



UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE GEOCIÊNCIAS
PÓS-GRADUAÇÃO EM GEOCIÊNCIAS APLICADAS E GEODINÂMICA

**DETECÇÃO DE DESMATAMENTOS NO OESTE DA BAHIA COM DADOS DE
RADAR (SENTINEL-1A) UTILIZANDO A PLATAFORMA *GOOGLE EARTH*
*ENGINE***

Dissertação n° 140

THAISE DA SILVA RODRIGUES

Orientador: Prof. Dr. Edson Eyji Sano

THAISE DA SILVA RODRIGUES

**DETECÇÃO DE DESMATAMENTOS NO OESTE DA BAHIA COM DADOS DE
RADAR (SENTINEL-1A) UTILIZANDO A PLATAFORMA *GOOGLE EARTH*
*ENGINE***

Dissertação de mestrado apresentada à banca examinadora do Instituto de Geociências da Universidade de Brasília, como exigência para obtenção do título de mestra em Geociências Aplicadas.

Área de concentração:
Geoprocessamento Aplicado à Análise Ambiental

Orientador: Prof. Dr. Edson Eyji Sano

Brasília – DF

2018

Nome: Thaise da Silva Rodrigues

Título: Detecção de Desmatamentos no Oeste da Bahia com Dados de Radar (Sentinel-1A)
Utilizando a Plataforma *Google Earth Engine*

Dissertação de mestrado apresentada à banca examinadora do Instituto de Geociências da
Universidade de Brasília, como exigência para obtenção do título de mestra em
Geociências Aplicadas.

Aprovado em: 30/08/2018

Banca Examinadora

Edson Eyji Sano

Embrapa Cerrados – Orientador

Tati de Almeida

Universidade de Brasília – Examinador interno

Joselisa Maria Chaves

Universidade Estadual de Feira de Santana – Examinador externo

Brasília – DF

Agosto de 2018

DEDICATÓRIA

*Dedico esse trabalho aos
meus familiares e amigos.*

AGRADECIMENTOS

Esse trabalho é fruto de esforços e contribuições de muitas pessoas às quais gostaria de deixar os meus agradecimentos:

Ao meu orientador Dr. Edson Sano, pela sua dedicação, auxílio, orientação e paciência, tornando possível a conclusão desse estudo.

Aos membros da banca examinadora, por gentilmente aceitarem o convite e pelas contribuições para o aprimoramento desse trabalho.

Ao Programa de Pós-Graduação em Geociências Aplicadas e Geodinâmica, pelo suporte acadêmico, e aos professores, pelo conhecimento repassado nas disciplinas, enriquecendo minha formação.

Aos amigos que, de uma forma ou de outra, contribuíram com suas amizades e com sugestões para a realização desse trabalho. Meus agradecimentos especiais ao meu amigo Juan Doblás, por me apresentar a plataforma *Google Earth Engine* e por ajudar na elaboração do *script*. Ao meu amigo Daniel Freitas, por suas orientações e contribuição direta na saída de campo desse trabalho.

Aos meus colegas de pós-graduação, que, ao dividirem comigo suas experiências, me ajudaram nos momentos difíceis também por eles enfrentados.

Aos meus familiares, pelo apoio e incentivo na superação das dificuldades, encorajando-me a seguir na luta pelos meus objetivos.

A todos que não estão listados aqui, mas que participaram direta ou indiretamente na realização desse estudo.

SUMÁRIO

1. CONTEXTUALIZAÇÃO	1
1.1 Objetivos.....	4
2. REVISÃO BIBLIOGRÁFICA	5
2.1 O Cerrado e sua ocupação no Oeste da Bahia	5
2.2 Imagens de radar	9
2.2.1 Polarização.....	11
2.2.2 Interação com a superfície do objeto	12
2.2.3 Comprimento de onda.....	13
2.2.4 Constante dielétrica	15
2.2.5 Monitoramento terrestre por sensoriamento remoto de radar	16
2.3 Sentinel-1	19
2.4 Google Earth Engine.....	21
3. MATERIAIS E MÉTODOS	22
3.1 Área de estudo	22
3.1.1 Localização	23
3.2.1 Imagens de satélite.....	29
3.2.2 Dados vetoriais	30
3.2.3 <i>Software</i>	31
3.3 Abordagem metodológica	31
3.3.1 Detecção visual do desmatamento em imagens do satélite Landsat-8.....	31
3.3.2 Validação <i>in loco</i> do desmatamento em imagens do satélite Landsat-8.....	32
3.3.3 Processamento das imagens Sentinel-1A	34
3.3.4. Detecção de mudanças usando o <i>Google Earth Engine</i>	35
4. RESULTADOS E DISCUSSÃO.....	36
4.1 Detecção visual de desmatamento com base em imagens do Landsat-8 OLI	36
4.2 Validação da detecção visual de desmatamento com base em imagens do Landsat-8 OLI .	37
4.3 Relação entre coeficientes de retroespalhamento (σ^0) provenientes de áreas naturais e desmatadas	40
4.4 Definição de limiares de desmatamento	45
4.5 Acurácia da detecção automática de desmatamento	51
5. CONSIDERAÇÕES FINAIS	53
REFERÊNCIAS	54

APENDICE 1. Script desenvolvido no <i>Google Earth Engine</i>	64
APENDICE 2. Fotos dos pontos visitados em campo.....	71

LISTA DE FIGURAS

Figura 2.1 Ilustração das formações e categorias fitofisionômicas do bioma Cerrado	37
Figura 2.2 Comprimento de onda e frequência das principais bandas de radar	37
Figura 2.3 Retroespalhamento esperado da energia de micro-ondas de 3 cm de comprimento de onda conforme a rugosidade da superfície do terreno e ângulo de depressão de 45°	37
Figura 2.4 Ilustração teórica de como um pulso de radar emitido nas bandas L, C e X interage em um dossel florestal	37
Figura 2.5 Imagens de radar do satélite Sentinel-1A da área de estudo, obtidas nas polarizações VV (a) e VH (b), respectivamente.....	37
Figura 3.1 Localização da área de estudo no Oeste da Bahia	37
Figura 3.2 Normais climatológicas (1961-1990) para o município de Barreiras – BA	37
Figura 3.3 Mapa pedológico da área de estudo	37
Figura 3.4 Mapa geológico da área de estudo	37
Figura 3.5 Mapa geomorfológico da área de estudo	37
Figura 3.6 Exemplos de áreas com Cerrado Sentido Restrito em (a), (b) e (c), e formação florestal do tipo Cerradão em (d).....	37
Figura 3.7 Fluxograma da metodologia aplicada para detecção de desmatamento na área de estudo.....	37
Figura 4.1 Localização dos polígonos de desmatamento identificados com base na interpretação visual de imagens Landsat-8 OLI de 2016 e 2017.	37
Figura 4.2 Composição colorida RGB das bandas 6, 5 e 4 do satélite Landsat-8 de 02 de outubro de 2016 e 21 de outubro de 2017 (antes e depois do desmatamento) no município de Barreiras em (a) e (d) e as imagens correspondentes do satélite Sentinel-1A obtidas em 03 de outubro de 2016 e 10 de novembro de 2017 na polarização VV em (b) e (e) e na polarização VH, em (c) e (f).....	37
Figura 4.3 Mapa dos pontos visitados em campo na área de estudo.....	37
Figura 4.4 Áreas validadas em campo apresentando vários estágios de desmatamento	37
Figura 4.5 Relação entre coeficientes de retroespalhamento (dB) provenientes de polígonos de desmatamento identificadas em imagens Landsat-8 e áreas naturais (controle) em 2016 e	

em 2017 na polarização VV, sem filtragem espacial (a), com filtro Refined Lee (b) e com filtro Quegan & Yu (c)	37
Figura 4.6 Relação entre coeficientes de retroespalhamento (dB) provenientes de polígonos de desmatamento identificadas em imagens Landsat-8 e áreas naturais (controle) em 2016 e em 2017 na polarização VH, sem filtragem espacial (a), com filtro Refined Lee (b) e com filtro Quegan & Yu (c)	37
Figura 4.7 Relação entre os valores digitais obtidos da divisão 2017/2016 nas polarizações VV e VH para os polígonos de desmatamento identificados nas imagens Landsat-8 e os polígonos de vegetação natural (controle) do Cerrado sem filtragem espacial (a), com filtro Refined Lee (b) e com filtro Quegan & Yu (c).	37
Figura 4.8 <i>Boxplot</i> da polarização VV, representando a distribuição em quartis dos dados da razão 2017/2016 dos valores digitais dos polígonos de desmatamento e das áreas naturais (controle) de Cerrado, sem filtragem (a), com filtro Refined Lee (b) e com filtro Quegan & Yu (c).	37
Figura 4.9 <i>Boxplot</i> da polarização VH, representando a distribuição em quartis dos dados da razão 2017/2016 dos valores digitais dos polígonos de desmatamento e das áreas naturais (controle) de Cerrado, sem filtragem (a), com filtro Refined Lee (b) e com filtro Quegan & Yu (c).	37
Figura 4.10 Comparação visual dos dados de desmatamento detectados automaticamente nas imagens Sentinel-1A em azul, com três limiares diferentes (0,8; 0,7; e 0,6) com relação aos dados ópticos vetorizados nas imagens Landsat-8, em vermelho, na polarização VV..	37
Figura 4.11 Comparação dos dados de desmatamento detectados automaticamente nas imagens Sentinel-1A em azul, com três limiares diferentes (0,76; 0,7; e 0,6) com relação aos dados ópticos vetorizados nas imagens Landsat-8, em vermelho, na polarização VH..	37
Figura 4.12 <i>Boxplot</i> representando a distribuição em quartis dos dados relativos à razão 2017/2016 para as classes de desmatamento e queimadas na polarização VV, sem filtragem (a), com filtro Refined Lee (b) e filtro Quegan & Yu (c) e na polarização VH, sem filtragem (d), com filtro Refined Lee (f) e filtro Quegan & Yu (g)	37

LISTA DE TABELAS

Tabela 2.1 Principais comprimentos de onda e frequência utilizados no sensoriamento remoto por radar.	37
Tabela 3.1 Datas das imagens de radar do satélite Sentinel-1A para detecção de desmatamento no Oeste da Bahia e do satélite Landsat-8 OLI para validação da referida detecção, com a indicação dos períodos de ocorrência de desmatamento.	37
Tabela 4.1 Valores médios de retrospalhamento das áreas desmatadas e das áreas sem mudança na cobertura vegetal para as duas polarizações, e em cada filtro.....	37
Tabela 4.2 Erro global calculado para os dados de detecção automática do Sentinel-1A validados com base nos dados ópticos de desmatamento nas imagens Landsat-8, para a polarização VV, e para os dados sem filtro e com o filtro Refined Lee e Quegan & Yu, em cada limiar de corte aplicado.	37
Tabela 4.3 Erro global calculado para os dados de detecção automática do Sentinel-1A validados com base nos dados ópticos de desmatamento nas imagens Landsat-8, para a polarização VH, e para os dados sem filtro e com o filtro Refined Lee e Quegan & Yu, em cada limiar de corte aplicado.	37

RESUMO

O Cerrado, *hotspot* mundial para conservação da biodiversidade, vem sofrendo intensa transformação na sua paisagem natural nas últimas décadas. Isso se deve principalmente à conversão de sua vegetação nativa em cultivos agrícolas, resultantes da expansão da fronteira agropecuária na região central do Brasil. Diversos estudos foram realizados mapeando a sua cobertura vegetal, no entanto, iniciativas voltadas ao seu monitoramento contínuo se fazem necessárias. Com a disponibilização de dados gratuitos de sensor orbital de radar (Sentinel-1A) da Agência Espacial Europeia (ESA), esse trabalho tem como objetivo a análise do potencial desses dados para identificação de indicativos de desmatamentos recentes no Bioma Cerrado, tendo como estudo de caso, uma área do Oeste da Bahia. Para isso, foram utilizados dados ópticos do satélite Landsat-8 *Operational Land Imager* (OLI) como base para identificar as áreas desmatadas nas imagens Sentinel-1A e extrair os valores de coeficientes de retroespalhamento antes e após o desmatamento. Foram analisados também os valores referentes à diferença de imagens aplicada entre o período inicial (outubro de 2016) e o período final de estudo (outubro de 2017). As imagens do satélite Sentinel-1A foram obtidas e pré-processadas na plataforma *Google Earth Engine*. Um *script* foi desenvolvido dentro da plataforma para aplicação de dois filtros espaciais (Refined Lee e Quegan & Yu) e a realização da imagem de diferença por divisão logarítmica. Os valores obtidos das áreas desmatadas foram analisados estatisticamente e três limiares de corte foram aplicados para cada filtro e polarização (VV e VH), de modo a obter uma detecção automática de desmatamento. Dos filtros analisados, o Refined Lee apresentou melhor resultado de detecção para o limiar 0,60, com 95% de acurácia e 38,6% de omissão na polarização VH.

Palavras-chaves: Sentinel, desmatamento, Cerrado, sensoriamento remoto, Oeste da Bahia.

ABSTRACT

The Cerrado, one of the world's hotspot for biodiversity conservation, has faced intensive transformation of its natural landscape in the past decades. This is happening mainly because of the conversion of its natural vegetation into agricultural crops, as a result of the agriculture frontier expansion in the central region of Brazil. Several studies were accomplished with the purpose of mapping the Cerrado's land cover. However, initiatives regarding continuous monitoring is highly demanding. Because of the availability of new Sentinel-1A satellite radar data from the European Space Agency (ESA), this study intends to analyze the potential of these data to identify recent deforestation in the Cerrado, taking a region of western Bahia as the test site. For this purpose, Landsat-8 Operational Land Imager (OLI) satellite data were used as a basis to identify deforested areas in the Sentinel-1A images and to extract backscatter coefficient values. The values related to image difference applied between the initial period (October 2016) and the final period (October 2017) were also analyzed. Sentinel-1A satellite imagery was obtained and preprocessed in the Google Earth Engine platform. A script was developed to process two spatial filters (Refined Lee and Quegan & Yu), and a logarithmic difference image. The values obtained from the deforested areas were analyzed statistically and three thresholds were defined for each filter and polarization (VV and VH) to obtain an automatic deforestation detection. The Refined Lee filter presented better detection result for threshold of 0.60, with 95% overall accuracy and 38.6% omission in VH polarization.

Keywords: Sentinel, deforestation, Cerrado, remote sensing.

1. CONTEXTUALIZAÇÃO

O termo Cerrado é amplamente utilizado para abordar o conjunto de fitofisionomias (matas de terra firme, matas de galeria, savanas e campos, dentre outras) que ocorre no Brasil Central (RIBEIRO et al., 2008). Considerado a maior savana da América do Sul, o Cerrado é também o segundo maior bioma do Brasil, ocupando uma área aproximada de 2 milhões de km², cerca de 1/4 do território brasileiro (SILVA & BATES, 2002; IBGE, 2004). Sua extensão abrange uma área contínua de parte dos estados da Bahia, Goiás, Maranhão, Mato Grosso, Mato Grosso do Sul, Minas Gerais, Paraná, Piauí, São Paulo e Tocantins, além do Distrito Federal. Situado na região central do Brasil, o Cerrado apresenta alta heterogeneidade em termos de biodiversidade e fitofisionomias (ARRUDA et al., 2008) e faz divisa com quatro biomas: Amazônia, Caatinga, Mata Atlântica, Pampa e Pantanal.

Apesar da sua rica biodiversidade e reconhecimento cada vez mais notório da sua importância ambiental, por exemplo, para conservação de espécies endêmicas de fauna e flora e como importante fonte de abastecimento de águas superficiais e subterrâneas das principais bacias hidrográficas e sedimentares do país, apenas 8,2% de seu território é protegido por lei na forma de unidades de conservação. Desse total, somente 2,9% correspondem a unidades de conservação de proteção integral (estações ecológicas, florestas naturais, parques nacionais, refúgios de vida silvestre e reservas biológicas) (MMA, 2018).

Desde a década de 1970, o Cerrado tornou-se a nova fronteira de expansão agropecuária do país. A implementação de políticas e programas de modernização da agricultura por parte do Estado acarretou uma nova configuração econômica no Cerrado, fazendo com que seu território assumisse uma importância estratégica para o desenvolvimento de um novo modelo agrícola voltado a atingir altos índices de produtividade (SILVA, 2000; PESSÔA & INOCÊNCIO, 2014). Extensas áreas do Cerrado foram convertidas em plantações de soja, milho, feijão, algodão, café e cana-de-açúcar, sendo o cultivo da soja o mais proeminente (SANO et al., 2008; THE ECONOMIST, 2010; RADA, 2013; CARNEIRO FILHO & COSTA, 2016).

A agricultura é uma das maiores e mais dinâmicas atividades econômicas do Brasil e é improvável que os esforços investidos para a conservação do Cerrado sejam capazes de retardar ou parar a expansão do setor (MARRIS, 2005). No período de 2000 a 2014, o crescimento da produção de soja no Cerrado foi de 253% (CARNEIRO FILHO & COSTA, 2016). Em regiões como a de Matopiba (área contínua de Cerrado que cobre parte dos estados do Maranhão, Tocantins, Piauí e Bahia), mais de 60% da expansão agrícola ocorreram em áreas de vegetação nativa no referido período. Nessa região, destaca-se o Oeste da Bahia que, desde a década de 1980, transformou-se em um dos principais polos de produção de grãos do Brasil (BRANNSTROM et al., 2008; MENKE et al., 2009; FLORES et al., 2012). O processo de ocupação do Cerrado no Oeste da Bahia ocorreu de forma acelerada e vários fatores contribuíram para o avanço da expansão agrícola na região, entre eles: incentivos financeiros do governo; topografia plana, favorável à mecanização agrícola; e disponibilidade de terra barata e em abundância (MONDARDO, 2010; SANTOS et al., 2010).

Segundo Klink & Machado (2005), essas transformações trouxeram grandes danos ambientais ao Cerrado, tais como fragmentação de habitats, extinção da biodiversidade, invasão de espécies exóticas, erosão dos solos, poluição de aquíferos, degradação de ecossistemas, alterações nos regimes de queimadas, desequilíbrios no ciclo do carbono, além de possíveis modificações climáticas regionais. Essa intensa modificação da paisagem somada à alta diversidade da fauna e flora da região, fez com que esse bioma se tornasse um *hotspot* mundial para conservação da biodiversidade (MYERS et al., 2000).

As sucessivas transformações ocorridas no Cerrado e o *status* de ameaçado de extinção de muitas de suas espécies levaram a um aumento de projetos de conservação de diversos setores da sociedade (KLINK & MACHADO, 2005). Iniciativas de mapeamento semidetalhado da cobertura vegetal natural e uso antrópico no Cerrado com a finalidade de monitorar a ocupação do Cerrado têm sido realizadas pelo Ministério do Meio Ambiente (MMA). Esses são os casos do Projeto de Conservação e Utilização Sustentável da Diversidade Biológica Brasileira (PROBIO) e do Projeto TerraClass Cerrado, que produziram os mapas de uso e cobertura de terras do Cerrado de 2002 (SANO et al., 2008; 2010) e 2013 (MMA, 2015), respectivamente, baseados no processamento e análise de imagens do satélite Landsat.

No mapeamento do uso da terra do bioma Cerrado para o ano de 2002, verificou-se que aproximadamente 39,5% do Cerrado apresentava algum tipo de uso da terra. Pastagens cultivadas e culturas agrícolas foram as classes predominantes, com 26,5% e 10,5%, respectivamente (SANO et al., 2008; 2010). No levantamento realizado pelo Projeto TerraClass Cerrado, identificou-se que 43,4% do Cerrado apresentavam algum tipo de uso antrópico. Faltam, ainda, estudos que avaliem, com mais precisão, os impactos da conversão da terra para a agricultura e outros usos, ou que mensurem a magnitude de esforços a serem investidos na proteção dos diferentes ecossistemas naturais e remanescentes dessa região (SILVA et al., 2006). Segundo Sano et al. (2010), essa deficiência resulta, provavelmente, da dificuldade e dos custos envolvidos no mapeamento detalhado de um bioma tão heterogêneo.

Existe ainda a necessidade de desenvolvimento de projetos operacionais de detecção de desmatamentos (remoção da cobertura vegetal natural) recentes no Cerrado para fins de fiscalização e controle de desmatamentos ilegais, como ocorre no bioma da Amazônia. A Amazônia conta com o Sistema de Detecção de Desmatamentos em Tempo Real (DETER) e o Monitoramento da Floresta Amazônica Brasileira por Satélite (PRODES), desenvolvidos pelo Instituto Nacional de Pesquisas Espaciais (INPE) como parte do Plano de Ação para a Prevenção e Controle do Desmatamento na Amazônia Legal (PPCDam) do MMA. As informações geradas por esses programas são essenciais para elaboração de estratégias de conservação na Amazônia Legal e ainda servem de subsídio para ações de fiscalização (INPE, 2018). O Cerrado, por outro lado, ofuscado pela elevada atenção aos passivos ambientais na Amazônia, ainda não tem recebido o merecido destaque por parte dos programas governamentais de preservação (FERREIRA et al., 2009).

Algumas dificuldades técnicas também representam um obstáculo para o efetivo monitoramento do desmatamento do Cerrado, como, por exemplo, a extensa área a ser recoberta por imagens de satélite de resolução espacial média-alta, período relativamente longo com ocorrência de nuvens, além de dificuldades de processamento e diferenciação de algumas fitofisionomias devido à sua forte mistura espectral (FERREIRA et al., 2009). Uma opção ou complementação ao monitoramento do desmatamento baseado em dados ópticos são os dados de radar. A discriminação de alvos nos dados de radar acontece de modo distinto em relação às imagens ópticas. A discriminação de alvos nas imagens ópticas

é baseada em diferenças na quantidade de energia refletida pelos diferentes alvos presentes na superfície terrestre nas faixas espectrais micrométricas do visível e do infravermelho próximo e médio. Nas imagens de radar, que operam nas faixas espectrais centimétricas, a distinção ocorre basicamente em função das diferenças na rugosidade do terreno, na constante dielétrica e na estrutura e biomassa da vegetação (JENSEN, 2011). A grande vantagem das imagens de radar é a sua independência em relação à presença de nuvens e às variações nas condições de iluminação solar (MENESES & ALMEIDA, 2012). Por outro lado, a interpretação dos dados de radar é mais complexa em relação aos dados ópticos, isto é, a identificação de alvos é mais imediata nas imagens ópticas, pois as imagens produzidas por sensores ópticos são mais similares às produzidas pelo olho humano.

Desde o início da década de 1990, diversos satélites de radar estão sendo lançados. Esses são os casos do satélite canadense RADARSAT (banda C; ~ 5 cm de comprimento de onda), do satélite japonês *Advanced Land Observing Satellite* (ALOS; banda L; ~ 23 cm de comprimento de onda), do satélite italiano Cosmos-SkyMed (banda X; ~ 3 cm de comprimento de onda) e do satélite alemão TerraSAR-X (banda X). No dia 03 de abril de 2014, a Agência Espacial Europeia (ESA) lançou o satélite de radar denominado de Sentinel-1A, que opera na banda C, polarizações VV e VH (H = polarização horizontal; V = polarização vertical) e resolução espacial de 20 metros no modo de imageamento *Interferometric Wide* (IW) (ESA, 2012; TORRES et al., 2012). Pela primeira vez, os dados de radar do Sentinel-1A estão sendo disponibilizados sem custos na internet, podendo ser obtidos em diversas plataformas como o *Earth Explorer* do Serviço Geológico dos Estados Unidos (USGS). Até o momento, não existe nenhum estudo que tenha avaliado o potencial das imagens do Sentinel-1A para detecção de desmatamentos recentes no bioma Cerrado.

1.1 Objetivos

O objetivo geral deste estudo é analisar o potencial dos novos dados do satélite Sentinel-1A para detecção de indicativos de desmatamentos recentes no bioma Cerrado. Como objetivos específicos, têm-se:

- a) Identificar, com base na técnica de detecção de mudanças (*change detection*) aplicada às imagens do satélite Sentinel-1A, os polígonos de desmatamentos recentes em uma região representativa do bioma Cerrado; e
- b) Analisar, com base na interpretação visual de imagens do satélite Landsat-8, os erros de omissão e comissão relativos à detecção de desmatamentos recentes baseados nas imagens do satélite Sentinel-1A.

2. REVISÃO BIBLIOGRÁFICA

2.1 O Cerrado e sua ocupação no Oeste da Bahia

De acordo com IBGE (2004), o Cerrado ocupa uma área de 204,7 milhões de hectares e concentra-se na região central do Brasil e em partes dos estados da Bahia, Goiás, Maranhão, Mato Grosso, Mato Grosso do Sul, Minas Gerais, Paraná, Piauí, São Paulo e Tocantins, além do Distrito Federal. Sua localização geográfica é condicionada predominantemente por fatores climáticos (temperatura, pluviosidade e umidade relativa) e em menor grau pelo tipo de substrato. O clima do Cerrado caracteriza-se pela presença de invernos secos e verões chuvosos, classificado como Aw de Köppen (tropical chuvoso). As chuvas se concentram geralmente de outubro a março, com precipitação média anual de 1500 mm, e a temperatura média dos meses mais frios é superior a 18 °C (RIBEIRO & WALTER, 1998).

O termo Cerrado pode ser usado tanto para se referir ao bioma, como também para designar tipos e formas de vegetação (BATALHA, 2011). No sentido amplo (*lato sensu*), o Cerrado abrange três formações fitofisionômicas: florestais, savânicas e campestres (RIBEIRO & WALTER, 1998). A Figura 2.1 ilustra as formas de vegetação presentes nesse bioma.

As formações florestais possuem predominância do estrato arbóreo, com formação de dossel, seja contínuo ou descontínuo. As fisionomias vegetais desse grupo são classificadas em Mata Ciliar, Mata de Galeria, Mata Seca e Cerradão. As formações savânicas compõem o Cerrado no sentido restrito, ou *stricto sensu*, e se caracterizam pela

presença de árvores e arbustos espalhados sobre um estrato herbáceo, sem a formação de dossel contínuo. As subclasses desse grupo se distinguem pela densidade de espécies arbóreas e arbustivas e são classificadas em Cerrado Denso, Típico e Ralo. Já as formações campestres referem-se às áreas com predomínio de espécies herbáceas e algumas arbustivas, cuja ocorrência em maior ou menor grau é critério de classificação em Campo Sujo e Campo Limpo. Nas formações savânicas e campestres, existe ainda o Cerrado Rupestre e o Campo Rupestre, respectivamente, que se caracterizam pela ocorrência em solos rasos com presença de afloramentos rochosos (RIBEIRO & WALTER, 1998).

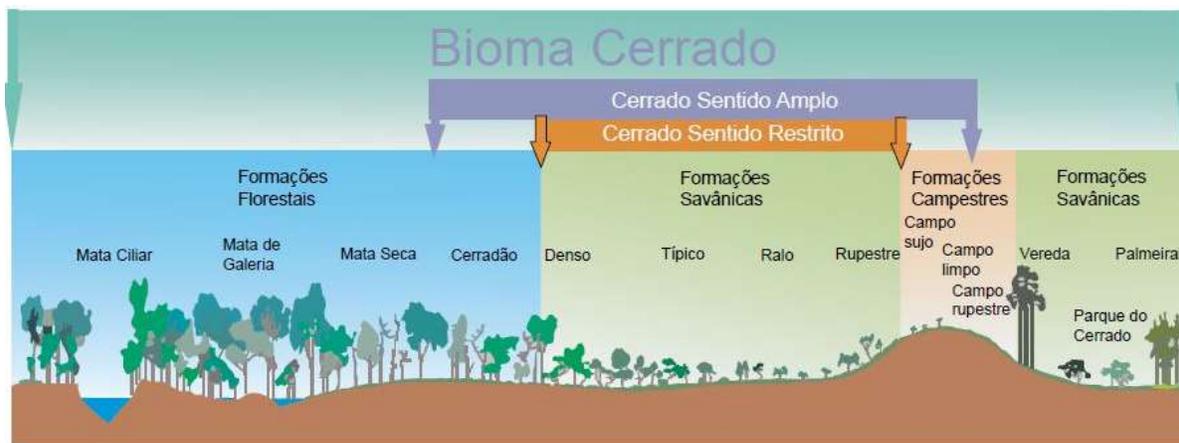


Figura 2.1 Ilustração das formações e categorias fitofisionômicas do bioma Cerrado. Fonte: Ribeiro & Walter (2008).

A vegetação do Cerrado desenvolveu-se sobre solos geralmente antigos, intemperizados, ácidos, deficientes em nutrientes e com concentrações elevadas de alumínio e sílica. Apesar disso, a pobreza dos solos não representou um obstáculo para a ocupação agrícola na região (KLINK & MACHADO, 2005). Na década de 1970, ainda era predominante a visão de que o Cerrado não oferecia potencial para exploração produtiva. Entretanto, com a implementação da “modernização conservadora” na agricultura, com grandes áreas de monocultura de grãos, o Cerrado foi sendo degradado no decorrer do tempo. A grande disponibilidade de terras que possuíam topografia plana, suavemente ondulada, favoreceu a agricultura mecanizada e a irrigação. Segundo Rezende (2002), o desenvolvimento de técnicas para a correção da acidez e dos problemas de baixa fertilidade natural provocou uma imensa mudança na aptidão agrícola dos solos do

Cerrado. Essa descoberta tecnológica tornou viável a expansão da fronteira agrícola sobre esse domínio fitogeográfico de modo extraordinariamente rápido (BERTOLINI, 2005).

O início da sua ocupação deu-se pela exploração mineradora. Com o esgotamento das reservas minerais, a economia local regrediu para uma agricultura de subsistência incipiente. O processo de ocupação agrícola se intensificou com a construção da ferrovia que ligava São Paulo à cidade de Anápolis, em 1930 e, a partir de 1950, a fronteira agrícola da região teve seu avanço intensificado com a construção de Brasília e do sistema rodoviário (MAROUELLI, 2003).

O estado desempenhou função relevante nesse processo de ocupação da terra. Ofertas de abundantes recursos a taxas sem juros, incentivos à pesquisa de variedades vegetais adequadas ao Cerrado e políticas e programas governamentais destinados a melhorar a infraestrutura agrícola beneficiaram a produção (HOSONO et al., 2016). O Polocentro e o Prodecer foram os programas que tiveram maior impacto sobre o crescimento da agricultura no Cerrado. Os vastos plantios de soja, milho, algodão, feijão e café são predominantes em regiões como Luís Eduardo Magalhães (BA), Jataí e Rio Verde (GO) e Lucas do Rio Verde, Sorriso e Sinop (MT) (SANO et al., 2008).

A região oeste do estado da Bahia corresponde a uma área representativa dessa ocupação agrícola no Cerrado. O Oeste da Bahia passou por um intenso desenvolvimento nas últimas décadas, tendo sua paisagem natural sofrido sucessivas transformações devido ao avanço da agricultura mecanizada e aos plantios em larga escala de diversos gêneros agrícolas desde o início da década de 1980 (EMBRAPA, 2010; MONDARDO, 2010; FLORES, 2012). O desmatamento do Cerrado do Oeste da Bahia, com fins para a agricultura, aconteceu de forma mais tardia em relação a outras áreas. Devido ao conhecimento dos solos pobres em nutrientes da região, aliado à carga depreciativa que a mídia promovia sobre o Nordeste brasileiro (“indústria da seca”), acreditava-se que não era possível a produção de grãos em larga escala nessa porção do país, como já ocorria no sul do Brasil (BORGES, 2014). Contudo, os baixos preços das terras, a oferta de mão-de-obra de baixo custo, a topografia e as condições climáticas favoráveis, o grande potencial para irrigação e os incentivos financeiros do governo contribuíram para o avanço da expansão agrícola na região (EMBRAPA, 2010; MONDARDO, 2010).

Outro fator que pode ser considerado, segundo Mondardo (2010), como participante nesse processo de avanço do cultivo agrícola na região, consiste na diferença das determinações legais ambientais aplicadas ao bioma Cerrado com relação ao da Amazônia, uma vez que nesse último bioma a obrigação de preservação ambiental é de 80% das propriedades rurais, enquanto no Cerrado é de 35% (quando inserido na Amazônia Legal) ou 20% (quando fora da Amazônia Legal) (SOARES-FILHO et al., 2014). As características biofísicas da paisagem do Oeste da Bahia, conforme já mencionado, desempenharam também papel determinante na consolidação desse processo, dado que os solos profundos da região, a estação climática bem definida e a topografia plana e elevada proporcionaram a mecanização das terras e favoreceram a produção de grãos (BORGES, 2014).

A mecanização e a modernização trazidas por imigrantes sulistas, incentivados pelo Estado e pela grande “oferta” de terras, permitiram o desenvolvimento de culturas fazendo uso, por exemplo, de defensivos agrícolas para o controle de pragas e doenças, colheitadeiras, beneficiamento de sementes e pivôs-centrais de irrigação (FLORES, 2012). A pecuária extensiva, em muitas áreas, foi substituída por monoculturas com produção em larga escala da soja, milho, algodão e feijão, tornando-se, assim, uma região de produção para exportação (MORAES, 2003; EMBRAPA, 2010). Esse processo acentuado de expansão agroindustrial fez do Oeste da Bahia uma região de fundamental importância no desenvolvimento do país, integrando a mais nova fronteira agrícola brasileira, composta pelo Cerrado dos estados do Maranhão, Tocantins, Piauí e Bahia, chamada de MATOPIBA (BORGES, 2014).

É claro que todo esse processo de transformação traz consigo e de modo simultâneo, sérios impactos ambientais ocasionados pelo desmatamento acelerado, uso excessivo dos recursos hídricos para irrigação, alterações no uso da terra com a utilização de fertilizantes, tratores e maquinários e inserção de espécies vegetais exóticas ao ambiente. Sua cobertura vegetal original está bastante fragmentada e vem sendo transformada para fins agrícolas em ritmo acelerado (RIBEIRO et al., 2008). A falta de planejamento e de um zoneamento agrícola que promova o manejo sustentável da agropecuária acarretam diversos impactos ambientais como a erosão hídrica e eólica, a perda de habitats, a alteração das características da fauna e flora, a diminuição da vazão, o assoreamento da rede de

drenagem e a perda genética, com consequente redução da biodiversidade (EMBRAPA, 2010; MONDARDO, 2010).

Contrapõe-se ao sucessivo processo de degradação do Cerrado, o grande avanço das tecnologias de sensoriamento remoto e dos sistemas de informações geográficas, tecnologia fundamental no monitoramento de mudanças da cobertura vegetal dos biomas, em particular o Cerrado, que tem recebido poucos investimentos voltados à sua conservação (ROCHA et al., 2011).

2.2 Imagens de radar

Na literatura, são encontradas várias formas e critérios empregados na definição de sensoriamento remoto. Para Jensen (2011), o sensoriamento remoto é a ciência de obter informações de um determinado objeto, área ou fenômeno através da análise dos dados adquiridos sem o contato direto com os objetos pesquisados. Já para Novo (2008), o sensoriamento remoto é a utilização conjunta de sensores para processamento de dados e equipamentos de transmissão desses dados de aeronaves, com o objetivo de estudar eventos, fenômenos e processos que ocorrem na superfície do planeta. Esse procedimento é feito a partir do registro e da análise das interações entre a radiação eletromagnética (REM) e as substâncias que a compõem. A REM é uma forma de transmissão da energia que consiste na aceleração de uma carga elétrica que provoca perturbações no campo elétrico e magnético, propagando-se no vácuo.

A maioria dos sensores utilizados no sensoriamento remoto utiliza o Sol como fonte de REM. Esses sensores são chamados de passivos. Há também os sistemas ativos, que independem da energia eletromagnética do Sol ou da energia emitida pela Terra na faixa espectral do termal. Dentre esses sistemas, o radar (*radio detection and ranging*) é o mais amplamente utilizado. A Figura 2.2 ilustra as diferentes regiões do espectro eletromagnético como também as bandas espectrais da região de micro-ondas.

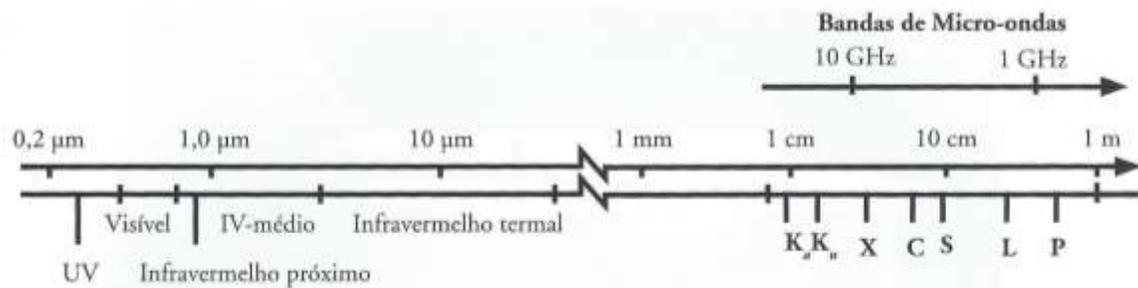


Figura 2.2 Comprimento de onda e frequência das principais bandas de radar. As antenas de radar transmitem e recebem a energia refletida em comprimentos de onda maiores (centímetros) Fonte: Jensen (2011).

O uso do radar teve início em 1922 para estimar a distância de navios no mar por meio de sinais de ondas de rádio e embora hoje a maioria dos sistemas de radar usem pulsos de radiação emitidos nos comprimentos de ondas das micro-ondas, ao invés de ondas de rádio, o acrônimo nunca foi alterado (JENSEN, 2011). Os sistemas de radar emitem sua própria energia em direção à superfície do terreno; ao interagir com um determinado alvo, parte da energia é retroespalhada, sendo registrada em seguida pela mesma antena que emitiu o sinal. Quanto maior for o retroespalhamento, mais clara será a tonalidade de cinza em uma imagem de radar (KUPLICH, 2003).

Esses sistemas podem ser aerotransportados ou colocados a bordo de satélites orbitais. Seu funcionamento tem, como base, uma antena fixada abaixo da aeronave ou satélite, que é direcionada para o lado (visada lateral). Por conta disso, dados de radar eram originalmente chamados de radares de visada lateral, em inglês, *side-looking radar* (SLR) ou *side-looking airborne radar* (SLAR), no caso de sistemas aerotransportados (LILLESAND, 2008). Segundo Jensen (2011), a sigla SLAR também pode significar “radar de abertura real”, onde a palavra “abertura” se refere à antena. Sistemas modernos de imageamento de radar usam métodos avançados de processamentos de dados, referidos hoje como radares de abertura sintética (*synthetic aperture radar* - SAR), uma vez que esses sistemas, além de contarem com uma antena de comprimento fixo, são capazes de simular uma antena muito maior (LILLESAND, 2008; JENSEN, 2011).

Os sistemas de radar diferem dos sensores ópticos na forma de imageamento da superfície terrestre. A discriminação de alvos nos dados de radar é baseada nas diferenças de rugosidade, umidade de solo e estrutura da vegetação, enquanto que os dados ópticos

fundamentam-se, por exemplo, nas diferenças de composição química e estrutura cristalina dos materiais (MENESES & ALMEIDA, 2012; LEHMANN et al., 2015).

Caracterizada por vários níveis de cinza, as imagens de radar devem ser interpretadas pela análise de diferenças de textura e de tonalidade. Pixels mais claros são resultado de um forte retroespalhamento, enquanto pixels com tons mais escuros são derivados de um baixo retroespalhamento (FREITAS, 2012). Essa variabilidade de textura e tons, de diversos valores de retroespalhamento, é resultado da sensibilidade da variação dos sinais de SAR relacionadas com variações na topografia, rugosidade do terreno e propriedades dielétricas dos materiais da superfície terrestre (KUMARA & PATNAIKB, 2013).

2.2.1 Polarização

A polarização se refere à orientação do campo elétrico de uma onda eletromagnética (WOODHOUSE, 2006). Nos sistemas de radar, são emitidos feixes de radiação em micro-ondas polarizadas por um cristal polarizador com eixo de transmissão posicionado na horizontal ou na vertical. Assim, a antena pode emitir um pulso de energia na direção horizontal (H) ou vertical (V) e registra a parte da energia retroespalhada também em uma das duas direções. Quando o pulso atinge um objeto, pode ocorrer a despolarização devido aos múltiplos espalhamentos gerados na interação com os alvos da superfície terrestre, de modo que o sinal pode retornar à antena numa direção diferente da polarização emitida. Dessa forma, a polarização de uma imagem de radar pode ser transmitida e recebida na direção horizontal ou vertical, chamada de polarização paralela (HH ou VV), como também pode ser transmitida em uma direção e recebida em outra, resultando na polarização cruzada (HV ou VH) (MENESES & ALMEIDA, 2012). A primeira letra indica a polarização de transmissão e a segunda indica a de recepção.

A polarização utilizada influencia na interação da onda em um alvo e, conseqüentemente, na discriminação dos materiais em função das variações de rugosidade da superfície (MENESES & ALMEIDA, 2012). Dados com polarização horizontal favorecem a discriminação entre áreas recém-desmatadas e floresta primária, já que a radiação emitida nessa polarização interage fortemente com os troncos deixados no chão

(KUPLICH, 2003). Satélites que apresentam dados de uma única polarização mostram, segundo Búfalo (2005), uma maior confusão para discriminar áreas recentes de desmatamentos. Já polarizações cruzadas, por exemplo, permitem uma melhor compreensão da interação do sinal com estruturas complexas de troncos e galhos de florestas como também na distinção entre os diferentes tipos de cobertura da terra (SANTOS et al., 2000; RAHMAN & SUMANTYO, 2010).

2.2.2 Interação com a superfície do objeto

Como a radiação em micro-ondas possui comprimentos de onda relativamente longos, as informações extraídas das imagens de radar são dependentes de uma relação entre o tamanho da onda com as variações texturais e estruturais das superfícies do terreno (MENESES & ALMEIDA, 2012). A rugosidade da superfície imageada, por exemplo, é um importante fator que influenciará o retorno do sinal de radar e a intensidade da energia retroespalhada. A quantidade dessa energia de micro-ondas retroespalhada em direção ao sensor é uma função da relação entre o comprimento de onda da energia incidente, o ângulo de depressão e a altura local dos objetos imageados. A Figura 2.3 ilustra o retroespalhamento esperado da energia de micro-ondas de acordo com as características de superfície do terreno.

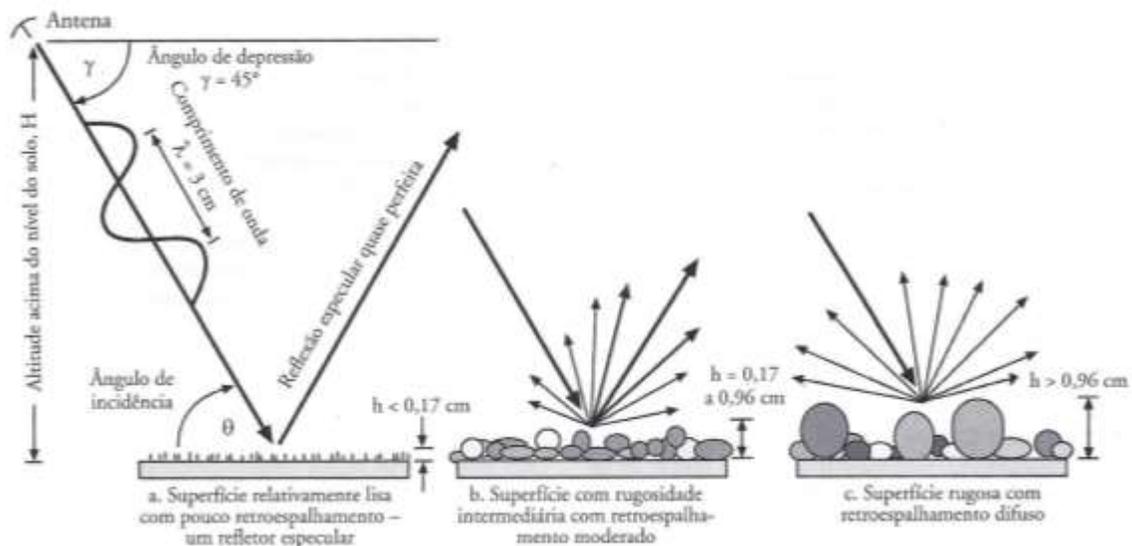


Figura 2.3 Retroespalhamento esperado da energia de micro-ondas de 3 cm de comprimento de onda conforme a rugosidade da superfície do terreno e ângulo de depressão de 45° . Em (a), um terreno com índice de rugosidade relativamente baixo ($h <$

0,17 cm), causando uma reflexão especular da radiação incidente. Esse tipo de reflexão aparece com tonalidade cinza escura em uma imagem de radar. Em (b), uma superfície com rugosidade intermediária ($0,17 < h < 0,96$ cm), produzindo uma resposta em tons de cinza intermediário em uma imagem do radar. Em (c), uma superfície com alta rugosidade ($h > 0,96$ cm), produzindo uma dispersão bastante difusa da radiação incidente. Este refletor difuso produzirá uma tonalidade de cinza claro em uma imagem de radar, devido à grande quantidade de energia refletida de volta para a antena. h = rugosidade do terreno. Fonte: Jensen (2011).

Uma área que apresenta superfície lisa retorna muito pouca energia retroespalhada para a antena, uma vez que a maior parte é refletida pelo terreno longe da antena. Dessa forma, a pequena parte que é registrada aparece escura na imagem do radar (JENSEN, 2011). À medida que a superfície apresenta maior rugosidade, a reflexão se torna mais difusa, e o retroespalhamento do sinal ocorre em todas as direções e com intensidades relativamente mais altas. De modo geral, a intensidade de retroespalhamento na imagem é diretamente proporcional à rugosidade de uma superfície. Em outras palavras, a rugosidade do objeto imageado determina o tipo de espalhamento. No caso de estruturas vegetais, o tamanho e a densidade desses elementos têm relação direta no tipo de interação com as micro-ondas incidentes e todos esses fatores são altamente influenciados pelo comprimento de onda (KUPLICH, 2003).

2.2.3 Comprimento de onda

O pulso de REM emitido pela antena possui uma duração e comprimento de onda específicos. A energia das micro-ondas é medida geralmente em centímetros, e os radares imageadores utilizados no sensoriamento remoto operam com pulsos que variam entre 1 cm a 100 cm de comprimento de onda (JENSEN, 2011). A Tabela 2.1 descreve as principais bandas de imageamento e seus respectivos comprimentos de onda e frequência utilizados.

Com relação à estrutura das feições representadas em uma imagem de radar, é importante selecionar comprimentos de ondas compatíveis com tamanho do alvo que se deseja identificar (MENESES & ALMEIDA, 2012). Quanto maior o comprimento de onda utilizado, maior será a penetração da radiação incidente no alvo imageado (MATHER, 1999; JENSEN, 2011). Para estudos florestais, por exemplo, pequenos comprimentos de onda, categorizados nas bandas X (comprimento de onda ~ 3 cm) e C (~ 5 cm), interagem

com camadas superiores do dossel através do retroespalhamento produzido nas folhas e pequenos galhos (Figura 2.4). Bandas com comprimentos de onda maiores, isto é, a banda L (~ 23 cm) e a banda P (~ 70 cm), possuem maior penetração no dossel vegetal, sendo o retroespalhamento ocasionado pelos troncos e galhos maiores (DOBSON, 2000).

Tabela 2.1 Principais comprimentos de onda e frequência utilizados no sensoriamento remoto por radar.

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

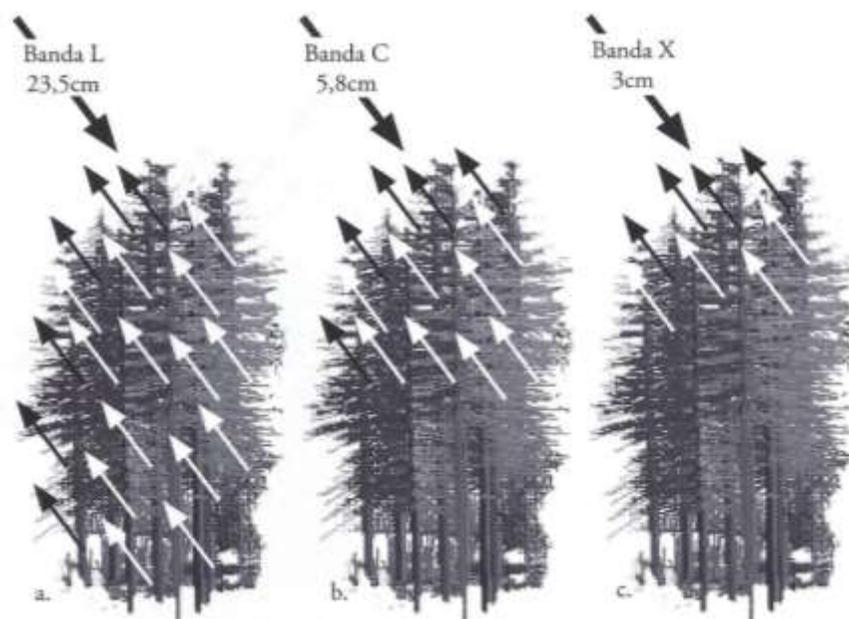


Figura 2.4 Ilustração teórica de como um pulso de radar emitido nas bandas L, C e X interage em um dossel florestal. Quanto maior o comprimento de onda, maior a capacidade de penetração e volume de espalhamento. Fonte: Jensen (2011).

Por isso, comprimentos de ondas mais longos têm mostrado maior sucesso na extração de parâmetros florestais (e.g., estoque de biomassa) quando usados em florestas mais densas, como também em florestas mais abertas como savanas (MAIN et al., 2016). Por outro lado, comprimentos de onda mais curtos facilitam a diferenciação entre espécies vegetais com menor biomassa (e.g., culturas agrícolas), pois sua penetração se restringe ao topo do dossel (KUPLICH, 2003).

2.2.4 Constante dielétrica

As propriedades dielétricas referem-se à capacidade dos materiais de formar dipolos, armazenar e conduzir energia elétrica na presença de um campo elétrico externo. Como a água possui alta constante dielétrica (ϵ), essa constante irá variar nos alvos naturais conforme a presença de água livre na sua estrutura. Assim, variações no conteúdo de água nos diferentes alvos vão influenciar fortemente na interação da REM com a superfície do terreno, sendo a micro-ondas a região do espectro eletromagnético que permite estimativas relativamente precisas de umidade de solos a partir de dados de sensoriamento remoto (FREITAS, 2012; MENESES & ALMEIDA, 2012).

Dessa forma, gradientes no teor de umidade do solo e no teor de água nas plantas entre tipos distintos de fitofisionomias produzem diferenças nos coeficientes de retroespalhamento (σ^0). No caso do Cerrado, Matas de Galeria, comumente encontradas ao longo de cursos d'água, são distinguidas de formações campestres e savânicas pela sua quantidade relativamente maior de água da planta e conteúdo de umidade do solo (SANO et al., 2005). O processo de retroespalhamento é influenciado pelas características dielétricas e a estrutura dos constituintes vegetais de diferentes formas, dependendo também da frequência em que os sensores operam, do ângulo de incidência e da polarização (SANO et al., 2001).

Nas últimas décadas, os dados de radar tiveram seu uso estendido para diversas aplicações em pesquisas ambientais, monitoramento de riscos, mapeamento topográfico, monitoramento da superfície dos oceanos para identificação de manchas de óleo, determinação de direção do vento, ondas e condições de gelo, dentre outras aplicações (LILLESAND, 2008; ROTT, 2009). Apesar do crescente número de pesquisas e estudos

com imagens de radar, esses dados, no entanto, não tiveram seu uso tão difundido como os dados de sensores ópticos (KUPLICH, 2003). O avanço na aquisição de imagens e radar e das técnicas de análise, a aplicação dessa tecnologia no sensoriamento remoto terrestre está ainda em constante evolução (LILLESAND, 2008). A dificuldade de interpretação e processamento desses dados representam uns dos obstáculos para sua disseminação (KASISCHKE et al., 1997).

2.2.5 Monitoramento terrestre por sensoriamento remoto de radar

A observação da Terra por sensores remotos possibilitou importantes avanços nos métodos e técnicas de mapeamento e monitoramento dos ecossistemas terrestres (KUPLICH, 2003). Dados de sensores obtidos na faixa óptica do espectro eletromagnético têm sido tradicionalmente utilizados na discriminação de diferentes classes de uso e cobertura da terra e como fonte primária de informações para subsidiar planos de controle, fiscalização e conservação de florestas (NOVO, 2008). Atualmente, existe a alternativa do uso de dados de radar. Por ser um sensor ativo, seu funcionamento não depende da iluminação solar e das condições atmosféricas, fator limitante nos dados ópticos (ROSA, 2011).

No que se refere aos dados ópticos, imagens do satélite Landsat têm sido a principal fonte de dados na realização de ações e programas voltados ao mapeamento da cobertura vegetal dos biomas brasileiros (SOUZA FILHO et al., 2006). Em 2006, o MMA elaborou um mapeamento da cobertura vegetal de todos os biomas brasileiros para o ano de 2002, por meio de convênios acordados com diferentes instituições do país. Em 2008, um acordo de cooperação técnica entre o MMA, o IBAMA e o PNUD foi estabelecido para elaboração e execução do Programa de Monitoramento do Desmatamento nos Biomas Brasileiros por Satélite (PMDBBS), visando quantificar o desflorestamento de áreas de vegetação nativa e, com isso, embasar ações de fiscalização e combate a desmatamentos ilegais nesses biomas (ROSA, 2011).

O monitoramento de desmatamento também tem sido foco de ações e programas do governo brasileiro junto a instituições ambientais e pesquisas espaciais, tendo como prioridade o bioma da Amazônia. Dentre esses programas, estão o PRODES e o DETER. O

PRODES é o sistema de detecção de desmatamentos que, desde 1988, vem calculando as taxas anuais de desflorestamento da Amazônia Legal baseado em imagens dos satélites da série Landsat. Já o DETER possui um sistema de detecção de desmatamentos em tempo quase real, realizado pelo INPE desde 2004, com dados do sensor *Moderate Resolution Imaging Spectrometer* (MODIS) do satélite Terra e, mais recentemente, com dados do sensor RESOURCESAT-2 AWIFS. Essas informações dão suporte à fiscalização e combate aos desmatamentos ilegais que vem sendo realizadas pelo IBAMA, possibilitando uma atuação mais rápida para interromper os desmatamentos detectados ainda em curso (INPE, 2016).

Quanto aos dados de radar, sua utilização no Brasil teve início na década de 1970 com o Projeto RADAM/RADAMBRASIL, cujo objetivo era a pesquisa de recursos naturais e mapeamento de todo o território nacional (CPRM, 2016). Nesse projeto, o mapeamento foi realizado utilizando um sistema de radar aerotransportado (banda X, polarização HH, faixa de imageamento de 37 km na direção norte-sul e sobreposição lateral de 25%). Já o surgimento de dados de radar a bordo de satélites teve início em 1978 com o lançamento das missões com ônibus espaciais da série *Shuttle Imaging Radar* (SIR), seguido na década de 1980 pelo programa *Soviet Cosmos Experiments*. Na década de 1990, os dados de radar começaram a ser obtidos por meio de satélite, com o lançamento do Almaz-1 em 1991, *Earth Resource Satellite* (ERS-1) em 1991, *Japanese Earth Resources Satellite* (JERS-1) em 1991 e Radarsat em 1995 (LILLESAND, 2008).

Os lançamentos desses satélites e outros nas décadas seguintes, como o *Environmental Satellite* (ENVISAT) da Agência Espacial Europeia (ESA), lançado em março de 2002, o *Advanced Land Observing System* (ALOS-1), da Agência de Exploração Aeroespacial do Japão (JAXA), lançado em janeiro de 2006, possibilitaram uma quantidade significativa de pesquisas voltadas a investigar o potencial dessas imagens na geração de informações sobre o monitoramento terrestre (FERREIRA et al., 2008). Atualmente, existem diferentes sistemas geradores de imagens SAR em nível orbital que operam em distintas bandas, como o RADARSAT-2 (banda C), o TerraSAR-X (banda X) e a constelação COSMO-SkyMed (banda X), e mais recentemente o Sentinel-1A (banda C). Como exemplo de radares aerotransportados operando no Brasil, destaca-se o sensor R99-SAR da Força Aérea Brasileira (FAB) que opera nas bandas X e L e, no setor privado, o

radar OrbiSAR RFP (Radar para Penetração em Folhagem) que opera nas bandas X e P, desenvolvido pela empresa OrbiSat da Amazônia (TEIXEIRA, 2015).

Diversos estudos vêm sendo realizados utilizando dados de radar aplicados às diferentes áreas. Devido à importância das florestas na manutenção da biodiversidade, na ecologia e no ciclo de carbono, aliado ao fato de que os dados de radar são mais sensíveis à estrutura da vegetação, conteúdo hídrico e condições do solo que outros dados de sensoriamento remoto, as imagens de radar têm sido utilizadas como uma ferramenta para estudos florestais e análises de mudanças (ARAÚJO et al., 1999; ROTT, 2009).

Em florestas tropicais, por exemplo, o uso de imagens SAR para mapear desmatamento tem sido comumente baseado na premissa que florestas não alteradas exibem consistentemente maior retroespalhamento que áreas desmatadas (ALMEIDA FILHO et al., 2007). Angelis et al. (2002) analisaram a evolução temporal do uso e cobertura da terra na Floresta Nacional do Tapajós, no estado do Pará, utilizando dados SAR do satélite JERS-1. Takeuchi e Oguro (2003) obtiveram ótimos resultados utilizando informação de coerência de dados de radar dos satélites JERS-1 e ERS-1 na detecção de desmatamento em florestas tropicais, na ilha de Sumatra. Almeida Filho et al. (2005) analisaram o potencial do satélite JERS-1 para detecção de desmatamento na Amazônia brasileira. Em estudo posterior, Almeida Filho et al. (2007) avaliaram o uso em conjunto desses dados com uma série temporal de imagens ópticas do satélite Landsat-7. Em ambos os estudos, foi possível concluir que a reposta do retroespalhamento para áreas desmatadas depende do estágio e processo do desmatamento.

Rahman e Sumantyo (2010) obtiveram ótimos resultados utilizando os dados do SIR-C (bandas L e C) com polarização dupla (HH e HV) e ALOS PALSAR com quatro polarizações (HH, HV, VH e VV) para mapeamento de cobertura da terra e detecção de mudanças em uma região de floresta tropical no sudeste de Bangladesh. Guerra et al. (2010) discriminaram incrementos de desmatamento em Rio Branco e Bujari, no estado do Acre, por meio de classificação automática de imagens R99-SAR/SIPAM. Mitchard et al. (2011) utilizaram imagens de radar JERS-1 e ALOS PALSAR (banda L), na produção de mapas de biomassa em regiões de ecótonos de Floresta-savana na porção central do continente Africano. Nesse estudo, foram identificadas áreas de desmatamento e degradação pela quantificação de perda de biomassa, essa variável também apresentou alta

correlação com os valores de retroespalhamento. Tanase et al. (2015) analisaram o potencial dos conjuntos de dados do *Shuttle Radar Topography Mission* (SRTM) e *Topography and Deformation Measurement* (TDM) para detectar e quantificar mudanças florestais em ambientes tropicais e semi-áridos. Joshi et al. (2015) detectaram processos de desmatamento, degradação e dinâmicas de sucessão utilizando valores de retroespalhamento das imagens de radar do ALOS PALSAR (banda L), em áreas de florestas no Peru. Reiche et al. (2018) combinaram o uso dos satélites ALOS-2 PALSAR-2 (banda L) e Landsat-7/ETM+ e Landsat-8/OLI com uma série temporal do satélite Sentinel-1 (banda C), para a detecção de desmatamento em florestas tropicais secas.

Estudos foram realizados para investigar também o comportamento do retroespalhamento das micro-ondas em formações savânicas, como o Cerrado. Sano et al. (2001) analisaram o potencial do satélite japonês JERS-1 na discriminação de fitofisionomias (herbáceo, arbustivo e arbóreo) do Cerrado. Em outro estudo, Sano et al. (2005) obtiveram uma melhor discriminação dessas fisionomias a partir da integração dos dados de radar com índices de vegetação. Carvalho et al. (2010) analisaram a capacidade das imagens PALSAR para mapeamento das diferentes fitofisionomias do Cerrado. Almeida Filho & Shimabukuro (2010) avaliaram o uso das imagens JERS-1 para identificação de áreas degradadas por mineração na serra do Tepequém, Roraima. No entanto, estudos de monitoramento de desmatamento em savanas, principalmente no Cerrado, utilizando dados de radar em comprimentos de onda menores que a banda L, ainda são escassos.

Uma vez que imagens SAR possam ser adquiridas sistematicamente e disponibilizadas de forma gratuita para a comunidade, esses dados poderão ser usados como complemento ou substituição de sistemas ópticos no monitoramento de desmatamento.

2.3 Sentinel-1

A missão do Sentinel-1 inclui uma constelação de dois satélites (A e B) orbitais e polares de imageamento de radar de abertura sintética (SAR) que opera dia e noite, possibilitando aquisição de imagens independente do tempo. Essa missão prevê o

lançamento de futuros satélites com o intuito de estender a série temporal do Sentinel-1 para no mínimo 20 anos.

O Sentinel-1A corresponde a um satélite SAR que opera na banda C (comprimento de onda de aproximadamente 5 cm), tendo quatro modos de imageamento com diferentes resoluções e coberturas (TORRES et al., 2012): *Stripmap* (SM), *Interferometric Wide swath* (IW), *Extra-Wide swath* (EW) e *Wave mode* (WV). Dentre esses quatro modos, destaca-se o modo IW, com resolução espacial de 20 metros, periodicidade de 12 dias e faixa de imageamento de 250 km e polarização dupla (HH e HV ou VV e VH) (Figura 2.5). Esse modo de imageamento utiliza o ScanSAR chamado de observação da terra com escaneamento progressivo SAR (em inglês, *Terrain Observation with Progressive Scan - TOPS*), no qual encolhe o padrão de antena azimutal ao longo da direção da trilha (*track direction*) (BALTZER et al., 2015).

Um único satélite Sentinel-1 tem o potencial de mapear o globo no modo IW a cada 12 dias numa única passagem (ascendente ou descendente). Os dois satélites juntos (Sentinel-1A e Sentinel-1B) possuem um ciclo de seis dias no equador.

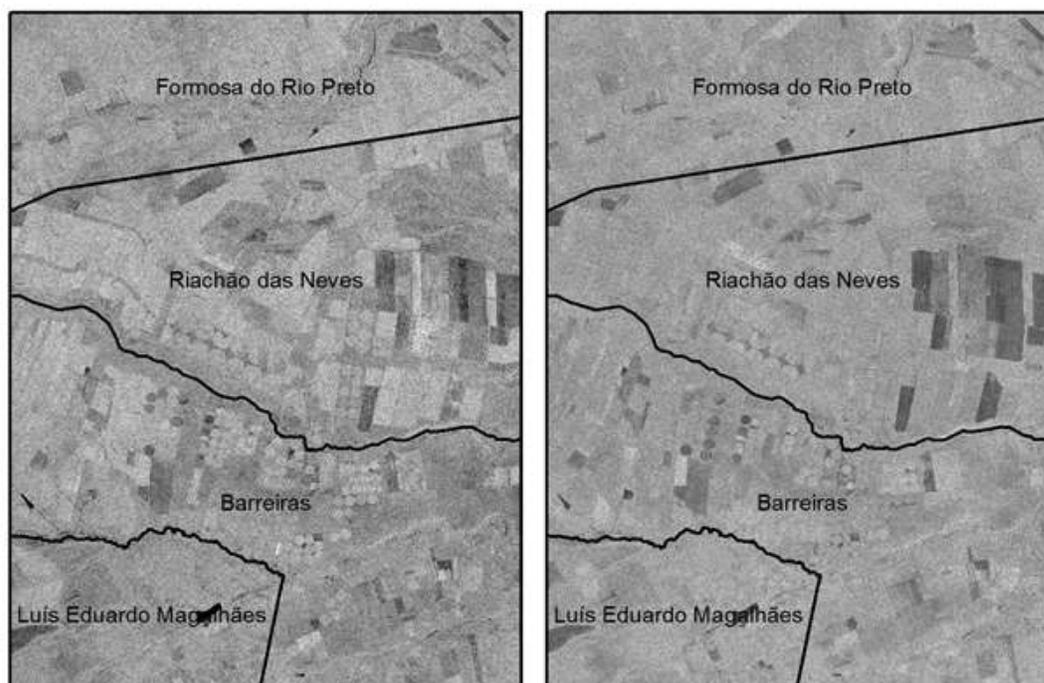


Figura 2.5 Imagens de radar do satélite Sentinel-1A da área de estudo, obtidas nas polarizações VV (a) e VH (b), respectivamente.

Alguns estudos já foram realizados com o intuito de avaliar o potencial das imagens do Sentinel-1. No estudo de Navarro et al. (2016), foram analisadas comparativamente imagens SAR do Sentinel-1A e imagens ópticas do SPOT-5 no monitoramento de culturas agrícolas. Verificou-se uma consistência entre as séries temporais ópticas e de micro-ondas para todos os tipos de culturas, o que permite, assim, a substituição de dados ópticos por dados de micro-ondas no monitoramento de culturas, visto que a persistência de nuvens em algumas regiões representa uma limitação para os dados óticos.

2.4 Google Earth Engine

Google Earth Engine (<https://earthengine.google.com/>) corresponde a uma plataforma computacional da Google™ que combina catálogo de imagens de satélites (e.g., séries históricas de imagens do Landsat, Terra MODIS e Sentinel), dados geoespaciais e capacidade de análise em escala planetária e em escala de petabytes. Ela está disponível para cientistas, pesquisadores e outros usuários públicos ou privados para diversas aplicações em nuvem. Existem várias maneiras de interagir com a plataforma. Por exemplo, com a ferramenta *Code Editor*, pode-se executar ou escrever *scripts* de modo a tornar os fluxogramas geoespaciais complexos mais rápidos e mais fáceis. Com a interface *Explorer* para o *Earth Engine Application Programming Interface* (API), pode-se consultar e visualizar o catálogo de dados ou mesmo executar análises mais simples. Pode-se desenvolver ainda aplicativos customizados por meio de linguagens de programação JavaScript ou Python. *Earth Engine* é gratuito para atividades de ensino, pesquisa e usos sem fins lucrativos.

Uma das primeiras aplicações envolvendo o uso do *Google Earth Engine* e que tem apresentado uma grande visibilidade por parte da comunidade científica internacional é o monitoramento da perda e ganho da cobertura florestal da superfície terrestre, exceto Antártica e algumas ilhas do Ártico, que vem sendo conduzido pela equipe do Matthew Hansen e Peter Potapov da Universidade de Maryland. Trata-se do sistema denominado Global Land Analysis & Discovery (GLAD), que utiliza imagens do satélite Landsat com resolução espacial de 30 m para monitorar a cobertura florestal da Terra. No estudo publicado por Hansen et al. (2013), em que foram analisadas imagens do Landsat de 2000 a

2012, foram identificadas perda de 2,3 milhões de km² de floresta, contra um ganho de 0,8 milhões de km² no referido período. Na região tropical, a redução do desmatamento no Brasil foi ofuscada pelo desmatamento acentuado em países como Indonésia, Malásia, Bolívia, Zâmbia e Angola.

Outro estudo com grande repercussão internacional foi o desenvolvido pelo Joint Research Centre (JRC) da Comissão Europeia que mapeou a localização, persistência e sazonalidade de águas superficiais do planeta por meio da análise de 3 milhões de imagens do satélite Landsat no período de 1984 a 2015 (PEKEL et al., 2016). Nesse período, quase 90.000 km² de águas superficiais desapareceram. No entanto, outros 184.000 km² surgiram, principalmente decorrentes da construção de barragens de diferentes portes. Mais de 70% das perdas ocorrem no Oriente Médio e na Ásia Central, relacionadas com seca e uso indiscriminado de águas.

No Brasil, destaca-se a iniciativa multi-institucional envolvendo universidades, organizações não-governamentais e empresas de tecnologia (e.g., Agrosatélite, AMAZON, Instituto de Pesquisa Ambiental da Amazônia, Universidade Estadual de Feira de Santana, Universidade Federal de Goiás e Universidade Federal do Rio Grande do Sul) que se uniram para produzir mapas anuais de uso e cobertura de terras do Brasil (período de 1985 a 2017), com base na análise de imagens do satélite Landsat. Trata-se do Projeto de Mapeamento Anual da Cobertura e Uso do Solo do Brasil - MapBiomias (<http://mapbiomas.org/>). Esse mapeamento envolve a discriminação de classes de formações florestais, formações savânicas, manguezais, florestas plantadas, pastagem e agricultura, dentre outras classes. A metodologia envolve ainda a produção de mosaicos anuais de imagens Landsat (média, mediana, valor mínimo, valor máximo, dentre outros mosaicos) e classificação automática pelo método do Random Forest. Segundo esse estudo, no período de 2000 a 2014, houve uma perda de 211.666 km² de cobertura florestal no país (média de 14.111 km²/ano).

3. MATERIAIS E MÉTODOS

3.1 Área de estudo

3.1.1 Localização

A área de estudo (Figura 3.1) corresponde a uma região dentro do Oeste da Bahia com aproximadamente 19 mil km², englobando parte dos municípios de Angical, Barreiras, Baianópolis, Cristópolis, Catolândia, Luís Eduardo Magalhães, Riachão das Neves e São Desidério no estado da Bahia, e parte dos municípios Dianópolis, Novo Jardim e Ponte Alta do Bom Jesus, no estado do Tocantins. A poligonal foi definida para cobrir a maior parte do município de Barreiras e localiza-se entre as coordenadas 11° 26' 42" e 12° 43' 08" de latitude sul e entre 46° 09' 43" e 44° 36' 11" de longitude oeste.

Portanto, dentre os municípios listados, Barreiras representa a maior parte da área de estudo (45%). Esse município constitui um polo das atividades agroindustriais que se expande territorialmente interligando vários municípios do Oeste da Bahia como Luís Eduardo Magalhães, São Desidério e Formosa do Rio Preto, por meio de uma rede de atividades produtivas e de serviços (FLORES et al., 2012). Já Luís Eduardo Magalhães, responsável por 60% da produção de grãos do estado, é entreposto de cargas, de comercialização e assistência técnica da agricultura moderna na região (MONDARDO, 2008).

3.1.2 Caracterização física

A área de estudo possui clima caracterizado como tropical continental (Aw), segundo a classificação de Köppen-Geiger, com inverno seco e verão chuvoso. Segundo dados de precipitação pluvial da Empresa Baiana de Desenvolvimento Agrícola (EBDA), a precipitação média anual do município de Barreiras é de 1.053 mm. De acordo com as normais climatológicas do Instituto Nacional de Meteorologia (INMET) (Figura 3.2), também do município de Barreiras, a área de estudo possui duas estações climáticas bem definidas, estação seca, que vai de meados de abril a final de setembro, e a estação chuvosa, que vai de início de outubro a meados de abril. As temperaturas são mais elevadas durante o período chuvoso e mais amenas no período seco.

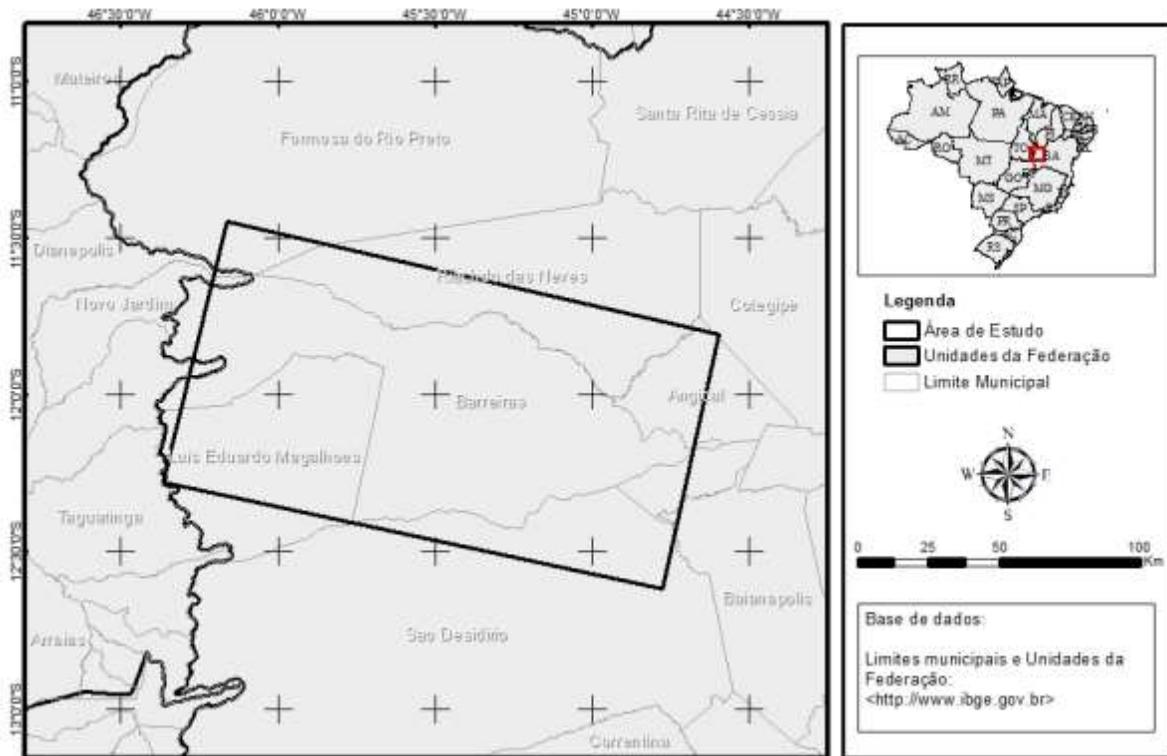


Figura 3.1 Localização da área de estudo no Oeste da Bahia.

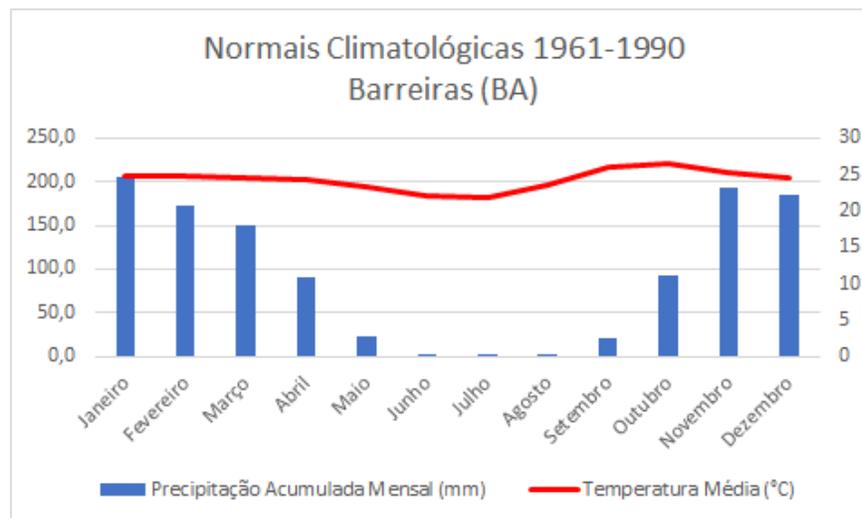


Figura 3.2 Normais climatológicas (1961-1990) para o município de Barreiras – BA.

Devido aos efeitos da sazonalidade, sua paisagem apresenta diferentes cenários durante o ano, principalmente na seca, cujo período prolongado é responsável pelo estresse

hídrico acentuado na grande maioria das fitofisionomias do Cerrado. Ainda assim, a área de estudo possui grande potencial aquífero resultante da recarga do aquífero Urucuaia. Mesmo durante o período de estiagem, os rios da região não perdem muito a vazão (BORGES, 2014).

A caracterização litológica e geomorfológica da área de estudo foi realizada utilizando os dados vetoriais na escala de 1:1.000.000 disponibilizados pela Companhia de Pesquisa de Recursos Minerais (CPRM, 2003), e a caracterização pedológica com os dados do Instituto Brasileiro de Geografia e Estatística (IBGE, 2017), na escala de 1:125.000. O tipo de solo predominante na área de estudo é o Latossolo Vermelho-Amarelo distrófico (Figura 3.3), solos profundos e bem desenvolvidos, ácidos e de baixa fertilidade, característicos de regiões com relevos planos, suave ondulados ou ondulados e propícios à mecanização agrícola (ZARONI, 2012). Ocorrem também, em menor proporção, os Neossolos Quartzarênicos, Litólicos e Flúvicos, que correspondem a solos rasos e pouco intemperizados, além de Cambissolos, Gleissolos Hápicos e Argissolos Vermelho-Amarelos.

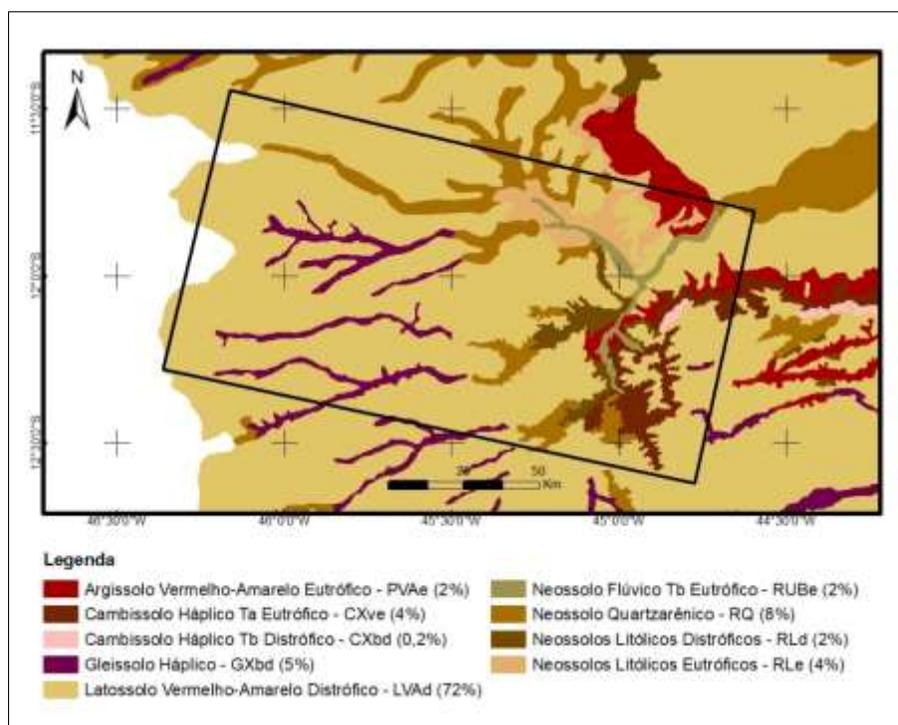


Figura 3.3 Mapa pedológico da área de estudo.

Dentro da área de estudo, são encontradas as seguintes unidades geológicas segundo o mapa geológico da Bahia (Figura 3.4) (CPRM, 2003): Grupo Urucuia, depósitos aluvionares, Grupo Riachão das Neves, Grupo Serra da Mamona e coberturas detrito-lateríticas ferruginosas. O Grupo Urucuia é caracterizado como uma unidade Neocretácica, cuja litologia é constituída por arenitos, pelitos e arenitos conglomeráticos. Os depósitos aluvionares são constituídos por areia e cascalho. O Grupo Riachão das Neves é formado por metarcóseos e metassiltitos. A Serra da Mamona é formada por mármore, ardósia, metarenito, metassilito e metamarga, e por fim, as coberturas detrito-lateríticas ferruginosas, constituídas por conglomerados, areia, argila e laterita (EMBRAPA, 2010).

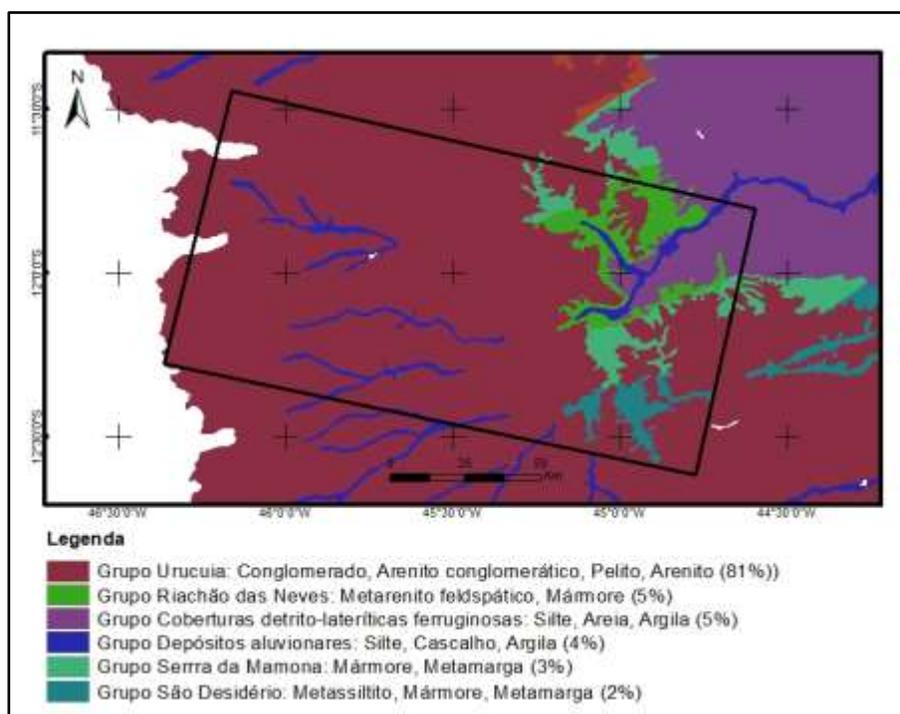


Figura 3.4 Mapa geológico da área de estudo. Fonte: CPRM (2003).

As Chapadas e Platôs abrangem a maior parte da área de estudo (66%), caracterizando-se por apresentar um conjunto de formas de relevo de topo plano, elaboradas sobre rochas sedimentares do Arenito Urucuia (Figura 3.5) (EMBRAPA, 2010). Nessa unidade, desenvolve-se a agricultura mecanizada, devido à topografia plana que permite a utilização de maquinários capazes de realizar a produção agrícola em larga escala (BORGES, 2014). Outras unidades geomorfológicas como vales encaixados, degraus

estruturais e rebordos erosivos, domínio de colinas e de morros, escarpas serranas, planícies fluviais e superfícies aplainadas são encontradas em menor proporção na área de estudo.

3.1.3 Cobertura vegetal

A área de estudo está inserida dentro do bioma Cerrado, cuja formação é constituída por mais de um tipo fitofisionômico. Segundo Ribeiro & Walter (2008), as fisionomias da vegetação desse bioma abrangem formações florestais, savânicas e campestres. As formações florestais possuem predominância de espécies arbóreas, com formação de dossel contínuo ou descontínuo, as formações savânicas constituem áreas com árvores e arbustos espalhados sobre um estrato graminoso sem dossel contínuo e as formações campestres referem-se às áreas com predomínio de espécies herbáceas e algumas arbustivas, não existindo árvores na paisagem.

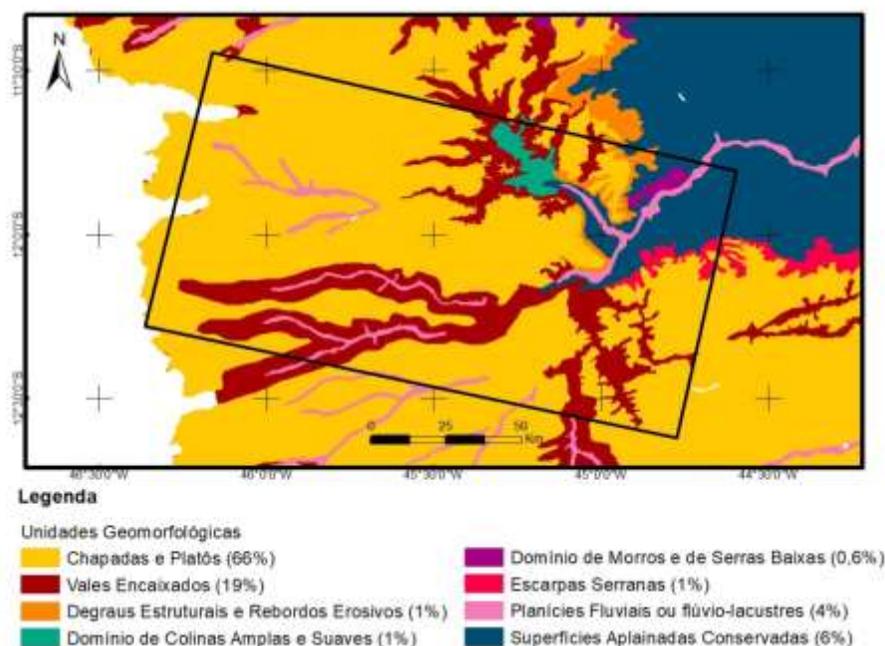


Figura 3.5 Mapa geomorfológico da área de estudo. Fonte: CPRM (2003).

A vegetação de uma determinada região é condicionada pelo clima, pelas propriedades químicas e físicas do solo, disponibilidade de água e nutrientes, geomorfologia, topografia, latitude, profundidade do lençol freático, como também por fatores antrópicos como frequência de queimadas e pastejo, dentre outros (RIBEIRO &

WALTER, 1998). A vegetação nas áreas de chapadas da área de estudo, posicionadas sobre Latossolos, caracteriza-se por feições típicas de Cerrado Sentido Restrito. Nos vales, a vegetação se apresenta de forma menos contínua que nas chapadas, desenvolvendo-se sobre solos arenosos da Formação Urucuia (EMBRAPA, 2010). A Figura 3.6 ilustra fitofisionomias típicas da vegetação do Cerrado encontradas na área de estudo.



(a)

Município: Barreiras; latitude: -12,01938°;
longitude: -45,39445°



(b)

Município: Angical; latitude: -11,9169°;
longitude: -44,6765°



(c)

Município: São Desidério; latitude: -
12,4064°; longitude: -44,8316°



(d)

Município: Angical; latitude: -12,0133°;
longitude: -44,7236°

Figura 3.6 Exemplos de áreas com Cerrado Sentido Restrito em (a), (b) e (c), e formação florestal do tipo Cerradão em (d).

O Cerrado sentido restrito pertence à classe das formações savânicas e se caracteriza pela presença de árvores baixas, inclinadas, tortuosas, com ramificações irregulares e retorcidas, geralmente com evidências de queimadas. Esse grupo ainda se subdivide conforme um gradiente de densidade de espécies arbóreas e arbustivas em Cerrado Denso, Cerrado Típico e Cerrado Ralo. Além desses três subtipos, existe ainda o Cerrado Rupestre que se diferencia dos demais pelo substrato, tipicamente em solos rasos com presença de afloramentos rochosos. Encontram-se também, na área de estudo, formações florestais como o Cerradão, caracterizadas pela presença de espécies que ocorrem no Cerrado sentido restrito e também por espécies de mata. Apesar de apresentar fisionomia florestal, sua composição florística é mais similar a um Cerrado. O Cerradão apresenta dossel predominantemente contínuo, cobertura arbórea acima de 50% e altura média do estrato arbóreo variando de 8 a 15 metros (RIBEIRO & WALTER, 1998).

3.2 Materiais

3.2.1 Imagens de satélite

Para análise do potencial de detecção de desmatamento, foram utilizadas imagens do satélite Sentinel-1A de outubro de 2016 e 2017, e também imagens ópticas do satélite Landsat-8 para auxiliar na interpretação das imagens de radar. As datas das imagens utilizadas neste trabalho são mostradas na Tabela 3.1.

Tabela 3.1 Datas das imagens de radar do satélite Sentinel-1A para detecção de desmatamento no Oeste da Bahia e do satélite Landsat-8 OLI para validação da referida detecção, com a indicação dos períodos de ocorrência de desmatamento.

Satélite	Data
Sentinel-1A	03/10/2016
	22/10/2017
Landsat-8 OLI	02/10/2016
	23/02/2017
	27/03/2017
	28/04/2017
	30/05/2017
	17/07/2017
	19/09/2017
	21/10/2017

O satélite Landsat-8 faz parte do programa Landsat, que fornece, há mais de 45 anos, dados de resolução espacial média e calibrada da superfície da Terra para uma ampla e variada comunidade de usuários, de forma gratuita. As imagens Landsat-8 possuem resolução de 15 m na banda pancromática e 30 m nas demais bandas multiespectrais. O satélite carrega dois instrumentos de varredura eletrônica: o *Operational Land Imager* (OLI) e o *Thermal Infrared Sensor* (TIRS) (ROY et al., 2014). Foram utilizadas duas imagens Landsat-8 para a detecção de desmatamento que correspondem ao período inicial e final da análise, e seis imagens auxiliares dentro desse período. As imagens Landsat-8 auxiliares foram utilizadas para registrar a época de ocorrência de cada desmatamento. As bandas utilizadas para a composição colorida falsa-cor foram as bandas 6 no vermelho (R), a banda 5 no verde (G), e a banda 4 no azul (B), todas com 30 metros de resolução espacial.

Os dados do Sentinel-1A utilizados nesse estudo foram obtidos da plataforma *Google Earth Engine* (GEE). As imagens foram obtidas na banda C e corresponderam ao produto nível 1, *ground range detection* (GRD), modo *interferometric wide* (IW) com duas polarizações (VV e VH) e tamanho de pixel de 10 m (ESA, 2018). Já as imagens Landsat-8 foram obtidas no site do Serviço Geológico dos Estados Unidos (USGS) (*earth explorer*), no nível 1, já ortoretificadas.

3.2.2 Dados vetoriais

Como esse trabalho teve o objetivo de detectar as mudanças ocorridas durante o período de um ano em áreas de Cerrado natural, foram utilizadas, como máscara, as classes de uso antrópico do Terraclass Cerrado 2013 (MMA, 2015) para auxiliar na detecção do desmatamento na área de estudo. As classes de uso antrópico mapeadas por esse projeto, coordenado pelo MMA, foram: agricultura anual, agricultura perene, áreas de mineração, mosaico de ocupações, pastagem cultivada, silvicultura, solo exposto e área urbana. Devido à lacuna de tempo entre o Terraclass Cerrado e o período de análise do presente trabalho, foi necessária a atualização da base vetorial para o período de 2016, conduzida com base na análise visual das imagens do Landsat-8.

3.2.3 Software

Para processamento das imagens, bem como manipulação e análise dos dados nas etapas iniciais e finais do projeto, dois programas básicos foram utilizados: o Sistema de Informação Geográfica (SIG) QGIS e a plataforma *Google Earth Engine*. O QGIS é um *software* de sistema de informações geográficas, com código-fonte aberto que permite a visualização, edição, processamento e análise de dados georreferenciados, sejam vetoriais ou matriciais, além de criação de mapas em diferentes projeções. O QGIS é mantido por um grupo ativo de desenvolvedores voluntários, sendo atualizado e corrigido rotineiramente. Teve sua primeira versão lançada em 2009 e desde 2012 foi traduzido para mais de 40 idiomas. A aplicação é usada internacionalmente em ambientes acadêmicos e profissionais e seu diferencial consiste na integração em uma biblioteca de *plug-ins* e complementos desenvolvidos em C++ ou *Python* por diversos usuários. Esse programa foi utilizado no presente trabalho para análise dos dados vetoriais, bem como para composição colorida das imagens Landsat-8. Detalhes do *Google Earth Engine* podem ser encontrados na Seção 2.5.

3.3 Abordagem metodológica

A abordagem metodológica desse estudo foi dividida em quatro etapas principais: detecção visual de desmatamento nas imagens Landsat-8, validação da detecção visual, pré-processamento das imagens Sentinel-1A e detecção de mudanças nas imagens Sentinel-1A utilizando o *Google Earth Engine*. A Figura 3.7 ilustra o fluxograma com as etapas e sub-etapas realizadas no trabalho.

3.3.1 Detecção visual do desmatamento em imagens do satélite Landsat-8

A primeira etapa desse trabalho serviu de fundamentação para a última etapa e objetivo final do estudo. A detecção de áreas desmatadas em imagens ópticas é comum devido à fácil discriminação da resposta espectral entre áreas vegetadas e solo exposto, quando não há cobertura de nuvens. Como a área de estudo possui um cenário dinâmico de

rotação de agricultura de plantio e colheita, a máscara de uso antrópico derivada do projeto Terraclass Cerrado 2013 foi atualizada para o ano de 2016 por meio da análise visual das imagens do satélite Landsat-8. Dessa forma, foram utilizadas duas imagens Landsat-8 para a detecção do desmatamento entre o período inicial (02/10/2016) e final da análise (21/10/2017). Essas áreas também foram interpretadas visualmente e vetorizadas manualmente no programa QGIS 2.14.3. Em seguida, mais seis imagens auxiliares foram utilizadas para classificar as áreas desmatadas conforme seu período de ocorrência. Essa parte foi realizada com o intuito de analisar se a época de ocorrência do desmatamento poderia influenciar o comportamento do retroespalhamento nas imagens do Sentinel-1A. Foram vetorizadas também as áreas de queimadas encontradas na área de estudo para avaliar a diferença dos valores de retroespalhamento com relação aos dados de desmatamento.

3.3.2 Validação *in loco* do desmatamento em imagens do satélite Landsat-8

Após a detecção visual, um conjunto de amostras de polígonos de desmatamento foi validado em campo. A validação consistiu em verificar *in loco* se houve de fato o desmatamento. A escolha dos elementos da amostra foi realizada de forma não-probabilística, priorizando áreas que tiveram desmatamento recente devido à sua importância em detecções em programas de monitoramento, e por conveniência, devido à inviabilidade de visita de algumas áreas por se encontrarem em propriedades privadas, cujo acesso não foi possível. O tamanho da amostra foi calculado pela seguinte fórmula:

$$n = \frac{N \cdot Z^2 \cdot p(1 - p)}{(N - 1) \cdot e^2 + Z^2 \cdot p(1 - p)} \quad (3.1)$$

Onde:

n = tamanho da amostra que se quer calcular;

N = tamanho do universo;

Z = desvio do valor médio aceito para alcançar o nível de confiança desejado (definido nesse estudo como $Z = 1,96$);

e = margem de erro máximo que se quer admitir ($e = 0,05$); e

p = proporção que se espera encontrar ($p = 0,5$).

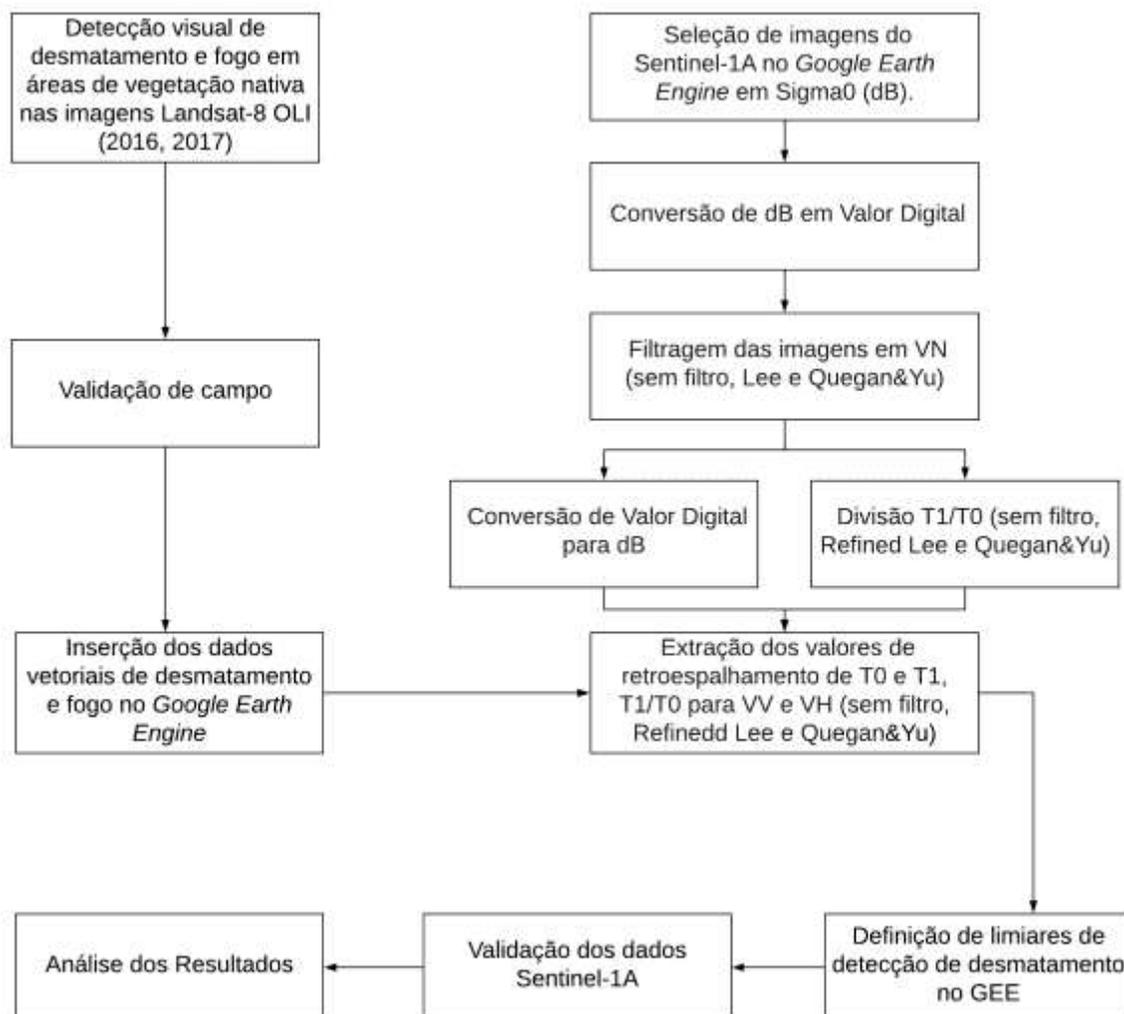


Figura 3.7 Fluxograma da metodologia aplicada para detecção de desmatamento na área de estudo.

Devido aos recursos limitados destinados à saída de campo, o número de elementos amostrais calculado foi de 48 pontos segundo a Eq. 3.1, utilizando, como valores de base para o cálculo, 10% de margem de erro máximo e 90% de nível de confiança. Para coleta dos pontos amostrais no campo, foi utilizado o receptor GPS Garmin Montana de navegação, com referencial geodésico no sistema de referência SIRGAS 2000 e no sistema de coordenadas geográficas (latitude/longitude). A campanha de campo foi realizada de 17 a 20 de novembro de 2017.

3.3.3 Processamento das imagens Sentinel-1A

As imagens do Sentinel-1A são disponibilizadas no *Google Earth Engine* já com alguns pré-processamentos realizados, tais como a aplicação de órbita, a remoção de ruídos termais, mescla de bordas, calibração radiométrica e ortorretificação. A aplicação de órbita atualiza as informações de metadados de órbita realizando uma restituição e a remoção de ruídos termais remove as faixas escuras próximas às bordas da cena que possuem dados inválidos. As bordas são então mescladas perfeitamente para formar uma única imagem contígua para cada polarização.

A calibração radiométrica computa a intensidade de retroespalhamento usando os parâmetros de calibração do sensor disponíveis nos metadados das imagens GRD. Já na etapa de ortorretificação, os dados são convertidos para σ° usando o modelo digital de elevação SRTM de 30 metros ou modelo digital de elevação ASTER para altas latitudes ($> 60^\circ$ ou $< -60^\circ$). Por último, o coeficiente de retroespalhamento, até então sem unidade, é convertido em dB. Os valores são então fixados no 1º e no 99º percentil para preservar a faixa dinâmica em relação a valores anômalos e quantificados para 16 bits.

Essas etapas seguem as implementações da caixa de ferramentas do SNAP (*Sentinel Application Platform*), *software* de processamento das imagens da constelação Sentinel, disponibilizado gratuitamente pela ESA (GEE, 2018). O coeficiente de retroespalhamento geralmente varia entre -32 dB a + 32 dB, dependendo do modo de imageamento do sistema sensor e das características dos alvos, isto é, das condições de rugosidade do terreno, umidade de solos, biomassa e estrutura da vegetação (HENDERSON & LEWIS, 1998; JENSEN, 2011).

Nesse estudo, as imagens do Sentinel-1A de 2016 e 2017, nas polarizações VV e VH, foram rescalonadas para valores digitais, conforme mostra a Eq. 3.2. Essa conversão foi feita com o objetivo de permitir a divisão das imagens em polarizações VV e VH em valores digitais ao invés de estarem transformadas em base logarítmica. Um *script* foi preparado especialmente para executar esse procedimento e os próximos que estarão descritos a seguir.

$$VD = 10^{\sigma^\circ(dB)/10} \quad (3.2)$$

Posteriormente, as imagens foram processadas pela técnica de filtragem espacial do tipo passa-baixa para reduzir o efeito *speckle*, um tipo de ruído multiplicativo e aleatório que é inerente ao processo de aquisição de imagens de radar. Segundo Dong et al. (2001), os filtros devem manter aproximadamente a intensidade média do retroespalhamento das imagens, porém, devem reduzir a variância e preservar bordas e textura. Nesse estudo, foram considerados dois filtros diferentes, o filtro adaptativo Refined Lee e o Quegan & Yu. O primeiro seleciona os pixels vizinhos com características de espalhamento similar (LEE et al., 2006), enquanto o último é um filtro linear, adequado quando existe uma sequência temporal de imagens (QUEGAN & YU, 2001). Exemplos de aplicações desses dois filtros podem ser encontrados em Vasile et al. (2010) e Bejima et al. (2014) para o filtro Refined Lee, e em Engdahl & Hyyppä (2003) e Bouvet et al. (2009) para o filtro Quegan & Yu.

3.3.4. Detecção de mudanças usando o *Google Earth Engine*

Os polígonos de desmatamento detectados com base nas imagens do Landsat-8 foram inseridos na plataforma *Google Earth Engine* para que os valores digitais médios e valores de retroespalhamento em cada polígono de desmatamento pudessem ser extraídos. Após essa etapa, foi realizada uma divisão entre as imagens de 2017 (T_1) pelas imagens de 2016 (T_0) das polarizações VV e VH, sem filtragem e processadas pelos filtros Refined Lee e Quegan & Yu. Esse produto retorna uma imagem que ressalta as mudanças ocorridas conforme as oscilações de intensidade do retroespalhamento. A escolha desse método se justifica por ser a operação base da ferramenta *Change Detection* do *software* SNAP para detecção de mudanças nas imagens Sentinel-1.

Em seguida, as imagens foram reconvertidas para retroespalhamento, conforme a Eq. 3.3, para permitir a extração de valores de retroespalhamento de T_0 e T_1 para as polarizações VV e VH, sem filtragem e processadas com os filtros Refined Lee e Quegan & Yu. Na sequência, os valores da razão T_1/T_0 e os valores de retroespalhamento de T_0 e T_1 foram analisados por meio de gráficos *boxplot* para embasar a escolha de três limiares de desmatamento. Para isso, foi também inserido no *script* a máscara de uso antrópico

atualizada para o ano de 2016, de forma que a detecção fosse realizada somente nas áreas com cobertura vegetal natural.

$$\sigma^{\circ} \text{ (dB)} = 10 \log (VD) \quad (3.3)$$

Os três limiares correspondem aos limites superior, intermediário e inferior dos valores digitais mínimo e máximo mostrados pelos gráficos *boxplot*. Esses limiares são inseridos no *script* desenvolvido na plataforma do *Google Earth Engine* com o intuito de exportar um arquivo *raster* no formato TIFF contendo esses valores de indicativo de desmatamento. Em seguida o arquivo foi convertido para o formato vetorial, a área dos polígonos foi calculada e as feições menores que 2 hectares foram excluídas da análise. Essa limpeza se fez necessária devido à característica granulosa das imagens de radar que geraram vários polígonos resultantes desse ruído. Posteriormente, os polígonos detectados segundo os limiares selecionados foram validados por meio de cruzamentos com os dados ópticos de desmatamento e os erros de omissão e comissão foram contabilizados.

4. RESULTADOS E DISCUSSÃO

4.1 Detecção visual de desmatamento com base em imagens do Landsat-8 OLI

Na Figura 4.1 é mostrada a localização de 195 polígonos de desmatamento identificados por meio de interpretação visual de imagens Landsat-8 OLI de 2016 e 2017. Todos os polígonos foram localizados nos municípios de Angical (32 polígonos), Barreiras (82 polígonos), Catolândia (7 polígonos), Luís Eduardo Magalhães (28 polígonos), Riachão das Neves (24 polígonos) e São Desidério (22 polígonos).

A Figura 4.2 mostra um exemplo de identificação de uma área desmatada em composição colorida RGB das bandas 6, 5 e 4 do satélite Landsat-8 no município de Barreiras e as imagens correspondentes do Sentinel-1A nas polarizações VV e VH. Percebe-se que a área desmatada aparece com uma tonalidade de cinza mais escura nas imagens do Sentinel-1A, em ambas as polarizações. Isso ocorre porque, com a remoção de árvores e arbustos, elimina-se a presença de dispersores que retroespalham os pulsos de radar emitidos pelos sensores imageadores. Consequentemente, a maioria das áreas

desmatadas no Cerrado aparece com tonalidades de cinza escuras. Exceção a essa regra é quando ocorre um evento de chuva próximo à passagem do satélite de radar, pois o aumento na umidade de solos aumenta o retroespalhamento da radiação incidente (MENESES & ALMEIDA, 2012) ou quando a passagem do satélite é bem próxima do desmatamento, de tal modo que troncos e galhos ainda estão presentes no terreno, aumentando a rugosidade do terreno (ALMEIDA FILHO et al., 2007).

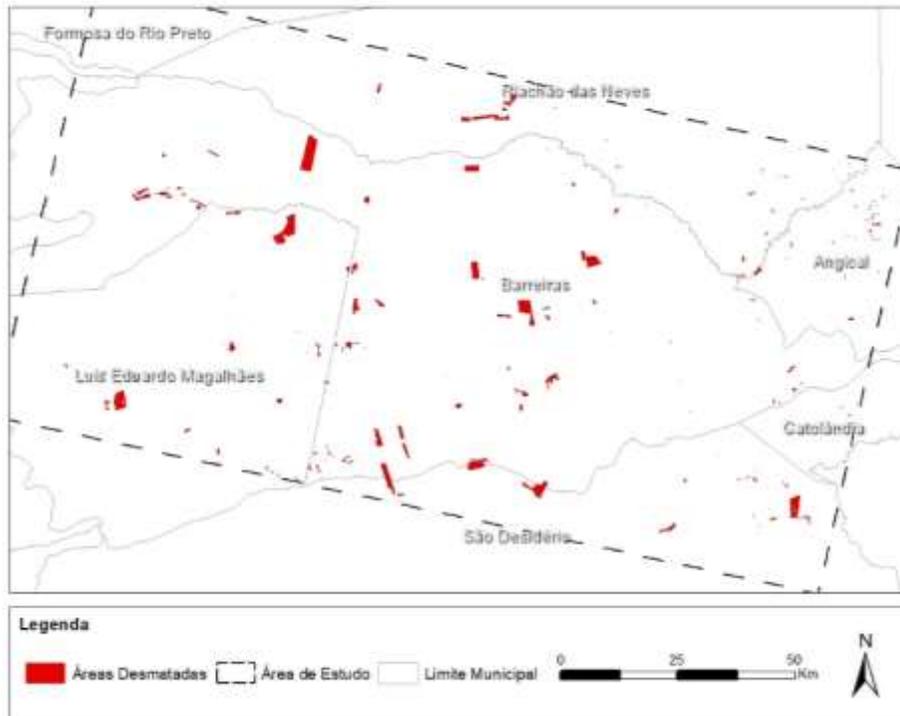


Figura 4.1 Localização dos polígonos de desmatamento identificados com base na interpretação visual de imagens Landsat-8 OLI de 2016 e 2017.

4.2 Validação da detecção visual de desmatamento com base em imagens do Landsat-8 OLI

Devido às limitações de custos e tempo, foi possível visitar 49 pontos no campo (Figura 4.3), dos quais 36 pontos foram confirmados como sendo desmatamento recente devido a presença de troncos e galhos no chão, espalhados ou enleirados, solo recém-revolvido, resquícios de queima e correntes utilizadas para o desmate em algumas áreas.

Também foi observada a presença de vegetação nativa nas áreas ao redor dos desmatamentos. Os outros pontos não puderam ter o desmatamento confirmado visto que as mudanças detectadas nas imagens de satélites já eram relativamente antigas, e essas áreas já apresentavam presença de culturas agrícolas ou pastagens cultivadas. A Figura 4.4 mostra algumas áreas visitadas em campo que confirmaram atividade recente de desmatamento.

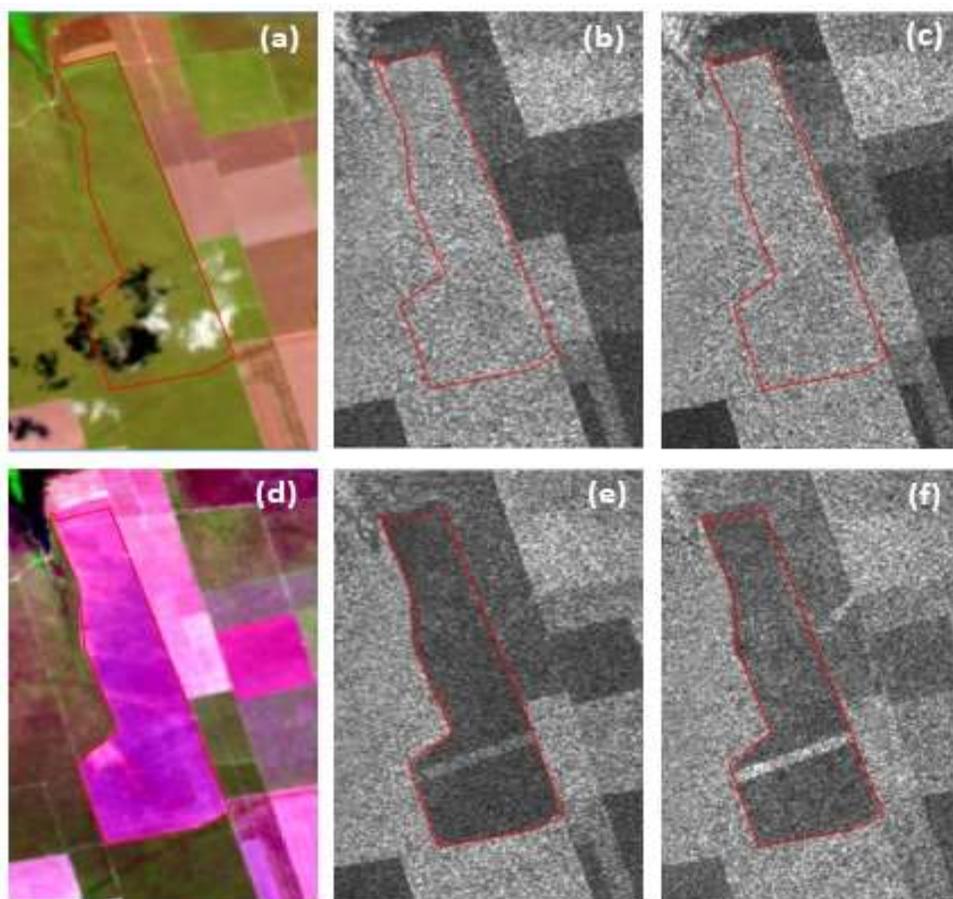


Figura 4.2 Composição colorida RGB das bandas 6, 5 e 4 do satélite Landsat-8 de 02 de outubro de 2016 e 21 de outubro de 2017 (antes e depois do desmatamento) no município de Barreiras em (a) e (d) e as imagens correspondentes do satélite Sentinel-1A obtidas em 03 de outubro de 2016 e 10 de novembro de 2017 na polarização VV em (b) e (e) e na polarização VH, em (c) e (f).

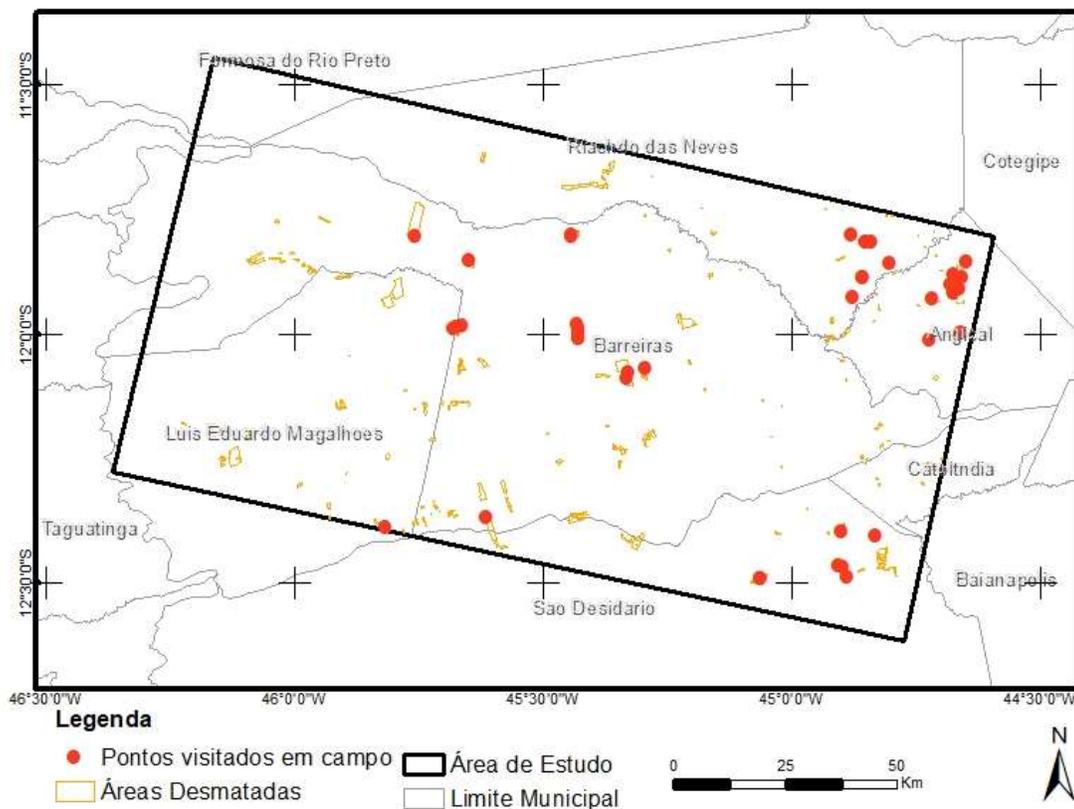


Figura 4.3 Mapa dos pontos visitados em campo na área de estudo.

Os polígonos cujo desmate havia ocorrido entre julho e outubro de 2017, segundo observações nas imagens Landsat-8, apresentaram, de forma geral, resquícios de vegetação como galhos, troncos e folhas, queimados ou não. Todavia, também foram encontrados restos de biomassa vegetal em polígonos em que a época do desmatamento era mais antiga, esses casos ocorreram em locais que a área do desmatamento era menor, o que indica que o padrão de limpeza do terreno pode estar associado com o tamanho da propriedade. Grandes proprietários rurais, por causa da maior disponibilidade de recursos, possuem uma dinâmica de desmatamento mais rápida que os pequenos proprietários. As grandes áreas desmatadas estiveram localizadas principalmente nos municípios de Barreiras e Luís Eduardo Magalhães, e as pequenas áreas nos municípios de Riachão das Neves e Angical.



Ponto 02 (município: Barreiras; latitude: -12,01125°; longitude: -45,42768°)



Ponto 37 (município: São Desidério; latitude: -12,48891°; longitude: -44,88680°)



Ponto 22 (município: Angical; latitude: -11,91087°; longitude: -44,66284°)



Ponto 23 (município: Angical; latitude: -11,93073°; longitude: -44,71570°)

Figura 4.4 Áreas validadas em campo apresentando vários estágios de desmatamento.

4.3 Relação entre coeficientes de retroespalhamento (σ°) provenientes de áreas naturais e desmatadas

Na Tabela 4.1, são mostrados os valores médios de retroespalhamento (σ°) dos dois períodos analisados, outubro de 2016 (data T_0) e outubro de 2017 (data T_1), e os valores da imagem de divisão entre T_1 e T_0 das áreas desmatadas e das áreas de controle selecionadas (áreas naturais que não foram observadas mudanças na cobertura) para as duas polarizações (VH e VV) e três tratamentos: sem aplicação de filtro, aplicação do filtro Refined Lee e aplicação do filtro temporal Quegan & Yu.

Tabela 4.1 Valores médios de retrospalhamento das áreas desmatadas e das áreas sem mudança na cobertura vegetal para as duas polarizações, e em cada filtro.

Sem Filtro							
Polarização VH				Polarização VV			
Cobertura	Data T ₀ *	Data T ₁ **	Razão	Cobertura	Data T ₀ *	Data T ₁ **	Razão
Desmatamento	-14.902	-18.917	0.516	Desmatamento	-9.429	-12.201	0.627
Áreas sem mudança	-15.123	-15.064	1.086	Áreas sem mudança	-9.479	-9.619	1.030

Filtro Lee							
Polarização VH				Polarização VV			
Cobertura	Data T ₀ *	Data T ₁ **	Razão	Cobertura	Data T ₀ *	Data T ₁ **	Razão
Desmatamento	-14.838	-18.597	0.514	Desmatamento	-9.374	-11.990	0.620
Áreas sem mudança	-15.037	-14.952	1.052	Áreas sem mudança	-9.405	-9.511	1.001

Filtro Quegan & Yu							
Polarização VH				Polarização VV			
Cobertura	Data T ₀ *	Data T ₁ **	Razão	Cobertura	Data T ₀ *	Data T ₁ **	Razão
Desmatamento	-15.323	-18.351	0.565	Desmatamento	-9.771	-11.967	0.653
Áreas sem mudança	-15.274	-15.189	1.035	Áreas sem mudança	-9.658	-9.742	0.991

Analisando os coeficientes médios de retroespalhamento (σ°), é possível constatar que entre a data T_0 e a data T_1 , há uma queda desses valores para as áreas desmatadas enquanto que nas áreas de controle, o valor manteve-se estável, sem grandes oscilações. Os valores da razão também são distintos entre as duas classes, sendo a média para as áreas desmatadas 0,5 na polarização VH e 0,6 na polarização VV, enquanto para as áreas sem mudança a média para a polarização VH e VV é de aproximadamente 1,0.

Na Figura 4.5 são mostrados os diagramas de dispersão entre coeficientes de espalhamento (σ°) provenientes de polígonos de desmatamento identificados nas imagens Landsat-8 e de polígonos provenientes de remanescentes de Cerrado na polarização VV, sem filtragem espacial e com filtros Lee e Quegan & Yu para os anos de 2016 e 2017. Praticamente todos os polígonos analisados apresentaram decréscimo nos valores de σ° após o evento de desmatamento, passando, grosso modo, de -14 dB a -7 dB (natural) para -20 dB a -8 dB (desmatado). A aplicação dos filtros Lee e Quegan & Yu não mostraram mudanças significativas em relação aos valores de retroespalhamento sem filtragem espacial.

Na Figura 4.6 são mostradas as relações entre os coeficientes de retroespalhamento (dB) relativos a polígonos de desmatamento identificados com base nas imagens Landsat-8 e polígonos de vegetação natural (controle) de Cerrado para os anos de 2016 e 2017, polarização VH, sem filtragem espacial (a) e com filtros Lee (b) e Quegan & Yu (c). Percebe-se novamente a queda nos valores de σ° após o evento de desmatamento, variando de -22 dB a -13 dB (2016) para -29 dB a -13 dB (2017) nessa polarização. Os realces por meio de filtros Lee e Quegan & Yu também não mostraram mudanças perceptíveis nas referidas relações.

Na Figura 4.7, são mostradas as relações entre a divisão 2017/2016 obtida para a polarização VV e VH, relativos a polígonos de desmatamento identificados nas imagens Landsat-8 e a polígonos de vegetação natural (controle) de Cerrado, sem filtragem (a), com filtro Refined Lee (b) e com filtro Quegan & Yu (c). Observa-se uma nítida separação entre os polígonos desmatados e os naturais em ambas as polarizações e independentemente da aplicação ou não de filtros espaciais. Portanto, a técnica de divisão 2017/2016 utilizada nesse estudo demonstra uma elevada capacidade para discriminar áreas desmatadas com base nas imagens do Sentinel-1A.

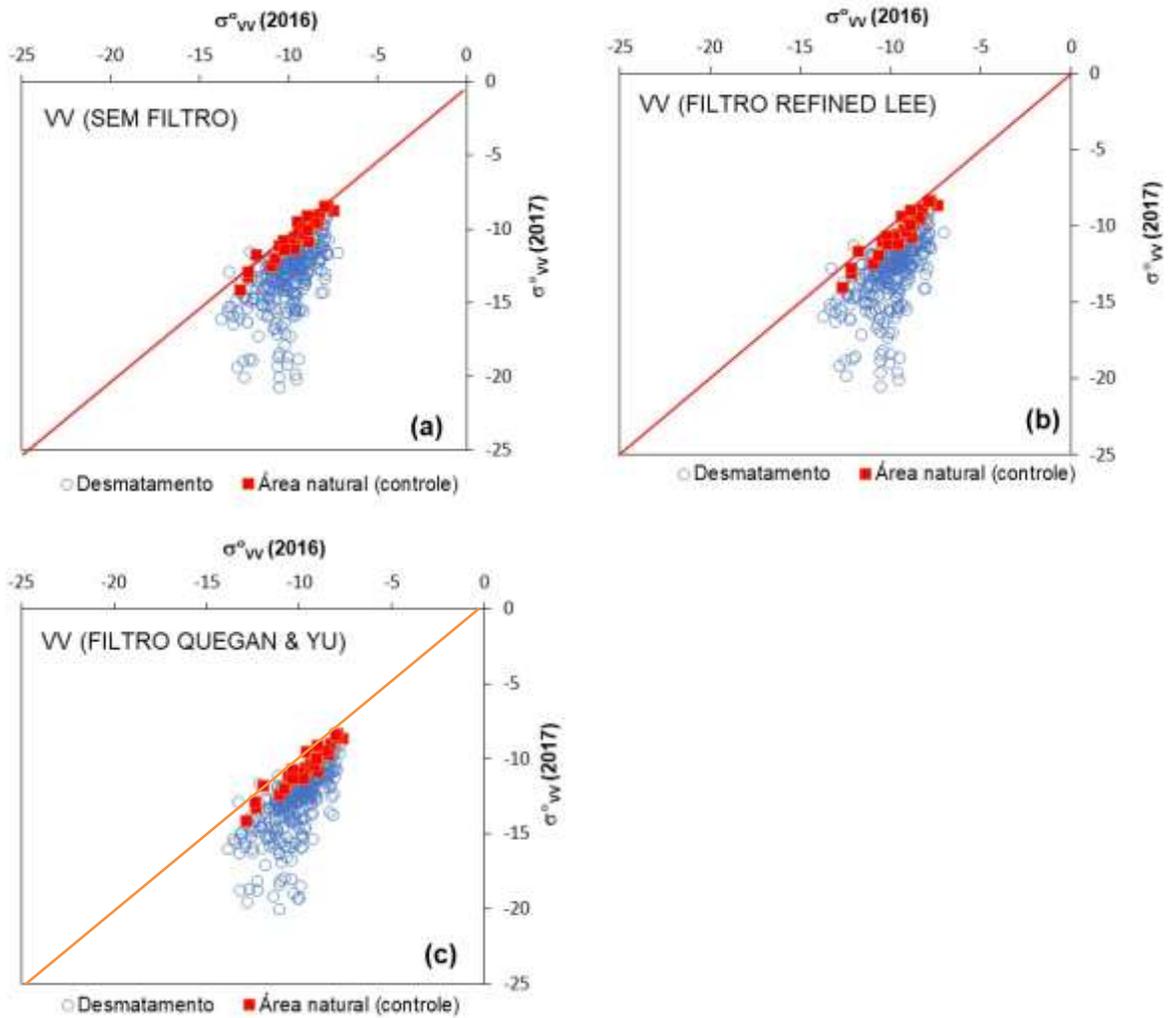


Figura 4.5 Relação entre coeficientes de retroespalhamento (dB) provenientes de polígonos de desmatamento identificadas em imagens Landsat-8 e áreas naturais (controle) em 2016 e em 2017 na polarização VV, sem filtragem espacial (a), com filtro Refined Lee (b) e com filtro Quesgan & Yu (c).

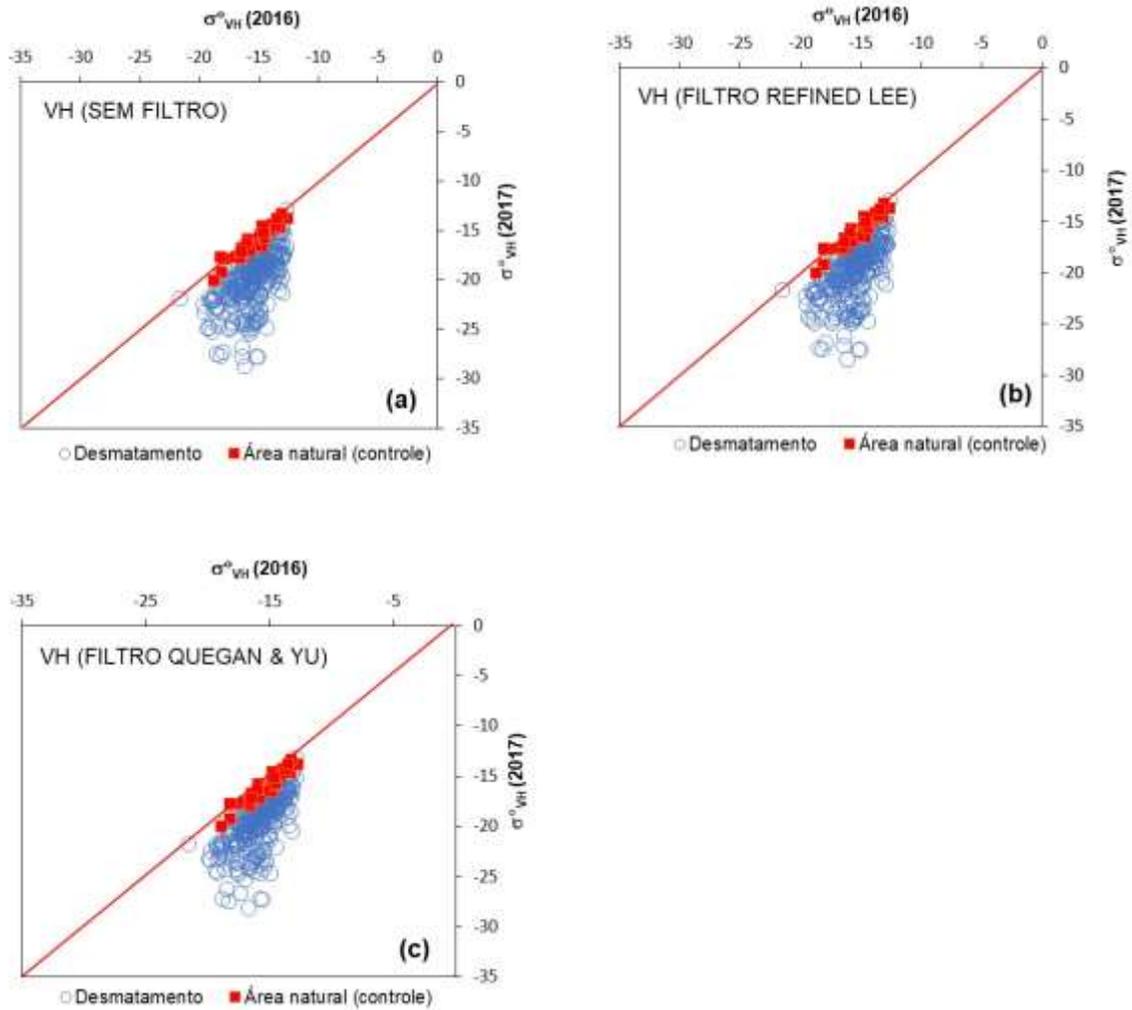


Figura 4.6 Relação entre coeficientes de retroespalhamento (dB) provenientes de polígonos de desmatamento identificadas em imagens Landsat-8 e áreas naturais (controle) em 2016 e em 2017 na polarização VH, sem filtragem espacial (a), com filtro Refined Lee (b) e com filtro Quegan & Yu (c).

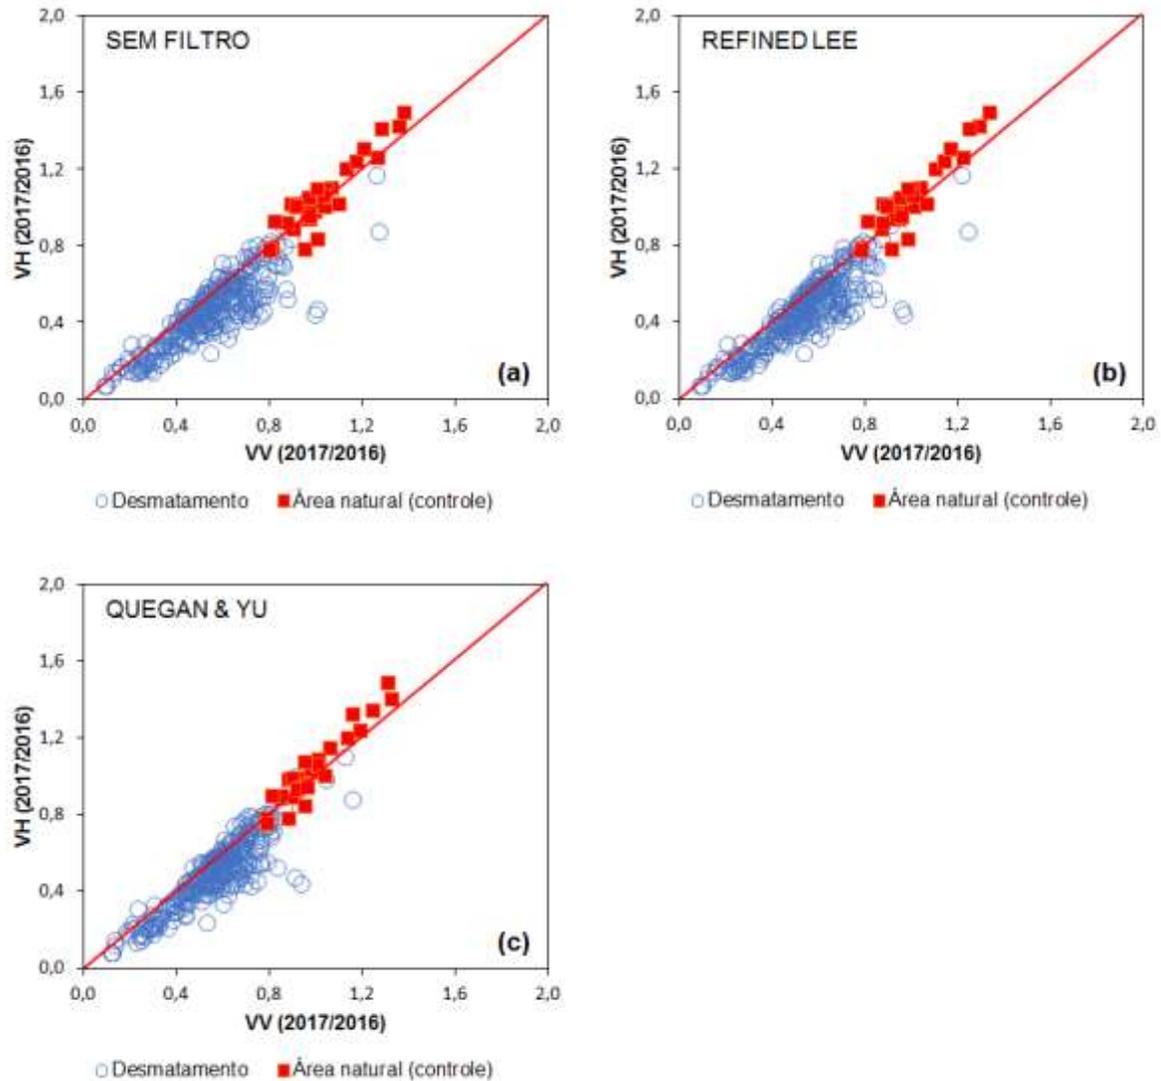


Figura 4.7 Relação entre os valores digitais obtidos da divisão 2017/2016 nas polarizações VV e VH para os polígonos de desmatamento identificados nas imagens Landsat-8 e os polígonos de vegetação natural (controle) do Cerrado sem filtragem espacial (a), com filtro Refined Lee (b) e com filtro Quegan & Yu (c).

4.4 Definição de limiares de desmatamento

Para visualizar melhor a distribuição geral dos dados da diferença entre o período inicial e final analisado para as duas classes, foram feitos gráficos *boxplot* representando os quartis de cada conjunto de dado. Ao analisar a distribuição dos dados referentes ao

desmatamento em comparação com as áreas naturais que não apresentaram mudanças no período analisado, observa-se novamente que existe uma nítida separação entre as duas classes. Na polarização VV (Figura 4.8), existe uma sobreposição de valores máximos de desmatamento com valores mínimos de áreas sem mudança entre 0,8 e 0,9, no entanto, ao considerar a média de 0,6 para esse conjunto de dados, é possível considerar um limiar de corte abaixo de 0,8.

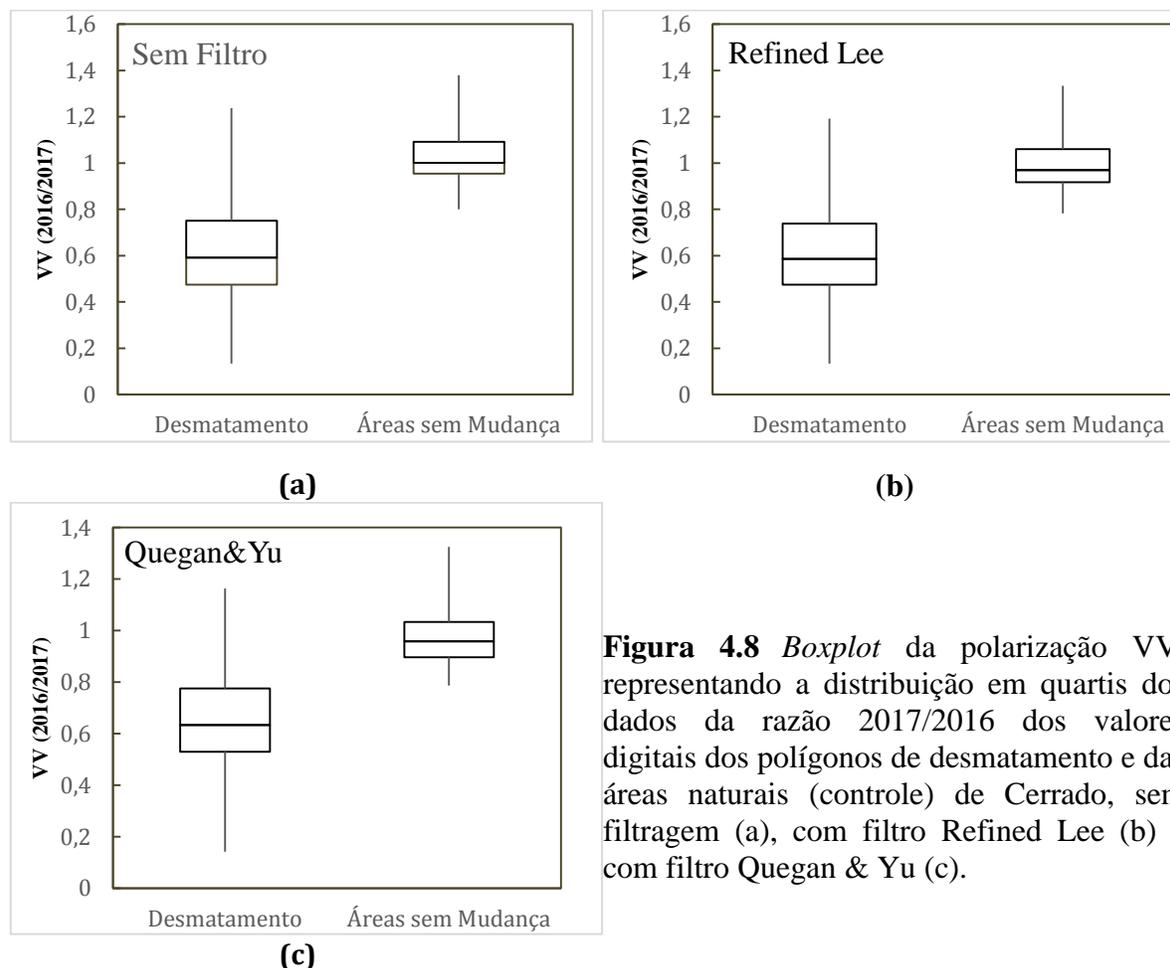


Figura 4.8 *Boxplot* da polarização VV, representando a distribuição em quartis dos dados da razão 2017/2016 dos valores digitais dos polígonos de desmatamento e das áreas naturais (controle) de Cerrado, sem filtragem (a), com filtro Refined Lee (b) e com filtro Quegan & Yu (c).

Na polarização VH, observa-se que os valores da razão (2017/2016) são um pouco menores, mas observa-se também, como na polarização VV, que existe uma separação entre a classe de desmatamento em comparação à classe de áreas naturais (Figura 4.9). A maior parte dos dados para a classe de desmatamento, do 3º quartil para baixo, apresentam valores abaixo de 0,8, e para a classe de áreas naturais, observa-se que os dados acima do 1º quartil estão acima de 0,9. Entre 0,8 e 0,9, também existe uma sobreposição de valores

máximos de desmatamento com valores mínimos de áreas sem mudança, no entanto, ao considerar a média de 0,5 para esse conjunto de dados, é possível considerar um limiar de corte abaixo de 0,8 nessa polarização.

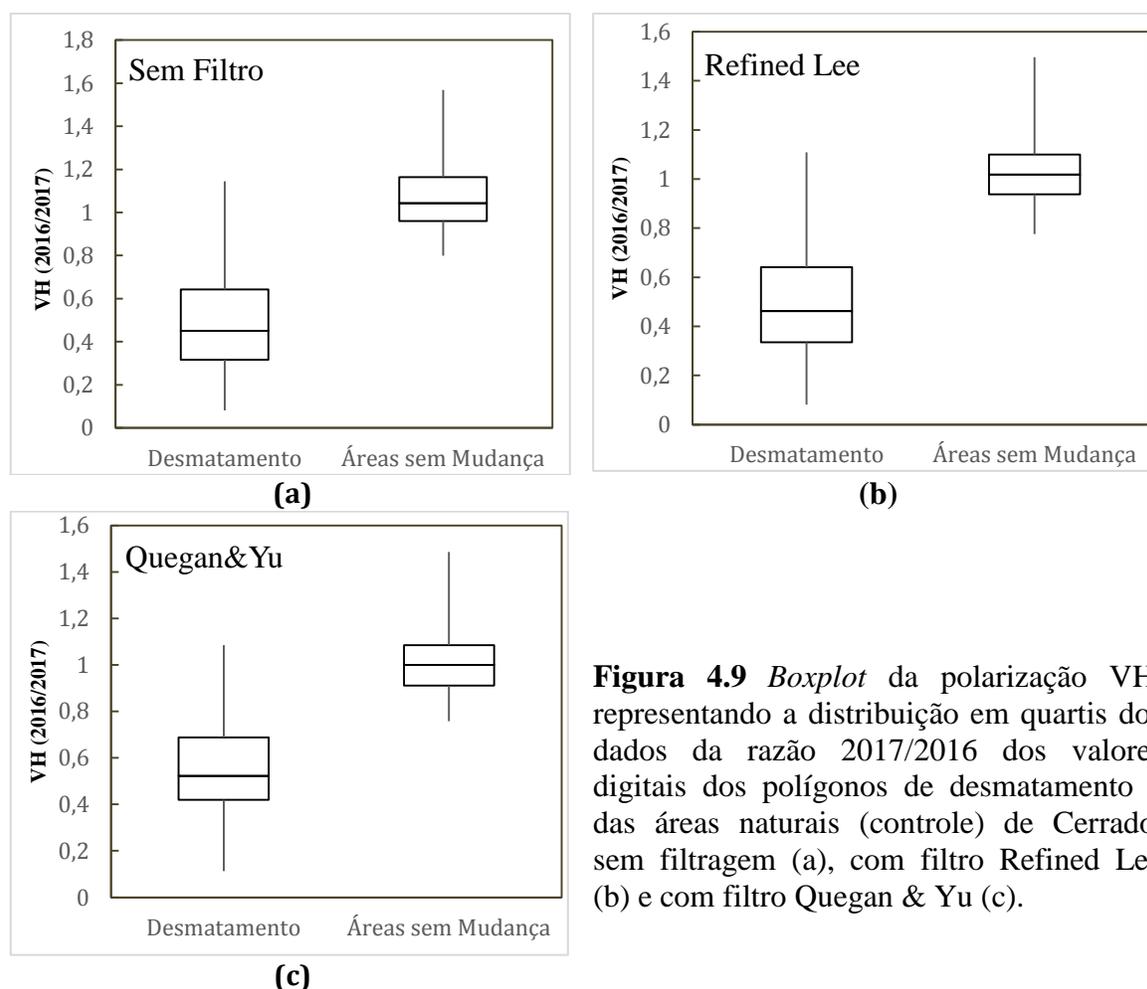


Figura 4.9 *Boxplot* da polarização VH, representando a distribuição em quartis dos dados da razão 2017/2016 dos valores digitais dos polígonos de desmatamento e das áreas naturais (controle) de Cerrado, sem filtragem (a), com filtro Refined Lee (b) e com filtro Quegan & Yu (c).

Considerando os dados apresentados, foram escolhidos três limiares de corte para detecção de desmatamento na área de estudo para cada polarização. Os limiares de corte máximo propostos possuem valores acima das médias apresentadas de modo a reduzir as possíveis omissões na detecção, mas também foi analisada a capacidade de detecção de desmatamento nas imagens do Sentinel-1A utilizando limiares abaixo desse valor de corte máximo. Foram escolhidos os seguintes limiares de corte para detecção de desmatamento na área de estudo para cada polarização: 0,6; 0,7 e 0,8 para a polarização VV; e 0,6; 0,7 e 0,76 para a polarização VH.

Após a aplicação do limiar de corte, os polígonos da detecção automática do Sentinel-1A foram analisados em comparação com os polígonos de desmatamentos vetorizados anteriormente com base nas imagens ópticas do Landsat-8, conforme ilustrado na Figura 4.10.

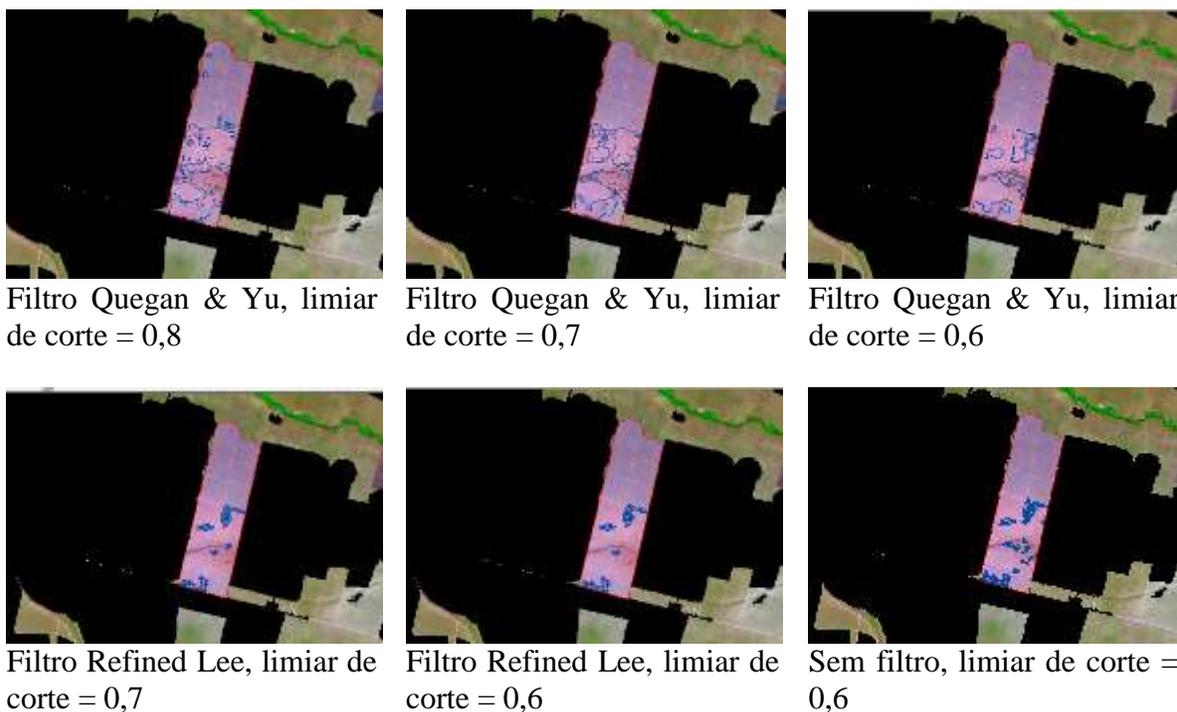


Figura 4.10 Comparação visual dos dados de desmatamento detectados automaticamente nas imagens Sentinel-1A em azul, com três limiares diferentes (0,8; 0,7; e 0,6) com relação aos dados ópticos vetorizados nas imagens Landsat-8, em vermelho, na polarização VV.

Para a polarização VV, foi possível observar nas figuras acima que a área desmatada foi detectada utilizando os três limiares, nos dados sem filtragem, e nos dois filtros aplicados (Quega & Yu e Refined Lee). Os polígonos gerados a partir dos dados com o filtro Quegan & Yu apresentaram geometria mais definida, com pouca influência do ruído *speckle*. Quanto maior o limiar para esse filtro, maior foi a área detectada. Os polígonos gerados a partir dos dados sem filtragem espacial e com o filtro Refined Lee apresentaram maior influência do ruído *speckle* na sua geometria, além de detectarem uma menor área. Para o exemplo em questão, as áreas de desmatamento detectadas com os limiares de corte

acima de 0,60 não apresentaram diferença dos polígonos detectados com o limiar de corte abaixo de 0,60, tanto para o filtro Refined Lee, quanto para os dados sem filtragem.

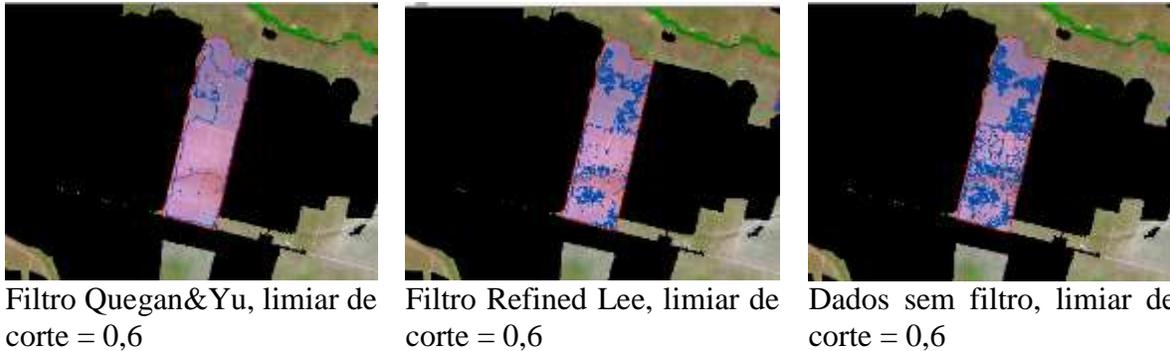


Figura 4.11 Comparação dos dados de desmatamento detectados automaticamente nas imagens Sentinel-1A em azul, com três limiares diferentes (0,76; 0,7; e 0,6) com relação aos dados ópticos vetorizados nas imagens Landsat-8, em vermelho, na polarização VH.

Para a polarização VH, as áreas desmatadas também foram detectadas nos dados sem filtragem, e nos dois filtros aplicados. Não houve diferença entre os polígonos detectados com o limiar de 0,60 e com os limiares maiores (0,76 e 0,70). Dessa forma, optou-se por ilustrar os polígonos detectados com o menor limiar. De mesmo modo que na polarização VV, os polígonos gerados a partir dos dados com o Filtro Quegan & Yu apresentaram geometria mais definida, com pouca influência do ruído *speckle*. Os polígonos gerados a partir dos dados sem filtragem espacial e com o filtro Refined Lee apresentaram maior influência do ruído *speckle* na sua geometria. Ao comparar as duas polarizações, a polarização VH apresentou maior área de detecção e uma qualidade maior no formato geométrico dos polígonos. Durante a validação, observou-se que áreas onde houve ocorrência de queimadas também foram detectadas. Por isso, optou-se por analisar se houve separação dos valores de diferença entre a classe de desmatamento e de queimadas antes de dar continuidade à validação e cálculo de acurácia.

Ao analisar os *boxplots* comparando a capacidade de discriminação entre áreas desmatadas e áreas queimadas (Figura 4.12), observou-se que não houve separação entre as duas classes, independentemente da polarização ou aplicação de filtros. Na polarização VH, os dados de queimada apresentaram valores um pouco maiores, variando entre 0,45 a 0,72, do primeiro ao terceiro quartil (50% dos dados), enquanto que os dados de desmatamento

para essa polarização variaram de 0,31 a 0,68. Já na polarização VV, as duas classes apresentaram variações similares, sendo de 0,47 a 0,77 para os dados de desmatamento e de 0,48 a 0,73 para os dados de queimada, do primeiro ao terceiro quartil.

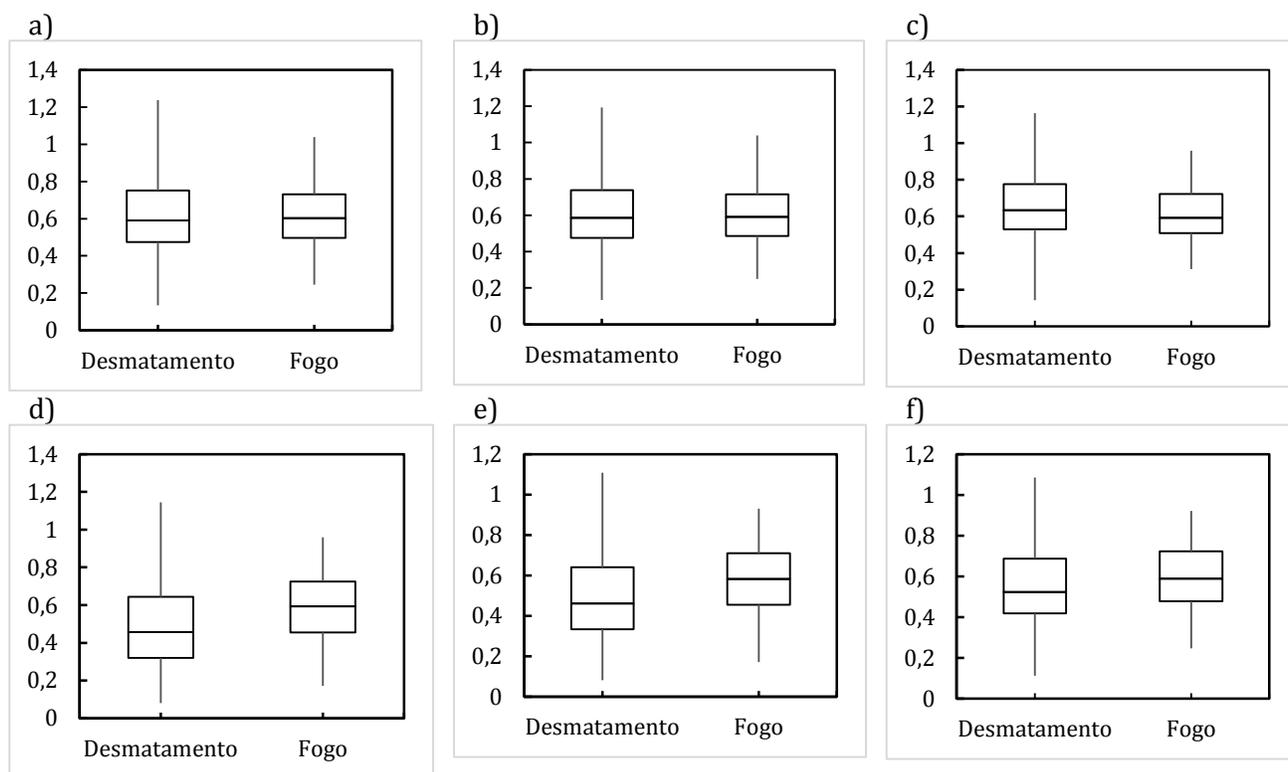


Figura 4.12 *Boxplot* representando a distribuição em quartis dos dados relativos à razão 2017/2016 para as classes de desmatamento e queimadas na polarização VV, sem filtragem (a), com filtro Refined Lee (b) e filtro Quegan & Yu (c) e na polarização VH, sem filtragem (d), com filtro Refined Lee (f) e filtro Quegan & Yu (g).

Como não foi possível discriminar entre desmatamento e queimada, os polígonos detectados de queimada foram considerados na análise de acurácia considerando agora não mais a detecção de desmatamento de forma isolada, mas sim o potencial do uso das imagens Sentinel-1A para detecção de mudança.

4.5 Acurácia da detecção automática de desmatamento

Os resultado das máscaras de mudanças geradas no *Google Earth Engine* utilizando a polarização VH das imagens do Sentinel-1A obtiveram resultados distintos para os três tratamentos, principalmente no que se refere ao filtro temporal em comparação ao filtro Refined Lee e às imagens sem filtro. Observa-se, na Tabela 4.2, que quanto menor o limiar de corte maior foi a acurácia e o erro de omissão. Contudo, o melhor resultado consistiu abaixo do limiar de 0,60 para o filtro *Refined Lee*, que não teve um aumento considerável no erro de omissão do limiar 0,70 para o limiar 0,60.

Tabela 4.2 Erro global calculado para os dados de detecção automática do Sentinel-1A validados com base nos dados ópticos de desmatamento nas imagens Landsat-8, para a polarização VV, e para os dados sem filtro e com o filtro Refined Lee e Quegan & Yu, em cada limiar de corte aplicado.

		Polarização VV		
		Limiars de corte aplicados		
		0,80	0,70	0,60
Sem filtragem	Acurácia (%)	-	-	91,80
	Erro de omissão (%)	-	-	52,88
Filtro Refined Lee	Acurácia (%)	77,53	87,96	92,77
	Erro de omissão (%)	53,22	53,22	54,24
Filtro Quegan & Yu	Acurácia (%)	15,22	66,67	86,43
	Erro de omissão (%)	21,69	35,93	54,24

Para a validação dos polígonos de detecção de mudança e cálculo da acurácia foi considerada a incidência da ocorrência, mesmo que a área detectada nas máscaras não abrangesse todo o polígono vetorizado nas imagens óticas do Landsat-8. Dessa forma, apesar da maior acurácia para os tratamentos das imagens sem filtro e com aplicação do filtro Refined Lee, esses dois tratamentos não conseguiram detectar os polígonos de desmatamento inteiramente, somente parte deles. Por outro lado, os polígonos detectados utilizando o filtro temporal tiveram melhores resultados considerando a área total dos desmatamentos, como também das áreas de fogo.

Os resultados dos valores de acurácia para a polarização VV foram de modo geral, menores que na polarização VH (Tabela 4.3). Somente para os limiares 0,70 e 0,60 do filtro

Quegan & Yu, os valores de acurácia foram maiores, por outro lado, a taxa de omissão também aumentou nessa polarização para esse filtro, como também para os outros dois tratamentos. Foi possível observar, nas duas polarizações, que quanto menor o limiar de corte maior é a acurácia, e maior também é o erro de omissão. Contudo, o melhor resultado consistiu abaixo do limiar de 0,60 para o filtro Refined Lee, que não teve um aumento considerável no erro de omissão do limiar 0,70 para o limiar 0,60.

Tabela 4.3 Erro global calculado para os dados de detecção automática do Sentinel-1A validados com base nos dados ópticos de desmatamento nas imagens Landsat-8, para a polarização VH, e para os dados sem filtro e com o filtro Refined Lee e Quegan & Yu, em cada limiar de corte aplicado.

		Polarização VH		
		Limiars de corte aplicados		
		0,76	0,70	0,60
Sem filtragem	Acurácia (%)	-	-	93,08
	Erro de Omissão (%)	-	-	38,64
Filtro Refined Lee	Acurácia (%)	-	91,26	95,02
	Erro de Omissão (%)	-	38,31	38,64
Filtro Quegan & Yu	Acurácia (%)	38,31	56,14	86,21
	Erro de Omissão (%)	18,98	22,71	37,97

Segundo Aboud Neta et al. (2010), os erros de inclusão podem acontecer devido ao acúmulo hídrico no solo alguns dias antes do imageamento do radar. No entanto, ao analisar os dados de precipitação do INMET da estação meteorológica de Barreiras observou-se que não houve registro de chuva nos dias anteriores ao imageamento. Ainda segundo Aboud Neta et al. (2010), os casos do erro de omissão podem ser, em parte, por causa de vestígios de restos de biomassa no solo, também reportado por Almeida Filho et al. (2007) nos casos de desmatamentos recentes. Ao analisar os casos de omissão por período de ocorrência nas imagens Landsat-8, observou-se que esses polígonos não possuem um padrão relacionado à data de desmate. Entretanto, não está descartada a hipótese da influência da biomassa no comportamento do retorno do sinal emitido pelo sensor, visto que a dinâmica de desmatamento (desmate, queima, limpeza de terreno) encontrada nos polígonos visitados em campo, além da velocidade dessa dinâmica, não

estava relacionada com o tempo que havia ocorrido o desmatamento, mas talvez, aos recursos financeiros do proprietário do terreno.

5. CONSIDERAÇÕES FINAIS

De posse dos resultados obtidos, pode-se concluir que o objetivo primordial do trabalho de detecção de desmatamento, ou mudanças de cobertura, utilizando dados de radar no Cerrado com os dados do Sentinel-1A, banda C, foi alcançado. Considerando a influência da cobertura de nuvens nos dados ópticos, constatou-se que o uso de radar no monitoramento de desmatamento é uma “ferramenta” importante de auxílio às imagens ópticas na aquisição de informações, visto que a ocorrência de erros de comissão e omissão limitam o uso do radar de forma independente, sendo necessário dados adicionais para análise das detecções encontradas.

Os filtros aplicados mostraram desempenhos distintos e influenciaram diretamente na detecção devido sua implicação na resolução espacial da imagem. O filtro Quegan & Yu não apresentou bom desempenho na detecção de mudanças nos dados do Sentinel-1A devido à elevada porcentagem de erros de inclusão. Já o filtro Refined Lee apresentou um bom desempenho, superior aos dados sem filtragem espacial (de acordo com o erro global), em comparação com as detecções realizadas nas imagens ópticas do Landsat-8 OLI.

Evidenciou-se que, em geral, não há perda significativa de informação ao comparar as duas polarizações, no entanto a polarização VH mostrou resultados superiores na detecção de desmatamento em comparação com a polarização VV.

A plataforma *Google Earth Engine* mostrou ser eficaz na aquisição, pré-processamento e processamento de dados de sensoriamento remoto por radar. Considerando que esses dados são robustos e que exigem uma grande capacidade de processamento, a realização desse trabalho tornou-se viável em uma plataforma de processamento em nuvem.

A grande dificuldade encontrada neste estudo foi a utilização de uma plataforma nova de processamento de dados de sensoriamento remoto, que ainda está em evolução e necessita de conhecimentos prévios de linguagem de programação para a execução de

scripts e algoritmos. No entanto, a escolha do uso do *Google Earth Engine* tornou rápido e ágil os processamentos dos dados de radar que costumam ser bastante lentos.

Além disso, existe uma carência de estudos envolvendo o uso de imagens de radar para monitoramento do Cerrado, dificultando a comparação dos resultados desse estudo com outros dados padrões. Há de se considerar que as imagens do satélite Sentinel-1A são disponibilizadas gratuitamente desde meados de 2015, algo inédito para sensores orbitais de radar. Dessa forma, estudos envolvendo monitoramento de desmatamento, como também o uso e cobertura da terra com esses dados, tendem a ampliar.

Recomenda-se, portanto, a continuidade desse estudo inicial, investigando outras formas de uso desses dados para detecção de desmatamento no Cerrado, bem como sua aplicação em todo bioma, indicando o nível de confiabilidade dele e a eficácia da metodologia empregada. Recomenda-se ainda o uso integrado de imagens obtidas por sensores de radares com imagens ópticas, como os satélites Landsat e Sentinel-2, ambos disponibilizados gratuitamente na internet. O uso combinado ou complementar de imagens ópticas, ou produtos provenientes desses dados, podem auxiliar na distinção entre desmatamento e fogo, minimizando erros ocasionados por ruídos.

REFERÊNCIAS

ALMEIDA FILHO, R.; ROSENQVIST, A.; SHIMABUKURO, Y. E.; SANTOS, J. R. Evaluation and perspectives of using multitemporal L-band SAR data to monitor deforestation in the Brazilian Amazônia. **IEEE Geoscience and Remote Sensing Letters**, vol. 2, n. 4, 2005.

ALMEIDA FILHO, R.; ROSENQVIST, A.; SHIMABUKURO, Y. E.; SILVA GOMEZ, R. Detecting deforestation with multitemporal L-band SAR imagery: a case study in Western Brazilian Amazon. **International Journal of Remote Sensing**, v. 28, n. 6, p. 1383-1390, 2007.

ALMEIDA FILHO, R.; SHIMABUKURO, Y. E. Detecting areas disturbed by gold mining activities through JERS-1 SAR images, Roraima State, Brazilian Amazon. **International Journal of Remote Sensing**, vol. 21, n. 17, p. 3357-3362, 2010.

ANGELIS, C. F.; FREITAS, C. C.; VALERIANO, D. M.; DUTRA L. V. Multitemporal analysis of land use/land cover JERS-1 backscatter in the Brazilian tropical rainforest. **International Journal of Remote Sensing**, vol. 23, n. 7, p. 1231-1240, 2002.

ARAÚJO, L. S.; SANTOS, J. R.; FREITAS, C. C.; XAUD, H. A. M. The use of microwave and optical data for estimating aerial biomass of the savanna and forest formations at Roraima State, Brazil. **Geoscience and Remote Sensing Symposium**, p. 1999.

ARRUDA, M. B.; PROENÇA, C. E. B.; RODRIGUES, S. C.; CAMPOS, R. N.; MARTINS, R. C.; MARTINS, E. S. Ecorregiões, unidades de conservação e representatividade ecológica do Bioma Cerrado. In: SANO, S. M.; ALMEIDA, S. P.; RIBEIRO, J. F. (Eds.). **Cerrado: Ecologia e Flora**. Brasília: Embrapa SPI, 2008. p. 229-272.

BALTZER, H.; COLE, B.; THIEL, C.; SCHMULLIUS, C. Mapping CORINE land cover from Sentinel-1A SAR and SRTM digital elevation model data using Random Forests. **Remote Sensing**, vol. 7, n. 11, p. 14876-14898, 2015.

BEJIMA, S. V.; COMBER, A.; LAMB, A. Random forest classification of salt marsh vegetation habitats using quad-polarimetric airborne SAR, elevation and optical RS data. **Remote Sensing of Environment**, vol. 149, p. 118–129, 2014.

BERTOLINI, V. A. **Ocupando o cerrado – Avaliação do processo de implantação de assentamentos rurais no entorno do Distrito Federal**. 2005. Dissertação (Mestrado em Arquitetura e Urbanismo), Faculdade de Arquitetura, Universidade de Brasília, Brasília.

BRANNSTROM, C.; JEPSON, W.; FILIPPI, A. M.; REDO, D.; XU, Z.; GANESH, S. Land change in the Brazilian savanna (Cerrado), 1986-2002: comparative analysis and implications for land-use policy. **Land Use Policy**, v. 25, p. 579-595, 2008.

BORGES, E. F. **Discriminação e característica fenológica de classes de cobertura vegetal na cobertura vegetal natural e antrópica do Oeste da Bahia a partir de séries temporais do sensor MODIS**. Tese de Doutorado, Universidade de Brasília, fevereiro de 2014.

BOUVET, A.; LE TOAN, T.; LAM-DAO, N. Monitoring of the rice cropping system in the Mekong delta using ENVISAT/ASAR dual polarization data. **IEEE Transactions on Geoscience and Remote Sensing**, vol., 47, n. 2, p. 517, 2009.

CARNEIRO FILHO, A.; COSTA, K. **A expansão da soja no Cerrado. Caminhos para a ocupação territorial, uso do solo e produção sustentável.** São Paulo: Agroícone, 28 p., 2016.

CARVALHO, L. M. T.; RAHAMAN, M. M.; HAY, G. J.; YACKEL, J. Optical and SAR imagery for mapping vegetation gradients in Brazilian savannas: Synergy between pixel-based and object-based approaches. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Vol. XXXVIII-4/C7, 2010.

CPRM. Companhia de Recursos Minerais. **Mapa Geológico do Estado da Bahia – Escala 1:1.000.000.** Salvador: CPRM, 2003. Versão 1.1. Programas Carta Geológica do Brasil ao Milionésimo e Levantamentos Geológicos Básicos do Brasil (PLGB). Convênio de Cooperação e Apoio técnico- Científico CPM-CPRM.

CPRM. Companhia de Recursos Minerais. **RADAM-D.** Acessado em novembro de 2016. Disponível em: <http://www.cprm.gov.br/publique/Geologia/Sensoriamento-Remoto-e-Geofisica/RADAM-D-628.html>.

DOBSON, M. C. Forest information from synthetic aperture radar. **Journal of Forestry**, vol. 98, n. 6, p. 41-43, 2000.

DONG, Y.; MILNE, A. K.; FORSTER, B. C. Toward edge sharpening: a SAR speckle filtering algorithm. **IEEE Transactions on Geoscience and Remote Sensing**, v. 39, n. 4, p. 851-863, 2001.

Embrapa. **Caracterização geomorfológica do município de Luís Eduardo Magalhães, oeste baiano, escala 1:100.000.** Boletim de Pesquisa e Desenvolvimento, Planaltina, DF: Embrapa Cerrados, 2010.

ENGDAHL, M. E.; HYYPPÄ, J. M. Land-cover classification using multitemporal ERS-1/2. **IEEE Transactions on Geoscience and Remote Sensing**, vol. 41, n. 7, p. 1620-1628, 2003.

FERREIRA, M. E.; FERREIRA, L. G.; FERREIRA, N. C.; ROCHA, G. F.; NEMAYER, M. Desmatamentos no bioma Cerrado: uma análise temporal (2001-2005) com base nos dados MODIS - MOD13Q1. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., Florianópolis, SC. **Anais...** São José dos Campos: INPE, p. 3877-3883, 2007.

FERREIRA, L. G.; FERREIRA, N. C.; FERREIRA, M. E. Sensoriamento remoto da vegetação: evolução e estado-da-arte. **Acta Scientiarum Biological Science**, v. 30, n. 4, p. 379-390, 2008.

FERREIRA, M. E.; MIZIARA, F.; FERREIRA Jr., L. G.; RIBEIRO, F. L.; FERREIRA N. C. Ativos ambientais do bioma cerrado: uma análise da cobertura vegetal nativa e sua relação com o preço da terra no estado de Goiás. **Revista Brasileira de Cartografia**, vol. 61, p. 37-50, 2009.

FLORES, P. M.; GUIMARÃES, R. F.; CARVALHO JÚNIOR, O. A.; GOMES, R. A. T. Análise multitemporal da expansão agrícola no município de Barreiras – Bahia (1988-2008). **Campo-Território**, v. 7, n. 14, p. 1-19, 2012.

FREITAS, D.M. **Potencial das imagens multipolarizadas do satélite ALOS/PALSAR na discriminação de cobertura vegetal do bioma Pantanal: estudo de caso na região do Médio Taquari, MS**. 2012. Dissertação (Mestrado em Geociências) - Universidade de Brasília, Brasília.

GUERRA, J. B.; MURA, J. C.; FREITAS, C. C. Discriminação de incrementos de desflorestamento na Amazônia com dados SAR R99B em banda L. **Acta Amazonica**, vol. 40, n. 3, p. 557-565, 2010.

GEE. 2018. Disponível em: <https://developers.google.com/earth-engine/sentinel1>. Acessado em novembro de 2017.

HANSEN, M. C.; POTAPOV, P. V.; MOORE, R.; HANCHER, M.; TURUBANOVA, S. A. et al. High-resolution global maps of 21st-century forest cover change. **Science**, v. 342, n. 6160, p. 850-853, 2013.

HENDERSON, F. M.; LEWIS, A. J. **Principles & Applications of Imaging Radar**. Manual of Remote Sensing. Nova York: John Wiley & Sons, Inc., 3^a ed., v. 2, p. 866, 1998,

HOSONO. A., ROCHA. C. M. C.; HONGO, Y.; KITANO, N. **Development for Sustainable Agriculture: The Brazilian Cerrado**. Palgrave Macmillan; 1^a ed., 2016.

IBGE. Instituto Brasileiro de Geografia e Estatística. 2004. **Mapa de Biomas e de Vegetação**. Disponível em: <http://www.ibge.gov.br>. Acessado em junho de 2017.

IBGE. **Noções Básicas de Cartografia**. 2007. Disponível em: <http://www.ibge.gov.br>. Acessado em novembro de 2017.

IBGE. Instituto Brasileiro de Geografia e Estatística. 2017. **Pedologia**. Rio de Janeiro, RJ. Disponível em: <https://www.ibge.gov.br/geociencias-novoportal/informacoes-ambientais/pedologia/10871-pedologia.html?=&t=downloads>. Acessado em março de 2018.

INPE. **Sistema de Detecção de Desmatamento em Tempo Real**. 2018. Disponível em: <http://www.obt.Inpe.br/deter/>.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente. Uma Perspectiva em Recursos Terrestres**. EPIPHANIO, J. C. N. (Coord. Trad.). São José dos Campos: Parêntese, p. 598, 2011.

LEE, J. S.; GRUNES, M. R.; SCHULER, D. L.; POTTIER, E.; FERRO-FAMIL, L. Scattering-model-based speckle filtering of polarimetric SAR data. **IEEE Transactions on Geoscience and Remote Sensing**, vol. 44, n. 1, pp. 176–187, 2006.

KASISCHKE, E. S.; MELACK, J. M.; DOBSON, M. C. The use of imaging radars for ecological applications - a review. **Remote Sensing of Environment**, vol. 59, n. 2, p. 141-156, 1997.

KLINK, C. A.; MACHADO, R. B. Conservation of the Brazilian Cerrado. **Conservation Biology**, v. 19, n. 3, p. 707-713, 2005.

KUPLICH, T. M. Estudos florestais com imagens de radar. **Espaço & Geografia**, vol. 6, n. 1, p. 65-90, 2003.

KUMARA, T.; PATNAIK, C. Discrimination of mangrove forests and characterization of adjoining land cover classes using temporal C-band synthetic aperture radar data: A case study of Sundarbans. **International Journal of Applied Earth Observation and Geoinformation**, vol. 23, p. 119–131, 2013.

LEHMANN, E. A.; CACCETTA, P.; LOWELL, K.; MITCHELL, A.; ZHOU, Z. S.; HELD, A.; MILNE, T.; TAPLEY, I. SAR and optical remote sensing: Assessment of complementarity and interoperability in the context of a large-scale operational forest monitoring system. **Remote Sensing of Environment**, vol. 156, p. 335–348, 2015.

LILLESAND, T. M., KIEFER, R. W.; CHIPMAN, J. W. **Remote Sensing and Image Interpretation**. 6^a ed., John Wiley & Sons, Hoboken. 2008.

MAIN, R.; MATHIEU, R.; KLEYNHANS, W.; WESSELS, K.; NAIDOO, L.; ASNER, G. P. Hyper-temporal C-band SAR for baseline woody structural assessments in deciduous savannas. **Remote Sensing**, vol. 8, p. 661, 2016.

MARRIS, E. Conservation in Brazil: The forgotten ecosystem. **Nature**, vol. 437, n. 3, p. 944-945, 2005.

MATHER, P. M. **Computer Processing of Remotely-Sensed Images**. An Introduction. Chichester: John Wiley and Sons, 1999.

MENKE, A. B.; CARVALHO JÚNIOR, O. A.; GOMES, R. A. T.; MARTINS, E. S.; OLIVEIRA, S. N. Análise das mudanças do uso agrícola da terra a partir de dados de sensoriamento remoto multitemporal no município de Luís Eduardo Magalhães (BA – Brasil). **Sociedade & Natureza**, vol. 21, p. 315-326, 2009.

MITCHARD, E. T. A.; SAATCHI, S. S.; LEWIS, S. L.; FELDPAUSCH, T. R.; WOODHOUSE, I. H.; SONKÉ, B.; ROWLAND, C.; MEIR, P. Measuring biomass changes due to woody encroachment and deforestation/degradation in a forest–savanna boundary region of central Africa using multi-temporal L-band radar backscatter. **Remote Sensing of Environment**, vol. 115, p. 2861–2873, 2011.

MMA. Ministério do Meio ambiente. **O bioma Cerrado**. Disponível em: <<http://www.mma.gov.br/biomas/cerrado>>. Acessado em janeiro 2018.

MMA. Ministério do Meio Ambiente. **Mapeamento do uso e cobertura do Cerrado: Projeto TerraClass Cerrado 2013**. Brasília: MMA, p. 67, 2015.

MYERS, N.; MITTERMEIER, R. A.; MITTERMEIER, C. G.; FONSECA, G. A. B.; KENT, J. Biodiversity hotspots for conservation priorities. **Nature**, v. 403, p. 853-858, 2000.

MAROUELLI, R. P. **O desenvolvimento sustentável da agricultura no Cerrado Brasileiro**. Brasília, 2003. Monografia (Especialização em Gestão Sustentável de Agricultura Irrigada), ISEA-FGV, Brasília.

MENESES, P. R., ALMEIDA, T. **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. 1ª. ed. Brasília, CNPq, v. 1, 2012. Disponível online em <http://www.cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8>

MONDARDO, M. L. A “territorialização” do agronegócio globalizado em Barreiras – BA: migração sulista, reestruturação produtiva e contradições sócio-territoriais. **Revista Nera**, v. 13, n. 17, p. 112-130, 2010.

NAVARRO, A.; ROLIM, J.; MIGUEL, I.; CATALÃO, J.; SILVA, J.; PAINNHO, M.; VEKERDY, Z. Crop monitoring based on SPOT-5 Take-5 and Sentinel-1A data for the estimation of crop water requirements. **Remote Sensing**, vol. 8, n. 6, p. 525, 2016.

NOVO, E. M. **Sensoriamento Remoto: Princípios e Aplicações**. São José dos Campos: Edgar Blücher, 2008.

PEKEL, J. F.; COTTAM, A.; GORELICK, N.; BELWARD, A. S. High-resolution mapping of global surface water and its long-term changes. **Nature**, vol. 540, n. 7633, p. 418-422, 2016.

PESSÔA, V. L. S.; INOCÊNCIO, M. E. O Prodecer (re)visitado: as engrenagens da territorialização do capital no Cerrado. **Campo-Território**, v. 9, n. 18, p. 1-22, 2014.

RADA, N. Assessing Brazil's Cerrado agricultural miracle. **Food Policy**, v. 38, p. 146-155, 2013.

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

REZENDE G. C. **Ocupação agrícola e estrutura agrária no Cerrado: O papel do preço da terra, dos recursos naturais e da tecnologia**. Rio de Janeiro: IPEA, 2002.

RIBEIRO, J. F.; ALMEIDA, S. P.; SANO, S. M. **Cerrado: ecologia e flora**. Planaltina: Embrapa Cerrados, 2008.

RIBEIRO, J. F.; WALTER, B. M. T. Fitofisionomias do bioma Cerrado. In: SANO, S. M.; ALMEIDA. **Cerrado. Ambiente e Flora**. Brasília: Embrapa Cerrados, 1998, p. 87-166.

ROSA, R. O uso de tecnologias de informação geográfica no Brasil. **Revista Geográfica de América Central**, vol. 2, n. 47E, p. 1-17, 2011.

ROCHA, G. F.; FERREIRA L. G.; FERREIRA, N. C.; FERREIRA, M. E. Detecção de desmatamentos no bioma Cerrado entre 2002 e 2009: padrões, tendências e impactos. **Revista Brasileira de cartografia**, n. 63/03, p. 341-349, 2011.

ROTT, H. Advances in interferometric synthetic aperture radar (InSAR) in Earth system science. **Progress in Physical Geography**, vol. 33, n. 6, p. 769-791, 2009.

ROY, D. P.; WULDER, M. A.; LOVELAND, T. R.; WOODCOCK, C. E.; ALLEN, R. G. et al. Landsat-8: Science and product vision for terrestrial global change research. **Remote Sensing of Environment**, v. 145, p. 154-172, 2014.

SANO, E. E.; PINHEIRO, G. G. C.; MENESES, P. R. Assessing JERS-1 synthetic aperture radar data for vegetation mapping in the Brazilian savanna. **Journal of the Remote Sensing Society of Japan**, vol. 21, n. 2, 2001.

SANO, E. E.; FERREIRA, L. G.; HUETE, A. R. Synthetic aperture radar (L-band) and optical vegetation indices for discriminating the Brazilian savanna physiognomies: A comparative analysis. **Earth Interactions**, vol. 9, Paper no. 15, 2005.

SANO, E. E.; ROSA, R.; BRITO, J. L. S.; FERREIRA, L. G. Notas Científicas. Mapeamento semidetalhado do uso da terra do bioma Cerrado. **Pesquisa Agropecuária Brasileira**, v. 43, p. 153-156, 2008.

SANO, E. E.; ROSA, R.; BRITO, J. L.; FERREIRA, L. G. Land cover mapping of the tropical savanna region in Brazil. **Environmental Monitoring & Assessment**, vol. 166, p. 113-124, 2010.

SANO, E. E.; SANTOS, C. C. M.; SILVA, E. M.; CHAVES, J. M. Fronteira agrícola do Oeste baiano: considerações sobre os aspectos temporais e ambientais. **Geociências**, vol. 30, n. 3, p. 479-489, 2011.

SANTOS, J. R.; KEIL, M.; ARAUJO, L. S.; PARDI LACRUZ, M. S.; KRAMER, J. C. M.; KANDLER, O. Biomass estimation of forest and savanna transition vegetation zone by JERS-1 and SIR-C backscatter data. **International Archives of Photogrammetry and Remote Sensing**, vol. XXXIII, Part B7, 2000.

SANTOS, M. A.; BARBIERI, A. F.; CARVALHO, J. A. M.; MACHADO, C. J. **O Cerrado Brasileiro. Notas para Estudo**. Belo Horizonte: UFMG/CEDEPLAR, n. 387, p. 15, 2010.

SILVA, L. L. O papel do estado no processo de ocupação das áreas de Cerrado entre as décadas de 60 e 80. **Caminhos de Geografia**, vol. 2, p. 24-36, 2000.

SILVA, J. M. C.; BATES, H. M. Biogeographic patterns and conservation in the South American Cerrado: a tropical savanna hotspot. **BioScience**, vol. 52, n. 3, p. 225-234, 2002.

SILVA, J. F.; FARIÑAS, M. R.; FELFILI, J. M.; KLINK, C. A. Spatial heterogeneity, land use and conservation in the Cerrado region of Brazil. **Journal of Biogeography**, vol. 33, p. 536-548, 2006.

SOUZA FILHO, P. W. M.; PARADELLA, W. R.; SOUZA JÚNIOR, C. S.; VALERIANO D. M.; MIRANDA, F. P. Sensoriamento remoto e recursos naturais da Amazônia. **Ciência e Cultura**, vol. 58, n. 3, p. 37-41, 2006.

SOARES-FILHO, B.; RAJÃO, R.; MACEDO, M.; CARNEIRO, A.; COSTA, W.; COE, M.; RODRIGUES, H.; ALENCAR, A. Cracking Brazil's Forest Code. **Science**, v. 344, n. 6182, p. 363-364, Apr. 25, 2014.

TEIXEIRA, W.F. **O uso de imagens R99-SAR/SIPAM no programa de monitoramento do desmatamento da Floresta Amazônica brasileira**. 2015. Dissertação (Mestrado em Geografia), Universidade Federal da Amazônia, Manaus.

THE ECONOMIST. **Brazilian agriculture. The miracle of the Cerrado**. Agosto de 2010. Disponível em: <<http://www.economist.com/node/16886442>>. Acessado em: 17 jan. 2018.

TORRES, R.; SNOEIJ, P.; GEUDTNER, D.; BIBBY, D.; DAVIDSON, M. et al. GMES Sentinel-1 mission. **Remote Sensing of Environment**, vol. 120, p. 9-24, 2012.

TANASE, M. A.; ISMAIL, I.; LOWEL, K.; KARYANTO, O.; SANTORO, M. Detecting and quantifying forest change: the potential of existing C- and X-band radar datasets. **PLOS One**, vol. 10, n. 6, p. e0131079, 2015.

TAKEUCHI, S.; OGURO, Y. A comparative study of coherence patterns in C-band and L-band interferometric SAR from tropical rain forest areas. **Advanced Space Research**, vol. 32, n. 11, p. 2305-2310, 2003.

VASILE, G.; OVARLEZ, J. P.; PASCAL, F.; TISON, C. Coherency matrix estimation of heterogeneous clutter in high-resolution polarimetric SAR images. **IEEE Transactions on Geoscience and Remote Sensing**, vol. 48, n. 4, p. 1809-1826, 2010.

WOODHOUSE I. **Introduction to Microwave Remote Sensing**. Boca Raton: CRC Press, 2006.

ZARONI, M. J.; SANTOS, H. G.; ALMEIDA, E. P. C. **Árvore do conhecimento solos tropicais**. Brasília: AGEITEC, 2012.

APÊNDICES

APENDICE 1. Script desenvolvido no *Google Earth Engine*

```
// Script para filtragem e detecção de mudanças sobre imagens Sentinel-1

var di='2016-10-15'
var df='2017-10-21'

var d1='2016-10-12'
var d2='2016-10-28'
var d3='2017-10-15'
var d4='2017-10-21'

var orbita=126
var colecaoSentinelVH=colecaoSentinel
.filterMetadata('relativeOrbitNumber_start','equals',orbita) //evita sobreposições
.filterBounds(AOI)
.filterDate(di,df)
.select(1) // Seleção de banda 0=VV 1=VH
var
  colecaoSentinelVH_f=QueganYuFilter(colecaoSentinelVH.map(toNatural),5).map(toDB)

var colecaoFiltradaVH1=colecaoSentinelVH.filterDate(d1,d2)
var colecaoFiltradaVH2=colecaoSentinelVH.filterDate(d3,d4)
var colecaoFiltradaVH1_f=colecaoSentinelVH_f.filterDate(d1,d2)
var colecaoFiltradaVH2_f=colecaoSentinelVH_f.filterDate(d3,d4)
print (colecaoFiltradaVH1)
print (colecaoFiltradaVH2)

var colecaoFiltradaVH1_media=colecaoFiltradaVH1.map(toNatural)
var colecaoFiltradaVH2_media=colecaoFiltradaVH2.map(toNatural)
var colecaoFiltradaVH1_media_lee=RefinedLee(colecaoFiltradaVH1.map(toNatural))
var colecaoFiltradaVH2_media_lee=RefinedLee(colecaoFiltradaVH2.map(toNatural))
var colecaoFiltradaVH1_media_f=colecaoFiltradaVH1_f.map(toNatural)
var colecaoFiltradaVH2_media_f=colecaoFiltradaVH2_f.map(toNatural)

var ratio=colecaoFiltradaVH2_media.divide(colecaoFiltradaVH1_media)
var ratio_lee=colecaoFiltradaVH2_media_lee.divide(colecaoFiltradaVH1_media_lee)
var ratio_f=colecaoFiltradaVH2_media_f.divide(colecaoFiltradaVH1_media_f)

var
  stack=ee.Image(toDB(colecaoFiltradaVH1_media)).addBands(ee.Image(toDB(colecaoFiltradaVH2_media))).addBands(ratio)
```

```

var
  stack_lee=ee.Image(toDB(colecaoFiltradaVH1_media_lee)).addBands(ee.Image(toDB(colecaoFiltradaVH2_media_lee))).addBands(ratio_lee)
var
  stack_f=ee.Image(toDB(colecaoFiltradaVH1_media_f)).addBands(ee.Image(toDB(colecaoFiltradaVH2_media_f))).addBands(ratio_f)
stack=stack.select([0,1,2],['media_p1','media_p2','ratio'])
print (stack)

Map.addLayer(stack,{min: [-20,-20,0],max: [-4,-4,32]},'composicao')
Map.addLayer(stack_lee,{min: [-20,-20,0],max: [-4,-4,32]},'composicao filtrada com lee')
Map.addLayer(stack_f,{min: [-20,-20,0],max: [-4,-4,32]},'composicao filtrada com QueganYu')

var valor_medio_CRs=stack.reduceRegions(CRs,ee.Reducer.mean(),20)
print (valor_medio_CRs)
Export.table.toDrive({
  collection: valor_medio_CRs ,
  description: 'media_extraida_sem_filtro',
  fileFormat: 'CSV'
});

var valor_medio_CRs_lee=stack_lee.reduceRegions(CRs,ee.Reducer.mean(),20)
print (valor_medio_CRs_lee)
Export.table.toDrive({
  collection: valor_medio_CRs_lee ,
  description: 'media_extraida_com_filtro_lee',
  fileFormat: 'CSV'
});

var valor_medio_CRs_f=stack_f.reduceRegions(CRs,ee.Reducer.mean(),20)
print (valor_medio_CRs_f)
Export.table.toDrive({
  collection: valor_medio_CRs_f ,
  description: 'media_extraida_com_filtro_temporal',
  fileFormat: 'CSV'
});

Map.addLayer(AOI,{},'AOI')
Map.addLayer(CRs,{},'CRs')

var ratio_f_masked=ratio_f.updateMask(ratio_f.lt(0.6)).clip(AreasNaturais)
Map.addLayer(ratio_f_masked)

var ratio_masked=ratio.updateMask(ratio.lt(0.6)).clip(AreasNaturais)

var ratio_lee_masked=ratio_lee.updateMask(ratio_lee.lt(0.6)).clip(AreasNaturais)

```

```

Export.image.toDrive({
image: colecaoFiltradaVH1_media_f.clip(AOI),
description: 'colecaoFiltradaVH1_media_f',
scale: 20,
region: AOI
});
Export.image.toDrive({
image: ratio_f.clip(AOI),
description: 'ratio_f',
scale: 20,
region: AOI
});
Export.image.toDrive({
image: colecaoFiltradaVH2_media_f.clip(AOI),
description: 'colecaoFiltradaVH2_media_f',
scale: 20,
region: AOI
});

```

```

Map.addLayer(Antropico, {}, 'Antropico 2016')

```

```

Export.image.toDrive({
image: ratio_f_masked.clip(AOI),
description: 'ChangeMask_f_t',
scale: 20,
region: AOI
});

```

```

Export.image.toDrive({
image: ratio_masked.clip(AOI),
description: 'ChangeMask',
scale: 20,
region: AOI
});

```

```

Export.image.toDrive({
image: ratio_lee_masked.clip(AOI),
description: 'ChangeMask_lee',
scale: 20,
region: AOI
});

```

```

var valor_medio_N_CRs=stack.reduceRegions(NovosCRs,ee.Reducer.mean(),20)
print (valor_medio_N_CRs)
Export.table.toDrive({
collection: valor_medio_N_CRs ,

```

```

description: 'N_CRs_media_extraida_sem_filtro',
fileFormat: 'CSV'
});

var valor_medio_fogo=stack.reduceRegions(Fogo,ee.Reducer.mean(),20)
print (valor_medio_fogo)
Export.table.toDrive({
collection: valor_medio_fogo ,
description: 'Fogo_media_extraida_sem_filtro',
fileFormat: 'CSV'
});

var valor_medio_N_CRs_lee=stack_lee.reduceRegions(NovosCRs,ee.Reducer.mean(),20)
print (valor_medio_N_CRs)
Export.table.toDrive({
collection: valor_medio_N_CRs ,
description: 'N_CRs_media_extraida_com_filtro_lee',
fileFormat: 'CSV'
});

var valor_medio_fogo_lee=stack_lee.reduceRegions(Fogo,ee.Reducer.mean(),20)
print (valor_medio_fogo_lee)
Export.table.toDrive({
collection: valor_medio_fogo_lee ,
description: 'Fogo_media_extraida_com_filtro_lee',
fileFormat: 'CSV'
});

var valor_medio_N_CRs_f=stack_f.reduceRegions(NovosCRs,ee.Reducer.mean(),20)
print (valor_medio_N_CRs_f)
Export.table.toDrive({
collection: valor_medio_N_CRs_f ,
description: 'N_CRs_media_extraida_com_filtro_temporal',
fileFormat: 'CSV'
});

var valor_medio_fogo_f=stack_f.reduceRegions(Fogo,ee.Reducer.mean(),20)
print (valor_medio_fogo_f)
Export.table.toDrive({
collection: valor_medio_fogo_f ,
description: 'Fogo_media_extraida_com_filtro_temporal',
fileFormat: 'CSV'
});

```

```
//----- FUNÇÕES -----
```

```

function toDB(img) {
return
  ee.Image(img).log10().multiply(10.0).copyProperties(img,['system:time_start','sliceNumber
  ']);
}
function toNatural(img) {
return
  ee.Image(10.0).pow(img.select(0).divide(10.0)).copyProperties(img,['system:time_start','sli
  ceNumber']);
}
function toGamma0(img) {
return
  img.select(0).subtract(img.select(1).multiply(Math.PI/180.0).cos().log10().multiply(10.0));
}

function computeENLS1(S1img,AOI){

S1img=ee.Image(S1img)
S1img=S1img.select([0],['band'])
var mean=ee.Number(S1img.reduceRegion(ee.Reducer.mean(),AOI,20).get('band'))
var std=ee.Number(S1img.reduceRegion(ee.Reducer.stdDev(),AOI,20).get('band'))
return (mean.divide(std)).pow(2)
}

function QueganYuFilter(imgCol,N){

var boxcar = ee.Kernel.square({radius: N, units: 'pixels', normalize: false});
var imgColMedian = imgCol.map(function(img){return img.convolve(boxcar)})
var correctionFactorCol=imgCol.map(function(img){return
  img.divide(img.convolve(boxcar))})
var correctionFactor=correctionFactorCol.sum().divide(imgCol.size())
return imgColMedian.map(function(img){return
  img.multiply(correctionFactor).copyProperties(img,['system:time_start','sliceNumber'])})
}

function RefinedLee(img) {
var weights3 = ee.List.repeat(ee.List.repeat(1,3),3);
var kernel3 = ee.Kernel.fixed(3,3, weights3, 1, 1, false);

var mean3 = img.reduceNeighborhood(ee.Reducer.mean(), kernel3);
var variance3 = img.reduceNeighborhood(ee.Reducer.variance(), kernel3);

var sample_weights = ee.List([[0,0,0,0,0,0,0], [0,1,0,1,0,1,0],[0,0,0,0,0,0,0], [0,1,0,1,0,1,0],
  [0,0,0,0,0,0,0], [0,1,0,1,0,1,0],[0,0,0,0,0,0,0]]);

var sample_kernel = ee.Kernel.fixed(7,7, sample_weights, 3,3, false);

```

```

var sample_mean = mean3.neighborhoodToBands(sample_kernel);
var sample_var = variance3.neighborhoodToBands(sample_kernel);

var gradients = sample_mean.select(1).subtract(sample_mean.select(7)).abs();
gradients =
  gradients.addBands(sample_mean.select(6).subtract(sample_mean.select(2)).abs());
gradients =
  gradients.addBands(sample_mean.select(3).subtract(sample_mean.select(5)).abs());
gradients =
  gradients.addBands(sample_mean.select(0).subtract(sample_mean.select(8)).abs());

var max_gradient = gradients.reduce(ee.Reducer.max());

var gradmask = gradients.eq(max_gradient);

gradmask = gradmask.addBands(gradmask);

var directions =
  sample_mean.select(1).subtract(sample_mean.select(4)).gt(sample_mean.select(4).subtract(
  sample_mean.select(7))).multiply(1);
directions =
  directions.addBands(sample_mean.select(6).subtract(sample_mean.select(4)).gt(sample_m
  ean.select(4).subtract(sample_mean.select(2))).multiply(2));
directions =
  directions.addBands(sample_mean.select(3).subtract(sample_mean.select(4)).gt(sample_m
  ean.select(4).subtract(sample_mean.select(5))).multiply(3));
directions =
  directions.addBands(sample_mean.select(0).subtract(sample_mean.select(4)).gt(sample_m
  ean.select(4).subtract(sample_mean.select(8))).multiply(4));

directions = directions.addBands(directions.select(0).not().multiply(5));
directions = directions.addBands(directions.select(1).not().multiply(6));
directions = directions.addBands(directions.select(2).not().multiply(7));
directions = directions.addBands(directions.select(3).not().multiply(8));

directions = directions.updateMask(gradmask);

directions = directions.reduce(ee.Reducer.sum());

var sample_stats = sample_var.divide(sample_mean.multiply(sample_mean));

var sigmaV =
  sample_stats.toArray().arraySort().arraySlice(0,0,5).arrayReduce(ee.Reducer.mean(), [0]);

var rect_weights =
  ee.List.repeat(ee.List.repeat(0,7),3).cat(ee.List.repeat(ee.List.repeat(1,7),4));

```

```

var diag_weights = ee.List([[1,0,0,0,0,0,0], [1,1,0,0,0,0,0], [1,1,1,0,0,0,0],
[1,1,1,1,0,0,0], [1,1,1,1,1,0,0], [1,1,1,1,1,1,0], [1,1,1,1,1,1,1]]);

var rect_kernel = ee.Kernel.fixed(7,7, rect_weights, 3, 3, false);
var diag_kernel = ee.Kernel.fixed(7,7, diag_weights, 3, 3, false);

var dir_mean = img.reduceNeighborhood(ee.Reducer.mean(),
  rect_kernel).updateMask(directions.eq(1));
var dir_var = img.reduceNeighborhood(ee.Reducer.variance(),
  rect_kernel).updateMask(directions.eq(1));

dir_mean = dir_mean.addBands(img.reduceNeighborhood(ee.Reducer.mean(),
  diag_kernel).updateMask(directions.eq(2)));
dir_var = dir_var.addBands(img.reduceNeighborhood(ee.Reducer.variance(),
  diag_kernel).updateMask(directions.eq(2)));

for (var i=1; i<4; i++) {
dir_mean = dir_mean.addBands(img.reduceNeighborhood(ee.Reducer.mean(),
  rect_kernel.rotate(i)).updateMask(directions.eq(2*i+1)));
dir_var = dir_var.addBands(img.reduceNeighborhood(ee.Reducer.variance(),
  rect_kernel.rotate(i)).updateMask(directions.eq(2*i+1)));
dir_mean = dir_mean.addBands(img.reduceNeighborhood(ee.Reducer.mean(),
  diag_kernel.rotate(i)).updateMask(directions.eq(2*i+2)));
dir_var = dir_var.addBands(img.reduceNeighborhood(ee.Reducer.variance(),
  diag_kernel.rotate(i)).updateMask(directions.eq(2*i+2)));
}

dir_mean = dir_mean.reduce(ee.Reducer.sum());
dir_var = dir_var.reduce(ee.Reducer.sum());

var varX =
  dir_var.subtract(dir_mean.multiply(dir_mean).multiply(sigmaV)).divide(sigmaV.add(1.0));

var b = varX.divide(dir_var);

var result = dir_mean.add(b.multiply(img.subtract(dir_mean)));
return(result.arrayFlatten(['sum']));
}

```

APENDICE 2. Fotos dos pontos visitados em campo



Ponto 02
Município: Barreiras
Latitude: -12,01125
Longitude: -45,42768



Ponto 03
Município: Barreiras
Latitude: -11,99898
Longitude: -45,42884



Ponto 04
Município: Barreiras
Latitude: -11,98996
Longitude: -45,42872



Ponto 05
Município: Barreiras
Latitude: -11,98191
Longitude: -45,42981



Ponto 09
Município: Barreiras
Latitude: -12,07944
Longitude: -45,32902



Ponto 10
Município: Barreiras
Latitude: -12,08946
Longitude: -45,32955



Ponto 11
Barreiras
Latitude: -12,07039
Longitude: -45,29213



Ponto 12
Angical
Latitude: -12,01326
Longitude: -44,72316



Ponto 13
Angical
Latitude: -11,99966
Longitude: -44,65862



Ponto 14
Município: Angical
Latitude: -11,91842
Longitude: -44,67375



Ponto 15
Município: Angical
Latitude: -11,90169
Longitude: -44,67858



Ponto 16
Município: Angical
Latitude: -11,89463
Longitude: -44,67089



Ponto 17
Município: Angical
Latitude: -11,89029
Longitude: -44,66972



Ponto 18
Município: Angical
Latitude: -11,88132
Longitude: -44,67399



Ponto 19
Município: Angical
Latitude: -11,88764
Longitude: -44,65755



Ponto 20
Município: Angical
Latitude: -11,85632
Longitude: -44,64852



Ponto 21
Município: Angical
Latitude: -11,91505
Longitude: -44,65449



Ponto 22
Município: Angical
Latitude: -11,91087
Longitude: -44,66284



Ponto 23
Município: Angical
Latitude: -11,93073
Longitude: -44,71570



Ponto 24
Município: Riachão das Neves
Latitude: -11,92827
Longitude: -44,87724



Ponto 25
Município: Riachão das Neves
Latitude: -11,88711
Longitude: -44,85775



Ponto 28
Município: Riachão das Neves
Latitude: -11,85981
Longitude: -44,80196



Ponto 29
Município: Riachão das Neves
Latitude: -11,81575
Longitude: -44,83905



Ponto 30
Município: Riachão das Neves
Latitude: -11,81672
Longitude: -44,85186



Ponto 31
Município: Riachão das



Ponto 32
Município: São Desidério



Ponto 33
Município: São Desidério

Neves
Latitude: -11,80295
Longitude: -44,88013



Ponto 35
Município: São Desidério
Latitude: -12,46630
Longitude: -44,90408

Latitude: -12,39922
Longitude: -44,89849



Ponto 36
Município: São Desidério
Latitude: -12,47107
Longitude: -44,89649

Latitude: -12,40647
Longitude: -44,83146



Ponto 37
Município: São Desidério
Latitude: -12,48891
Longitude: -44,88680



Ponto 40
Município: São Desidério
Latitude: -12,49375
Longitude: -45,06291



Ponto 42
Município: Luís Eduardo Magalhães
Latitude: -12,38922
Longitude: -45,81569



Ponto 43
Município: Barreiras
Latitude: -12,36998
Longitude: -45,61443



Ponto 44
Município: Barreiras
Latitude: -11,98332
Longitude: -45,66151

Ponto 45
Município: Barreiras
Latitude: -11,98759
Longitude: -45,67266

Ponto 46
Município: Luís Eduardo
Magalhães
Latitude: -11,99014
Longitude: -45,67896



Ponto 47
Município: Barreiras
Latitude: -11,85473
Longitude: -45,64656

Ponto 48
Município: Barreiras
Latitude: -11,80547
Longitude: -45,75551

Ponto 49
Município: Barreiras
Latitude: -11,80600
Longitude: -45,44100