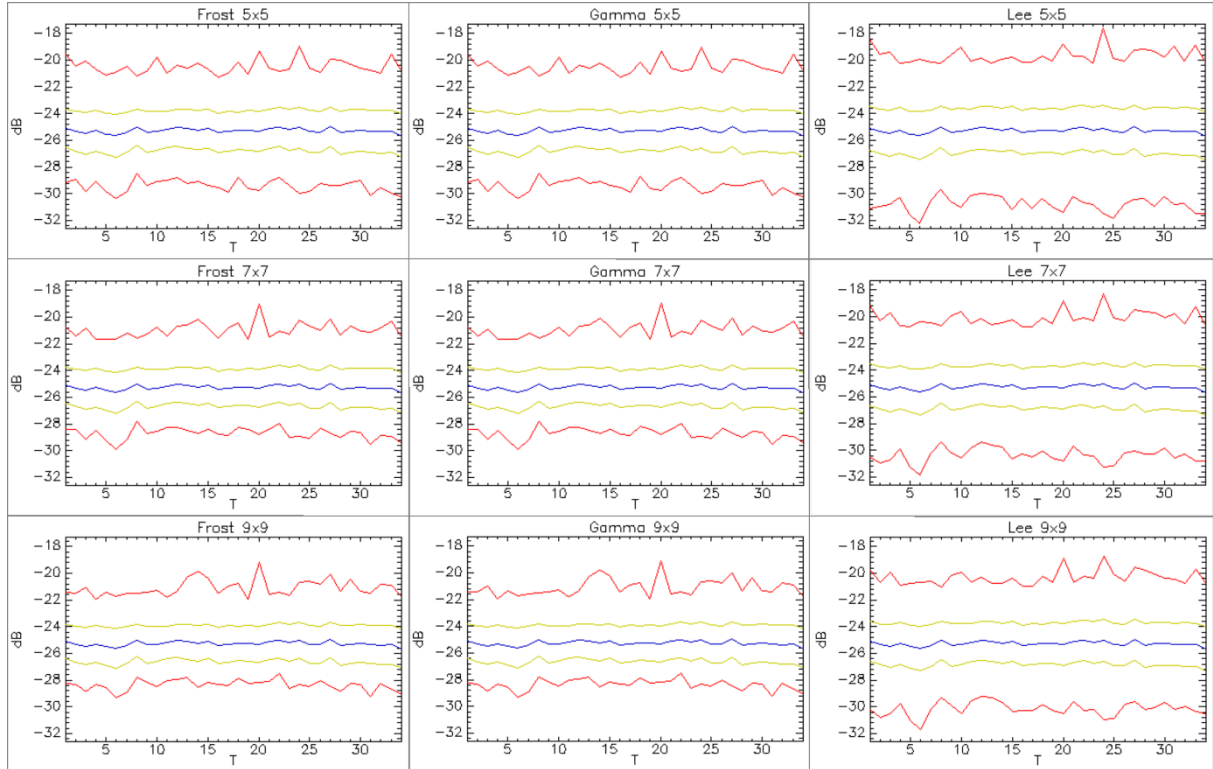
Figura 7. Valores de retroespalhamento das amostras de água nas 34 imagens Sentinel-1 sem filtro. Mínimos e máximos em vermelho, média em azul, desvio padrão em amarelo.



A suavização dos coeficientes de retroespalhamentos mínimos e máximos foi mais intensa conforme o aumento da dimensão da janela de filtragem (**Figura 8**). Os menores e os maiores valores de retroespalhamento das amostras de água foram observados na janela 5x5 de cada um dos filtros, demonstrando menor efeito de suavização em relação as janelas de tamanho 7x7 e 9x9. Destarte, quanto maior o tamanho da janela, menor é a amplitude total, variabilidade e desvio-padrão dos dados (RASHEED & HUSSEIN, 2017).

Os gráficos da **Figura 8** e os valores de retroespalhamento da **Tabela 1** demonstram grande semelhança dos valores mínimos, médios, máximos e de desvio-padrão existentes entre as amostras de água nas imagens com o filtro Frost e Gamma. Em todas as datas, verificou-se maior suavização dos picos de retroespalhamento das amostras de água nas imagens com os filtros Frost e Gamma e maior amplitude total e de desvio-padrão do retroespalhamento nas imagens com o filtro Lee.

Figura 8. Valores de retroespalhamento (dB) mínimo, máximo, médio e desvio-padrão das amostras de água nas 34 datas (T) do Sentinel-1, com os filtros Frost, Gamma e Lee, nas janelas 5x5, 7x7 e 9x9. Mínimos e máximos em vermelho, média em azul, desvio-padrão em amarelo.



Os menores valores dos coeficientes de σ° (dB) das amostras de água, em ordem, foram nos filtros Lee 5x5 (-32,25 dB), Frost 5x5 (-30,38 dB), Gamma 5x5 (-30,37 dB), ambos aferidos na imagem do dia 28 de novembro de 2016 (T6). Nessa data, a estação fluviométrica registrou 657 cm. Em ordem decrescente, os valores de σ° máximo encontrado foi no filtro Lee 5x5 (-17,65 dB), Frost 5x5 (-18,95 dB), Gamma 5x5 (-19,00 dB), ambos da imagem do dia 02 de julho de 2017 (T24). O menor desvio-padrão dos filtros Frost, Gamma e Lee nas janelas de tamanho 5x5, 7x7 e 9x9 foi no dia 27 de janeiro de 2017 (T11). Os maiores desvios-padrões das imagens com os filtros Frost e Gamma nas três janelas de filtragem foi no dia 19 de agosto de 2017 (T28). Já o filtro Lee registrou os maiores desvios-padrões no filtro Lee no dia 28 de novembro de 2016 (T6), nos três tamanhos de janela.

Tabela 1. Data dos menores e maiores valores de σ° (dB) mínimos, máximos, médios, desvio-padrão e amplitude total das amostras de água nas 34 datas, nos filtros Frost, Gamma e Lee nas janelas 5x5, 7x7 e e 9x9. Em vermelho são os menores valores e em azul os maiores.

FROST						GAMMA						LEE					
Datas	Min	Max	Média	Desvio-padrão	Amp. Total	Datas	Min	Max	Média	Desvio-padrão	Amp. Total	Datas	Min	Max	Média	Desvio-padrão	Amp. Total
5x5																	
28/11/2016	-30,377	-20,900	-25,637	1,618	9,477	28/11/2016	-30,374	-20,903	-25,637	1,618	9,471	28/11/2016	-32,246	-19,924	-25,642	1,791	12,322
22/12/2016	-28,480	-21,213	-25,016	1,361	7,266	22/12/2016	-28,478	-21,214	-25,016	1,360	7,264	22/12/2016	-29,652	-20,247	-25,014	1,542	9,406
27/01/2017	-28,999	-21,010	-25,197	1,355	7,989	27/01/2017	-28,997	-21,013	-25,197	1,355	7,984	20/02/2017	-30,050	-20,251	-25,115	1,657	9,798
28/03/2017	-29,562	-21,279	-25,418	1,455	8,283	28/03/2017	-29,561	-21,281	-25,418	1,455	8,281	02/07/2017	-31,506	-17,646	-25,067	1,708	13,860
02/07/2017	-29,964	-18,951	-25,058	1,536	11,013	02/07/2017	-29,963	-19,000	-25,058	1,536	10,962	07/08/2017	-30,415	-19,227	-24,990	1,642	11,188
07/08/2017	-29,389	-19,909	-24,986	1,462	9,480	07/08/2017	-29,387	-19,951	-24,986	1,462	9,436						
19/08/2017	-29,398	-20,027	-25,422	1,622	9,371	19/08/2017	-29,398	-20,032	-25,422	1,621	9,365						
7x7																	
28/11/2016	-29,913	-21,670	-25,636	1,530	8,243	28/11/2016	-29,912	-21,669	-25,636	1,530	8,244	28/11/2016	-31,827	-20,413	-25,641	1,710	11,413
22/12/2016	-27,789	-21,616	-25,018	1,266	6,172	22/12/2016	-27,788	-21,595	-25,018	1,266	6,194	22/12/2016	-29,369	-20,719	-25,015	1,457	8,649
27/01/2017	-28,275	-21,455	-25,182	1,246	6,821	27/01/2017	-28,273	-21,453	-25,182	1,246	6,820	27/01/2017	-29,829	-20,545	-25,198	1,455	9,284
15/05/2017	-28,788	-19,023	-25,317	1,404	9,765	15/05/2017	-28,787	-18,965	-25,317	1,404	9,822	28/03/2017	-30,294	-20,793	-25,416	1,548	9,501
07/08/2017	-28,703	-20,139	-24,981	1,366	8,564	07/08/2017	-28,703	-20,115	-24,981	1,366	8,589	02/07/2017	-31,283	-18,322	-25,061	1,618	12,961
19/08/2017	-28,995	-21,325	-25,422	1,548	7,670	19/08/2017	-28,994	-21,329	-25,422	1,548	7,666	07/08/2017	-30,035	-19,449	-24,988	1,554	10,586
9x9																	
28/11/2016	-29,272	-21,748	-25,635	1,484	7,524	28/11/2016	-29,270	-21,746	-25,635	1,484	7,525	28/11/2016	-31,699	-20,678	-25,641	1,668	11,021
22/12/2016	-27,773	-21,529	-25,020	1,224	6,245	27/01/2017	-28,014	-21,805	-25,166	1,194	6,210	22/12/2016	-29,293	-21,033	-25,016	1,414	8,260
27/01/2017	-28,015	-21,804	-25,166	1,194	6,211	03/05/2017	-28,229	-21,978	-25,232	1,338	6,251	27/01/2017	-29,489	-20,695	-25,189	1,406	8,794
03/05/2017	-28,229	-21,977	-25,232	1,338	6,252	15/05/2017	-28,143	-19,142	-25,299	1,348	9,001	08/02/2017	-29,254	-20,281	-25,060	1,445	8,973
15/05/2017	-28,147	-19,169	-25,299	1,348	8,978	08/06/2017	-27,503	-21,402	-25,006	1,346	6,101	02/07/2017	-30,927	-18,706	-25,057	1,566	12,221
08/06/2017	-27,503	-21,402	-25,007	1,346	6,102	07/08/2017	-28,484	-19,980	-24,978	1,320	8,504	07/08/2017	-29,636	-19,559	-24,986	1,509	10,078
07/08/2017	-28,482	-20,048	-24,979	1,320	8,435	19/08/2017	-28,864	-21,380	-25,421	1,515	7,485						
19/08/2017	-28,862	-21,386	-25,421	1,514	7,476												
SEM FILTRO																	
	Datas	Min	Max	Média	Desvio-padrão	Amp. Total											
	28/11/2016	-37,012	-17,861	-25,648	2,217	19,151											
	22/12/2016	-32,009	-18,753	-25,011	1,991	13,255											
	20/02/2017	-32,011	-18,974	-25,107	2,112	13,036											
	07/08/2017	-33,139	-18,436	-24,995	2,080	14,703											
	24/09/2017	-33,706	-16,015	-25,327	2,127	17,690											

As menores amplitudes foram constatadas no dia 22 de dezembro de 2016 (T8) em todos os filtros e janelas, com exceção do filtro Gamma 9x9 que apresentou a menor amplitude em 08 de junho de 2017 (T22). A menor amplitude dos sinais de retroespalhamento das amostras de água foi na imagem com o filtro Gamma 9x9, seguida da imagem com o filtro Frost 9x9. Os valores de σ° mínimo e máximo das amostras de água nos filtros Frost e Gamma foram semelhantes em todas as janelas, demonstrando dispersão de amplitude total semelhante.

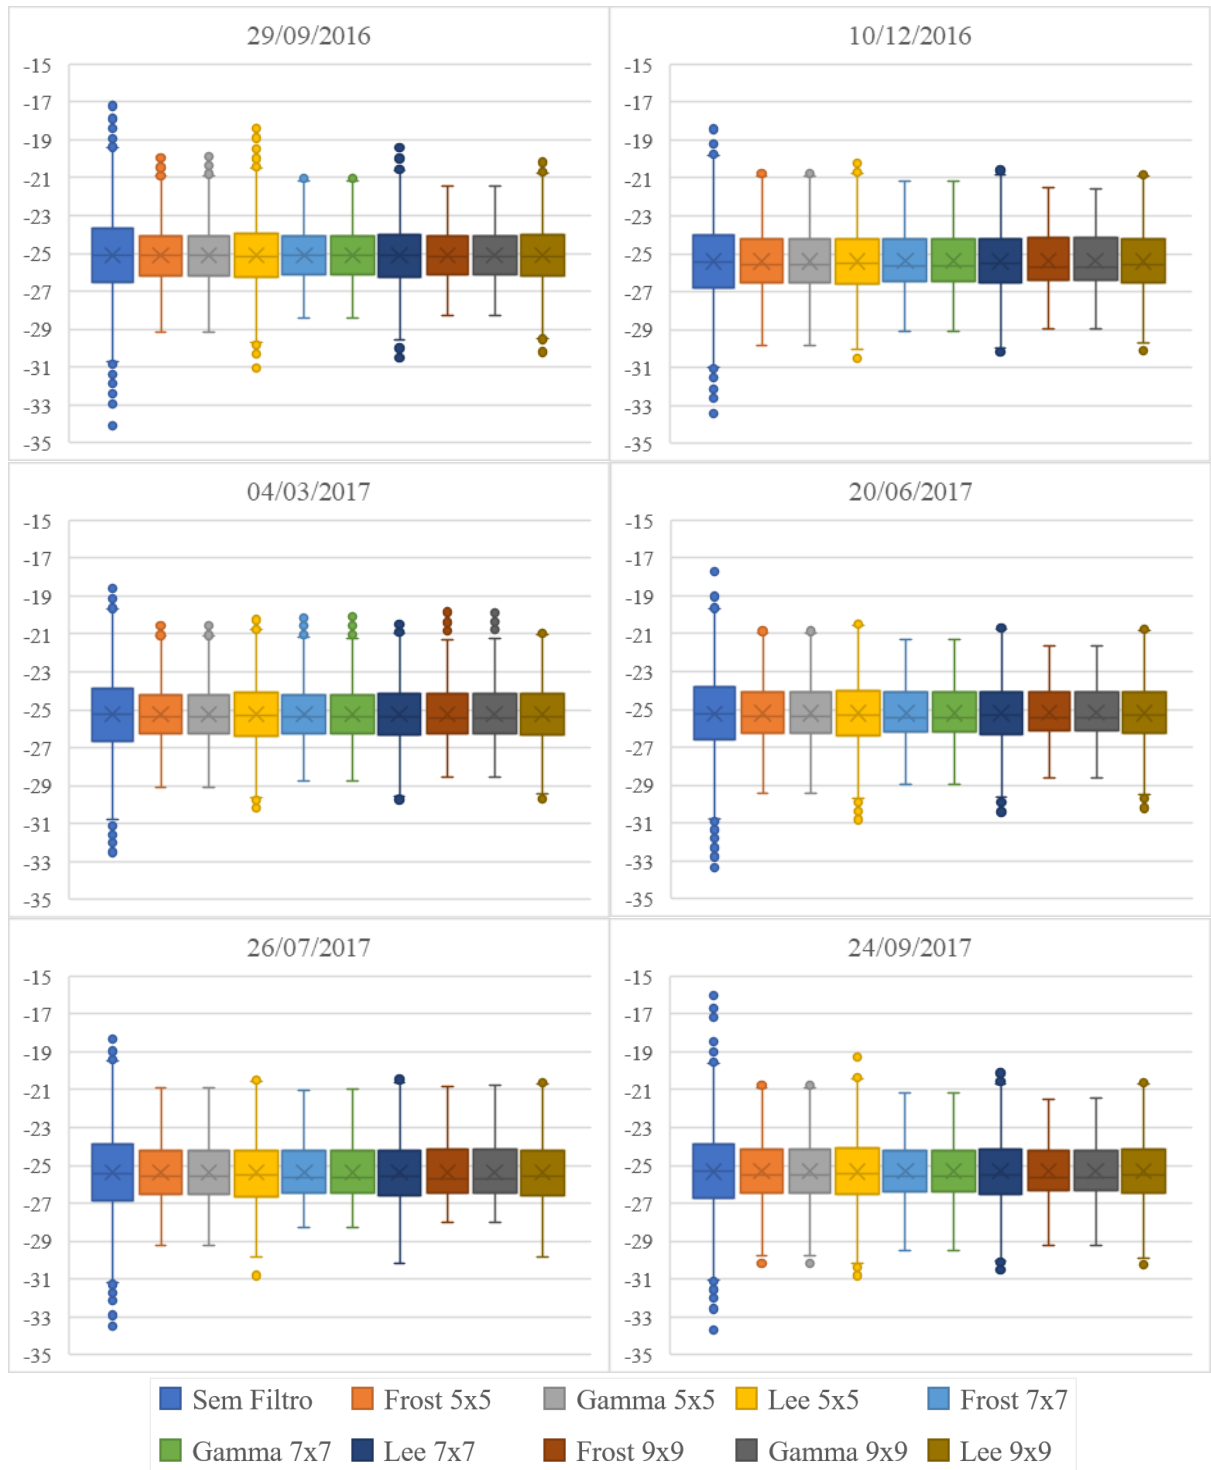
Entre os filtros, o Lee apresentou a maior amplitude total nos valores de retroespalhamento das amostras de água em todos os tamanhos de janela, sendo a maior no dia 02 de julho de 2017 (T24). As maiores variações foram na janela 5x5 (13,86 dB), seguida da 7x7 (12,96 dB) e por último a 9x9 (12,22 dB). As menores foram constatadas no dia 22 de dezembro de 2016 (T8), variando 9,41 dB na janela 5x5, 8,65 dB na janela 7x7 e 8,26 dB na janela 9x9. Nessa data, foram registrados os maiores valores de retroespalhamento das amostras nas imagens Lee nos tamanhos de janela 5x5 e 7x7. As imagens com esse filtro também obtiveram os maiores valores de desvio-padrão. Isso mostra a ocorrência de picos oriundos do ruído *speckle* nas imagens com o filtro Lee 5x5 e, conseqüentemente, menor suavização dos picos de sinal das imagens quando comparados as imagens dos outros filtros.

A partir do *boxplot*, foi possível verificar a distribuição dos valores de retroespalhamento das amostras de água em cada filtro e janela, em seis datas: 29 de setembro de 2016 (T1), 10 de dezembro de 2016 (T7), 04 de março de 2017 (T14), 20 de junho de 2017 (T23), 26 de julho de 2017 (T26) e 24 de setembro de 2017 (T31). As imagens sem filtro mostraram uma tendência de valores de retroespalhamento com maiores amplitudes de picos de sinal nessas datas, como era esperado, em decorrência dos ruídos *speckle*. Também exibiu maior intervalo interquartil em todas as datas. Os picos de amplitude de sinal das imagens sem filtro foram suavizados por todos os filtros.

A mesma tendência do aumento da suavização dos picos de sinal conforme aumenta a janela também foi constatada a partir do *boxplot*. Em todos os filtros, os valores de limites mínimos de retroespalhamento das amostras de água aumentam conforme é aumentado o tamanho da janela de filtragem. Já os valores máximos diminuem conforme aumenta o tamanho da janela de filtragem. Dessa forma, quanto maior o tamanho da janela de filtragem, mais os picos de sinal das amostras de água são suavizados, apresentando menor amplitude dos valores mínimos e máximos de retroespalhamento e de intervalo interquartil. Quanto menor a janela,

maior é a variabilidade de dados. O *boxplot* mais achatado nas imagens com janela de filtragem 9x9 indica uma baixa variabilidade e baixo desvio-padrão (**Figura 9**).

Figura 9. Diagramas de caixa comparando a distribuição dos valores de σ° (dB) das amostras de água com filtros Frost, Gamma e Lee (5x5, 7x7 e 9x9) aplicados nas imagens Sentinel-1 de 29 set. 2016, 10 dez. 2016, 04 mar. 2017, 20 jun. 2017, 26 jul. 2017 e 24 set. 2017.



Nas seis datas supracitadas, os valores de retroespalhamento das amostras de água e a dispersão desses nas imagens com os filtros Frost e Gamma foram praticamente iguais, quando comparadas com as imagens com janelas de filtragem de mesmo tamanho. A divergência entre a distribuição dos valores de amostras de água desses dois filtros foi na casa dos milésimos ou dos décimos de milésimos (dB). As imagens com o filtro Lee registraram os maiores picos de valores mínimos e máximos de retroespalhamento em relação ao Frost e Gamma, quando comparadas com as janelas de filtragem de mesmo tamanho.

Os valores de retroespalhamento das medianas foram semelhantes em todos os filtros e também entre as imagens sem filtro, variando de -25,72 dB na imagem com o filtro Gamma 9x9 de 10 de dezembro de 2016 a -25,12 dB na imagem com o filtro Frost 5x5 de 29 de setembro de 2016. As maiores variações da mediana entre as imagens com os diferentes filtros e janelas foi de 0,22 dB no dia 10 de dezembro de 2016, entre o filtro Lee 5x5 (-25,50 dB) e Gamma 9x9 (-25,72 dB). A menor variação entre os valores das medianas foi no dia 29 de setembro de 2016, com variação de apenas 0,02 dB nos diferentes filtros e tamanhos de janela de filtragem. Na imagem dessa data, a mediana nas imagens com os filtros Frost e Gamma, nas janelas de tamanho 5x5 foram praticamente iguais, diferenciando apenas na casa dos milésimos.

Em todas as datas, houve mais *outliers* nas imagens sem filtro. Entre os filtros, em todas as datas das imagens, no filtro Lee havia mais *outliers* do que os filtros Frost e Gamma. As imagens com o filtro Lee apresentaram *outliers* dos limites superior e inferior em todas as datas e janelas, com exceção do dia 26 de julho de 2017 que não houve *outlier* de limite inferior nas janelas 7x7 e 9x9. Diferentemente das outras cinco datas, as imagens de 04 de março de 2017 obtiveram *outliers* em todas as imagens filtradas. Essa data corresponde a imagem da maior cota registrada pelo sensor (848 cm), estando apenas 3 cm abaixo da maior cota durante o período de análise (851 cm).

As imagens do dia 26 de julho de 2017 com os filtros Frost e Gamma não demonstraram *outliers*. Em todas as outras datas, esses filtros registraram *outliers* de limites superiores apenas na janela de tamanho 5x5. Além da imagem do dia 04 de março de 2017, que obteve *outliers* nas imagens de todos os filtros e tamanhos de janela, a outra exceção foi a imagem de 29 de setembro de 2016. Nessa data, que representa a imagem com a menor cota do rio (449 cm), foi constatado *outliers* também nas imagens com o filtro Frost e Gamma nas janelas 7x7. A imagem do dia 24 de setembro de 2017 foi a única imagem em que os filtros Frost e Gamma, além de apresentar *outliers* de limite superior, também registrou *outliers* de limite inferior na janela 5x5.

Através do intervalo interquartil, foi possível verificar que metade das amostras de água possuíam valores de retroespalhamento entre -24 dB e -26,5 dB em todas as datas, filtros e tamanhos de janelas. Em todas as imagens, o intervalo interquartil nas imagens com o filtro Lee foi maior do que nas imagens com o Frost e Gamma. As menores amplitudes dos intervalos de interquartil foi na imagem de 04 de março de 2017, data da imagem mais cheia. As maiores foram nas imagens do dia 27 de julho de 2017. Nessa data, foi registrada a cota de 673 cm.

As maiores amplitudes entre os valores de *threshold* dos limites superiores e inferiores foram registradas nas imagens sem filtro e com o filtro Lee 5x5 do dia 29 de setembro de 2016 e 24 de setembro de 2017, data das menores cotas anuais registradas durante o período de análise. A menor amplitude entre os valores de limites superior e inferior nas imagens sem filtro e com o filtro Lee foi no dia 04 de março de 2017. Essa data corresponde a imagem registrada pelo satélite Sentinel-1 com a maior cota durante o período em análise. A menor amplitude registrada nas imagens com o filtro Lee foi na janela 9x9. Dessa forma, pode-se concluir que quanto maior for a cota do rio, menor será a amplitude entre os valores mínimos e máximos nas imagens sem filtro e com o filtro Lee. Isso pode ser em decorrência das amostras de água nas imagens com menor vazão estarem mais rasas. Os valores de retroespalhamento das lâminas d'água nas imagens com a menor cota pode ter sido influenciada pelos bancos de areia, pedrais e vegetação inundada, provocando um aumento da rugosidade dos alvos de água e dos valores de retroespalhamento. Os maiores e menores valores de amplitude de limites superior e inferior registrados nas imagens com os filtros Frost e Gamma foram registrados no dia 29 de setembro de 2016, nas janelas 5x5 e 9x9, respectivamente.

A correlação de Pearson existente entre os valores de retroespalhamento das amostras de água nas imagens filtradas e dessas com as imagens sem filtro foram positivas nas seis datas distintas (**Tabelas 2 a 7**). A correlação entre as imagens filtradas e sem filtro diminuiu ligeiramente com o aumento no tamanho da janela de filtragem em todos os filtros e datas.

Tabela 2. Correlação dos filtros na imagem de 29 de setembro de 2016.

	<i>Sem Filtro</i>	<i>Frost 5x5</i>	<i>Gamma 5x5</i>	<i>Lee 5x5</i>	<i>Frost 7x7</i>	<i>Gamma 7x7</i>	<i>Lee 7x7</i>	<i>Frost 9x9</i>	<i>Gamma 9x9</i>	<i>Lee 9x9</i>
<i>Sem filtro</i>	1	-	-	-	-	-	-	-	-	-
<i>Frost 5x5</i>	0,778125	1	-	-	-	-	-	-	-	-
<i>Gamma 5x5</i>	0,777449	0,999999	1	-	-	-	-	-	-	-
<i>Lee 5x5</i>	0,952234	0,932753	0,932363	1	-	-	-	-	-	-
<i>Frost 7x7</i>	0,687133	0,965180	0,965375	0,863580	1	-	-	-	-	-
<i>Gamma 7x7</i>	0,685989	0,964670	0,964867	0,862674	0,999997	1	-	-	-	-
<i>Lee 7x7</i>	0,938644	0,934707	0,934384	0,993144	0,895524	0,894820	1	-	-	-
<i>Frost 9x9</i>	0,631202	0,912061	0,912309	0,805631	0,979722	0,979968	0,851632	1	-	-
<i>Gamma 9x9</i>	0,629751	0,910950	0,911201	0,804256	0,979205	0,979459	0,850495	0,999993	1	-
<i>Lee 9x9</i>	0,931483	0,922123	0,921808	0,982908	0,896062	0,895447	0,995873	0,870065	0,869135	1

Tabela 3. Correlação dos filtros na imagem de 10 de dezembro de 2016.

	<i>Sem Filtro</i>	<i>Frost 5x5</i>	<i>Gamma 5x5</i>	<i>Lee 5x5</i>	<i>Frost 7x7</i>	<i>Gamma 7x7</i>	<i>Lee 7x7</i>	<i>Frost 9x9</i>	<i>Gamma 9x9</i>	<i>Lee 9x9</i>
<i>Sem filtro</i>	1	-	-	-	-	-	-	-	-	-
<i>Frost 5x5</i>	0,784536	1	-	-	-	-	-	-	-	-
<i>Gamma 5x5</i>	0,784025	0,999999	1	-	-	-	-	-	-	-
<i>Lee 5x5</i>	0,951438	0,937321	0,937033	1	-	-	-	-	-	-
<i>Frost 7x7</i>	0,710003	0,970783	0,970911	0,880937	1	-	-	-	-	-
<i>Gamma 7x7</i>	0,709226	0,970445	0,970574	0,880332	0,999998	1	-	-	-	-
<i>Lee 7x7</i>	0,938376	0,939217	0,938978	0,993603	0,909628	0,909168	1	-	-	-
<i>Frost 9x9</i>	0,664865	0,929325	0,929484	0,834985	0,984024	0,984173	0,875171	1	-	-
<i>Gamma 9x9</i>	0,663916	0,928626	0,928786	0,834104	0,983706	0,983858	0,874453	0,999996	1	-
<i>Lee 9x9</i>	0,930746	0,929693	0,929461	0,984585	0,911399	0,911000	0,996375	0,891952	0,891374	1

Tabela 4. Correlação dos filtros na imagem de 04 de março de 2017.

	<i>Sem Filtro</i>	<i>Frost 5x5</i>	<i>Gamma 5x5</i>	<i>Lee 5x5</i>	<i>Frost 7x7</i>	<i>Gamma 7x7</i>	<i>Lee 7x7</i>	<i>Frost 9x9</i>	<i>Gamma 9x9</i>	<i>Lee 9x9</i>
<i>Sem filtro</i>	1	-	-	-	-	-	-	-	-	-
<i>Frost 5x5</i>	0,775430	1	-	-	-	-	-	-	-	-
<i>Gamma 5x5</i>	0,774830	0,999999	1	-	-	-	-	-	-	-
<i>Lee 5x5</i>	0,950265	0,933516	0,933173	1	-	-	-	-	-	-
<i>Frost 7x7</i>	0,685921	0,968805	0,968974	0,867289	1	-	-	-	-	-
<i>Gamma 7x7</i>	0,684956	0,968403	0,968575	0,866541	0,999998	1	-	-	-	-
<i>Lee 7x7</i>	0,934185	0,938601	0,938324	0,993371	0,900396	0,899814	1	-	-	-
<i>Frost 9x9</i>	0,640778	0,925807	0,926014	0,820434	0,984003	0,984174	0,865557	1	-	-
<i>Gamma 9x9</i>	0,639671	0,925029	0,925238	0,819419	0,983661	0,983838	0,864722	0,999995	1	-
<i>Lee 9x9</i>	0,926461	0,928610	0,928342	0,984050	0,902362	0,901850	0,996345	0,882607	0,881920	1

Tabela 5. Correlação dos filtros na imagem de 20 de junho de 2017.

	<i>Sem Filtro</i>	<i>Frost 5x5</i>	<i>Gamma 5x5</i>	<i>Lee 5x5</i>	<i>Frost 7x7</i>	<i>Gamma 7x7</i>	<i>Lee 7x7</i>	<i>Frost 9x9</i>	<i>Gamma 9x9</i>	<i>Lee 9x9</i>
<i>Sem filtro</i>	1	-	-	-	-	-	-	-	-	-
<i>Frost 5x5</i>	0,784044	1	-	-	-	-	-	-	-	-
<i>Gamma 5x5</i>	0,783521	0,999999	1	-	-	-	-	-	-	-
<i>Lee 5x5</i>	0,950765	0,937763	0,937469	1	-	-	-	-	-	-
<i>Frost 7x7</i>	0,710035	0,974138	0,974258	0,883464	1	-	-	-	-	-
<i>Gamma 7x7</i>	0,709297	0,973846	0,973967	0,882905	0,999999	1	-	-	-	-
<i>Lee 7x7</i>	0,937813	0,941001	0,940751	0,994373	0,910284	0,909849	1	-	-	-
<i>Frost 9x9</i>	0,674694	0,939629	0,939770	0,846476	0,986623	0,986738	0,882940	1	-	-
<i>Gamma 9x9</i>	0,673879	0,939061	0,939203	0,845736	0,986370	0,986487	0,882335	0,999998	1	-
<i>Lee 9x9</i>	0,933067	0,931553	0,931304	0,987000	0,909769	0,909378	0,996965	0,894994	0,894499	1

Tabela 6. Correlação dos filtros na imagem de 26 de julho de 2017.

	<i>Sem Filtro</i>	<i>Frost 5x5</i>	<i>Gamma 5x5</i>	<i>Lee 5x5</i>	<i>Frost 7x7</i>	<i>Gamma 7x7</i>	<i>Lee 7x7</i>	<i>Frost 9x9</i>	<i>Gamma 9x9</i>	<i>Lee 9x9</i>
<i>Sem filtro</i>	1	-	-	-	-	-	-	-	-	-
<i>Frost 5x5</i>	0,785770	1	-	-	-	-	-	-	-	-
<i>Gamma 5x5</i>	0,785176	0,999999	1	-	-	-	-	-	-	-
<i>Lee 5x5</i>	0,952272	0,937067	0,936731	1	-	-	-	-	-	-
<i>Frost 7x7</i>	0,701136	0,969469	0,969630	0,874218	1	-	-	-	-	-
<i>Gamma 7x7</i>	0,700163	0,969062	0,969226	0,873467	0,999997	1	-	-	-	-
<i>Lee 7x7</i>	0,937673	0,940746	0,940469	0,993572	0,905220	0,904635	1	-	-	-
<i>Frost 9x9</i>	0,655812	0,926160	0,926358	0,827253	0,983921	0,984095	0,870380	1	-	-
<i>Gamma 9x9</i>	0,654662	0,925354	0,925555	0,826204	0,983569	0,983749	0,869518	0,999995	1	-
<i>Lee 9x9</i>	0,930653	0,930294	0,930024	0,984448	0,906470	0,905953	0,996432	0,886548	0,885834	1

Tabela 7. Correlação dos filtros na imagem de 24 de setembro de 2017.

	<i>Sem Filtro</i>	<i>Frost 5x5</i>	<i>Gamma 5x5</i>	<i>Lee 5x5</i>	<i>Frost 7x7</i>	<i>Gamma 7x7</i>	<i>Lee 7x7</i>	<i>Frost 9x9</i>	<i>Gamma 9x9</i>	<i>Lee 9x9</i>
<i>Sem filtro</i>	1	-	-	-	-	-	-	-	-	-
<i>Frost 5x5</i>	0,797491	1	-	-	-	-	-	-	-	-
<i>Gamma 5x5</i>	0,796985	0,999999	1	-	-	-	-	-	-	-
<i>Lee 5x5</i>	0,953656	0,942071	0,941789	1	-	-	-	-	-	-
<i>Frost 7x7</i>	0,722240	0,972488	0,972624	0,886509	1	-	-	-	-	-
<i>Gamma 7x7</i>	0,721429	0,972133	0,972271	0,885880	0,999998	1	-	-	-	-
<i>Lee 7x7</i>	0,940125	0,945114	0,944884	0,993993	0,914723	0,914246	1	-	-	-
<i>Frost 9x9</i>	0,679014	0,933857	0,934034	0,843192	0,985348	0,985514	0,882234	1	-	-
<i>Gamma 9x9</i>	0,677985	0,933108	0,933286	0,842245	0,985007	0,985179	0,881462	0,999996	1	-
<i>Lee 9x9</i>	0,933059	0,936319	0,936101	0,985668	0,916387	0,915980	0,996685	0,897634	0,897010	1

As tabelas supramencionadas demonstraram forte correlação entre as imagens sem filtro e o filtro Lee ($R \geq 0,92$). As maiores correlações entre este filtro e as imagens sem filtro foi na janela 5x5, nos dias 29 de setembro de 2016, 29 de julho de 2017 e 24 de setembro ($R = 0,95$). A menor foi no dia 04 de março de 2017 ($R = 0,93$), na janela de tamanho 9x9. As imagens sem filtro apresentaram uma forte correlação com as janelas de filtragem 5x5 dos filtros Frost e Gamma em todas as datas ($0,77 \leq R \leq 0,80$). Na janela 7x7, esses filtros apresentaram correlação moderada com a imagem sem filtro ($0,68 \leq R \leq 0,72$), sendo as menores sendo registradas nos dias 29 de setembro de 2016 e 04 de março de 2017 ($R = 0,68$). Essas datas correspondem as datas da menor e maior cota registrada pelo Sentinel-1. Nas seis datas, a correlação entre as imagens sem filtro e as imagens com os filtros Frost e Gamma na janela de filtragem 9x9, foram moderadas ($0,63 \leq R \leq 0,68$) e menores em relação à janela 7x7.

A maior correlação existente entre as diferentes janelas de um mesmo filtro ocorreu nas imagens com o filtro Lee. As correlações do filtro Lee 7x7 com os filtros 5x5 e 9x9 foram fortíssimas, apresentando coeficiente de Person acima de 0,99 em todas as datas. A correlação entre o Lee 5x5 e 9x9 também foi fortíssima em todas as datas ($R \geq 0,98$). As correlações entre amostras de água extraídas das imagens com o filtro Frost nas diferentes datas e janelas também foram fortíssimas ($0,91 \leq R \leq 0,97$), assim como com o filtro Gamma.

A correlação entre as amostras de água nas imagens com os filtros Frost e Gamma, e janelas de mesmo tamanho, foi fortíssima em todas as datas, com coeficiente de Pearson igual a 0,99. Essa correlação e as análises supracitadas mostraram que esses dois filtros são praticamente iguais. Dessa forma, o filtro Lee demonstrou as maiores diferenças entre os filtros e maior semelhança com a imagem sem filtro. A grande similaridade do filtro Lee com as imagens sem filtro pode ter sido decorrente dos valores de picos de sinal terem sido menos suavizados nas imagens com o filtro Lee do que com os outros dois filtros.

4.3. MELHOR THRESHOLD

A área de análise para identificar o melhor *threshold* correspondeu a uma sobreposição entre as imagens SAR e verdade terrestre, englobando as áreas à jusante do reservatório, reservatório principal, trecho de vazão reduzida, área urbana consolidada da cidade de Altamira e áreas agropastoris adjacentes ao rio (**Figura 10**). A detecção do melhor limiar considerou o maior coeficiente *Kappa* proveniente da comparação da imagem verdade (Sentinel-2 de 28 de

julho de 2017) com 100 diferentes *thresholds* de fatiamento igualmente espaçados entre os valores máximos e mínimos da imagem SAR (Sentinel-1 de 26 de julho de 2017). A sequência de coeficiente *Kappa* nos diferentes *thresholds* pode ser representada na forma de um gráfico. As Figuras 11 a 19 apresentam os gráficos de coeficiente *Kappa* para os diferentes filtros e tamanhos de janela.

Figura 10. Área de sobreposição entre as imagens Sentinel-1 e Sentinel-2.

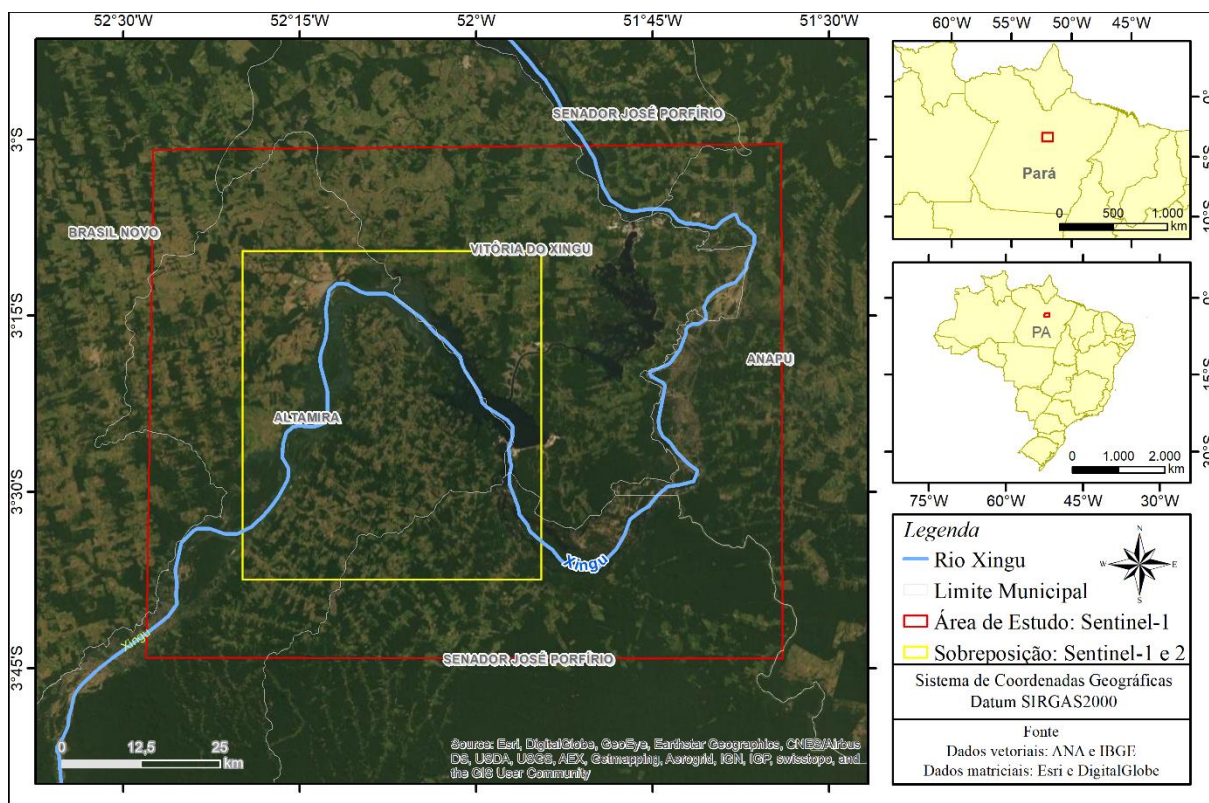


Figura 11. Gráfico do melhor *threshold* para classificar os corpos d'água usando o filtro Frost 5x5. O *Kappa* atinge o coeficiente máximo no valor de *threshold* -21,11dB.




Figura 12. Gráfico do melhor *threshold* para classificar os corpos d'água usando o filtro Gamma 5x5. O *Kappa* atinge o coeficiente máximo no valor de *threshold* -21,11dB.




Figura 13. Gráfico do melhor *threshold* para classificar os corpos d'água usando o filtro Lee 5x5. O *Kappa* atinge seu valor máximo no valor de *threshold* -21,76 dB.




Figura 14. Gráfico do melhor *threshold* para classificar os corpos d'água usando o filtro Frost 7x7. O *Kappa* atinge seu valor máximo no valor de *threshold* -20,90 dB.




Figura 15. Gráfico do melhor *threshold* para classificar os corpos d'água usando o filtro Gamma 7x7. O *Kappa* atinge seu valor máximo no valor de *threshold* -20,74 dB.




Figura 16. Gráfico do melhor *threshold* para classificar os corpos d'água usando o filtro Lee 7x7. O *Kappa* atinge seu valor máximo no valor de *threshold* -21,17 dB.

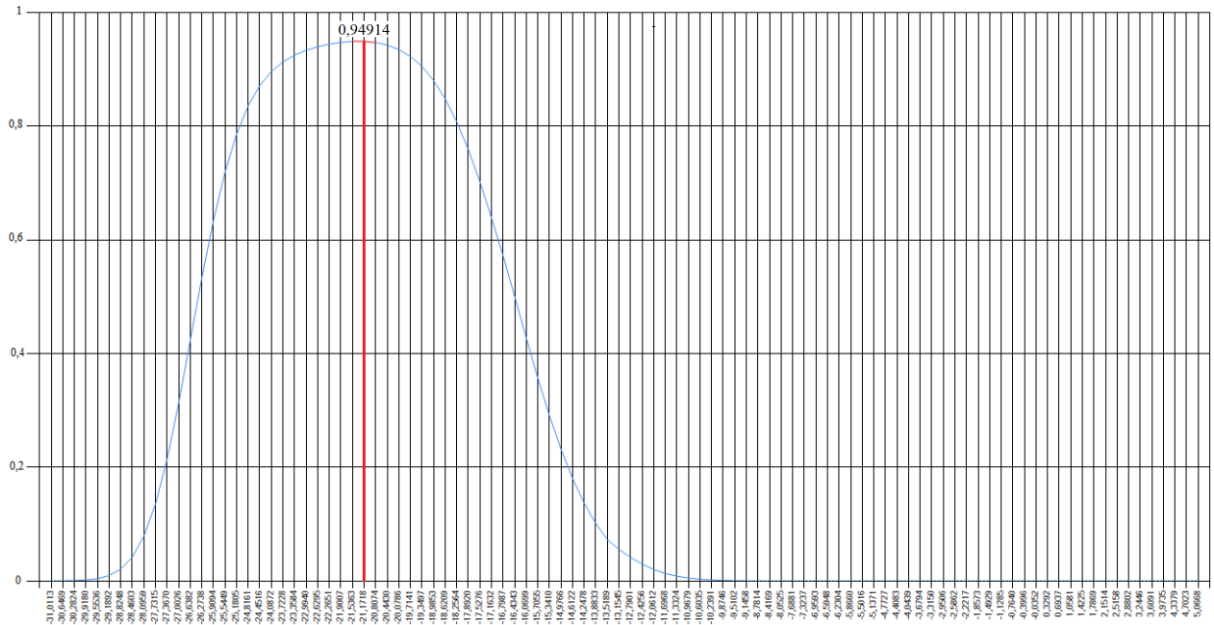


Figura 17. Gráfico do melhor *threshold* para classificar os corpos d'água usando o filtro Frost 9x9. O *Kappa* atinge seu valor máximo no valor de *threshold* -20,71 dB.



Figura 18. Gráfico do melhor *threshold* para classificar os corpos d'água usando o filtro Gamma 9x9. O *Kappa* atinge seu valor máximo no valor de *threshold* -20,65 dB.



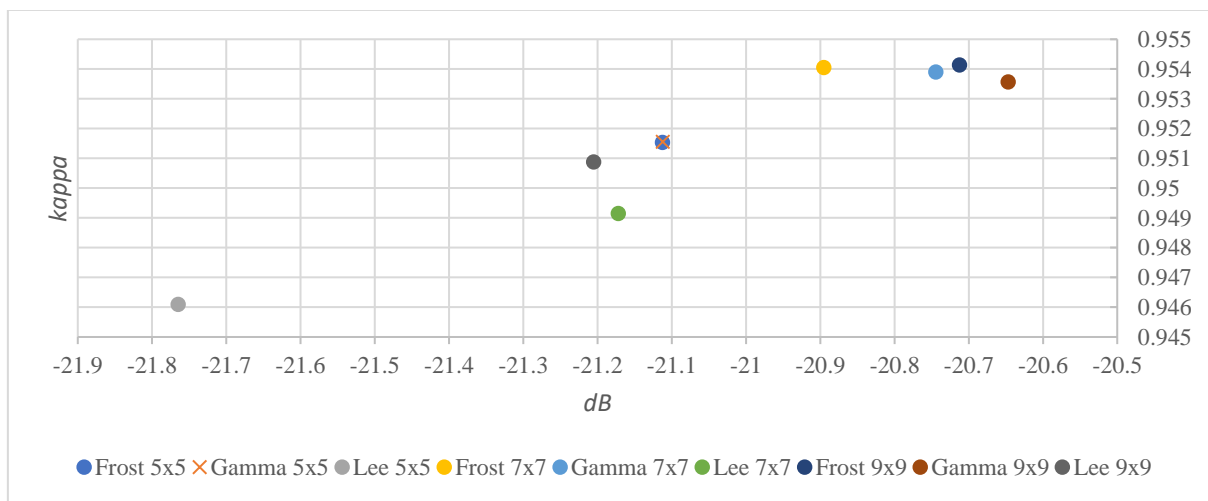


Figura 19. Gráfico do melhor *threshold* para classificar os corpos d'água usando o filtro Lee 9x9. O índice *Kappa* atinge seu valor máximo no valor de *threshold* -21,21 dB.



Os melhores valores de limiar variaram entre -20,65 dB e -21,76 dB. Em todos os tipos de filtros, os picos de sinal foram mais suavizados conforme o aumento do tamanho da janela de filtragem. Por isso, os melhores valores de *threshold* identificados aumentaram à medida que aumentava o tamanho das janelas de filtragem. A **Figura 20** aponta os melhores valores de *threshold* das imagens de 26 de julho de 2017 com os filtros Frost, Gamma e Lee, nas janelas 5x5, 7x7 e 9x9 e o *Kappa* resultante.

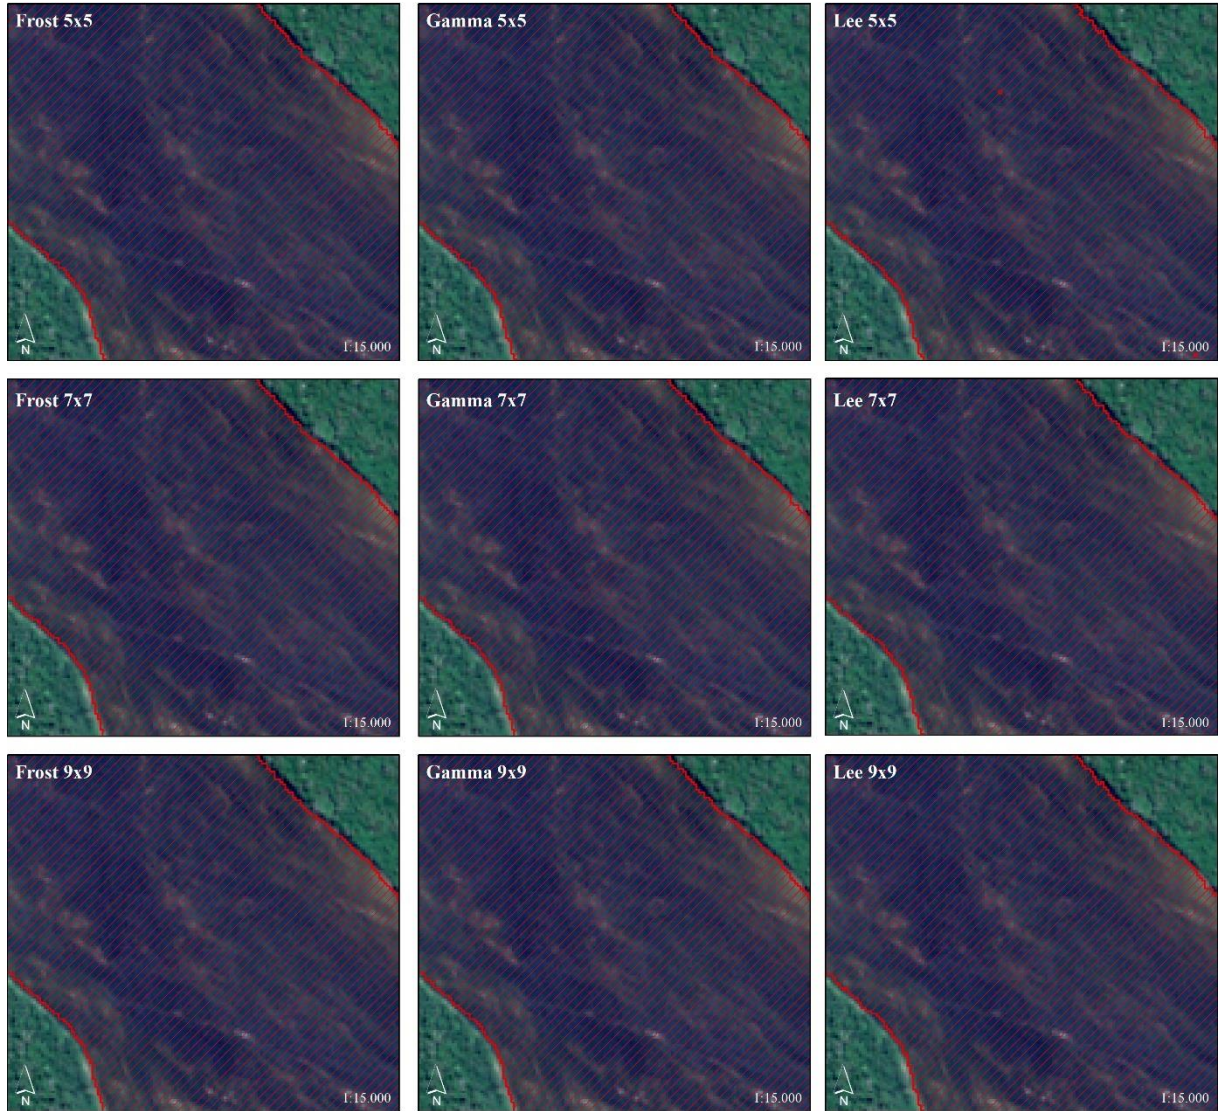
Figura 20. Gráfico dos melhores valores de *threshold* e os respectivos coeficientes *Kappa*.



A **Figura 20** evidencia uma pequena diferença entre os coeficientes *Kappa* nos diferentes filtros e tamanhos de janela. As imagens com os filtros Frost e Gamma na janela de 5x5 *pixels* apresentaram valores de limiar e coeficientes *Kappa* praticamente iguais. O melhor limiar com o filtro Frost na janela 5x5 foi -21,113 dB e o *Kappa* de 0,95153. No filtro Gamma, com janela de mesmo tamanho, o melhor limite para mapear a água apontado foi de -21,112 dB onde o *Kappa* atingiu o índice 0,95155. Sendo assim, o filtro Gamma evidenciou resultado de coeficiente *Kappa* ligeiramente maior do que o filtro Frost, na janela de filtragem 5x5. Nas outras janelas, o filtro Gamma obteve índice *Kappa* menor que o Frost.

Todos os coeficientes *Kappa* empregando os melhores valores de *threshold* em cada um dos filtros e janelas foram superiores a 0,95, com exceção das imagens com o filtro Lee nas janelas de filtragem de tamanho 5x5 e 7x7. As imagens com o filtro Lee apresentaram os menores valores de *threshold* e os menores índices *Kappa* nas janelas com todos os tamanhos. Ainda assim, os coeficientes *Kappa* foram bem satisfatórios nas imagens Sentinel-1 com o filtro Lee. O melhor valor de *threshold* do filtro Lee na janela de filtragem de tamanho 5x5 foi de -21,76 dB e o coeficiente *Kappa* 0,946; 7x7 foi de -21,17 dB e o *Kappa* 0,949; e 9x9 de -21,20 dB e o *Kappa* de 0,951. A **Figura 21** demonstra como as áreas de transições foram bem delineadas em todos os filtros, na qual a cor escura e com textura lisa são os corpos d'água e em verde com textura rugosa, a vegetação. O mapeamento dos corpos d'água foi representado pela hachura de cor vermelha.

Figura 21. Mapeamento dos corpos d'água elaborado a partir das imagens Sentinel-1 de 26 de julho de 2017 com filtros Frost, Gamma e Lee, janelas de filtragem de tamanho 5x5, 7x7 e 9x9, e adotando os respectivos melhores valores de *threshold*.



O índice *Kappa* também aumentou conforme o tamanho da janela de filtragem aumentou, com exceção do filtro Gamma. O filtro Gamma registrou o melhor desempenho na imagem com janela de filtragem 7x7, onde o índice *Kappa* foi de 0,954. Apesar de perder resolução espacial, os filtros Frost e Lee obtiveram os melhores coeficientes *Kappa* nas janelas 9x9, de 0,954 e 0,951, respectivamente. Cabe ressaltar que esses valores de *Kappa* não foram usados para avaliar a acurácia, foram usados exclusivamente para mensurar o valor de *threshold* nas imagens Sentinel-1 em que o *Kappa* atingiu seu melhor valor.

Áreas vegetadas que foram inundadas pela represa possuíam rugosidade e valores de

retroespalhamento elevados, não sendo classificadas como água. Por exemplo, à jusante da área urbana de Altamira, há um trecho de ilhas cobertas por vegetação aluvial sobre afloramento rochoso que foram parcialmente inundadas pelo reservatório (**Figura 23**), estavam em processo de decomposição e não foram classificadas como água (**Figura 22**). Na **Figura 22**, as feições de textura rugosa e de cor violeta localizadas no canto superior direito representam essas vegetações. Nos estudos de Arst (2003) e de Colditz et. al (2018), é pontuada a influência de vegetação, algas e sedimentos no mapeamento dos corpos d'água, ocasionando rugosidade e aumento do sinal de retroespalhamento.

Figura 22. Mapeamento da água com os filtros Frost, Gamma e Lee nas janelas de tamanho 5x5, 7x7 e 9x9.





Figura 23. Vegetação morta que cobria ilhas do rio Xingu, próximos a Altamira, que foram inundadas.



Fonte: Folha de São Paulo, 2018. Fotografia de Lalo de Almeida/Folhapress.

4.4. VALIDAÇÃO

A análise de acurácia comparou as classificações dos corpos d'água usando os melhores valores de *threshold* na imagem Sentinel-1 (26 de julho de 2017) com a máscara de água elaborada com a Sentinel-2 (28 de julho de 2017). Os mapeamentos dos corpos d'água com os diferentes filtros e janelas exibiram alto grau de acurácia com a imagem verdade, com coeficiente *Kappa* acima de 0,94 e exatidão global acima de 98%.

Portanto, a adoção do melhor limiar otimizou o mapeamento, apresentando poucos erros de omissão e comissão. Os erros de comissão em todos os testes decorrem da classificação errônea de outros alvos com superfície especular, tais como a área urbana de Altamira e o solo exposto de áreas agropastoris (**Figura 24**). Visualmente, os filtros Frost e Gamma mostraram menos erros de comissão, quando comparados ao filtro Lee, em todas as janelas. O aumento do tamanho da janela de filtragem reduziu os erros de comissão (**Figura 24**). Os erros de omissão ocorreram majoritariamente em pequenas áreas de corpos d'água e nas áreas de margem do rio. Esses erros reduziram nas janelas de filtragem de tamanho maiores (**Figura 25**).

Figura 24. Erros de comissão no mapeamento da água usando o melhor *threshold*.






Figura 25. Mapeamento dos corpos d'água elaborado filtro Frost, nas janelas 5x5, 7x7 e 9x9.



Em todos os tipos de filtros e tamanhos de janelas, a acurácia do usuário foi maior que a do produtor. Ou seja, em todos os filtros e janelas, os erros de comissão foram superiores aos erros de omissão. Ao adotar os melhores limiares, foram registrados valores de acurácia do usuário acima de 96% e do produtor maiores que 94% (**Figura 26**).

Figura 26. Acurácia do usuário e do produtor do mapeamento de água elaborado com as imagens Sentinel-1 de 26 de julho de 2017 nos diferentes filtros e tamanhos de janela de filtragem.



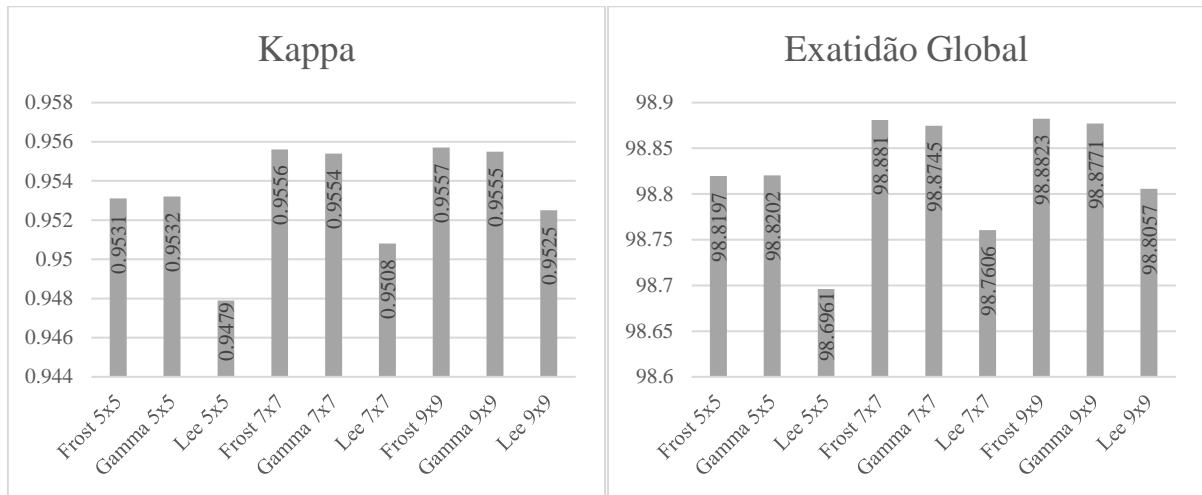
O filtro Lee na janela 5x5 alcançou a maior acurácia do usuário quando comparado às outras janelas e filtros. Entretanto, a imagem com esse filtro e janela obteve a menor acurácia do produtor. Ou seja, apesar de apresentar a maior confiabilidade na classificação da água, a imagem com esse filtro e janela demonstrou menor sensibilidade em distinguir corretamente a água dos demais alvos, com maiores erros de comissão. Dentre todos os filtros e tamanhos de janelas de filtragem, a imagem com o filtro Gamma 7x7 obteve a maior acurácia do produtor.

A **Figura 27** representa as variações da acurácia da classificação dos corpos d'água com o melhor *threshold* nas imagens Sentinel-1 de acordo com o filtro e tamanho da janela, sob o panorama do índice *Kappa* e de exatidão global. Não apenas o filtro, mas o tamanho da janela de filtragem também exerceu influência nos resultados.

Em todos os filtros, as janelas 7x7 e 9x9 obtiveram melhores desempenhos em relação à janela 5x5. Cabe ressaltar que o filtro Frost e Gamma apresentaram índices *Kappa* e de exatidão global semelhantes e superiores em relação ao Lee em todas as janelas. Conforme aumenta a

janela, mais intensa é a filtragem dos *pixels* com picos de sinal e melhores foram os resultados.

Figura 27. Análise de acurácia por meio de índice *Kappa* e exatidão global.



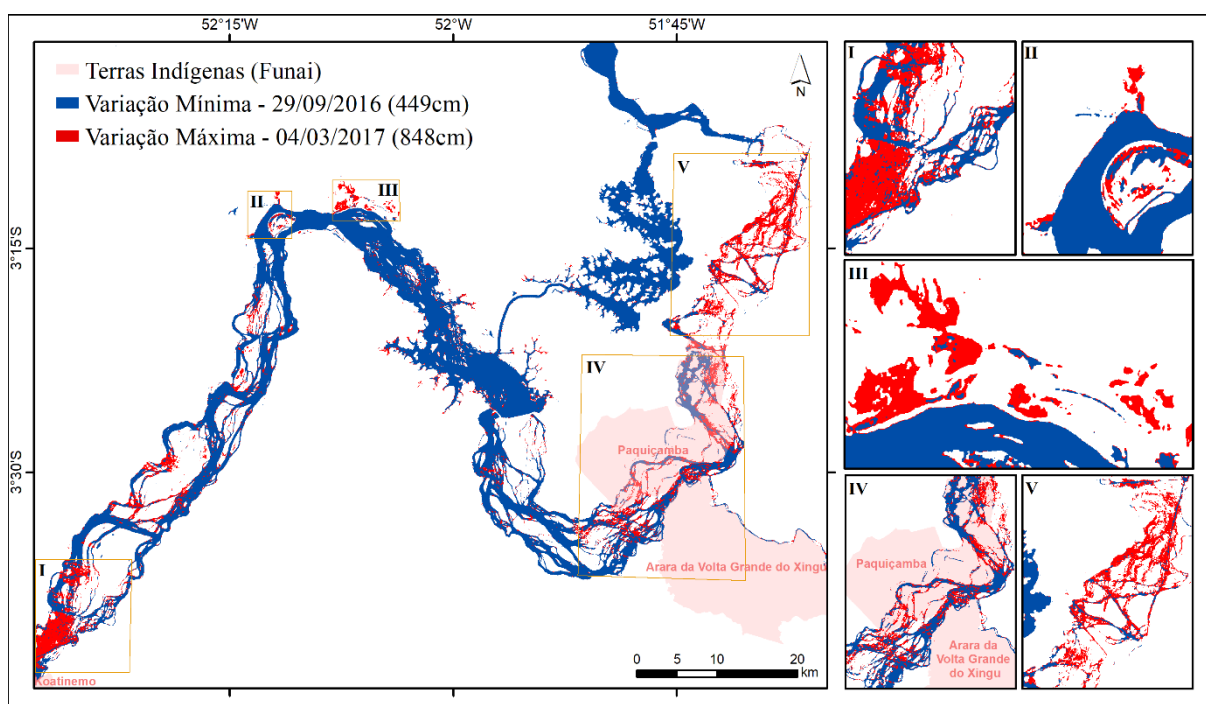
O filtro Frost 9x9 com o *threshold* de -20,71 dB obteve o melhor índice *Kappa* e de exatidão global. No trabalho de Santoso et al. (2016) com Alos-Palsar, ao comparar os desempenhos dos filtros Lee, Frost, Média e Mediana, o filtro Frost também apresentou melhor desempenho. Apesar de perder a resolução espacial nas janelas de tamanhos maiores, esse filtro na janela 9x9 balanceou melhor os erros de comissão e de omissão. Um último teste foi realizado na imagem de Sentinel-1 de 26 de julho de 2017 com o filtro Frost 9x9. Ao adotar o maior valor de retroespalhamento encontrado nas amostras de água dessa data (-19,17 dB), a acurácia diminuiu. A exatidão global ficou em 98,18% e o índice *Kappa* em 0,93.

Sendo assim, o filtro Frost com janela de 9x9 *pixels* foi adotado no mapeamento multitemporal das imagens Sentinel-1, por ter apresentado o maior coeficiente *Kappa* e acurácia de exatidão global, de 0,96 e 98,88%, respectivamente. Valores menores que -20,71 dB foram aplicados em todas as 34 imagens da série temporal para delimitar os corpos d'água. Devido o objetivo do estudo ser mapear os corpos d'água do rio Xingu, foi elaborada uma máscara incluindo a área da cota máxima maximorum, do TVR e um raio de 500m a partir dos limites desses. Ela foi usada em todas as 34 imagens Sentinel-1, onde todos os *pixels* classificados como água e fora da abrangência da máscara foram desconsiderados.

4.5. AMPLITUDE MÁXIMA FLUVIAL

Foram selecionadas as imagens da menor e maior cota para delimitar a amplitude máxima dos corpos d'água de áreas abertas da Volta Grande do Xingu registrada pelo Sentinel-1, sendo de 29 de setembro de 2016 e 04 de março de 2017, respectivamente. A mudança entre os mapeamentos de água foi detectada através da adoção das imagens Frost 9x9 da maior e menor cota durante o período de análise (**Figura 28**).

Figura 28. Detecção da amplitude fluvial na Volta Grande do Xingu, Pará.



I - áreas inundáveis à montante do reservatório principal; II - região dos igarapés Panela, Ambé e da ilha do Arapujá; III - pequeno trecho de planícies fluviais na divisa de Altamira e Vitória Grande do Xingu; IV - terras indígenas Paquiçamba e Arara da Volta Grande do Xingu; V – fim do TVR, à jusante das terras indígenas.

A **Figura 28** demonstra grande variação à montante do reservatório principal (I), entretanto, o canal de derivação, os reservatórios principal e intermediário não apresentaram grandes variações fluviais entre as imagens de 29 de setembro de 2016 e 04 de março de 2017. Nas proximidades da área urbana de Altamira, pode-se verificar uma variação fluvial nos igarapés Ambé e Pannels, além da ilha do Arapujá (II). Às margens do reservatório principal, na divisa municipal de Altamira com Vitória Grande do Xingu, foi observada variação nas planícies de inundação que não foram permanentemente inundadas pelo reservatório (III). A

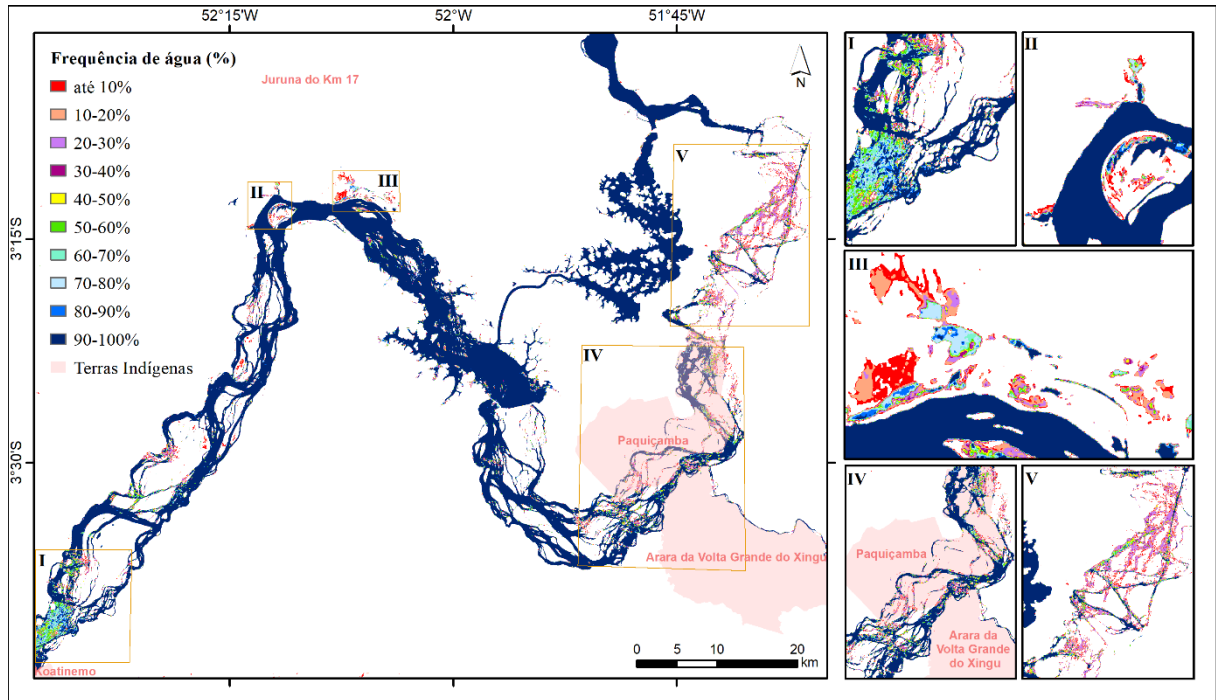
vazão da água à jusante do barramento do Sítio Pimental, no trecho das terras indígenas Arara da Volta Grande, Paquiçamba (IV) até o final do TVR (V) constatou as maiores variações fluviais, chegando a ficar praticamente seco em alguns trechos na imagem de 29 de setembro de 2016.

Dessa forma, apesar de não terem sido alagadas, essas terras indígenas foram intensamente pressionadas com a intensa redução do volume de água. A redução do fluxo de água provocou intensas alterações na fauna, na flora, na economia e subsistência dos povos e comunidades tradicionais que dependiam das águas do Xingu, principalmente no Trecho de Vazão Reduzida (TVR). Nessa área notou-se trechos com exposição do leito do rio, secamento das corredeiras e acumulação de água em poças (**Figura 28**) ocasionando baixa oxigenação no TVR. Esses fatores provocam o isolamento da biota, a mortandade de peixes e a proliferação de mosquitos. Além disso, devido às altas cargas de sedimento no trecho à jusante da barragem, a água ficou insalubre. Isso demonstra a importância de se monitorar o comportamento hidrológico estudando maneiras viáveis de reduzir os impactos do empreendimento.

A porcentagem de ocorrência de água no *pixel*, realizada a partir das 34 imagens, demonstrou bem o comportamento fluvial entre outubro de 2016 e outubro de 2017. Além de ilustrar a extensão da variação máxima dos corpos d'água superficiais, o mapa da **Figura 29** também representa o tempo da ocorrência de inundação de cada *pixel*. Dessa forma, pode-se distinguir as áreas permanentemente inundadas das áreas sazonalmente inundáveis nas imagens usando o filtro Frost 9x9.

A partir do mapa da **Figura 29**, foi possível avaliar os trechos onde ocorreram e não ocorreram as variações fluviais, e a ocorrência de água no *pixel*. Conforme previsto, após a construção da UHE Belo Monte, o TVR perdeu grandes áreas de água. Cabe ressaltar que as águas do TVR são controladas pela barragem do Sítio Pimental. Durante o período de análise, nessas áreas foram constatadas variações fluviais mais acentuadas, assim como no trecho à montante do reservatório principal. À montante do reservatório principal, a maior parte dos *pixels* com água ficaram inundados de 50% a 90% das imagens. No TVR, a dinâmica da água ficou mais acentuada conforme ia se afastando do reservatório principal, no sentido da jusante. Nesse trecho, a maior parte das áreas ficou inundada entre 10% e 30% das imagens e poucas áreas ficaram cobertas por água de 90% a 100% do tempo.

Figura 29. Frequência de água no pixel na Volta Grande do Xingu.



I - áreas inundáveis à montante do reservatório principal; II - região dos igarapés Panela, Ambé e da ilha do Arapujá; III - pequeno trecho de planícies fluviais na divisa de Altamira e Vitória Grande do Xingu; IV - terras indígenas Paquiçamba e Arara da Volta Grande do Xingu; V – fim do TVR, à jusante das terras indígenas.

No TVR à jusante da Terra Indígena, houve uma variação maior do que nas Terras Indígenas. Ao comparar as áreas com as maiores dinâmicas na Volta Grande do Xingu, os trechos à montante do reservatório principal ficaram inundados por mais tempo do que à jusante. Assim como o mapa da variação máxima do Xingu, o mapa de ocorrência de água no *pixel* demonstrou pouca mudança na área coberta por água no canal de derivação e nos reservatórios principal e intermediário.

5. CONCLUSÕES

Os resultados demonstraram que o uso da série temporal de imagens SAR Sentinel-1 possui grande potencial em mapear os corpos d'água com elevado nível de acurácia de forma gratuita. A adoção das imagens multitemporais SAR viabilizou o mapeamento da extensão da inundação em áreas abertas, além da compreensão da dinâmica espaço-temporal dessas áreas. A metodologia de definição do melhor *threshold* para detectar a água conseguiu distinguir bem os corpos d'água abertos nas imagens Sentinel-1. Cada filtro possui um valor *threshold* específico para a obtenção do maior índice *Kappa*. Utilizando o *threshold* adequado, todos os filtros tiveram alta performance. Foi constatado melhor desempenho de mapear a água ao adotar o filtro Frost 9x9 e o *threshold* de -20,71 dB.

A partir da detecção de mudança, foi possível discriminar as áreas susceptíveis a alagamentos sazonais em áreas abertas. O mapa de porcentagem de ocorrência de água no *pixel* permitiu verificar o período inundado por água em cada *pixel* e avaliar detalhes da dinâmica fluvial entre 2016 e 2017. Existem áreas de grande relevância ecológica que inundavam antes da construção da UHE de Belo Monte que não inundam mais. À montante da barragem principal, verificou-se uma dinâmica mais acentuada das áreas inundáveis do que a jusante.

As análises da amplitude máxima do rio e da ocorrência de água do *pixel* evidenciou variações significativas no TVR e à montante do reservatório principal. Corroborou ainda que a maior parte das águas do TVR ficaram inundadas de 10% a 30% das imagens. Enquanto isso, a maior parte das águas à montante do reservatório principal ficaram inundadas de 50% a 90%.

Esse trabalho viabilizou o entendimento da dinâmica da água após a construção da UHE de Belo Monte. Isso permite associar a metodologia adotada com outras ferramentas para identificar a vazão ecológica. A metodologia proposta também pode auxiliar na fiscalização do nível do rio e confrontar se os limites apresentados no projeto estão de acordo com a realidade. A continuidade do programa Copernicus viabiliza a realização de um monitoramento e fornece subsídios para realizar monitoramentos eficazes de detecção de mudança dos corpos hídricos na Volta Grande do Xingu e no mundo.

REFERÊNCIAS BIBLIOGRÁFICAS

- Adam, E., Mutanga, O., Rugege, D. 2009. Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation: a review. *Wetlands Ecology and Management*, 18(3), 281–296.
- Alsdorf, D., Han, S.-C., Bates, P., Melack, J. 2010. Seasonal water storage on the Amazon floodplain measured from satellites. *Remote Sensing of Environment*, 114(11), 2448–2456.
- Arnesen, A. S., Silva, T. S. F., Hess, L. L., Novo, E. M. L. M., Rudorff, C. M., Chapman, B. D., McDonald, K. C. 2013. Monitoring flood extent in the lower Amazon River floodplain using ALOS/PALSAR ScanSAR images. *Remote Sensing of Environment*, 130, 51–61.
- Becker, B. K. 2005. Geopolítica da Amazônia. *Estudos Avançados*, 19(53), 71–86.
- Benetti, A. D.; Lanna, A. E.; Cabalchini, M. S. 2003. Metodologias para determinação de vazões ecológicas em rios. *Revista Brasileira de Recursos Hídricos*, 8(2), 149–160.
- Bioresita, F., Puissant, A., Stumpf, A., Malet, J.-P. 2018. A method for automatic and rapid mapping of water surfaces from Sentinel-1 imagery. *Remote Sensing*, 10(2), 217.
- Bourgeau-Chavez, L. L., Kasischke, E. S., Brunzell, S. M., Mudd, J. P., Smith, K. B., Frick, A. L. 2001. Analysis of space-borne SAR data for wetland mapping in Virginia riparian ecosystems. *International Journal of Remote Sensing*, 22(18), 3665–3687.
- Brisco, B., Ahern, F., Murnaghan, K., White, L., Canisus, F., Lancaster, P. 2017. Seasonal change in wetland coherence as an aid to wetland monitoring. *Remote Sensing*, 9(2), 158.
- Carvalho Júnior, O. A., Guimarães, R. F., Gillespie, A. R., Silva, N. C., Gomes, R. A. 2011. A new approach to change vector analysis using distance and similarity measures. *Remote Sensing*, 3(11), 2473-2493.
- Cazals, C., Rapinel, S., Frison, P.-L., Bonis, A., Mercier, G., Mallet, C., Corgne, S., Rudant, J.-P. 2016. Mapping and characterization of hydrological dynamics in a coastal marsh using high temporal resolution Sentinel-1A images. *Remote Sensing*, 8(7), 570.

- Chapman, B., McDonald, K., Shimada, M., Rosenqvist, A., Schroeder, R., Hess, L. 2015. Mapping regional inundation with spaceborne L-Band SAR. *Remote Sensing*, 7(5), 5440–5470
- Chignell, S., Anderson, R., Evangelista, P., Laituri, M., Merritt, D. 2015. Multi-temporal independent component analysis and Landsat 8 for delineating maximum extent of the 2013 Colorado front range flood. *Remote Sensing*, 7(8), 9822–9843.
- Choi, H., Jeong, J. 2019. Speckle noise reduction technique for SAR images using statistical characteristics of speckle noise and discrete wavelet transform. *Remote Sensing*, 11(10), 1184.
- Clement, M. A., Kilsby, C. G., Moore, P. 2017. Multi-temporal synthetic aperture radar flood mapping using change detection. *Journal of Flood Risk Management*, 11(2), 152–168.
- COPPE – Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia. 2015. Impactos ambientais do trecho de vazão reduzida em hidrelétricas. *Caderno de Energia*, n.4, Programa de Planejamento Energético, Universidade Federal do Rio de Janeiro, Rio de Janeiro. Disponível em: http://antigo.ppe.ufrj.br/pppe/downloads/ce_site4.pdf. Acesso em: 26 de março de 2018.
- Colditz, R. R., Troche Souza, C., Vazquez, B., Wickel, A. J., Ressler, R. 2018. Analysis of optimal thresholds for identification of open water using MODIS-derived spectral indices for two coastal wetland systems in Mexico. *International Journal of Applied Earth Observation and Geoinformation*, 70, 13–24.
- CPRM – Serviço Geológico Do Brasil. 2004. Carta geológica do Brasil ao milionésimo. Disponível em: <http://www.cprm.gov.br/publique/Geologia/Geologia-Basica/Carta-Geologica-do-Brasil-ao-Milionesimo-298.html>.
- DeVries, B., Huang, C., Lang, M., Jones, J., Huang, W., Creed, I., Carroll, M. 2017. Automated quantification of surface water inundation in wetlands using optical satellite imagery. *Remote Sensing*, 9(8), 807.
- Eletrobrás. 2009a. Avaliação ambiental integrada da Bacia do Rio Xingu. Disponível em: https://eletrobras.com/pt/AreasdeAtuacao/geracao/belo_monte/AAI-Xingu-Volume-I.pdf. Acesso em: 05 de março de 2019.

Eletrobrás. 2009b. Relatório de Impacto Ambiental da Usina Hidrelétrica de Belo Monte. Disponível em: https://eletrobras.com/pt/AreasdeAtuacao/geracao/belo_monte/Rima-AHE-Belo-Monte.pdf. Acesso em: 26 de junho de 2019

Eletrobrás. 2009c. Estudo de Impacto Ambiental da Usina Hidrelétrica de Belo Monte. Disponível em: <http://licenciamento.ibama.gov.br/Hidreletricas/Belo%20Monte/EIA/>. Acesso em 15 de março de 2018.

ESA. European Space Agency. 2017. Copernicus Open Access Hub. Disponível em: <https://scihub.copernicus.eu/dhus/#/home>. Acesso em: 01 de novembro de 2017.

ESA. European Space Agency. 2015. Sentinel 1 - data access and products. Disponível em: https://sentinel.esa.int/documents/247904/1653440/Sentinel1_Data_Access_and_Products.

ESA. European Space Agency. 2011. Next ESA SAR Toolbox (NEST): a cookbook. TIGER Capacity Building Facility - II Training Course on Active and Passive Microwave Remote Sensing. 20-24 June 2011. Delft University of Technology, Netherlands. Disponível em: https://earth.esa.int/documents/507513/1077921/2011_Tiger_NEST_cookbook.pdf/da84f918-a9e4-4404-8515-b624b7a6210c.

ESA. European Space Agency. 2013. Sentinel-1: user handbook. Disponível em: https://sentinel.esa.int/documents/247904/685163/Sentinel-1_User_Handbook. Acesso em: 03 de novembro de 2017.

ESA. European Space Agency. 2019. Sentinel-1: product specification. Disponível em: <https://sentinel.esa.int/documents/247904/349449/Sentinel-1-Product-Specification.pdf>. Acesso em: 03 de maio de 2019.

Ettritch, G., Hardy, A., Bojang, L., Cross, D., Bunting, P., Brewer, P. 2018. Enhancing digital elevation models for hydraulic modelling using flood frequency detection. *Remote Sensing of Environment*, 217, 506–522.

Feng, L., Hu, C., Chen, X., Cai, X., Tian, L., Gan, W. 2012. Assessment of inundation changes of Poyang Lake using MODIS observations between 2000 and 2010. *Remote Sensing of Environment*, 121, 80–92.

Feng, L., Han, X., Hu, C., Chen, X. 2016. Four decades of wetland changes of the largest freshwater lake in China: possible linkage to the Three Gorges Dam? *Remote Sensing of Environment*, 176, 43–55.

Fearnside, P.M. 2015. Hidrelétricas na Amazônia brasileira como fontes de gases de efeito estufa. pp. 141-159. In: P.M. Fearnside (ed.) Hidrelétricas na Amazônia: impactos ambientais e sociais na tomada de decisões sobre grandes obras. Editora do INPA, Manaus, 2, 297p. Disponível em: <https://acervo.socioambiental.org/sites/default/files/documents/Q3D00023.pdf>. Acesso em: 22 de outubro de 2018.

Folha de São Paulo. Prestes a ser concluída, Belo Monte é criticada por atingidos e especialistas. Disponível em: <https://temas.folha.uol.com.br/projeto-amazonia/hidreletricas/prestes-a-ser-concluida-belo-monte-e-criticada-por-atingidos-e-especialistas.shtml>. Acesso em 15 de junho de 2019.

Hardy, A., Ettritch, G., Cross, D., Bunting, P., Liywalii, F., Sakala, J., Silumesii, A., Singini, D., Smith, M., Willis, T., Thomas, C. J. 2019. Automatic detection of open and vegetated water bodies using Sentinel 1 to map African malaria vector mosquito breeding habitats. *Remote Sensing*, 11(5), 593.

Herrera, J. A.; Moreira, R. P. 2013. Resistência e conflitos sociais na Amazônia Paraense: a luta contra o empreendimento hidrelétrico de Belo Monte. *Campo-Território: Revista de Geografia Agrária*, 8 (16), 130-151. Disponível em: <http://www.seer.ufu.br/index.php/campoterritorio/article/view/19861>.

Hong, S., Jang, H., Kim, N., Sohn, H.-G. 2015. Water Area Extraction Using RADARSAT SAR Imagery Combined with Landsat Imagery and Terrain Information. *Sensors*, 15(3), 6652–6667.

Huang, C., Chen, Y., Wu, J. 2014. Mapping spatio-temporal flood inundation dynamics at large river basin scale using time-series flow data and MODIS imagery. *International Journal of Applied Earth Observation and Geoinformation*, 26, 350–362.

IBGE. Instituto Brasileiro de Geografia e Estatística. IBGE Cidades: Altamira. Disponível em: <http://cidades.ibge.gov.br/xtras/perfil.php?codmun=150060>.

- ISA. Instituto Socioambiental. Avança destruição no Xingu. 2017. Disponível em: <https://www.socioambiental.org/pt-br/noticias-socioambientais/avanca-destruicao-do-rio-xingu>.
- Jiang, X., Lu, D., Moran, E., Calvi, M. F., Dutra, L. V., Li, G. 2018. Examining impacts of the Belo Monte hydroelectric dam construction on land-cover changes using multitemporal Landsat imagery. *Applied Geography*, 97, 35–47.
- Jin, H., Huang, C., Lang, M. W., Yeo, I.-Y., Stehman, S. V. 2017. Monitoring of wetland inundation dynamics in the Delmarva Peninsula using Landsat time-series imagery from 1985 to 2011. *Remote Sensing of Environment*, 190, 26–41.
- Landis, J. R., Koch, G. G. 1977. The Measurement of Observer Agreement for Categorical Data. *Biometrics*, 33(1), 159.
- Lê, T. T., Atto, A. M., Trouvé, E., Solikhin, A., Pinel, V. 2015. Change detection matrix for multitemporal filtering and change analysis of SAR and PolSAR image time series. *ISPRS Journal of Photogrammetry and Remote Sensing*, 107, 64–76.
- Liang, J., Liu, D. 2020. A local thresholding approach to flood water delineation using Sentinel-1 SAR imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 159, 53–62. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0924271619302540>. Acesso em: 20 de novembro de 2019.
- Long, S., Fatoyinbo, T. E., Policelli, F. 2014. Flood extent mapping for Namibia using change detection and thresholding with SAR. *Environmental Research Letters*, 9(3), 035002.
- Magalhães, S; Hernandez, F. (org.). 2009. Painel de especialistas - análise crítica do Estudo de Impacto Ambiental do Aproveitamento Hidrelétrico de Belo Monte. Belém. Disponível em: http://www.socioambiental.org/banco_imagens/pdfs/Belo_Monte_Painel_especialistas_EIA.pdf.
- Magalhães, S. B., Silva, Y. Y. P., Vidal, C. L. 2016. Não há peixe para pescar neste verão: efeitos socioambientais durante a construção de grandes barragens – o caso Belo Monte. *Desenvolvimento e Meio Ambiente*, 37, 111-134. Edição Especial Nexo Água e Energia. Disponível em: <http://revistas.ufpr.br/made/article/view/45595>.

- Matgen, P., Hostache, R., Schumann, G., Pfister, L., Hoffmann, L., Savenije, H. H. G. 2011. Towards an automated SAR-based flood monitoring system: Lessons learned from two case studies. *Physics and Chemistry of the Earth, Parts A/B/C*, 36(7-8), 241–252.
- Meneses, P. R., Almeida, T. de, Rosa, A. N. de C., Sano, E. E., Souza, E. B. de, Baptista, G. M. de M., Brites, S. R. 2012. Introdução ao processamento de imagens de sensoriamento remoto. Universidade de Brasília, Brasília.
- MEA. Millennium Ecosystem Assessment. 2005. Ecosystems and human well-being: wetlands and water synthesis. *World Resources Institute*. Washington, DC.
- Mohammadi, A., Costelloe, J. F., Ryu, D. 2017. Application of time series of remotely sensed normalized difference water, vegetation and moisture indices in characterizing flood dynamics of large-scale arid zone floodplains. *Remote Sensing of Environment*, 190, 70–82.
- Moran, E. F. 2016. Roads and dams: infrastructure-driven transformations in the brazilian amazon. *Ambiente & Sociedade*, 19(2), 207–220.
- MPEG. Museu Paraense Emílio Goeldi. 2008. Descrição e análise da flora da região do médio-baixo Rio Xingu. Convênio MCT/MPEG/Camargo Corrêa/Odebrecht/Andrade Gutierrez/Eletróbrás/Fidesa. Relatório Técnico. Belém. Disponível em: http://philip.inpa.gov.br/publ_livres/Dossie/BM/DocsOf/EIA09/Vol%2017/TEXTO/FLORA/0%20RELAT%C3%93RIO%20FINAL%20VEGETA%C3%87%C3%83O%20SEM_TB%20V_1.pdf.
- Nascimento, E.P, Drummond, J.A. (org.). 2003. Amazônia: dinamismo econômico e conservação ambiental. Garamond, Rio de Janeiro.
- Ogilvie, A., Belaud, G., Delenne, C., Bailly, J.-S., Bader, J.-C., Oleksiak, A., Ferry, L., Martin, D. 2015. Decadal monitoring of the Niger Inner Delta flood dynamics using MODIS optical data. *Journal of Hydrology*, 523, 368–383.
- Olesk, A.; Voormansik, K.; Pohjala, M.; Noorma, M. 2015. Forest change detection from Sentinel-1 and ALOS-2 satellite images. *IEEE 5th Asia-Pacific Conference on Synthetic Aperture Radar (APSAR)*, 522-527.

O'Loughlin, F. E., Paiva, R. C. D., Durand, M., Alsdorf, D. E., Bates, P. D. 2016. A multi-sensor approach towards a global vegetation corrected SRTM DEM product. *Remote Sensing of Environment*, 182, 49–59.

Olthof, I. (2017). Mapping Seasonal Inundation Frequency 1985–2016 along the St-John River, New Brunswick, Canada using the Landsat archive. *Remote Sensing*, 9(2), 143.

Manjusree, P., Prasanna Kumar, L., Bhatt, C. M., Rao, G. S., Bhanumurthy, V. 2012. Optimization of threshold ranges for rapid flood inundation mapping by evaluating backscatter profiles of high incidence angle SAR images. *International Journal of Disaster Risk Science*, 3(2), 113–122.

Mohammadi, A., Costelloe, J. F., Ryu, D. 2017. Application of time series of remotely sensed normalized difference water, vegetation and moisture indices in characterizing flood dynamics of large-scale arid zone floodplains. *Remote Sensing of Environment*, 190, 70–82.

Montgomery, J., Brisco, B., Chasmer, L., Devito, K., Cobbaert, D., Hopkinson, C. 2019. SAR and Lidar temporal data fusion approaches to Boreal wetland ecosystem monitoring. *Remote Sensing*, 11(2), 161.

Mueller, N., Lewis, A., Roberts, D., Ring, S., Melrose, R., Sixsmith, J., Lymburner, L., McIntyre, A., Tan, P., Curnow, S., Ip, A. 2016. Water observations from space: mapping surface water from 25 years of Landsat imagery across Australia. *Remote Sensing of Environment*, 174, 341–352.

Norte Energia. 2019. Usina à fio d'água e menor área alagada. Disponível em: <https://www.norteenergiasa.com.br/pt-br/uhe-belo-monte/arranjo>. Acesso em: 04 de novembro de 2019.

Paz, A. R.; Collischonn, W.; Tucci, C. E. M. 2010. Simulação hidrológica de rios com grandes planícies de inundação. *Revista Brasileira de Recursos Hídricos*, 15 (4), 31–43.

Pekel, J.-F., Cottam, A., Gorelick, N., Belward, A. S. 2016. High-resolution mapping of global surface water and its long-term changes. *Nature*, 540(7633), 418–422.

Plank, S., Jüssi, M., Martinis, S., Twele, A. 2017. Mapping of flooded vegetation by means of polarimetric Sentinel-1 and ALOS-2/PALSAR-2 imagery. *International Journal of Remote*

Sensing, 38(13), 3831–3850.

Poff, N. L., Richter, B. D., Arthington, A. H., Bunn, S. E., Naiman, R. J., Kendy, E., Acreman, M., Apse, C., Bledsoe, B. P., Freeman, M. C., Henriksen, J., Jacobson, R.B., Kennen, J. G., Merrit, D. M., O’Keeffe, J. H., Olden, J. D., Rogers, K., Tharme, R. E., Warner, A. 2010. The ecological limits of hydrologic alteration (ELOHA): a new framework for developing regional environmental flow standards. *Freshwater Biology*, 55(1), 147–170.

Ponzoni, F. J., Shimakuburo, Y. E., Kuplich, T. M. 2012. Sensoriamento remoto da vegetação. *Oficina de Textos*, 2ª edição, 176p.

Portal Brasil. 2016. Dilma inaugura Usina Hidrelétrica de Belo Monte. Disponível em: <http://www.brasil.gov.br/governo/2016/05/dilma-inaugura-usina-hidreletrica-de-belo-monte>.

Rahman, M. R., Thakur, P. K. 2017. Detecting, mapping and analysing of flood water propagation using synthetic aperture radar (SAR) satellite data and GIS: A case study from the Kendrapara District of Orissa State of India. *The Egyptian Journal of Remote Sensing and Space Sciences*, 21, 37–41. <https://doi.org/10.1016/j.ejrs.2017.10.002>

Rasheed, A. H., Hussein, H. M. 2017. Effect of different window size on median filter performance with variable noise densities. *International Journal of Computer Applications*, 178(2), 22.

Roscoche, L. F.; Vallerius, D. M. 2014. Os Impactos da Usina Hidrelétrica de Belo Monte nos Atrativos Turísticos da Região do Xingu. *Revista Eletrônica de Administração e Turismo*, 5(3), 414–430. Disponível em: <https://periodicos.ufpel.edu.br/ojs2/index.php/AT/article/view/2905/3547>. Acesso em: 03 de abril de 2018.

Salomão, R. P; Vieira, I. C. G.; Suemitsu, C.; Rosa, N. A.; Almeida, S. S.; Amaral, D. D.; Menezes, M. P. M. 2007. As florestas de Belo Monte na grande curva do rio Xingu, Amazônia Oriental. *Boletim do Museu Paraense Emílio Goeldi Ciências Naturais*, 2(3), 55–153. Disponível em: http://scielo.iec.gov.br/scielo.php?script=sci_arttext&pid=S198181142007000300006&lng=pt&nrm=iso.

Santoso, A. W., Bayuaji, L., Sze, L. T., Lateh, H., Mohamad, J. 2016. Comparison of various speckle noise reduction filters on Synthetic Aperture Radar Image. *International Journal of Applied Engineering Research*, 11(5), 8760–8767.

Shen, X., Wang, D., Mao, K., Anagnostou, E., Hong, Y. 2019. Inundation extent mapping by Synthetic Aperture Radar: a review. *Remote Sensing*, 11(7), 879.

Solbø, S., Solheim, I. 2004. Towards operational flood mapping with satellite SAR. *Proceedings of the 2004 Envisat & ERS Symposium (ESA SP-572)*. Salzburg, Austria. Disponível em: <http://adsabs.harvard.edu/full/2005ESASP.572E.264S>

Souza-Cruz-Buenaga, F. V. A., Espig, S. A., Castro, T. L. C., Santos, M. A. 2018. Environmental impacts of a reduced flow stretch on hydropower plants. *Brazilian Journal of Biology*. 2019, 79(3), 470–487. Disponível em: <http://www.scielo.br/pdf/bjb/v79n3/1519-6984-bjb-1519-6984183883.pdf>. Acesso em: 30 de outubro de 2019.

Souza Filho, P. W. M., Paradella, W. R., Souza Junior, C.; Valeriano, D. M.; Miranda, F. P. 2006. Sensoriamento Remoto e Recursos Naturais Da Amazônia. *Ciência e Cultura*, 58(3), 37–41.

Tian, H., Li, W., Wu, M., Huang, N., Li, G., Li, X., Niu, Z. 2017. Dynamic Monitoring of the Largest Freshwater Lake in China Using a New Water Index Derived from High Spatiotemporal Resolution Sentinel-1A Data. *Remote Sensing*, 9(6), 521.

Vanderbilt, V. C., Perry, G. L., Livingston, G. P., Ustin, S. L., Diax Barrios, M. C., Bréon, F.-M., Leroy, M. M., Balois, J. I., Morrissey, L. A., Shewchuk, S. R., Stearn, J. A., Syder, J. L. Herman, M. 2002. Inundation discriminated using sun glint. *IEEE Transactions on Geoscience and Remote Sensing*, 40(6), 1279–1287.

Vreugdenhil, M., Wagner, W., Bauer-Marschallinger, B., Pfeil, I., Teubner, I., Rüdiger, C., Strauss, P. 2018. Sensitivity of Sentinel-1 backscatter to vegetation dynamics: an Austrian case study. *Remote Sensing*, 10(9), 1396.

Welcomme, R. L., Winemiller, K. O., Cowx, I. G. 2006. Fish environmental guilds as a tool for assessment of ecological condition of rivers. *River Research and Applications*, 22(3), 377–396.

White, L., Brisco, B., Dabboor, M., Schmitt, A., Pratt, A. 2015. A collection of SAR methodologies for monitoring wetlands. *Remote Sensing*, 7(6), 7615–7645.