



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

**MONITORAMENTO DA REGENERAÇÃO DA VEGETAÇÃO DE ÁREAS
DESMATADAS EMBARGADAS NO BIOMA AMAZÔNIA POR MEIO DA
ANÁLISE DE IMAGENS MULTITEMPORAIS**

HANRY ALVES COELHO

Orientador: Prof. Dr. Edson Eyji Sano

Dissertação de Mestrado

nº 218

Área de Concentração: Geoprocessamento e Análise Ambiental

Linha de Pesquisa: Detecção de Mudanças e Evolução do Meio Ambiente

Brasília/DF

2023

HANRY ALVES COELHO

**MONITORAMENTO DA REGENERAÇÃO DA VEGETAÇÃO DE ÁREAS
DESMATADAS EMBARGADAS NO BIOMA AMAZÔNIA POR MEIO DA
ANÁLISE DE IMAGENS MULTITEMPORAIS**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Geociências Aplicadas e Geodinâmica, na área de concentração Geoprocessamento e Análise Ambiental, do Instituto de Geociências da Universidade de Brasília (UnB), para obtenção do título de Mestre.

Orientador: Prof. Dr. Edson Eyji Sano

Brasília/DF

2023

**MONITORAMENTO DA REGENERAÇÃO DA VEGETAÇÃO DE ÁREAS
DESMATADAS EMBARGADAS NO BIOMA AMAZÔNIA POR MEIO DA
ANÁLISE DE IMAGENS MULTITEMPORAIS**

BANCA EXAMINADORA

Prof. Dr. Edson Eyji Sano
Embrapa Cerrados
Orientador

Prof. Dra. Rejane Ennes Cicerelli
Universidade de Brasília (UnB)
Examinadora interna

Dr. Marcos Adami
Instituto Nacional de Pesquisas Espaciais (INPE)
Examinador externo

Brasília/DF
2023

FICHA CATALOGRÁFICA

AGRADECIMENTOS

Gostaria de expressar meus mais sinceros agradecimentos a todos os envolvidos na minha jornada de pesquisa e escrita desta dissertação de mestrado. Este momento representa a conclusão de um capítulo significativo da minha vida profissional e acadêmica e não poderia deixar de reconhecer o apoio e contribuição de cada um de vocês.

Primeiramente, sou grata aos professores do Programa de Pós-Graduação em Geociências Aplicadas e Geodinâmica, do Instituto de Geociências da UnB, em especial os professores Dra. Rejane Cicerelli, Dr. Gustavo Baptista e Dra. Tati de Almeida, que me acompanharam e me guiaram ao longo dessa trajetória. Agradeço especialmente ao meu orientador, Dr. Edson Sano, pela sua orientação, paciência e valiosas sugestões. Seu profissionalismo e conhecimento foram essenciais para o desenvolvimento do meu trabalho. Registro meu agradecimento especial também aos membros titular e suplente externos da banca, respectivamente, Dr. Marcos Adami, do INPE, e Dr. Alexandre Camargo Coutinho, da Embrapa, por aceitarem o convite e por dedicarem seu tempo e *expertise* para avaliar meu trabalho.

Não poderia deixar de mencionar minha família, que sempre esteve ao meu lado, oferecendo incentivo e apoio incondicional. Seu amor e encorajamento foram o combustível que impulsionou minha jornada acadêmica. Sou profundamente grata por isso.

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

RESUMO

O uso de sensoriamento remoto e geotecnologias no monitoramento de áreas desmatadas são amplamente difundidos. O Brasil possui metodologias consolidadas que permitem quantificar remotamente as áreas desmatadas em corte raso, em especial no bioma Amazônia. Contudo, as iniciativas de monitoramento da recuperação da vegetação nativa são incipientes. Assim este estudo analisou estatisticamente a radiometria do sensor OLI embarcado nos satélites Landsat 8 e Landsat 9 e o desempenho do NDVI convertido para fração de cobertura vegetal (FCV) com a imagem fração de vegetação (IFV) derivada de modelo linear de mistura espectral (MLME) para o monitoramento da regeneração da vegetação. Foram selecionadas nove áreas de estudo, que estão inseridas no estado do Mato Grosso, localizadas no bioma Amazônia. Para a comparação radiométrica do sensor OLI (Landsat 8 e 9) foram analisadas duas cenas conjugadas desses satélites (diferença de 8 dias entre as datas de passagem), adquiridas em abril (estação chuvosa) e setembro (estação seca) de 2022. Os resultados mostraram que os dados obtidos pelos dois satélites são, regra geral, estatisticamente similares, mas podem ser diferentes dependendo da estação do ano e da classe de uso e cobertura de terras, principalmente em função da diferença espectral e radiométrica dos sensores. As diferenças máximas nos valores de NDVI foram significativamente maiores na estação chuvosa do que na estação seca. Para a comparação das imagens FCV com a IFV, foram selecionadas 35 imagens do satélite Landsat 8 da estação seca do período de 2018 a 2022. Observou-se uma forte correlação linear entre os modelos em todas as áreas de estudo apresentando coeficientes de correlação entre 0,81 a 0,98. Pode-se constatar que ambos os modelos aplicados são eficientes no monitoramento da regeneração da vegetação de áreas desmatadas embargadas no bioma Amazônia, porém, sugere-se ampliar o estudo para outras áreas e para uma série temporal maior e aprimorar a aplicação da metodologia para a confirmação dos resultados.

Palavras-chave: Floresta amazônica; Fração de vegetação; Modelo linear de mistura espectral.

ABSTRACT

The use of remote sensing and geotechnologies in monitoring deforested areas is widespread. Brazil has consolidated methodologies that allow quantifying deforested areas remotely, especially in the Amazon biome. However, initiatives to monitor the regeneration of native vegetation are incipient. Thus, this study statistically analyzed the radiometry of the OLI sensor onboard the Landsat 8 and Landsat 9 satellites and the performance of the NDVI converted to fraction vegetation cover (FVC) with the vegetation fraction image (VFI) derived from the linear spectral mixture model (LSMM) for monitoring vegetation regeneration. The nine study areas are inserted in the state of Mato Grosso, located in the Amazon biome. For the radiometric comparison of the OLI sensor (Landsat 8 and 9), two combined scenes of these satellites were analysed (8 days difference between the passing dates), acquired in April (rainy season) and September (dry season) of 2022. of the performance of the NDVI converted to FVC compared with the VFI, one image per year from the Landsat 8 satellite of the dry season (from August/September) in the period from 2018 to 2022 was used. In the radiometric comparison of the OLI sensor of Landsat 8 and 9 the results showed that the data obtained by the two satellites are, in general, statistically similar, but can be different depending on the season of the year and the class of use and land cover. The two satellites did not reproduce the same NDVI values. Maximum differences in NDVI values were significantly greater in the wet season than in the dry season. To compare the FVC and VFI images, 35 images from the Landsat 8 satellite of the dry season from 2018 to 2022 were selected. A strong linear correlation was observed between the models in all areas of study, showing correlation coefficients between 0.81 and 0.98. It can be seen that both applied models are efficient in monitoring the regeneration of vegetation in embargoed deforested areas in the Amazon biome, however, it is suggested to expand the study to other areas and to a larger time series to improve the application of the methodology for the confirmation of results.

Keywords: Amazon Forest; Vegetation fraction; Linear Spectral Mixing Model.

Sumário

CAPÍTULO 1 - INTRODUÇÃO.....	14
1.1 Contextualização.....	14
1.1.1 Desmatamento por corte raso na Amazônia Legal.....	14
1.1.2 Principais projetos de monitoramento do desmatamento da Amazônia Legal.....	16
1.1.3 Desmatamento legal × desmatamento ilegal	17
1.1.4 Combate aos desmatamentos ilegais na AML.....	18
1.1.5 Monitoramento da recuperação de áreas embargadas	21
1.2 Objetivos	23
1.3 Hipóteses.....	24
1.4 Justificativa	24
1.5 Organização do volume	25
CAPÍTULO 2 - FUNDAMENTAÇÃO TEÓRICA	27
2.1 Monitoramento da regeneração da vegetação nativa	27
2.2 Principais sensores ópticos para o monitoramento da restauração da vegetação natural em áreas desmatadas	29
2.3 Semelhanças e diferenças entre os sensores Landsat 8 e Landsat 9	30
2.4 Principais técnicas de processamento de imagens ópticas para o monitoramento contínuo da regeneração: séries temporais de índice de vegetação e imagens-fração do modelo linear de mistura espectral	32
2.4.1. Índices de vegetação.....	32
2.4.2. Modelo linear de mistura espectral (MLME): Imagens-fração de vegetação (IFV).....	35
2.5 Fração de cobertura vegetal verde (FCV): Equação proposta por Qi et al. (2000).....	36
CAPÍTULO 3 - COMPARAÇÃO RADIOMÉTRICA DAS IMAGENS LANDSAT 8/9 OLI VISANDO O MONITORAMENTO DA RESTAURAÇÃO DE ÁREAS DESMATADAS E EMBARGADAS NA AMAZÔNIA	38

3.1	Introdução	39
3.2	Material e métodos.....	40
3.3	Resultados e discussão	42
3.4	Conclusões	44
CAPÍTULO 4 - COMPARAÇÃO DO DESEMPENHO DA FRAÇÃO DE COBERTURA VEGETAL (FCV) E DA IMAGEM-FRAÇÃO DE VEGETAÇÃO (IFV) PARA O MONITORAMENTO DA RESTAURAÇÃO DE ÁREAS DESMATADAS NO BIOMA AMAZÔNIA		45
4.1	Introdução	47
4.2	Material e métodos.....	49
4.2.1	Área de estudo	49
4.2.2	Material.....	51
4.2.3	Abordagem metodológica.....	52
4.3	Resultados e discussão	56
4.3.1	Coefficiente de correlação de Pearson	56
4.3.2	Teste t de Student	57
4.3.3	Diagrama de dispersão (<i>Scatter plot</i>)	58
4.4	Conclusões	61
4.5	Informações suplementares.....	63
CAPÍTULO 5 - CONSIDERAÇÕES FINAIS		74
REFERÊNCIAS		75

LISTA DE FIGURAS

Capítulo 3 – Artigo 1

- Figura 1.** Localização da área de estudo no estado do Mato Grosso (A) e no município de Nova Maringá/MT (B). A imagem corresponde à composição colorida RGB das bandas 4, 5 e 6 do satélite Landsat 8 OLI adquirida em 27 de abril de 2022.....41
- Figura 2.** Relação entre valores de reflectância obtidas em abril de 2022 nas bandas 4 (A), 5 (B) e 6 (C) dos satélites Landsat 8/9 OLI e em setembro de 2022 nas mesmas três bandas (D, E e F), a partir de regressão linear simples. AGR = culturas agrícolas; FLO = floresta primária; PAS = pastagem cultivada; VSE = vegetação secundária; AGU = massas d'água.....43
- Figura 3.** Diferença entre os valores de NDVI do mês de abril (A) e setembro (B) de 2022, calculados para os satélites Landsat 8 (L8) e Landsat 9 (L9).....44

Capítulo 4 – Artigo 2

- Figura 1.** Localização das áreas de estudo (A1 a A9) no bioma Amazônia e no estado do Mato Grosso. As imagens correspondem a composições coloridas RGB das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI de 2022, fusionadas com a banda pancromática 8.....50
- Figura 2.** Fluxograma das etapas de coleta de dados, pré-processamento, processamento e análise dos dados gerados.....52
- Figura 3.** Exemplo do processo de coleta de amostras por área de estudo de regeneração florestal entre 2018 e 2022. Composições coloridas RGB das bandas 4, 5 e 6 do satélite Landsat 8 de 2018 (A) e 2022 (B) da área de estudo 3.....53
- Figura 4.** Exemplo do processo de seleção e das repostas espectrais dos *endmembers*: (A) água (em azul); (B) vegetação (em verde); e (C) solo exposto (em vermelho), selecionados na cena de 2018, da área de estudo A1.....56
- Figura 5.** Relação entre as médias das porcentagens de fração de cobertura vegetal (FCV) e imagem-fração de vegetação (IFV) nas nove áreas de estudo para os anos de 2018, 2019,

2020, 2021 e 2022. Os valores de r correspondem aos coeficientes de correlação de Pearson. A reta tracejada corresponde à reta 1:1, enquanto a reta sólida corresponde à linha de tendência.....57

Figura 6. Relação entre porcentagem de fração de cobertura vegetal (FCV) e imagem-fração de vegetação (IFV) para cada uma das nove áreas de estudo no período de 2018 a 2022. A reta tracejada corresponde à reta 1:1 e a reta sólida à linha de tendência.....58

Informações suplementares

Figura 1. Ilustração da evolução do processo de regeneração da vegetação nas áreas amostrais da área de estudo A1. As imagens correspondem a composições coloridas RGB das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI, fusionadas com a banda pancromática 8, de (A) 2018, (B) 2019, (C) 2020, (D) 2021 e (E) 2022.....65

Figura 2. Ilustração da evolução do processo de regeneração da vegetação nas áreas amostrais da área de estudo A2. As imagens correspondem a composições coloridas RGB das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI, fusionadas com a banda pancromática 8, de (A) 2018, (B) 2019, (C) 2020, (D) 2021 e (E) 2022.....66

Figura 3. Ilustração da evolução do processo de regeneração da vegetação nas áreas amostrais da área de estudo A3. As imagens correspondem a composições coloridas RGB das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI, fusionadas com a banda pancromática 8, de (A) 2018, (B) 2019, (C) 2020, (D) 2021 e (E) 2022.....67

Figura 4. Ilustração da evolução do processo de regeneração da vegetação nas áreas amostrais da área de estudo A4. As imagens correspondem a composições coloridas RGB das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI, fusionadas com a banda pancromática 8, de (A) 2018, (B) 2019, (C) 2020, (D) 2021 e (E) 2022.....68

Figura 5. Ilustração da evolução do processo de regeneração da vegetação nas áreas amostrais da área de estudo A5. As imagens correspondem a composições coloridas RGB das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI, fusionadas com a banda pancromática 8, de (A) 2018, (B) 2019, (C) 2020, (D) 2021 e (E) 2022.....69

Figura 6. Ilustração da evolução do processo de regeneração da vegetação nas áreas amostrais da área de estudo A6. As imagens correspondem a composições coloridas RGB

das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI, fusionadas com a banda pancromática 8, de (A) 2018, (B) 2019, (C) 2020, (D) 2021 e (E) 2022.....70

Figura 7. Ilustração da evolução do processo de regeneração da vegetação nas áreas amostrais da área de estudo A7. As imagens correspondem a composições coloridas RGB das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI, fusionadas com a banda pancromática 8, de (A) 2018, (B) 2019, (C) 2020, (D) 2021 e (E) 2022.....71

Figura 8. Ilustração da evolução do processo de regeneração da vegetação nas áreas amostrais da área de estudo A8. As imagens correspondem a composições coloridas RGB das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI, fusionadas com a banda pancromática 8, de (A) 2018, (B) 2019, (C) 2020, (D) 2021 e (E) 2022.....72

Figura 9. Ilustração da evolução do processo de regeneração da vegetação nas áreas amostrais da área de estudo A9. As imagens correspondem a composições coloridas RGB das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI, fusionadas com a banda pancromática 8, de (A) 2018, (B) 2019, (C) 2020, (D) 2021 e (E) 2022.....73

LISTA DE TABELAS

Capítulo 3 – Artigo 1

Tabela 1. Características de imageamento das imagens Landsat 8/9 OLI selecionadas para o desenvolvimento desta pesquisa (órbita = 227; ponto = 69).....	41
----------------------------------------------------------------------------------------------------------------------------------------------------------------	----

Capítulo 4 – Artigo 2

Tabela 1. Tamanho da área e localização municipal das áreas de estudo selecionadas para esta pesquisa.....	51
Tabela 2. Descrição das áreas amostrais das áreas de estudo.....	53
Tabela 3. Resultados do teste t de Student aplicado em cada uma das nove áreas de estudo para comparar as médias de FCV e IFV no período de 2018 a 2022. $T_{calc} = t_{calculado}$; $t_{crit} = t_{crítico}$ para nível de significância de 5% e 4 graus de liberdade.....	58

Informações suplementares

Tabela 1. Órbita/ponto e datas de passagem das imagens Landsat 8 OLI selecionadas para cada área estudo.....	63
Tabela 2. Descrição dos anos em que ocorreram decréscimo nas porcentagens de fração de cobertura vegetal (FCV) e índice-fração de vegetação (IFV) em relação ao ano anterior.....	64

CAPÍTULO 1

INTRODUÇÃO

1.1 Contextualização

A floresta Amazônica, a maior floresta tropical do mundo, com uma biodiversidade superior a 40.000 espécies de plantas, abrange aproximadamente 7 milhões de km² da América do Sul. Presente em toda a região norte do Brasil, essa floresta se estende pela Bolívia, Colômbia, Equador, Guiana, Guiana Francesa, Peru, Suriname e Venezuela (COUTINHO, 2016).

No Brasil, a Amazônia Legal (AML) abrange em torno de 5 milhões de km², o que representa aproximadamente 59% do território do País e compreende os estados do Acre, Amapá, Amazonas, Mato Grosso, Pará, Rondônia, Roraima e Tocantins e parte do estado do Maranhão, perfazendo um total de mais de 4 milhões de km² de florestas originárias (ALMEIDA et al., 2010; INPE, 2021).

Apesar de sua importância mundialmente reconhecida e todas as preocupações ambientais discutidas ao longo de décadas em torno de sua proteção, a floresta Amazônica brasileira sofre irreversivelmente com o desmatamento ilegal. O desmatamento iniciou-se na década de 1960 em função principalmente do incentivo do governo federal para a ocupação da região, motivado por objetivos estratégicos de segurança nacional, uso da terra e exploração de seus recursos naturais (VEIGA et al., 2003). Esse modelo de ocupação do território, pautado na supressão da vegetação nativa, foi intensificado na década de 1990, quando passou a repercutir negativamente e a chamar a atenção da sociedade nacional e internacional. Nesse momento, pressionado a interromper esse processo depredatório, o governo brasileiro procurou buscar estratégias e ações para conter o desmatamento da floresta Amazônica (SCHMITT, 2015).

1.1.1 Desmatamento por corte raso na Amazônia Legal

No bioma Amazônia, o desmatamento pode ser entendido como um processo que se inicia com a floresta intacta e termina com a conversão da floresta original em outras coberturas. Desmatamento pode ser definido como a conversão por supressão de áreas de fisionomia florestal primária por ações antropogênicas (INPE, 2021).

A conversão da floresta original geralmente inicia-se com a supressão de árvores de valor comercial (degradação florestal), financiando o restante do processo de supressão total da floresta, conhecido como corte raso (BRASIL, 2022). O desmatamento por corte raso ocorre quando a floresta é completamente removida e substituída por outras coberturas e usos ou mesmo por um processo de regeneração por abandono da área (INPE, 2021).

As primeiras iniciativas de acompanhamento do desmatamento na AML foram iniciadas ainda na década de 1970, por meio de uma parceria entre o Instituto Nacional de Pesquisas Espaciais (Inpe) e o antigo Instituto Brasileiro de Desenvolvimento Florestal (IBDF), órgão que foi incorporado ao Instituto Brasileiro de Meio Ambiente e Recursos Naturais Renováveis (Ibama) em 1989 (SHIMABUKURO et al., 2020). Em 1988, o Inpe passou a disponibilizar números oficiais das taxas anuais de desmatamento por corte raso na AML, mensurado sistematicamente por meio do projeto Monitoramento da Floresta Amazônica Brasileira por Satélite (PRODES) (INPE, 2021).

O PRODES é um instrumento de suma importância para subsidiar as instâncias governamentais na formulação e na avaliação de políticas públicas voltadas à gestão do uso da terra, bem como tem sido uma referência em acordos internacionais como a Convenção Quadro das Nações Unidas sobre Mudança do Clima (UNFCCC) (MAURANO et al., 2019). Estima-se que já foram desmatados aproximadamente 20% do total de 390,2 milhões de hectares da extensão florestal originária do bioma Amazônico (CAMARA et al., 2023).

Cabe destacar que os maiores picos de desmatamento registrados foram nos anos de 1995, com aproximadamente 29 mil km², e 2004, com mais de 27,5 mil km². A partir de 2005, as taxas caíram consideravelmente, atingindo 4,5 mil km² em 2012, a menor taxa registrada desde que se iniciou o monitoramento do desmatamento (PRODES, 2023).

Entretanto, após mudanças no Código Florestal, essas taxas voltaram a subir em 2013 (BRASIL, 2022). No período de 2018 a 2022, a taxa de desmatamento subiu de aproximadamente 7,5 mil km² para mais de 11,5 mil km², registrando, em 2021, cerca de 13 mil km², a maior taxa registrada desde 2006 (BRASIL, 2023). Considerando a taxa estimada de 2022, mesmo com a queda registrada em comparação com a taxa de 2021, ainda assim, tem-se o segundo maior montante de desmatamento registrado desde 2008.

1.1.2 Principais projetos de monitoramento do desmatamento da Amazônia Legal

O PRODES tem por objetivo avaliar a perda da cobertura florestal primária e estimar a taxa anual de desmatamento por corte raso nos 5 milhões de km² da AML (SHIMABUKURO et al., 2020; INPE, 2021). A metodologia do PRODES é incremental, isto é, a cada ano, o sistema mapeia os novos incrementos do desmatamento (INPE, 2021), porém não avalia as áreas que foram desmatadas e que estão em processo de regeneração (SHIMABUKURO et al., 2020).

Ao longo dos anos, o projeto PRODES passou por diversos aprimoramentos. Inicialmente, o PRODES analógico foi realizado até 2003 com imagens do satélite Landsat 5 (SHIMABUKURO et al., 2020). No final da década de 1990, iniciou-se o desenvolvimento do PRODES Digital, que consistia em uma metodologia semiautomatizada baseada em imagens-fração (SHIMABUKURO et al., 2020). Atualmente, o projeto utiliza imagens dos satélites Landsat, Sentinel-2 e CBERS-4/4A (INPE, 2021).

Visando subsidiar as ações governamentais de prevenção e combate aos desmatamentos na AML, em 2004, foi criado o projeto DETER com o propósito de detectar polígonos de desmatamento em tempo quase real (SHIMABUKURO et al., 2020). O DETER produz alertas diários de alteração na cobertura florestal para áreas maiores que 3 ha (INPE, 2021). Além de identificar as áreas desmatadas por corte raso, também identifica padrões de degradação e exploração madeireira (Diniz et al., 2015). Entretanto, considerando-se que o principal objetivo do DETER é subsidiar as ações de fiscalização, os alertas diários estão disponíveis apenas para os órgãos de fiscalização, como, por exemplo, o Ibama e as secretarias estaduais de meio ambiente. Para o público em geral, esses dados são atualizados semanalmente no portal TerraBrasilis do Inpe (INPE, 2021).

No Brasil, além dos projetos PRODES e DETER, existe o Sistema de Alerta de Desmatamento (SAD) do Programa de Geoinformação da Amazônia (ImazonGeo), desenvolvido e lançado em 2007 pelo Instituto do Homem e Meio Ambiente da Amazônia (Imazon) com o apoio das Fundações Moore e Packard (IMAZONGEO, 2023). O objetivo do portal do ImazonGeo é fornecer gratuitamente informações sobre a situação, dinâmica e pressão sobre as florestas e áreas protegidas da AML para promover o desenvolvimento sustentável na região.

A grande inovação do portal ImazonGeo é a disponibilização de boletins mensais com as informações dos percentuais de desmatamento e de degradação florestal e a possibilidade de interação com usuários, permitindo o envio de informações de campo de desmatamento e queimadas na plataforma. Um dado interessante desse relatório é o detalhamento dos desmatamentos que ocorrem em propriedades privadas ou sob diversos estágios de posse, assentamentos, unidades de conservação e terras indígenas. A título de exemplificação, segundo o boletim do SAD de março de 2023, foram detectados 344 km² de desmatamento na AML, o que representa um aumento de 180% em comparação ao mesmo mês do ano anterior. Foram detectados ainda 42 km² de degradação, o que representa um aumento de 68% em relação a março de 2022. Do total de áreas desmatadas, 76% ocorreram em propriedades privadas ou posses.

O uso das informações do SAD/ImazonGeo em conjunto com os dados do PRODES, pode ser útil para identificar onde a floresta está sendo convertida em atividade agrícola e, assim, subsidiar pesquisas e implementação de políticas públicas (LOURENÇONI et al., 2021). Ressalta-se que o PRODES é o banco de dados de desmatamento mais utilizado no Brasil, constituindo-se em um produto acessível, transparente e gratuito (DEMARCHI et al., 2023), além de ser considerado o maior projeto de sensoriamento remoto do mundo em termos de monitoramento de desmatamento em florestas tropicais (SHIMABUKURO et al., 2020).

Todavia, dependendo do objetivo para o qual se pretende usar os dados de desmatamento, um ponto a considerar como desvantagem com relação aos dados do PRODES é o fato dele contabilizar apenas as florestas primárias e não estimar o quantitativo de florestas secundárias ou em regeneração (DEMARCHI et al., 2023).

1.1.3 Desmatamento legal × desmatamento ilegal

Por desmatamento ilegal, entende-se a supressão da vegetação nativa sem autorização dos órgãos ambientais competentes como o Ibama e as secretarias estaduais ou municipais de meio ambiente (SCHMITT, 2015). Por outro lado, o desmatamento legal ocorre quando há autorização expressa emitida pelo órgão ambiental competente. O banco de dados que mais se aproxima dessa possibilidade de distinção entre desmatamento legal e ilegal é o Sistema Nacional de Cadastro Ambiental Rural (Sicar). Nesse contexto, a partir da análise dos dados do Cadastro Ambiental Rural (CAR), Rajão et al. (2020) afirmaram que 2% das propriedades localizadas nos biomas Amazônia e

Cerrado são responsáveis por 62% do total de desmatamento potencialmente ilegal. Segundo esses mesmos autores, em torno de 20% da soja exportada e ao menos 17% da carne exportada para a União Europeia, provenientes desses dois biomas, talvez sejam oriundas de áreas em que ocorreram desmatamentos ilegais.

No bioma Amazônia, 91% dos desmatamentos realizados nas propriedades particulares após 2008 foram potencialmente ilegais (RAJÃO et al., 2020). Já Valdiones et al. (2021) estimaram que, no período de 2008 a 2020, aproximadamente 94% dos desmatamentos ocorreram de forma ilegal. A menor estimativa foi obtida por Camara et al. (2023) que afirmaram que aproximadamente 80% do desmatamento ocorrido na Amazonia no período de 2008 a 2021 são ilegais e 82,5% do desmatamento ocorrido em áreas particulares estão concentrados em 1% do total de propriedades cadastradas no CAR.

Apesar dessas estimativas, o fato é que, na prática, é difícil constatar em campo a diferença entre desmatamento legal e ilegal considerando as bases de dados disponíveis atualmente (BRASIL, 2022). A dificuldade na obtenção dos dados das autorizações de desmatamento disponibilizados pelos estados e governo federal, ou até mesmo a ausência dessas informações, dificulta essa diferenciação (VALDIONES et al., 2021). Talvez, no futuro, isso se torne possível com o cruzamento das camadas do Sicar com dados de outros sistemas de monitoramento ambiental em um único sistema nacional e público (RAJÃO et al., 2020). Por enquanto, com exceção de estudos pontuais, as informações se reportam ao desmatamento como um todo (BRASIL, 2022). Independentemente de haver ou não uma forma de diferenciar desmatamento legal de ilegal, a legislação ambiental brasileira determina que as áreas desmatadas ilegalmente devem ser autuadas e restauradas (SCHMITT, 2015).

1.1.4 Combate aos desmatamentos ilegais na AML

Assim, com o propósito de conter o desmatamento ilegal, a política pública mais empregada entre as diversas medidas adotadas pelo governo é o poder de polícia ambiental (SCHMITT, 2015). O poder de polícia normalmente aplicado na área ambiental é a fiscalização, que contempla ações preventivas, de monitoramento, de inspeção, de advertência, punitivas e corretivas, entre outras (SCHMITT; SCARDUA, 2015). A fiscalização ambiental tem a finalidade de induzir mudanças no comportamento

das pessoas por meio da coerção, de modo a evitar que novos danos ambientais venham a acontecer (SCHMITT; SCARDUA, 2015).

No Brasil, compete, aos órgãos ambientais das três esferas da federação (municípios, estados e União), o papel de fiscalizar e aplicar as sanções para a efetiva responsabilização e reparação dos danos ambientais (RAJÃO et al., 2021). Os órgãos responsáveis por exercer as atividades de fiscalização ambiental são aqueles que integram o Sistema Nacional do Meio Ambiente (Sisnama) e detêm, na sua carga de competência, tal prerrogativa (BRASIL, 1998; SCHMITT, 2015). Atualmente, todos os estados e o Distrito Federal contam com um órgão estadual de meio ambiente (Oema) com atribuição de fiscalização ambiental (SCHMITT, 2015). No âmbito da União, o Ibama é o principal órgão de meio ambiente com o poder de fiscalizar e sua principal ação de fiscalização é combater o desmatamento ilegal na Amazônia (SCHMITT; SCARDUA, 2015).

A história ambiental do País foi marcada por grandes desastres ambientais, exploração predatória dos recursos naturais, acelerado crescimento econômico e altas taxas de desmatamento na Amazônia nas décadas de 1970 e 1980. Todos esses acontecimentos, somados principalmente às pressões nacional e internacional, levaram à criação do Ibama em 1989 com a função de ser o grande executor e de gerir de forma integrada a política ambiental brasileira (IBAMA, 2019).

Nesse novo cenário, logo após à criação do Ibama, em 1990, foi criado o primeiro plano com foco nas ações de prevenção e controle do desmatamento na floresta Amazônica e na Mata Atlântica, o Programa Piloto para Proteção das Florestas Tropicais do Brasil (PPG7). Esta foi uma iniciativa de longo prazo que deixou um grande legado, com forte apoio e colaboração entre os países do G7 (OLIVEIRA FILHO, 2020). Somado a essa iniciativa, em 1996, a legislação ambiental brasileira restringiu o desmatamento na Amazônia a um total de 20% de cada propriedade rural localizada no bioma Amazônico (IBAMA, 2019).

Em 2004, ano em que se obteve a segunda maior taxa registrada de desmatamento na floresta Amazônica, foi criado o 1º Plano de Ação para Prevenção e Controle do Desmatamento na Amazônia Legal (PPCDAm) (BRASIL, 2004), com o objetivo de reduzir continuamente o desmatamento na AML e criar as condições para a transição para um modelo de desenvolvimento sustentável na região (MMA, 2023).

Com o advento do PPCDAm, o Ibama recebeu investimentos que propiciaram uma considerável melhora em sua capacidade operativa de fiscalização, culminando em uma das principais iniciativas do governo para conter o avanço do desmatamento na

AML, ilegal na sua maioria (RAJÃO et al., 2021). Como resultado das ações desenvolvidas na 1ª e na 2ª fase do PPCDAm, a taxa de desmatamento na região amazônica caiu 84% no período de 2004 a 2012 (BRASIL, 2022), com uma queda de 75% no período de 2007 a 2011 (ASSUNÇÃO, et al., 2013). Durante a 3ª fase do PPCDAm, a agenda ambiental se deparou com um novo desafio que foram as alterações no marco regulatório ambiental, conhecido como novo Código Florestal (BRASIL, 2012) e a 4ª fase do plano (2016-2019) que não foi totalmente implementada, portanto, sem alcançar os objetivos propostos (BRASIL, 2023).

Somando-se a isso, tem-se que, no período de 2017 a 2019, apenas 82 áreas desmatadas foram embargadas, o que representa apenas 1,2% do total de embargos aplicados no período de 2008 a 2017 (DA SILVA et al., 2022) e, no período de 2008 a 2012, época de forte ação governamental, 75% dos desmatamentos ocorreram em 1% das propriedades privadas. No intervalo de 2018 a 2021, quando a fiscalização foi fortemente reduzida, apenas 0,5% das propriedades particulares cadastradas no CAR foram responsáveis por 75% do desmatamento (CAMARA et al., 2023). Essa concentração extrema de áreas desmatadas em uma parcela ínfima do total de propriedades particulares é um dado importante para as ações de fiscalização, podendo ser usado como uma estratégia potencial para reduzir significativamente o desmatamento ao atingir os responsáveis pela maior parte dos danos (CAMARA et al., 2023).

Os fatos mostram que a aplicação da legislação e de políticas ambientais, combinadas com a colaboração de todos os setores governamentais e não governamentais, é eficaz no contexto amazônico, podendo levar a um equilíbrio entre conservação e produção e a uma economia de baixo carbono na Amazônia brasileira (OLIVEIRA FILHO, 2020).

Não obstante o aumento das taxas de desmatamento que tornaram a subir a partir desse período, o PPCDAm foi extinto pelo governo federal em 2019 (MMA, 2023). Reinstituído pelo Decreto nº 11.367 de 1º de janeiro de 2023 (BRASIL, 2023), atualmente a sua 5ª fase está em consulta pública. Com vigência prevista para o período de 2023 a 2027, o plano tem como objetivo fornecer as bases para alcançar a meta de desmatamento zero até 2030 (BRASIL, 2023). O plano está estruturado em quatro eixos temáticos: I. Atividades produtivas sustentáveis; II. Monitoramento e controle ambiental; III. Ordenamento territorial e fundiário; e IV. Instrumentos normativos e econômicos (BRASIL, 2023).

O eixo II. Monitoramento e controle ambiental concentra a maior parte das ações do Ibama e contempla quatro objetivos principais: 4. Garantir a responsabilização pelos crimes e infrações administrativas ambientais ligadas ao desmatamento e degradação florestal; 5. Aprimorar a capacidade de monitoramento do desmatamento, incêndios, degradação e cadeias produtivas; 6. Prevenir e combater a ocorrência dos incêndios florestais; e 7. Fortalecer a articulação com os estados da AML nas ações de fiscalização ambiental. Destaca-se, além das usuais estratégias de comando e controle, a previsão, no Objetivo 5, de criação de um sistema automatizado com inteligência artificial para monitorar remotamente as áreas embargadas (BRASIL, 2023).

1.1.5 Monitoramento da recuperação de áreas embargadas

Considerando que o embargo visa evitar a continuidade dos danos ambientais e viabilizar a recuperação da área degradada (BRASIL, 2008), a implementação do eixo II detalhado acima pode preencher uma lacuna inexistente atualmente que é a do monitoramento sistemático de toda a base de dados de áreas embargadas, visando constatar a efetiva reparação do dano, ou seja, a recuperação da vegetação nativa nos casos relacionados a desmatamento ilegal na AML. Da Silva et al. (2022) estima que apenas 13% das áreas embargadas na Amazônia cumprem as restrições impostas. A maior parte das áreas embargadas foram caracterizadas com o uso de pastagem (em torno de 81%) ou culturas agrícolas (6%) entre os anos de 2017 e 2019. Segundo Schmitt (2015), muitos embargos são descumpridos, em especial, nos estados do Pará e Mato Grosso em que há diversos registros de autuações por impedir a regeneração natural. Situações em que foram feitas novas autuações em áreas já autuadas, motivadas pelo descumprimento do embargo.

Com o aumento da vegetação secundária, que é a regeneração da vegetação nativa que se forma nas áreas desflorestadas abandonadas, os efeitos do desmatamento na Amazônia, como a redução de fertilidade do solo, erosão, alterações nos regimes hidrológico local e global e emissão de gases de efeito estufa, podem ser minimizados (ALMEIDA et al., 2010).

Por muito tempo, as ações de recuperação de vegetação nativa não foram priorizadas, mas agora é uma necessidade eminente e imprescindível para garantir o abastecimento de água em várias partes do País, sustentar a geração de energia hidráulica,

propiciar a recuperação do solo, aumentar a produção agrícola, reduzir a emissões de carbono e fomentar a inclusão social, com geração de emprego e renda (BRASIL, 2017).

A recuperação de terras degradadas não só é importante para a conservação da biodiversidade (OLIVEIRA FILHO, 2020), como também é uma medida necessária para uma economia inclusiva, robusta, sustentável e baseada no uso racional dos recursos naturais (BRASIL, 2017). Na verdade, há uma oportunidade sem precedentes de transformar terras improdutivas e degradadas em paisagens funcionais e ecossistemas restaurados, propiciando diversos benefícios à sociedade e às gerações futuras (CHAZDON et al., 2017).

Políticas ambientais aplicadas nesse sentido mostram que é possível haver uma mudança de comportamento dos proprietários de terras para um melhor aproveitamento das áreas desmatadas, com claros sinais de melhoria nos sistemas de produção de soja e carne, por exemplo. Isto corresponde ao início de um longo caminho para alcançar uma paisagem ambientalmente equilibrada (OLIVEIRA FILHO, 2020). Contudo, a legislação ambiental brasileira tende a focar na proteção da floresta primária, visando evitar sua perda e pouco investi no potencial da restauração da paisagem em escala e da conectividade florestal que podem influenciar fortemente na conservação da biodiversidade e nos serviços ecossistêmicos (CHAZDON et al., 2020). A proteção e expansão das áreas de floresta secundária, somadas à preservação dos remanescentes de floresta primária, são estratégias fundamentais para a mitigação das mudanças climáticas (HEINRICH et al., 2021).

Assim como no combate ao desmatamento da Amazônia, alguns estudos mostram que a aplicação da legislação ambiental também pode desempenhar um papel importante no processo de recuperação da vegetação nativa em fronteiras ativas de desmatamento na Amazônia brasileira (OLIVEIRA FILHO, 2020). No entanto, o governo precisa adequar as políticas de proteção e restauração florestal às condições dos diferentes tipos de propriedades, considerando suas práticas de uso da terra, capacidade técnica e recursos financeiros (CAMARA et al., 2023).

Nesse sentido, situação análoga ao monitoramento de áreas degradadas embargadas é a necessidade de quantificar e qualificar as áreas em processo de recuperação existentes em todo território nacional. Essa é uma das estratégias do Plano Nacional de Recuperação da Vegetação Nativa (Planaveg): criar um “sistema nacional de planejamento espacial e de monitoramento” para subsidiar a tomada de decisão para recuperação da vegetação nativa (BRASIL, 2017). O Planaveg, instituído pelo Governo

Federal em 2017, tem, por objetivo, ampliar e fortalecer políticas públicas, entre outras medidas, para fomentar a recuperação da vegetação nativa em 12 milhões de hectares até 2030, principalmente em áreas de preservação permanente (APP), reserva legal (RL) e áreas degradadas com pouca produtividade agrícola (BRASIL, 2017).

Para se obter um monitoramento eficaz, é necessário realizar um mapeamento de alta qualidade de uso e cobertura da terra (NEVES et al., 2020). Com esse propósito, vale citar o Mapeamento do Uso e Cobertura da Terra nas Áreas Desflorestadas da Amazônia Legal (TerraClass), criado em 2010 pelo Inpe e pela Empresa Brasileira de Pesquisa Agropecuária (Embrapa) para mapear o uso e a ocupação das áreas desflorestadas na AML (ALMEIDA et al., 2016). No mapeamento das classes “vegetação secundária” e “agricultura anual”, o Projeto TerraClass utiliza, em sua metodologia, respectivamente, o Modelo Linear de Mistura Espectral (MLME) e as séries temporais do Índice de Vegetação por Diferença Normalizada (NDVI), obtidas do sensor *Moderate Resolution Imaging Spectroradiometer* (MODIS) e disponibilizadas a cada 16 dias (COUTINHO et al., 2013).

Outro ponto importante a ser considerado no mapeamento da vegetação secundária é a possibilidade de melhorar a periodicidade das informações dos satélites integrando-se dois ou mais satélites. Nesse sentido, a combinação de séries temporais de dos sensores OLI-1 e OLI-2 embarcados nos satélites Landsat 8 e 9, respectivamente, é bastante promissora, pois, em teoria, eles operam com o mesmo modo de imageamento em termos de resoluções espaciais, espectrais e temporal.

1.2 Objetivos

O objetivo geral deste estudo é propor uma abordagem metodológica para monitorar a regeneração da vegetação nativa, desmatada ilegalmente, em áreas embargadas pelo Ibama no bioma Amazônia.

Considerando-se que a abordagem metodológica que está sendo proposta nesta pesquisa é baseada na análise de séries temporais dos satélites Landsat 8 e Landsat 9, convertidas em fração de cobertura vegetal (FCV), estimada a partir do índice de vegetação por diferença normalizada (NDVI), e em imagem-fração de vegetação verde (IFV), derivada de MLME, foram definidos os seguintes objetivos específicos:

- I. Comparar estatisticamente a radiometria do sensor OLI embarcado nos satélites Landsat 8 e Landsat 9; e
- II. Comparar estatisticamente o desempenho da fração de cobertura vegetal (FCV) estimada a partir do NDVI convertido para porcentagem de cobertura vegetal com a imagem-fração de vegetação verde, derivada de MLME, para o monitoramento da regeneração da vegetação em áreas embargadas pelo Ibama.

1.3 Hipóteses

Este estudo pretende analisar as seguintes hipóteses:

- I. A radiometria das imagens obtidas pelos satélites Landsat 8 OLI e Landsat 9 OLI na região Amazônica é estatisticamente igual.
- II. O desempenho da FCV é superior ao da IFV para o monitoramento da regeneração da vegetação nativa do bioma Amazônia.
- III. O monitoramento da regeneração da vegetação é possível com o uso dos satélites Landsat 8 OLI e Landsat 9 OLI

1.4 Justificativa

O uso de sensoriamento remoto e geotecnologias com foco no controle do desmatamento é amplamente difundido e o Brasil possui metodologias consolidadas que permitem quantificar remotamente as áreas desmatadas, em especial no bioma Amazônia (SHIMABUKURO et al., 2020). Contudo, tendo em vista as metas mundiais de mitigação de mudanças climáticas, faz-se necessário, além do controle do desmatamento, promover a recuperação de áreas degradadas visando principalmente o sequestro de carbono e a conservação da biodiversidade (ALMEIDA et al., 2010; BRASIL, 2017; CHAZDON et al., 2020).

As iniciativas de monitoramento remoto visando identificar a recuperação da vegetação nativa do território brasileiro são relativamente recentes e as metodologias utilizadas são incipientes em escala de território nacional. Não obstante o avanço das iniciativas e projetos criados com esse propósito, ainda é um desafio ter informações precisas do estágio de regeneração da vegetação natural em determinadas áreas em grandes escalas. Falsos positivos podem não ser considerados significativos em escalas de bioma ou todo o território nacional. No entanto, em escalas de pequenas e médias

propriedades rurais, os erros de classificação acentuam-se, inviabilizando o monitoramento remoto, tornando obrigatórias as vistorias em campo para constatar o real estágio de recuperação ou não de uma determinada área.

Assim, faz-se necessário aprimorar a acurácia dos modelos atuais para se identificar, com maior precisão espacial e temporal, o quantitativo de área em processo de regeneração natural e o estágio de recuperação da vegetação nativa. O Ibama, desde 2019, por meio do projeto “Monitoramento da recuperação de áreas degradadas” (MonitoRAD), vem realizando o monitoramento remoto de áreas embargadas e licenciadas pelo órgão com o propósito de acompanhar o processo de recuperação da vegetação nativa e a execução de projetos de recuperação de áreas degradadas (PRAD) mediante plantios ou regeneração natural, para fins de reparação do dano ambiental ou compensação ambiental, respectivamente. Em síntese, o propósito do MonitoRAD é monitorar o processo de restauração das áreas desmatadas a partir da aplicação do índice NDVI em séries temporais dos satélites Landsat 5 OLI e 8 OLI. O principal desafio desse monitoramento, de forma semelhante aos diversos estudos citados anteriormente, é distinguir, com precisão temporal e espacial, a regeneração da vegetação nativa de atividades agrícolas, pastagens e plantios florestais ou mesmo atividades agrosilvipastoris.

Nesse cenário, tendo em vista a necessidade de aprimorar a metodologia de monitoramento da recuperação das áreas degradadas, a presente proposta de pesquisa busca identificar um método mais adequado para monitorar remotamente a regeneração da vegetação nativa em áreas embargadas pelo Ibama no bioma Amazônia, a partir da comparação de técnicas mais utilizadas em pesquisas científicas e em projetos governamentais ou de organizações não-governamentais.

1.5 Organização do volume

Inicialmente é apresentada a fundamentação teórica desse trabalho e na sequência são apresentados os resultados na estrutura de dois artigos que contemplam os três objetivos específicos dessa pesquisa. O primeiro artigo aborda a questão da comparação radiométrica dos sensores OLI dos satélites Landsat 8 e 9 e foi apresentado e publicado nos Anais do XX Simpósio Brasileiro de Sensoriamento Remoto, realizado em Florianópolis/SC, no período de 2 a 5 de abril de 2023.

A segunda proposta de artigo visa apresentar os resultados da comparação do desempenho da fração de cobertura vegetal (FCV), derivada do NDVI, com a imagem-fração de vegetação verde (IFV), derivada de MLME, para o monitoramento da regeneração da vegetação em áreas embargadas pelo Ibama no bioma Amazônia.

CAPÍTULO 2

FUNDAMENTAÇÃO TEÓRICA

2.1 Monitoramento da regeneração da vegetação nativa

A floresta em regeneração natural ainda tem sido pouco mapeada para fins de planejamento e tomada de decisões e cumprimento da legislação brasileira e de metas internacionais acordadas (CHAZDON et al., 2020; SILVA JÚNIOR et al., 2020). As estimativas de desmatamento na Amazônia que são conduzidas pelo projeto PRODES não incluem áreas de florestas secundárias ou em processo de regeneração natural (CHAZDON et al., 2020; DEMARCHI et al., 2023). No entanto, sabe-se que o desmatamento de florestas secundárias contribui significativamente para a emissão de CO₂ na atmosfera. Além disso, quando a floresta naturalmente regenerada é mapeada, o ganho em área florestal proveniente de vegetação secundária é computado juntamente com o ganho obtido pelos reflorestamentos (CHAZDON et al., 2020).

Um exemplo de iniciativa que realiza o mapeamento de vegetação secundária é o *Global Forest Change* (GFC), plataforma disponibilizada pela Universidade de Maryland/EUA. Essa plataforma disponibiliza dados globais de perdas e ganhos do dossel florestal (GLOBAL FOREST CHANGE, 2013). Embora o GFC represente um grande progresso na quantificação de mudanças florestais em diferentes países do mundo, a plataforma apresenta algumas limitações para aplicação no Brasil. Por exemplo, conforme mencionado acima, não há separação dos ganhos de cobertura florestal em termos de origem (regeneração natural ou floresta plantada), dificultando o atendimento às leis previstas no Código Florestal Brasileiro que faz distinção entre essas duas classes (DEMARCHI et al., 2023).

No Brasil, a primeira iniciativa de classificação e quantificação da vegetação secundária em escala de bioma está sendo realizada pelo Projeto TerraClass. Trata-se de um sistema de mapeamento do uso e ocupação da terra, desenvolvido e executado pela Coordenação Espacial da Amazônia (COEAM) do Inpe em parceria com a Embrapa. Esse projeto procura qualificar os polígonos de desmatamento por corte raso mapeados pelo PRODES depois de passados dois anos. As categorias de uso e cobertura de terras consideradas pelo TerraClass são: vegetação secundária, silvicultura, pastagem com regeneração lenhosa e regeneração com pastagem (ALMEIDA et al., 2016; INPE, 2019, 2021). A partir desses mapas produzidos pelo projeto TerraClass, diversos estudos têm

estimado o total de vegetação secundária existente no bioma Amazônia (ALMEIDA et al., 2016; SILVA JÚNIOR et al., 2020; HEINRICH et al., 2021; CAMARA et al., 2023; SILVA et al., 2023).

De acordo com Almeida et al. (2016), a vegetação secundária cobria 21% (15 milhões de ha) da área desflorestada da AML em 2008. Segundo Silva Júnior et al. (2020), havia em torno de 26,3 milhões de ha de florestas secundárias no Brasil em 2018, a maior parte (14,9 milhões de ha) no bioma Amazônia. Camara et al. (2023) estimaram a existência de 5,86 milhões de ha de vegetação secundária na Amazônia em áreas que foram desmatadas após 2014. Em 2008, 19,2% das áreas desmatadas em Mato Grosso estavam em processo de regeneração natural (CHAZDON et al., 2020).

Pinto et al. (2021) estimaram a área em regeneração da vegetação nativa do bioma Amazônia com base nos dados de vegetação secundária elaborada pelo Imazon e disponibilizada na plataforma FloreSer. Segundo esses autores, havia 7,2 milhões de ha de vegetação secundária no bioma Amazônia em 2019. FloreSer é uma plataforma que dispõe mapas anuais de vegetação secundária produzidos com base nos mapas de uso e cobertura da terra gerados pelo projeto MapBiomas.

Com base nos resultados exemplificados acima, pode-se observar que ainda não se tem um consenso ou uma métrica consolidada para mapear floresta secundária. Segundo Pinto et al. (2021), ainda não há um sistema de monitoramento contínuo da vegetação secundária no Brasil. Portanto, faz-se necessário implementar um sistema eficaz para monitorar a regeneração da vegetação nativa de forma consistente em todo o País (BRASIL, 2017; SILVA et al., 2023) para se obter uma compreensão espacial e temporal mais ampla dos fatores ambientais que afetam a magnitude e a sustentabilidade da regeneração da floresta secundária (HEINRICH et al., 2021).

Da mesma forma que é possível mapear áreas desmatadas ao longo do tempo, também é possível mapear as mudanças no uso e cobertura da terra no que se refere às florestas secundárias advindas de regeneração natural, a partir de ferramentas de sensoriamento remoto como, por exemplo, as coleções de imagem de satélite Landsat (SILVA JÚNIOR et al., 2020).

2.2 Principais sensores ópticos para o monitoramento da restauração da vegetação natural em áreas desmatadas

Ao longo das últimas décadas, houve um grande avanço no desenvolvimento de tecnologias geoespaciais para o monitoramento ambiental da superfície da Terra. Entre esses avanços, pode-se citar a continuidade das imagens ópticas dos satélites da série Landsat que há décadas vem disponibilizando imagens com uma resolução espacial de 30 m (MASEK et al., 2020; WULDER et al., 2021). Um exemplo de importante melhoria que pode ser implementada a partir de imagens desse programa é o aprimoramento de sua resolução espacial combinando-se os dados Landsat com o *Planet Fusion*, criando-se, assim, uma série temporal aprimorada para monitorar e identificar a evolução da regeneração da vegetação nativa a longo prazo em paisagens heterogêneas (KONG et al., 2023).

Outro importante sensor utilizado em estudos multitemporais é o MODIS, dos satélites Terra e Aqua, que disponibiliza gratuitamente uma série temporal de pouco mais de 20 anos de dados de todo o território da América do Sul, com correções geométrica, radiométrica e atmosférica. No Brasil, esses dados são disponibilizados desde 2014 pelo Sistema de Análise Temporal da Vegetação (SATVeg), desenvolvido pela Embrapa Informática Agropecuária, que fornece perfis do índice vegetativo NDVI e do índice de vegetação aprimorado (EVI) a partir do sensor MODIS (ESQUERDO et al., 2020). O foco desse sistema é o acompanhamento de ganhos e perdas da biomassa verde de culturas agrícolas, mas também vem sendo aplicado no monitoramento de desmatamentos e no mapeamento do uso e cobertura do solo, a exemplo do Projeto TerraClass que utiliza esses dados (ALMEIDA et al., 2016).

Em comparação com as coleções de imagens Landsat, vale ressaltar as diferenças em relação a resolução espacial do sensor MODIS de 250 metros e a série temporal disponibilizada apenas a partir do ano 2000 pelo satélite Terra (ESQUERDO et al., 2020). Com o lançamento de seu primeiro satélite em 1972, o Landsat é o programa de satélite terrestre mais antigo do mundo em operação contínua (ZHU et al., 2019; MASEK et al., 2020). O sucesso desse programa está intrinsecamente ligado à política de dados abertos e gratuitos que foi implementada em 2008, o que levou a uma expansão sem precedentes da taxa diária de acesso e aquisição de imagens, passando a configurar como uma importante ferramenta de monitoramento (WULDER et al., 2019; ZHU et al., 2019). O

livre acesso às imagens do Landsat tem promovido o uso desses dados em diversos estudos científicos, subsidiando o melhor gerenciamento dos recursos naturais terrestres.

O programa Landsat tem sido a principal referência de comparação para a maioria dos sistemas ópticos de satélites de resolução espacial mais grosseira. Após a implementação de política de dados abertos, o programa Landsat passou a garantir não só o desenvolvimento de pesquisas científicas a longo prazo, como também a aceitação e institucionalização das estimativas baseadas no Landsat em programas oficiais de governo (WULDER et al., 2019). O seu bom desempenho na disseminação de imagens pode ser observado na disponibilização de produtos prontos para serem utilizados, proporcionando melhorias na fidelidade geométrica e radiométrica das imagens (WULDER et al., 2019).

2.3 Semelhanças e diferenças entre os sensores Landsat 8 e Landsat 9

O Landsat 8, lançado em 11 de fevereiro de 2013, foi uma adição tardia à missão, sendo construído com uma expectativa de vida útil de três anos. Embora o seu desempenho já tenha excedido esta expectativa, o sensor infravermelho termal (TIRS) tem apresentado algumas falhas (MASEK et al., 2020). Nesse cenário, com o objetivo de continuar uma cadeia ininterrupta de sensoriamento remoto da Terra que começou com o lançamento do Landsat 1 em 1972 (GROSS et al., 2022), foi desenvolvido o Landsat 9 com o objetivo de corrigir os problemas identificados e dar continuidade ao Landsat 8 (MASEK et al., 2020). Assim, o Landsat 9, desenvolvido com diversas melhorias e com uma vida útil de cinco anos, foi lançado em 27 de setembro de 2021 (GROSS et al., 2022).

O Landsat 9 foi lançado com alguns aprimoramentos importantes nos sensores OLI e TIRS. O OLI-2 aprimora as medições de refletância enquanto o TIRS-2 resolve problemas como a incursão de luz difusa e um mau funcionamento no espelho de seleção de cena (GROSS et al., 2022; MENG et al., 2022). A principal diferença entre o Landsat 8 e 9 está na resolução radiométrica. No Landsat 8 OLI, os dados são adquiridos com resolução radiométrica de 12 bits e disponibilizados para o público em geral em 16 bits, uma melhoria significativa em relação aos 8 bits dos sensores TM e ETM+ anteriores. Já o Landsat 9 OLI-2 opera com uma resolução radiométrica de 14 bits (GROSS et al., 2022; MENG et al., 2022). A melhoria na resolução radiométrica pode aumentar a capacidade de detecção e classificação de alvos terrestres (MENG et al., 2020) por causa da melhora

na relação sinal/ruído, principalmente na identificação de alvos mais escuros como as águas costeiras (MASEK et al., 2020).

O sensor OLI a bordo dos satélites Landsat 8 e Landsat 9 operam com o mesmo modo de imageamento em termos de bandas espectrais (oito bandas multiespectrais com resolução espacial de 30 m e uma banda pancromática com resolução de 15 m) e em termos de periodicidade (16 dias). Considerando-se que os dois satélites circulam ao redor da Terra em um mesmo plano orbital, ao serem combinados, é capaz de reduzir a periodicidade de 16 dias para 8 dias (GROSS et al., 2022).

Nesse contexto, dentre os diferentes sistemas sensores orbitais atualmente em operação, as imagens obtidas pelos satélites Landsat 8 e 9 são as mais utilizadas no mapeamento e monitoramento da superfície terrestre (WULDER et al., 2019). Estudos recentes têm avaliado a precisão desses dois satélites, com resultados promissores (CHOATE et al., 2022; GROSS et al., 2022; MENG et al., 2022), incentivando o seu uso em diversas aplicações como identificação de ilhas de calor urbanas, detecção geotérmica e pesquisa vulcanológica (MENG et al., 2022).

Gross et al. (2022) afirmaram que, historicamente, para fins de calibração cruzada envolvendo diferentes sensores, o fator mais limitante tem sido as diferenças nas datas de passagens dos sensores. Considerando o intervalo relativamente curto de oito dias entre as passagens dos satélites Landsat 8 e Landsat 9 e assumindo que as variações espectrais dos alvos decorrentes desse intervalo de tempo podem ser negligenciadas, as diferenças radiométricas entre as duas imagens estariam restritas às diferenças nos ângulos de elevação e azimute solar (CHOATE et al., 2022).

Os resultados das análises realizadas por Meng et al. (2022) em diferentes tipos de superfície terrestre mostraram que os dados do sensor TIRS do Landsat 9 possuem uma forte correlação e está em consonância com os do Landsat 8. No entanto, esses autores ressaltaram que o Landsat 9 precisa de alguns aprimoramentos, mesmo considerando que a avaliação foi insuficiente por não haver ainda um número adequado de imagens disponíveis das áreas de estudo.

Wulder et al. (2019) ressaltaram que um ponto importante a ser considerado em se tratando do uso de dados prontos para análise em processamentos automatizados é a necessidade de um alinhamento geométrico de alta precisão para se evitar erros de registros incorretos em séries temporais e para permitir a integração com outros conjuntos de dados espaciais. De forma geral, partindo do princípio de que a qualidade dos dados do Landsat 9 OLI-2 e TIRS-2 será igual ou superior à qualidade radiométrica, espectral e

geométrica do Landsat 8, espera-se que o Landsat 9 continue a fornecer dados globais e de acesso aberto para subsidiar avaliações em longo prazo com relação às mudanças de uso e cobertura da terra (MASEK et al., 2020).

As constantes melhorias na instrumentação, armazenamento a bordo e taxas de transmissão de dados para o usuário vem permitindo o monitoramento intra-anual de rotina da superfície da Terra e a detecção de mudanças cada vez mais sutis nas propriedades e nos ecossistemas (WULDER et al., 2019).

2.4 Principais técnicas de processamento de imagens ópticas para o monitoramento contínuo da regeneração: séries temporais de índice de vegetação e imagens-fração do modelo linear de mistura espectral

2.4.1. Índices de vegetação

Desde que a NASA tomou a decisão de tornar os dados Landsat públicos e gratuitos, abriu-se um leque de possibilidades para a pesquisa e inovações. Como resultado, diversos algoritmos de detecção de mudanças para perdas florestais foram rapidamente desenvolvidos com base nas séries temporais Landsat de longa duração (HUA et al., 2021).

O uso de series temporais para estimar parâmetros de vegetação tem fornecido informações relevantes em diferentes aplicações tanto na agricultura como no meio ambiente (CHAVES et al., 2013). Algoritmos de segmentação temporal como o LandTrendr têm sido utilizados para identificar fenômenos abruptos ou lentos em séries temporais do Landsat (HUA et al., 2021). A previsão de tendências tem sido o grande diferencial (WULDER et al., 2019). Antes desse cenário, as análises priorizavam a compreensão apenas do espaço, utilizando-se imagens de uma única data devido à limitação de séries temporais de alta qualidade e à falta de abordagens metodológicas adequadas para processar os dados em grandes escalas (ADAMI et al., 2018). Assim, a disponibilidade de séries temporais de alta qualidade tem trazido contribuições relevantes para a análise da vegetação, possibilitando detectar e monitorar mudanças e avaliar o comportamento espectral de uma determina área em um determinado período (CHAVES et al., 2013).

Os índices de vegetação são transformações espectrais de duas ou mais bandas que objetivam realçar áreas nas cenas com cobertura vegetal total ou parcial com

diferenças em termos de propriedades fotossintéticas e variações estruturais do dossel (ZHOU et al., 2023). Os índices de vegetação têm sido bastante aplicados em estudos regionais e globais de monitoramento do uso e cobertura da terra (ADAMI et al., 2018). A grande vantagem de sua aplicação está no fato de ser menos susceptível a alguns fatores ambientais externos, como fatores de terreno e condições atmosféricas, quando comparado ao uso de dados de uma única banda espectral (HUA et al., 2021).

Os principais índices de vegetação utilizados para detectar alterações na vegetação podem ser divididos em “índices de verdor”, que combinam as bandas do vermelho e infravermelho próximo, e os “índices de umidade”, que combinam bandas do infravermelho próximo (NIR) e do infravermelho de ondas curtas (ZHOU et al., 2023). Dentre os “índices de verdor”, os mais conhecidos são o Índice de Vegetação por Diferença Normalizada (NDVI) (Eq. 1), proposto por Rouse et al. (1974) e o Índice de Vegetação Aprimorado (EVI) (Eq. 2), proposto por Huete et al. (1997).

$$NDVI = \frac{IVP - VM}{IVP + VM} \quad (1)$$

em que IVP = reflectância na faixa do infravermelho próximo; e VM = reflectância na faixa do vermelho.

$$EVI = G \times \left(\frac{(IVP - VM)}{(IVP + (C1 \times VM) - (C2 \times AZ) + L)} \right) \quad (2)$$

em que G = fator de ganho; IVP = reflectância na faixa do infravermelho próximo; VM = reflectância na faixa do vermelho; C1 e C2 = coeficientes de ajuste para efeitos de aerossóis; AZ = reflectância na faixa do azul; e L = fator de ajuste para o solo.

O NDVI e o EVI são, por exemplo, produzidos globalmente a partir do sensor MODIS e disponibilizados a cada 16 dias e estão, respectivamente, mais relacionados com a quantidade de clorofila e área foliar da vegetação (TUCKER, 1979; HUETE et al., 2002). O uso integrado desses dois índices permite análises regulares da cobertura vegetal de toda a superfície terrestre, visando o aprimoramento da detecção de mudanças na vegetação e a extração de parâmetros biofísicos do dossel (HUETE et al., 2002; RISSO et al., 2009; ZHOU et al., 2023). O índice de vegetação mais utilizado em pesquisas científicas é o NDVI, devido à sua capacidade de descrever propriedades biofísicas da vegetação com uma formulação matemática bastante simples, calculado a partir da razão

simples (RS) dos valores de reflectância das bandas do vermelho e do infravermelho próximo (**Eq. 3**) (HUETE et al., 2002).

$$RS = \frac{IVP}{VM}$$

tal que

(3)

$$NDVI = \frac{RS - 1}{RS + 1}$$

em que SR = razão simples; IVP = reflectância na faixa do infravermelho próximo; VM = reflectância na faixa do vermelho.

Embora o NDVI sofra interferência de efeitos aditivos de solos e da atmosfera, a sua maior vantagem está justamente em utilizar o conceito de divisão que é capaz de reduzir formas de ruídos multiplicativos, tais como as diferenças de iluminação solar, sombras de nuvens, atenuação atmosférica e certas variações topográficas, presentes em múltiplas bandas (HUETE, 1988).

Os índices de vegetação podem ser utilizados, por exemplo, para estimar índice de área foliar e fração de cobertura vegetal (FCV) (CHAVES et al., 2013). A FCV é uma derivação de índices de vegetação e é usualmente aplicada em metodologias baseadas em abordagens empíricas usando índices como o NDVI (**Eq. 4**) (JIMÉNEZ-MUÑOZ et al., 2009). FCV pode ser entendida como um importante parâmetro biofísico, pois pode estimar a proporção da vegetação que vai interagir com a atmosfera (CHAVES et al., 2013).

$$FCV = \frac{NDVI - NDVI_S}{NDVI_V - NDVI_S} \quad (4)$$

em que FCV = fração do solo coberta por vegetação verde; NDVI_S = valor representativo de NDVI para solo exposto (FVC = 0); e NDVI_V = valor representativo de NDVI para vegetação (FVC = 1).

2.4.2. Modelo linear de mistura espectral (MLME): Imagens-fração de vegetação (IFV)

As alterações na cobertura vegetal podem ser analisadas por meio de imagens orbitais convertidas em imagens-fração de vegetação (IFV), obtidas a partir de Modelo Linear de Mistura Espectral (MLME). A IFV fornece informações semelhantes aos índices de vegetação (SHIMABUKURO et al., 2020).

A não uniformidade da maioria dos ambientes naturais geralmente resulta no fenômeno conhecido como mistura espectral, o qual ocorre quando se tenta classificar um pixel que contém uma mistura de materiais diferentes na superfície, como solo, vegetação, rochas ou água. Quando há vários componentes em um pixel, o simples aumento na resolução espacial dos sensores pode não melhorar os resultados da classificação de imagens (SHIMABUKURO et al., 2020). Solucionar essa questão tem sido alvo de pesquisas desde a década de 1970. Diversas fórmulas foram criadas e aplicadas desde então para resolver o problema da mistura espectral (SHIMABUKURO et al., 2020). Essas equações, obtidas de diversos satélites de observação da Terra, tentam estimar as proporções dos componentes dentro dos pixels, gerando imagens separadas e correspondentes aos componentes presentes em cada pixel e são denominadas de imagens-fração.

As imagens-fração são definidas pela relação linear usada para representar a mistura espectral dos componentes dentro do elemento de resolução do sensor, onde a resposta de cada pixel em qualquer banda espectral pode ser definida como uma combinação linear das respostas de cada componente no alvo imageado (SHIMABUKURO, 1998). Uma das vantagens do MLME é justamente a conversão dos dados espectrais em imagens-fração que levam a uma redução significativa na dimensionalidade dos dados e realçam as informações a serem analisadas (SHIMABUKURO et al., 2020).

As imagens-fração de solo, vegetação e sombra ou água são as mais utilizadas para o mapeamento e monitoramento dos diferentes tipos de uso e cobertura da terra, por estarem diretamente relacionadas à dinâmica dos alvos na superfície. Por essa razão, têm sido utilizadas em várias áreas de pesquisa e tem sido importante para o desenvolvimento de projetos de estimativa de áreas desflorestadas como o PRODES e o DETER (SHIMABUKURO, 1998; SHIMABUKURO et al., 2020). O MLME vem sendo aplicado

em diversos trabalhos como os desenvolvidos por Li et al. (2023), Ma et al. (2023) e Sha et al. (2023) para analisar a acurácia de outros modelos.

Adami et al. (2018) aplicaram MLME para mapear, em escala continental, mudanças sazonais no uso e cobertura da terra em toda a América do Sul. Shimabukuro et al. (2020a) e Shimabukuro et al. (2020b) mapearam as classes de uso e cobertura da terra mais representativas do Brasil e as áreas queimadas no estado do Mato Grosso, respectivamente, utilizando o referido modelo. Alencar et al. (2023) utilizaram o MLME para identificar os efeitos do desmatamento na dinâmica temporal e espacial da vegetação secundária na região amazônica.

Shimabukuro (1998), ao comparar os dois métodos de determinação de fração de vegetação apresentados nesta seção, isto é, a FCV, derivada de índices de vegetação, e a IFV, obtida a partir da aplicação do MLME, concluiu que, apesar de existir alta correlação entre IFV e FCV, a primeira é mais indicada para avaliar a cobertura vegetal por ser mais susceptível às variações de cobertura vegetal do solo. Em pesquisa mais recente, Sato et al. (2021) corroboraram os resultados obtidos por Shimabukuro (1998), afirmando que a IFV é menos susceptível às variações de fatores como condições de iluminação da cena e variações atmosféricas.

2.5 Fração de cobertura vegetal verde (FCV): Equação proposta por Qi et al. (2000)

Muitas são as possibilidades de aplicação de diferentes modelos como os índices de vegetação e MLME para classificar, de forma mais precisa possível, áreas com cobertura vegetal. Dentre as diversas técnicas desenvolvidas, algumas buscam uma fórmula alternativa em que os resultados sejam menos susceptíveis aos efeitos atmosféricos. Uma dessas equações práticas é a conversão do NDVI em fração de cobertura vegetal verde (FCV), proposta por Qi et al. (2000) (Eq. 5).

$$FCV = \frac{NDVI - NDVI_{SOIL}}{NDVI_{VEG} - NDVI_{SOIL}} \quad (5)$$

em que $NDVI_{SOIL}$ = valor do pixel puro de solo exposto ou sem vegetação; e $NDVI_{VEG}$ = valor do pixel puro de vegetação verde.

Segundo esses autores, as estimativas das propriedades da vegetação com imagens de sensoriamento remoto têm sido bem-sucedidas, no entanto, são necessários enormes esforços de processamento relacionados com correções atmosféricas e com fatores bidirecionais (geometria de iluminação e visada). Embora existam procedimentos para corrigir esses efeitos, os dados auxiliares sobre as condições atmosféricas e as propriedades bidirecionais são limitados no espaço e no tempo. Nesse cenário, esses autores propuseram converter NDVI em FCV que é menos sensível ao efeito atmosférico em comparação com índices de vegetação espectral como o NDVI.

Qi et al. (2000) ressaltaram, porém, que a avaliação quantitativa dos efeitos atmosféricos e bidirecionais na dinâmica dos índices de vegetação e na estimativa de FCV precisam ser melhor investigada. Assim, considerando as incertezas na estimativa de FCV associadas a vários tipos de vegetação quantificadas, aplicar essa equação em grande escala em outras áreas de estudo pode ser um bom exercício.

Nesse contexto, e tendo em vista que a equação de Qi et al. (2000) foi aplicada inicialmente em clima árido e semiárido, uma proposta seria aplicar essa equação em áreas localizadas em condições atmosféricas e climáticas diferentes, como no bioma Amazônia, onde o clima predominante é tropical úmido e comparar essa aplicação com os resultados de outras técnicas conhecidas como o MLME.

CAPÍTULO 3

COMPARAÇÃO RADIOMÉTRICA DAS IMAGENS LANDSAT 8/9 OLI VISANDO O MONITORAMENTO DA RESTAURAÇÃO DE ÁREAS DESMATADAS E EMBARGADAS NA AMAZÔNIA

Artigo publicado nos Anais do XX Simpósio Brasileiro de Sensoriamento Remoto, realizado em Florianópolis/SC, no período de 2 a 5 de abril de 2023.

RESUMO

A legislação brasileira determina que áreas desmatadas de forma ilegal sejam embarcadas e restauradas. Séries temporais de imagens do satélite Landsat são comumente utilizadas para o monitoramento da restauração dessas áreas. O objetivo deste estudo é comparar a qualidade radiométrica das imagens dos satélites Landsat 8/9 OLI visando o monitoramento da restauração de áreas desmatadas e embargadas. Foram analisadas duas cenas conjugadas desses satélites (diferença de 8 dias entre as datas de passagem), adquiridas em abril (estação chuvosa) e setembro (estação seca) de 2022, sobre uma área embargada de 2.760 ha no município de Nova Maringá/MT. Valores de reflectância de superfície, índices espectrais e imagens-fração dos dois satélites foram comparados estatisticamente. Resultados mostraram que os dados obtidos pelos dois satélites são, regra geral, estatisticamente similares, mas que podem ser diferentes dependendo da estação do ano e da classe de uso e cobertura de terras.

Palavras-chave: modelo linear de mistura espectral, índice espectral, desmatamento ilegal.

ABSTRACT

According to the Brazilian legislation, illegally deforested areas must be embargoed and restored. Time series of Landsat images are commonly used to monitor the restoration of deforested areas. The objective of this study is to compare the radiometric quality of

Landsat 8/9 OLI satellite images over the Brazilian Amazon for monitoring the restoration of deforested areas. Two pairs of Landsat8/9 scenes (difference of 8 days between the two overpasses) acquired in April (rainy season) and September (rainy season) of 2022 were selected over a 2760-ha embargoed area in the municipality of Nova Maringá/MT. Surface reflectances, spectral indices, and fraction-images were compared statistically. Results showed that the data obtained by these two satellites are, in general, statistically similar. However, they may be different depending on the season of the year and the land use and land cover class.

Key words: spectral mixing linear model, spectral indice, illegal deforestation.

3.1 Introdução

A legislação ambiental brasileira determina que as áreas desmatadas ilegalmente devem ser autuadas e restauradas. Por desmatamento ilegal, entende-se a supressão da vegetação nativa sem autorização por parte de órgãos ambientais competentes como o Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA) e as secretarias ambientais estaduais ou municipais (SCHMITT, 2015). O processo de restauração dessas áreas desmatadas é relativamente demorado, precisando ser monitorado sistematicamente. Uma das únicas formas de efetuar tal monitoramento é a partir de análise de séries temporais de imagens de satélite.

Dentre os diferentes sistemas sensores orbitais atualmente em operação, destacam-se as imagens obtidas pelos satélites Landsat 8 e Landsat 9 (neste estudo, denominados de Landsat 8/9) *Operational Land Imager* (OLI) como sendo as mais utilizadas no mapeamento e monitoramento da superfície terrestre (WULDER et al., 2019). Esses dois satélites foram lançados em 11 de fevereiro de 2013 em 27 de setembro de 2021, respectivamente. O sensor OLI a bordo desses dois satélites opera com o mesmo modo de imageamento em termos de bandas espectrais (oito bandas multiespectrais com resolução espacial de 30 m e uma banda pancromática com resolução de 15 m) e em termos de periodicidade (16 dias). A principal diferença está na resolução radiométrica original que é de 12 bits no Landsat 8 e 14 bits no Landsat 9 (MASEK et al., 2020).

Os dois satélites operam em um mesmo plano orbital. Quando combinados, a periodicidade reduz de 16 para 8 dias. Este estudo pretende analisar a seguinte questão científica: a radiometria das imagens obtidas pelos satélites Landsat 8/9 OLI na região

Amazônica é estatisticamente igual ou diferente? Para isto, foi assumida a premissa de que as variações espectrais decorrentes da sazonalidade climática na área de estudo, no intervalo de 8 dias, podem ser negligenciadas.

3.2 Material e métodos

A área de estudo selecionada corresponde a uma área de 2.760 ha que foi autuada pelo IBAMA (Processo 02013.001238/2008-02) em 15 de julho de 2015 pela equipe de fiscalização de campo (**Figura 1**). A área localiza-se no município de Nova Maringá, próximo à rodovia MT-160, região central do estado de Mato Grosso e distante certa de 370 km da capital Cuiabá. Trata-se de uma área com predomínio de floresta ombrófila densa, porém, com intensa ocupação humana para produção de grãos e carne bovina, além de áreas em processo de regeneração, denominadas de vegetação secundária (MAPBIOMAS, 2022).

Os materiais básicos deste estudo foram compostos pelas imagens dos satélites Landsat 8/9 OLI (coleção 2, nível 2) convertidos para reflectância de superfície e disponíveis para download no site *earth explorer* do U.S. *Geological Survey* (USGS). Foram adquiridas duas cenas de abril (final da estação chuvosa) e duas cenas de setembro (estação seca) (**Tabela 1**). O seguinte fator de escala (**Eq. 1**) foi aplicado para que os valores de reflectância variassem de 0 (pixels escuros, alta absorção da radiação incidente na superfície terrestre) a 1 (pixels claros, alta reflexão da radiação incidente):

$$B_r = B_o \times 0,0000275 - 0,2 \quad (1)$$

em que B_r = banda reescalada para o intervalo de valores [0,1]; e B_o = banda original das imagens multiespectrais disponibilizadas na coleção 2, nível de processamento 2.

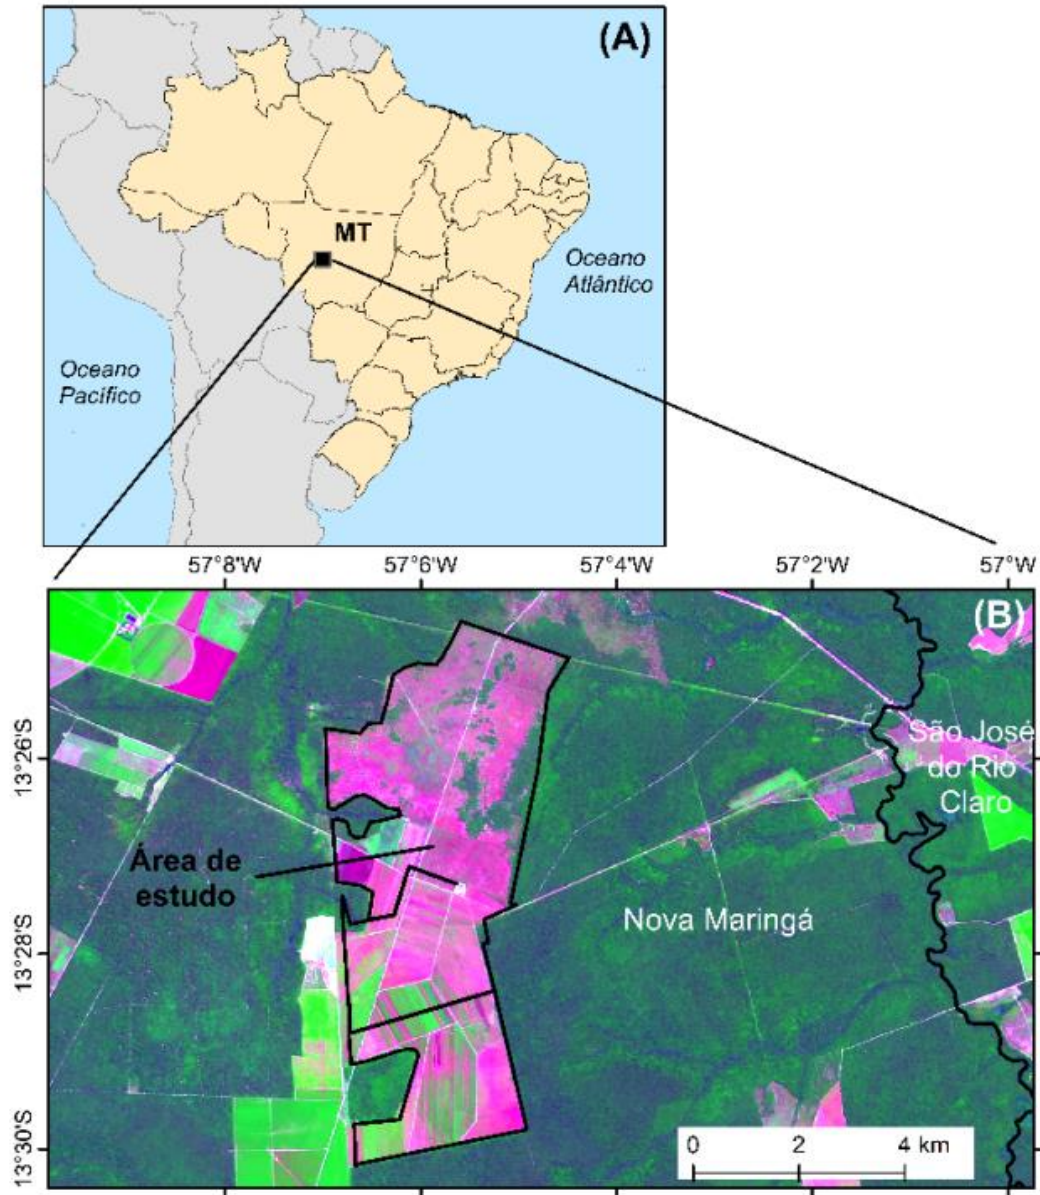


Figura 1. Localização da área de estudo no estado do Mato Grosso (A) e no município de Nova Maringá/MT (B). A imagem corresponde à composição colorida RGB das bandas 4, 5 e 6 do satélite Landsat 8 OLI adquirida em 27 de abril de 2022.

Tabela 1. Características de imageamento das imagens Landsat 8/9 OLI selecionadas para o desenvolvimento desta pesquisa (órbita = 227; ponto = 69).

Parâmetro	Landsat 8	Landsat 9
Datas de passagem (chuva)	27/04/2022	19/04/2022
Datas de passagem (seca)	18/09/2022	10/09/2022
Resolução radiométrica	12 bits	14 bits
% cobertura de nuvens (chuva)	0	0
% cobertura de nuvens (seca)	4	0

Uma das análises radiométricas conduzidas neste estudo foi baseada na comparação dos valores de reflectância obtidas nas bandas 4 (faixa espectral do vermelho), 5 (infravermelho próximo) e 6 (infravermelho médio) pelos dois satélites e nas duas estações climáticas (chuva e seca). As seguintes classes de uso e cobertura de terras foram consideradas, baseadas no mapeamento anual de uso e cobertura de terras do Projeto MapBiomas (MAPBIOMAS, 2022): floresta primária; vegetação secundária; culturas agrícolas; pastagens cultivadas; e massas d'água. Foram obtidas 10 amostras de reflectância distribuídas aleatoriamente dentro de cada classe de uso e cobertura de terras. O total de pixels de cada classe espectral variou de 57^a (água) a 760 pixels (pastagem). Em função da ausência de massas d'água na área embargada, as suas amostras foram obtidas em reservatórios e leitos de rios perenes localizados próximos ao polígono de desmatamento ilegal.

A outra análise envolveu a conversão dos valores de reflectância para índice de vegetação por diferença normalizada (NDVI) (**Eq. 2**) (TUCKER, 1979). Os valores de NDVI variam no intervalo de [-1, +1] e estão diretamente relacionados com o nível de atividade fotossintética do dossel vegetal. Trata-se do índice espectral mais popular da literatura.

$$NDVI = \frac{\rho_{IVP} - \rho_{VM}}{\rho_{IVP} + \rho_{VM}} \quad (2)$$

em que ρ_{IVP} = reflectância na faixa do infravermelho próximo; ρ_{VM} = reflectância na faixa do vermelho.

3.3 Resultados e discussão

Na **Figura 2**, são mostradas as relações entre os valores de reflectância obtidos, nos meses de abril e setembro, nas bandas 4, 5 e 6, dos satélites Landsat 8/9, por meio de regressão linear simples. Regra geral, as reflectâncias são bastante similares independentemente da banda espectral e da sazonalidade climática. A exceção ficou por conta das culturas agrícolas que apresentou uma tendência de superestimação para as bandas 4 e 6 do Landsat 9 em abril e de subestimação para a banda 5. Para a estação seca, a similaridade radiométrica foi mais acentuada.

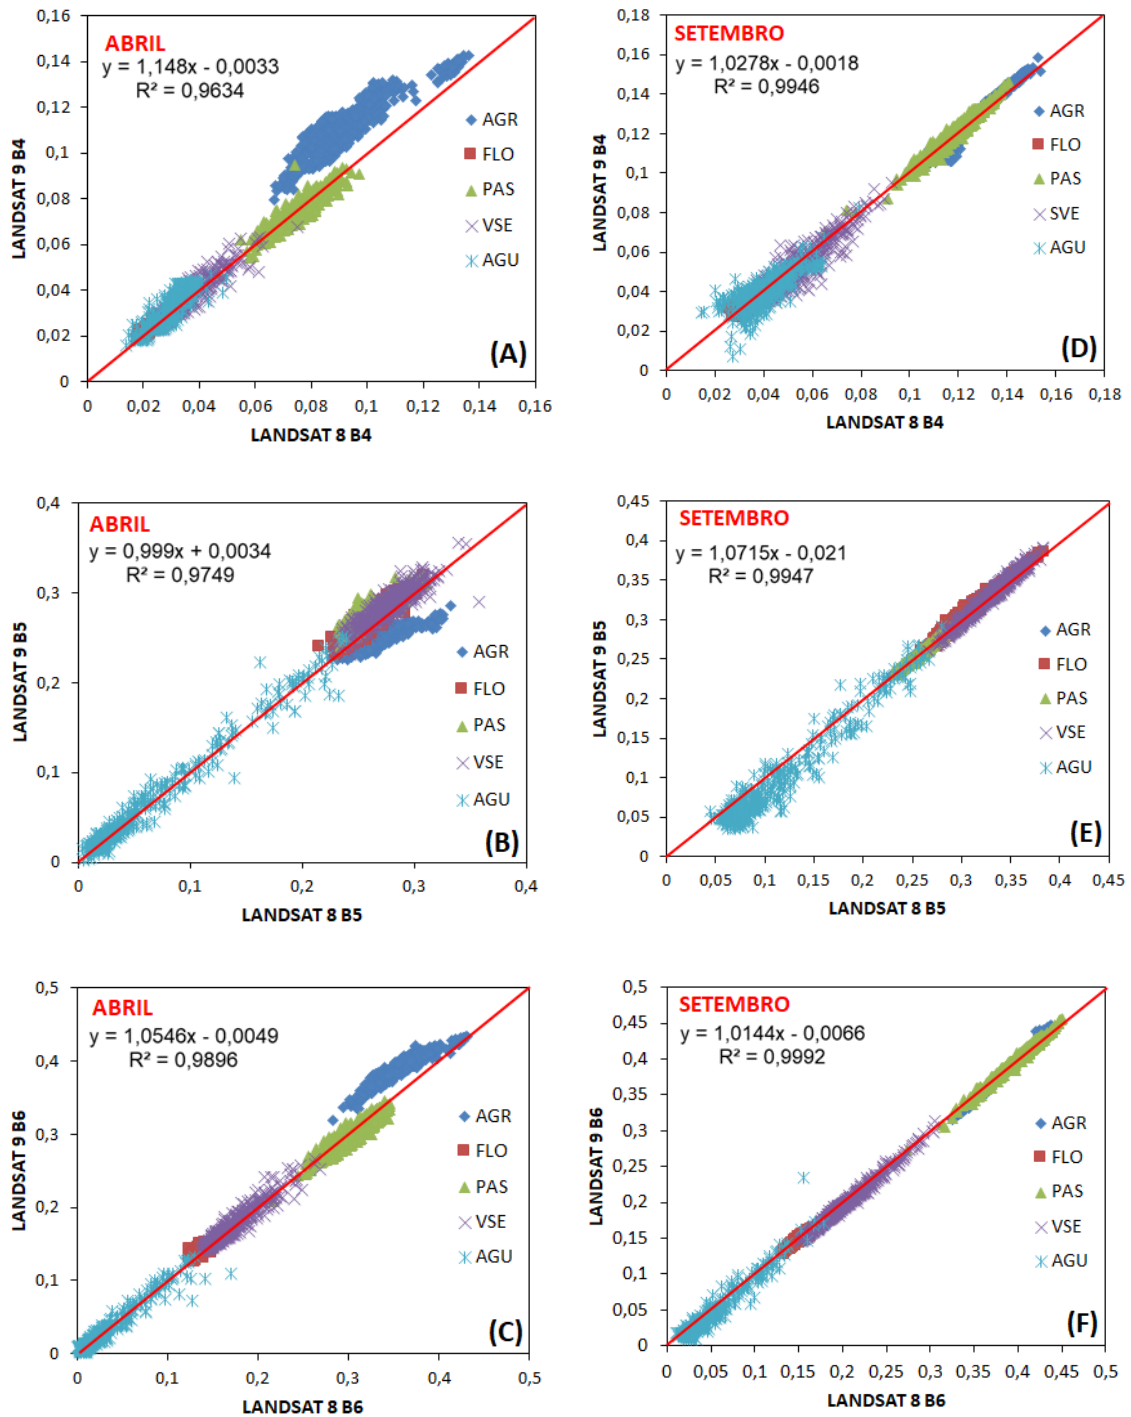


Figura 2. Relação entre valores de reflectância obtidas em abril de 2022 nas bandas 4 (A), 5 (B) e 6 (C) dos satélites Landsat 8/9 OLI e em setembro de 2022 nas mesmas três bandas (D, E e F), a partir de regressão linear simples. AGR = culturas agrícolas; FLO = floresta primária; PAS = pastagem cultivada; VSE = vegetação secundária; AGU = massas d'água.

A diferença entre os valores de NDVI calculados para os dois satélites para o mês de abril indicou que 47% dos pixels apresentaram valores inferiores para o Landsat 8, enquanto o restante (53%) apresentaram valores superiores (**Figura 3**). A maioria dos valores mais altos para o Landsat 8 situaram-se na porção norte da área autuada. Para o mês de setembro, 68% dos pixels apresentaram valores inferiores para o Landsat 8. Esses resultados mostram que, em termos de NDVI, os dois satélites não conseguem reproduzir os mesmos valores de NDVI. As diferenças máximas positivas e negativas nos valores de NDVI entre os dois satélites foi significativamente maior na estação chuvosa (-0,14 e +0,16) do que na estação seca (-0,03 e +0,07).

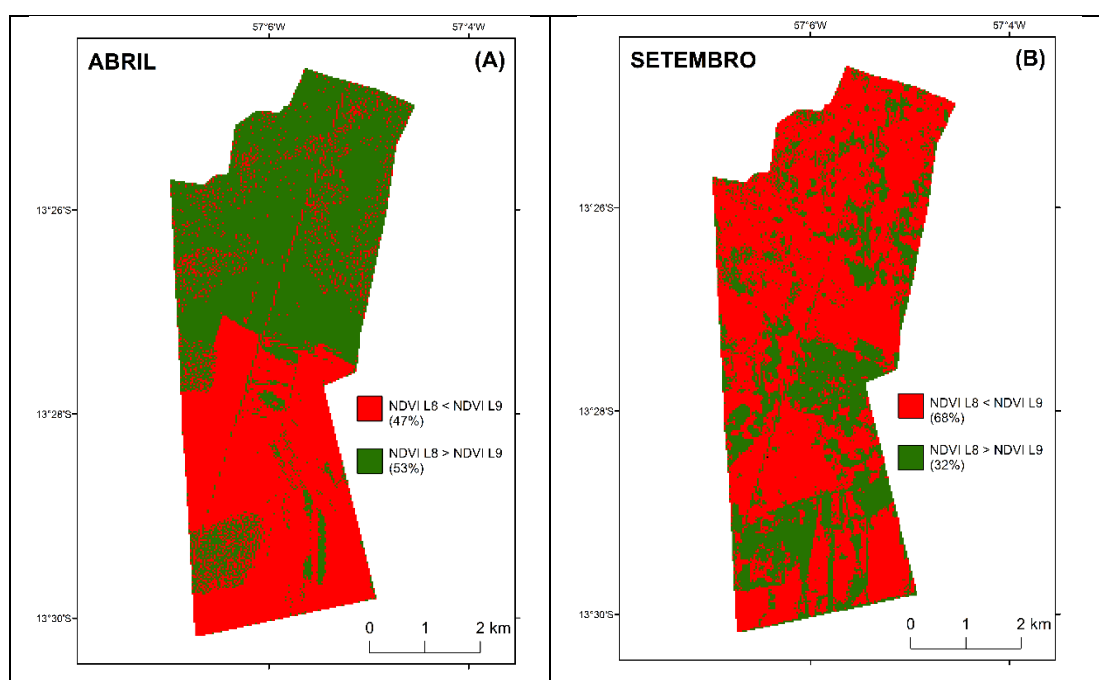


Figura 3. Diferença entre os valores de NDVI do mês de abril (A) e setembro (B) de 2022, calculados para os satélites Landsat 8 (L8) e Landsat 9 (L9).

3.4 Conclusões

Os resultados preliminares deste estudo indicaram que a radiometria dos pares conjugados de cenas dos satélites Landsat 8/9 da área de estudo, localizada no município amazônico de Nova Maringá/MT, são estatisticamente similares, com maior ou menor nível de variação dependendo da classe espectral e da sazonalidade climática. Outros processamentos como o modelo linear de mistura espectral e a classificação não-paramétrica por redes neurais estão sendo processados e os resultados serão divulgados em breve.

CAPÍTULO 4

COMPARAÇÃO DO DESEMPENHO DA FRAÇÃO DE COBERTURA VEGETAL (FCV) E DA IMAGEM-FRAÇÃO DE VEGETAÇÃO (IFV) PARA O MONITORAMENTO DA RESTAURAÇÃO DE ÁREAS DESMATADAS NO BIOMA AMAZÔNIA

RESUMO

A disponibilidade de séries temporais do satélite Landsat tem trazido contribuições relevantes para o monitoramento da cobertura vegetal. Projetos voltados ao monitoramento de desmatamento no bioma Amazônia são fundamentais para a gestão do uso e ocupação do solo na região. Em especial no direcionamento das ações de fiscalização que culminam na paralização das atividades ilícitas e no embargo das áreas visando a restauração da vegetação nativa. Assim, o presente estudo teve como objetivo avaliar os desempenhos da fração de cobertura vegetal (FCV) derivada do índice de vegetação por diferença normalizada (NDVI) e da imagem-fração de vegetação (IFV) derivada de modelo linear de mistura espectral (MLME) para o monitoramento da regeneração da vegetação em áreas desmatadas e embargadas pelo Instituto Brasileiro de Meio Ambiente e dos Recursos Naturais Renováveis (Ibama). As áreas de estudo selecionadas correspondem a imóveis rurais embargados pelo Ibama, localizados no estado do Mato Grosso, no bioma Amazônia. Foram selecionadas 35 imagens do satélite Landsat 8 da estação seca do período de 2018 a 2022. Os resultados estatísticos comparando o desempenho dos dois modelos apresentaram uma forte correlação linear em todas as áreas de estudo, com coeficientes de correlação variando entre 0,81 e 0,98. O teste t de Student mostrou que as diferenças nas classificações encontradas entre as variáveis não foram estatisticamente diferentes. Ambos os modelos mostraram ser eficientes no monitoramento da recuperação de áreas desmatadas. No entanto, sugere-se ampliar o estudo para outras áreas e outros biomas não-amazônicos, envolvendo uma série temporal mais longa para corroborar os resultados encontrados nesta pesquisa.

Palavras-chave: Floresta amazônica; Fração de vegetação; Modelo linear de mistura espectral.

ABSTRACT

The availability of time series of Landsat satellite has brought relevant contributions to the monitoring of vegetation cover. Projects aimed at monitoring deforestation in the Amazon biome are essential for managing land use and occupation in the region. Especially in directing inspection actions that culminate in the paralysis of illegal activities and the embargo of areas aimed at restoring native vegetation. Thus, this study aimed to evaluate the performance of the fraction vegetation cover (FVC) derived from the normalized difference vegetation index (NDVI) and the vegetation fraction image (VFI) derived from the linear spectral mixing model (LSMM) for monitoring vegetation regeneration in areas deforested and embargoed by the Brazilian Institute for the Environment and Renewable Natural Resources (Ibama). The selected study areas correspond to rural properties embargoed by Ibama, located in the state of Mato Grosso, in the Amazon biome. We selected dry season images from the Landsat 8 satellite acquired from 2018 to 2022. The statistical results comparing the performance of the two models showed a strong linear correlation in all study areas, with coefficients of correlation ranging from 0.81 to 0.98. The Student's t-test showed that the differences in the classifications found between the variables were not statistically different. Both models proved to be efficient in monitoring the regeneration of deforested areas. However, we suggest expanding the study to other areas and other non-Amazonian biomes, involving a longer time series to corroborate the results found in this research.

Key words: spectral mixing linear model, spectral indice, illegal deforestation.

4.1 Introdução

A floresta Amazônica, a maior floresta tropical do mundo, com uma biodiversidade superior a 40.000 espécies de plantas, cobre uma área de aproximadamente 7 milhões de km² na América do Sul (COUTINHO, 2016). No Brasil, a Amazônia Legal (AML) abrange em torno de 4 milhões km² de florestas originárias (ALMEIDA et al., 2010; INPE, 2021). Apesar de sua importância mundialmente reconhecida e todas as preocupações ambientais discutidas ao longo de décadas em torno de sua proteção, a floresta Amazônica brasileira sofre constantemente com o desmatamento ilegal. Estima-se que já foram desmatados aproximadamente 20% da extensão florestal originária do bioma Amazônico (CAMARA et al., 2023). Desse percentual, mais de 90% dos desmatamentos em áreas particulares ocorreram de forma ilegal nos últimos quinze anos (RAJÃO et al., 2020; VALDIONES et al., 2021).

Pressionado pela sociedade nacional e internacional para a resolução do problema, o governo brasileiro vem, desde a década de 1990, buscando estratégias e ações para conter esse processo destrutivo da floresta (SCHMITT, 2015). A principal iniciativa nesse sentido é o projeto Monitoramento da Floresta Amazônica Brasileira por Satélite (PRODES), que disponibiliza as taxas anuais de desmatamento por corte raso na AML (INPE, 2021). Todavia, as estimativas de desmatamento na Amazônia que são conduzidas pelo PRODES contabilizam apenas as florestas primárias, não incluindo as áreas de floresta ou vegetação secundária (CHAZDON et al., 2020; DEMARCHI et al., 2023) – considerando como conceito de vegetação secundária, a regeneração da vegetação nativa que se forma nas áreas desflorestadas abandonadas (ALMEIDA et al., 2010).

No entanto, sabe-se que o desmatamento de florestas secundárias contribui significativamente para a redução de emissão de CO₂ na atmosfera (CHAZDON et al., 2020). Com o aumento da vegetação secundária podem ser minimizados os efeitos do desmatamento na Amazônia, tais como a redução de fertilidade do solo, erosão, alterações nos regimes hidrológico local e global e emissão de gases de efeito estufa, (ALMEIDA et al., 2010). A proteção e expansão das áreas de floresta secundária, somadas à preservação dos remanescentes de floresta primária, são estratégias fundamentais para a mitigação das mudanças climáticas (HEINRICH et al., 2021). Porém, de forma geral, a floresta em regeneração natural ainda tem sido pouco mapeada para fins de planejamento e tomada de decisões e cumprimento da legislação brasileira e de metas internacionais acordadas (CHAZDON et al., 2020; SILVA JÚNIOR et al., 2020).

Uma dessas iniciativas do governo brasileiro é o projeto Mapeamento do Uso e Cobertura da Terra nas Áreas Desflorestadas da Amazônia Legal (TerraClass), que tem, como propósito, qualificar os polígonos de desmatamento por corte raso que são mapeados pelo PRODES depois de passados dois anos. As categorias de uso e cobertura de terras consideradas pelo TerraClass são, dentre outras: vegetação secundária, silvicultura, pastagem com regeneração lenhosa e regeneração com pastagem, que são fonte para diversos estudos estratégicos na Amazônia (ALMEIDA et al., 2016; INPE, 2019, 2021; SILVA JÚNIOR et al., 2020; HEINRICH et al., 2021; CAMARA et al., 2023; SILVA et al., 2023). Contudo, ainda não há um sistema de monitoramento contínuo da vegetação secundária no Brasil para uma compreensão espaço-temporal ampla dos fatores ambientais que afetam a magnitude e a sustentabilidade da regeneração da floresta secundária (PINTO et al., 2021; HEINRICH et al., 2021)

Os índices de vegetação podem ser ferramentas eficazes para apoiar na observação evolutiva da variação da cobertura vegetal em áreas de regeneração da floresta (CHAVES et al., 2013; GAO et al., 2020; ALENCAR et al., 2023). A Fração de Cobertura vegetal (FCV) é uma derivação de índices de vegetação, usualmente aplicada em metodologias baseadas em abordagens empíricas envolvendo índices espectrais como o Índice de Vegetação por Diferença Normalizada (NDVI) (JIMÉNEZ-MUÑOZ et al., 2009). Nessa técnica os valores de NDVI são diretamente relacionados com o nível de atividade fotossintética do dossel vegetal pela fórmula proposta por Qi et al. (2000), em que envolve o uso do pixel puro do solo exposto da vegetação. Segundo os autores ainda há questões relacionadas a interferência atmosférica e tipos de vegetação, que pode tornar o NDVI variável, no qual os fatores precisam ser bem quantificados.

As alterações na cobertura vegetal também podem ser analisadas em imagens fração de vegetação (IFV), obtidas a partir de Modelo Linear de Mistura Espectral (MLME). O MLME tenta estimar as proporções dos componentes dentro dos pixels, gerando imagens separadas e correspondentes aos componentes presentes em cada pixel e são denominadas de imagens-fração. As imagens-fração de solo, vegetação e sombra ou água são as mais utilizadas para o mapeamento e monitoramento dos diferentes tipos de uso e cobertura da terra, por estarem diretamente relacionadas à dinâmica dos alvos na superfície. Um caráter louvável da técnica é seu potencial de ser menos suscetível às variações de fatores como condições de iluminação da cena e variações atmosféricas (Shimabukuro, 1998; Sato et al., 2021).

Nesse contexto, o objetivo deste trabalho é comparar o desempenho dos modelos FCV e IFV no processo de regeneração da vegetação em áreas desflorestadas e embargadas no bioma Amazônia. Espera-se que as técnicas sejam sensíveis a variações no padrão de regeneração florestal para apoio no monitoramento da recuperação florestal em áreas que sofreram com o desflorestamento ilegal.

4.2 Material e métodos

4.2.1 Área de estudo

As nove áreas de estudo (A1 a A9) estão localizadas na porção do estado de Mato Grosso pertencente ao bioma Amazônia (**Figura 1**). A vegetação predominante é a Floresta Ombrófila Densa e o clima é caracterizado como quente e úmido, com estações sazonais de seca (maio a setembro) e chuva (outubro a abril) bem definidas (FISCH et al., 1992).

Este estudo priorizou o bioma Amazônia por ser o bioma em que se localiza a maior parte das áreas embargadas pelo Ibama e o estado do Mato Grosso por ser o estado onde há um maior número de áreas embargadas em processo de regeneração, monitoradas pelo Ibama. As áreas de estudo estão localizadas em regiões em que há intensa ocupação humana para produção de grãos e carne bovina e processos de regeneração da vegetação secundária (CHAZDON et al., 2020; ALENCAR et al., 2023) e correspondem as frações dos imóveis rurais embargados pela fiscalização do Ibama, por desmatamento ilegal de floresta ou demais formas de vegetação, com fulcro na Lei nº 9.605/1998 (Lei de Crimes Ambientais).

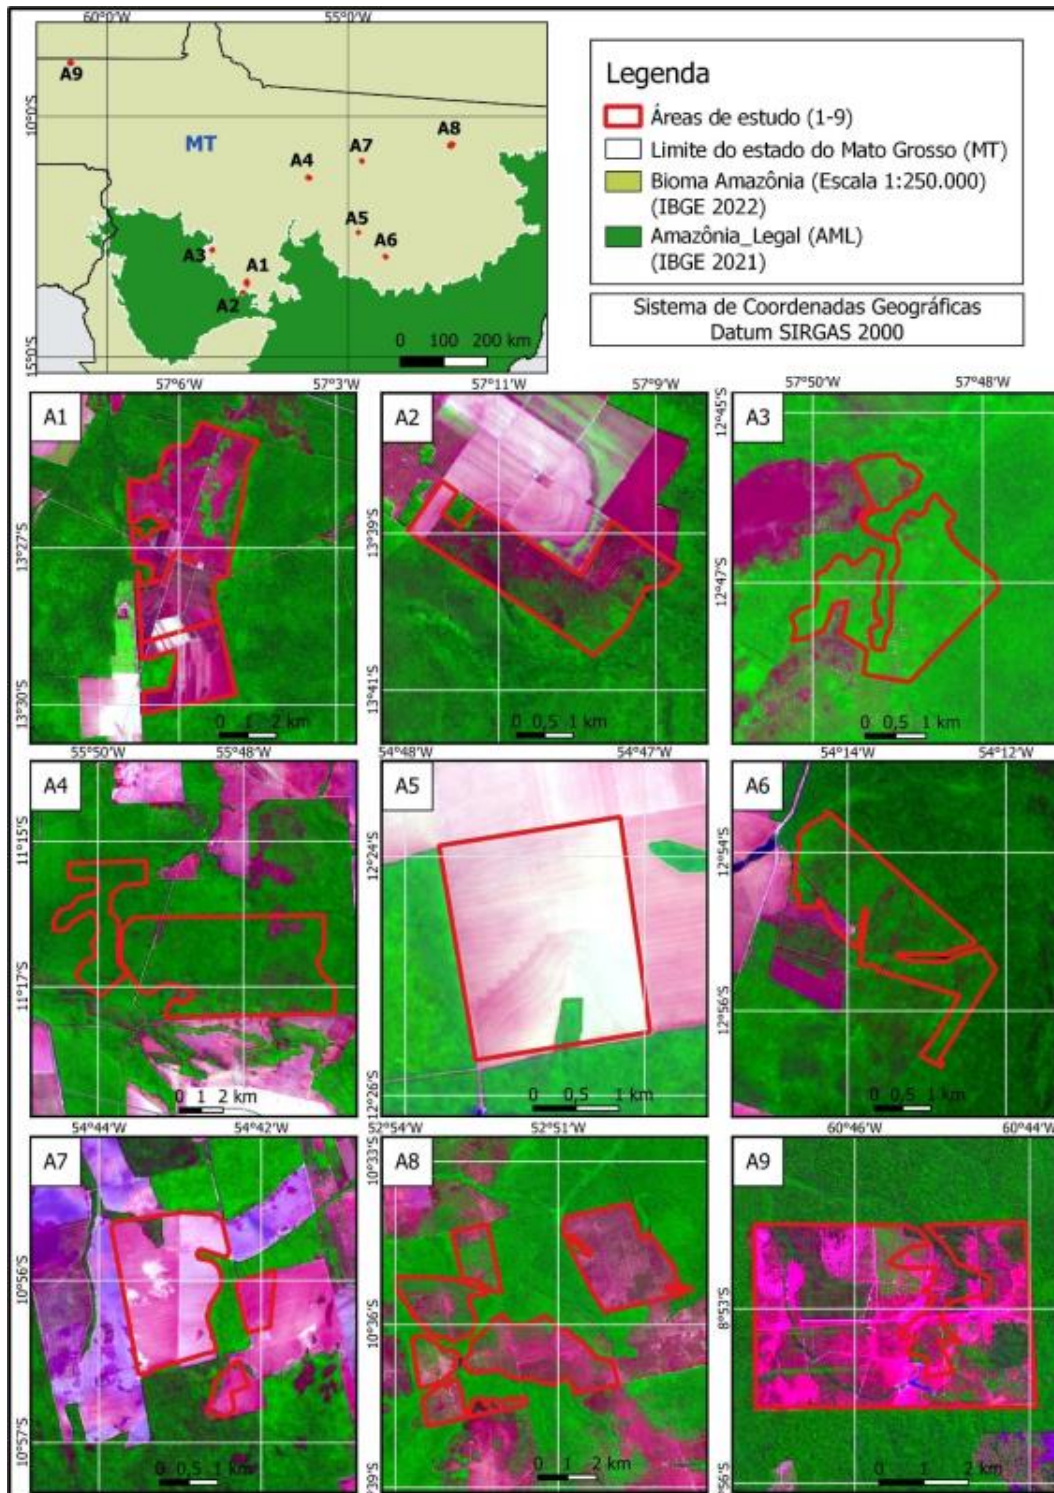


Figura 1. Localização das áreas de estudo (A1 a A9) no bioma Amazônia e no estado do Mato Grosso. As imagens correspondem a composições coloridas RGB das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI de 2022, fusionadas com a banda pancromática 8.

As áreas de estudo foram selecionadas dentre as áreas embargadas e monitoradas no âmbito do projeto Monitoramento da Recuperação de Áreas Degradadas (MonitoRAD), conduzido pelo Centro Nacional de Monitoramento e Informações

Ambientais (Cenima) do Ibama. Foram selecionadas áreas classificadas como “com indício de recuperação” no Relatório do projeto MonitoRAD de 2023.

As áreas embargadas somam aproximadamente 11.500 ha de áreas com desmatamento por corte raso ou extração seletiva em diferentes estágios de regeneração da vegetação. Duas delas encontram-se localizadas nos municípios de Nova Maringá, enquanto as outras estão localizadas nos municípios de Brasnorte, Itaúba, Feliz Natal, Paranatinga, Marcelândia, São José do Xingu e Colniza (**Tabela 1**).

Tabela 1. Tamanho da área e localização municipal das áreas de estudo selecionadas para esta pesquisa.

Área de estudo	Área (ha)	Município
A1	2.760	Nova Maringá
A2	527	Nova Maringá
A3	522	Brasnorte
A4	1.205	Itaúba
A5	516	Feliz Natal
A6	535	Paranatinga
A7	475	Marcelândia
A8	2.764	São José do Xingu
A9	2.202	Colniza

4.2.2 Material

Os materiais deste estudo foram compostos pela base de dados de áreas embargadas do Ibama e por imagens do satélite Landsat 8 OLI (L8), Coleção 2 (C2), *Level 2* (L2), convertidas para reflectância de superfície e com no máximo 5% de cobertura de nuvens. A maioria das imagens analisadas nesta pesquisa apresentaram 0% de cobertura e nuvens. As informações textuais e os dados geoespaciais das áreas embargadas do Ibama utilizadas nessa pesquisa foram obtidas em 28 de julho de 2022 no endereço eletrônico <http://siscom.ibama.gov.br/geoserver/web>.

As imagens do satélite L8 foram obtidas no site *Earth Explorer* do U.S. *Geological Survey* (USGS). Foram selecionadas uma imagem por ano da estação seca

(agosto ou setembro) no período de 2018 a 2022. Foram adquiridas um total de 35 cenas, conforme detalhado na Tabela 1 das Informações suplementares. Neste estudo, foram consideradas as imagens multiespectrais nas bandas do verde, vermelho e infravermelho próximo, além da banda pancromática, processada no *Level 1* (L1).

4.2.3 Abordagem metodológica

As principais etapas desta pesquisa são mostradas no fluxograma da **Figura 2**. Todos os processamentos dos dados foram realizados com o auxílio dos aplicativos gratuitos QGIS v. 3.28.1 e TerraView do Instituto Nacional de Pesquisas Espaciais (Inpe). As imagens Landsat foram projetadas no sistema de projeção Universal Transversa de Mercator (UTM), zonas 20S, 21S ou 22S, dependendo da localização da área de estudo, e *datum* SIRGAS2000.

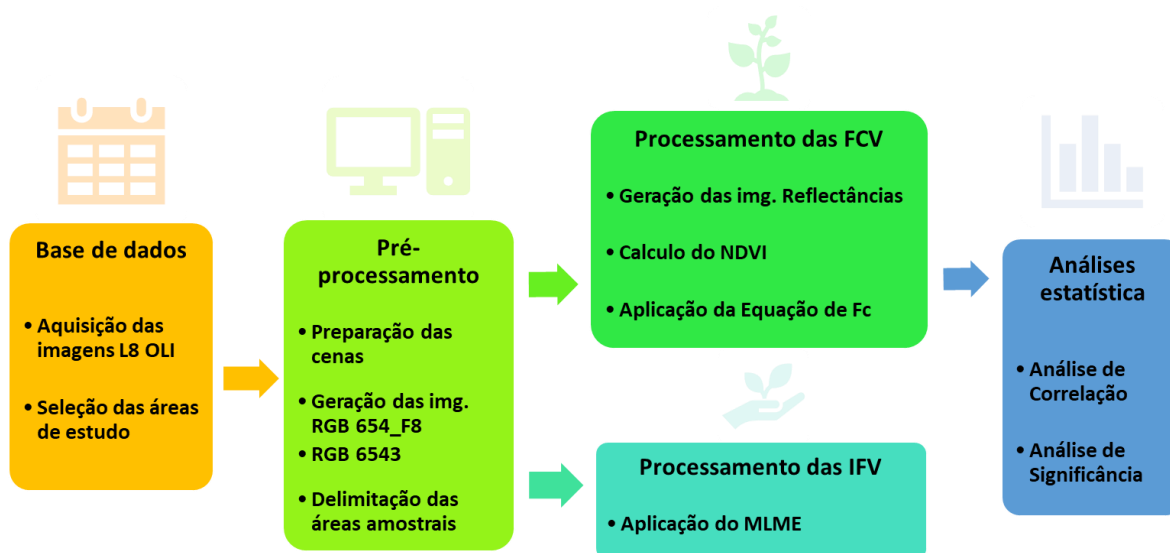


Figura 2. Fluxograma das etapas de coleta de dados, pré-processamento, processamento e análise dos dados gerados.

Foram delimitados 41 polígonos retangulares (3 a 54 ha) dentro das áreas de estudo em que, por meio de inspeção visual, foram observadas presença de solo exposto nas imagens de 2018 e de vegetação secundária nas cenas de 2022, conforme exemplificado na **Figura 3**. Foram selecionadas de 1 a 15 áreas amostrais dentro de cada uma das nove áreas de estudo, totalizando uma área de 593 ha (**Tabela 2**).

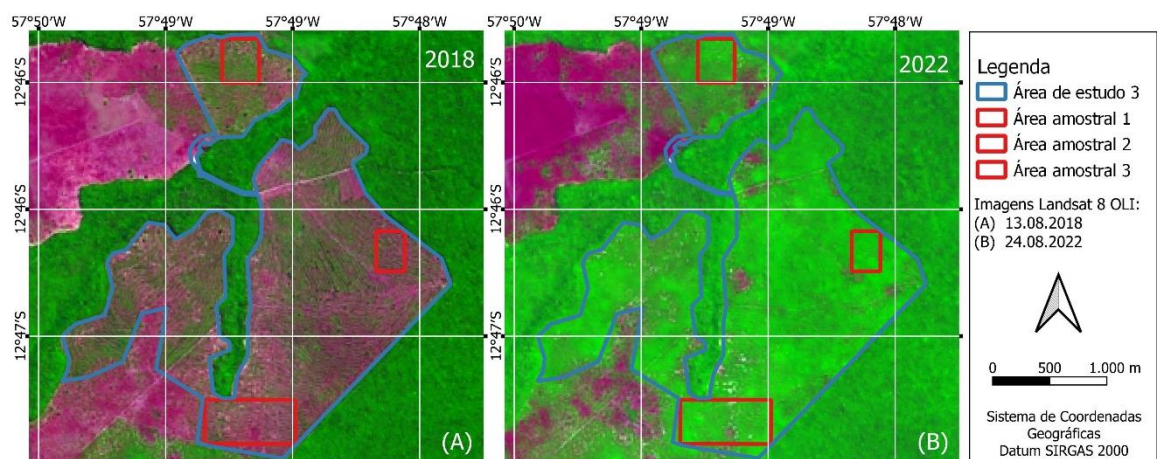


Figura 3. Exemplo do processo de coleta de amostras por área de estudo de regeneração florestal entre 2018 e 2022. Composições coloridas RGB das bandas 4, 5 e 6 do satélite Landsat 8 de 2018 (A) e 2022 (B) da área de estudo 3.

Tabela 2. Descrição das áreas amostrais das áreas de estudo.

Área de estudo	Área amostral	Área (ha)	Área de estudo	Área amostral	Área (ha)	
A1	1	3,00	A3	24	12,04	
	2	18,98		25	29,79	
	3	50,39		26	8,54	
	4	19,14		27	7,94	
	5	3,73	A4	28	21,95	
	6	3,22		29	28,61	
	A2	7	5,56	A5	30	6,71
		8	9,96	A6	31	38,18
9		3,73	32		31,67	
10		4,48	33		28,00	
11		3,48	A7	34	5,78	
12		3,63		35	3,17	
13		3,79	A8	36	53,58	
14		5,54		37	39,50	
15		3,99		38	27,24	
16		4,94	A9	39	3,23	
17		3,06		40	30,06	
18		4,43		41	34,84	
A2		19	6,63			
		20	3,39			
		21	4,07			
	22	10,15				
	23	3,09				
Total					593 ha	

As imagens adquiridas nas bandas 4 e 5 foram utilizadas para produzir as séries temporais de NDVI do período de 2018 a 2022. O NDVI, proposto por ROUSE et al. (1974), é obtido por meio da seguinte fórmula (**Equação 1**):

$$NDVI = \frac{NIR-R}{NIR+R} \quad (1)$$

em que NIR = banda do infravermelho próximo; e R = banda do vermelho.

Os valores do NDVI variam no intervalo de [-1, +1], estão diretamente relacionados com o nível de atividade fotossintética do dossel vegetal e foram utilizados para calcular a FCV de cada área amostral por meio da seguinte fórmula (**Equação 2**) proposta por Qi et al. (2000):

$$FCV = \frac{NDVI - NDVI_{SOIL}}{NDVI_{VEG} - NDVI_{SOIL}} \quad (2)$$

em que $NDVI_{SOIL}$ = valor do pixel puro de solo exposto; e $NDVI_{VEG}$ = valor do pixel puro de vegetação.

Os pixels puros de solo exposto e de vegetação foram definidos, respectivamente, a partir dos menores e maiores valores de reflectância convertidas para NDVI dos pixels de cada área de estudo.

Em seguida, foram obtidas as imagens-fração verde (IFV), derivadas do MLME e que visa calcular as frações de cada alvo presente em um pixel (**Equação 3**) (SHIMABUKURO & PONZONI, 2017):

$$R_i = \sum_{j=1}^m x_j a_{i,j} + e_i \quad (3)$$

em que:

R_i = reflectância espectral do pixel para a i-ésima banda espectral;

x_j = valor de proporção do j-ésimo componente no pixel;

$a_{i,j}$ = reflectância espectral do j-ésimo componente no pixel (*endmembers*) para a i-ésima banda espectral;

e_i = erro para a i-ésima banda espectral;

$i = 1, 2, \dots, n$ ($n =$ número de bandas espectrais dos sensores); e
 $j = 1, 2, \dots, m$ ($m =$ número de componentes considerados no pixel).

O MLME consiste em gerar, separadamente, as imagens de cada um dos componentes que são encontradas na cena e são denominadas de imagens-fração. Elas são geradas a partir da seleção dos componentes puros (*endmembers*) que geralmente correspondem a vegetação verde, solo exposto e água ou sombra de nuvem ou relevo (SHIMABUKURO & PONZONI, 2017). Neste estudo, foram utilizadas as bandas do verde (B3), vermelho (B4), infravermelho próximo (B5) e infravermelho médio (B6) do satélite L8 para gerar as imagens-fração de vegetação verde, solo exposto e água/sombra.

As amostras de água/sombra foram obtidas em reservatórios e leitos de rios perenes localizados próximos as áreas de estudo devido à ausência de cobertura de nuvens e inexistência de massas d'água nas áreas de estudo. Da mesma forma, nas situações em que não foi identificado um polígono inalterado de componente puro de solo exposto ou vegetação dentro da área, no período da pesquisa, a amostragem foi realizada em áreas mais próximas possível da área de estudo em questão.

Nesse processo de amostragem, foram coletados um *endmember* de vegetação verde, solo exposto e água/sombra para cada área de estudo a partir da cena de 2018 e foram observados os histogramas das respostas espectrais dos *endmembers* com o intuito de garantir a existência de uma relação decrescente de valores de reflectância nas seguintes ordens: solo = $B6 > B5 > B4$; vegetação = $B5 > B6 > B4$; e água/sombra = $B4 > B5 > B6$, conforme exemplificado na **Figura 4**.

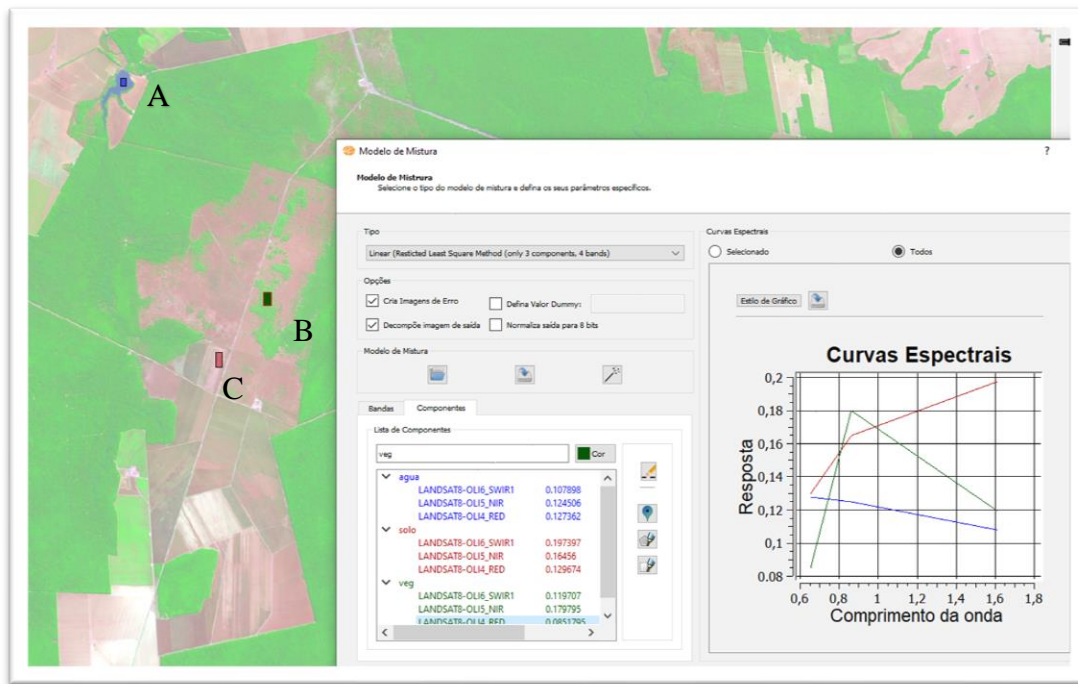


Figura 4. Exemplo do processo de seleção e das repostas espectrais dos *endmembers*: (A) água (em azul); (B) vegetação (em verde); e (C) solo exposto (em vermelho), selecionados na cena de 2018, da área de estudo A1.

O método utilizado para gerar as imagens-fração foi o de mínimos quadrados com restrição, o qual estima a proporção de cada componente dentro do pixel, minimizando a soma dos erros ao quadrado (SHIMABUKURO et al., 2020). Todas as imagens-fração foram geradas no programa TerraView.

A comparação dos dados de IFV e FCV do período de 2018 a 2022 foi feita por meio do coeficiente de correlação linear de Pearson (r), que é uma medida de associação linear entre variáveis em que os valores são adimensionais e variam entre -1 (correlação inversa perfeita) a +1 (correlação direta perfeita). Valor zero indica ausência de correlação (LANDIM, 2003). O teste de igualdade das médias dos dois modelos considerados (FCV e IFV) foi realizado por meio do teste t de Student, para um nível de significância de 5%.

4.3 Resultados e discussão

4.3.1 Coeficiente de correlação de Pearson

Na **Figura 5**, é mostrada a correlação das porcentagens médias de FCV e IFV das áreas de estudo no período de 2018 a 2022. Regra geral, obteve-se uma alta correlação linear entre os dois modelos em todas as áreas de estudo ($r = 0,97$). Os coeficientes de

correlação de Pearson das áreas variaram entre 0,81 e 0,98. Considerando que o coeficiente de correlação é positivo, conclui-se que os valores de ambos os modelos aumentaram com o passar dos anos em todas as áreas de estudo.

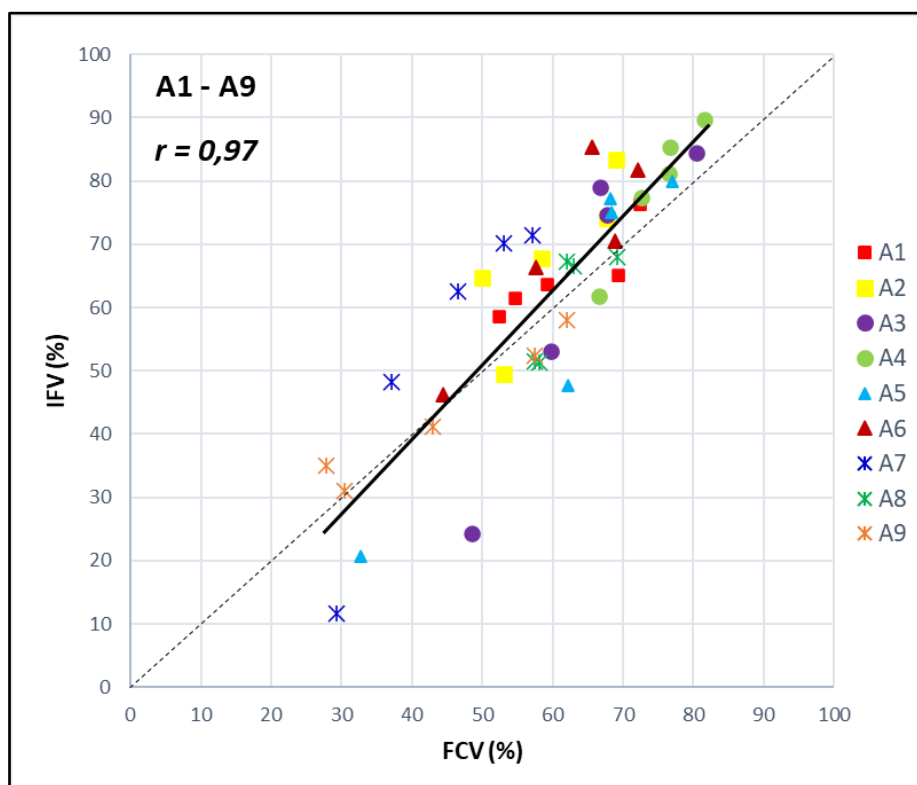


Figura 5. Relação entre as médias das porcentagens de fração de cobertura vegetal (FCV) e imagem-fração de vegetação (IFV) nas nove áreas de estudo para os anos de 2018, 2019, 2020, 2021 e 2022. Os valores de 'r' correspondem aos coeficientes de correlação de Pearson. A reta tracejada corresponde à reta 1:1, enquanto a reta sólida corresponde à linha de tendência.

4.3.2 Teste t de Student

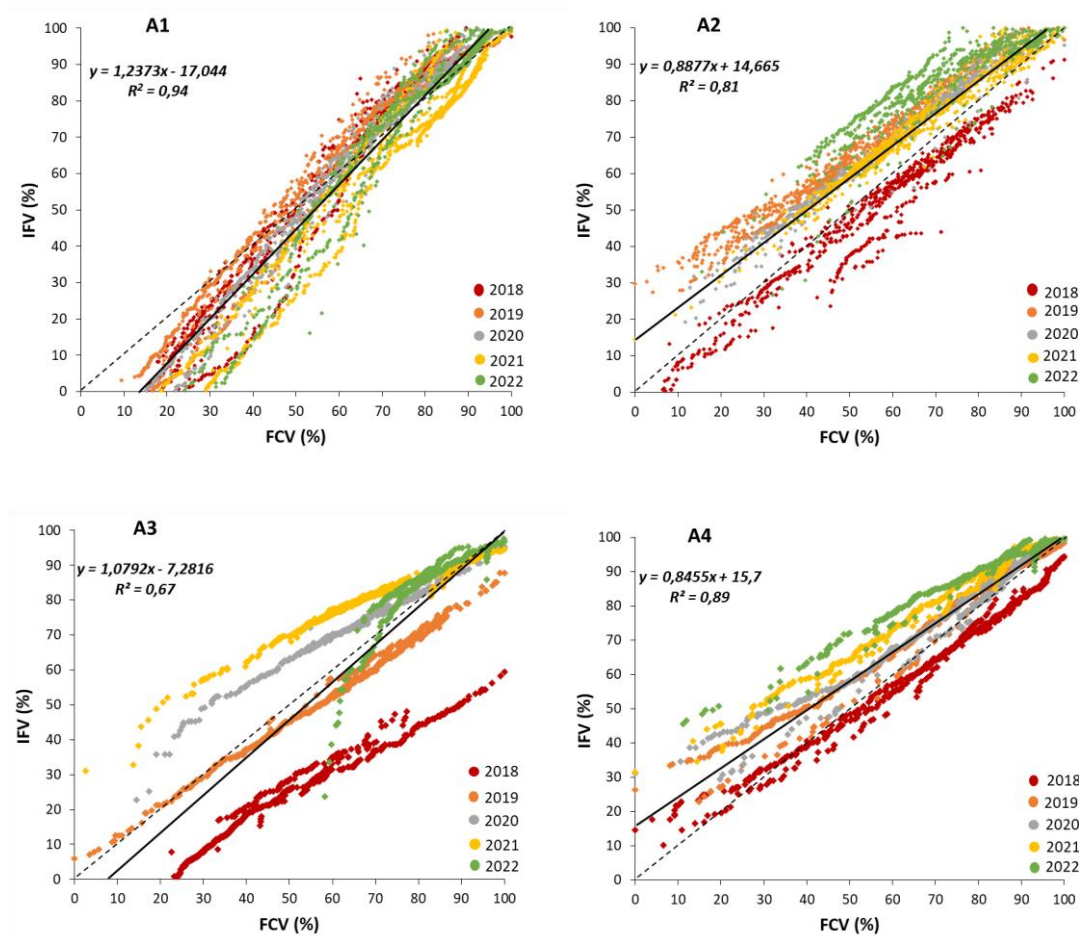
Os resultados do teste t de Student (**Tabela 3**) aplicado entre as médias anuais das porcentagens de fração de cobertura vegetal (FCV) e imagem-fração de vegetação (IFV) para as nove áreas de estudo indicaram que não há diferença estatisticamente significativa entre os modelos aplicados. Sendo o t_{calc} menor que o $t_{crítico}$ (tabelado), tem-se que o t_{calc} não é significativo a nível de significância de 5%. Assim sendo, aceitou-se a hipótese H_0 de que os modelos aplicados são iguais.

Tabela 3. Resultados do teste t de Student aplicado em cada uma das nove áreas de estudo para comparar as médias de FCV e IFV no período de 2018 a 2022. $T_{\text{calc}} = t_{\text{calculado}}$; $t_{\text{crit}} = t_{\text{crítico}}$ para nível de significância de 5% e 4 graus de liberdade.

Teste t de Student	Área de estudo								
	1	2	3	4	5	6	7	8	9
t_{calc}	0,26	0,13	0,45	0,23	0,46	0,18	0,27	0,41	0,47
$t_{\text{crit}} (0,05;4)$	2,78								

4.3.3 Diagrama de dispersão (*Scatter plot*)

Na **Figura 6**, são mostradas as relações entre FCV e IFV para as nove áreas de estudo e para o período de 2018 a 2022, considerando-se todos os pixels de 30 m das áreas amostrais. A relação linear entre os dois modelos, FCV e IFV, foi relativamente alta, com valor médio de coeficiente de determinação (R^2) de 0,77 e valores mínimo e máximo de 0,31 e 0,94, respectivamente. Todas as nove áreas de estudo apresentaram uma tendência de crescimento nos valores de FCV e IFV de 2018 para 2022.



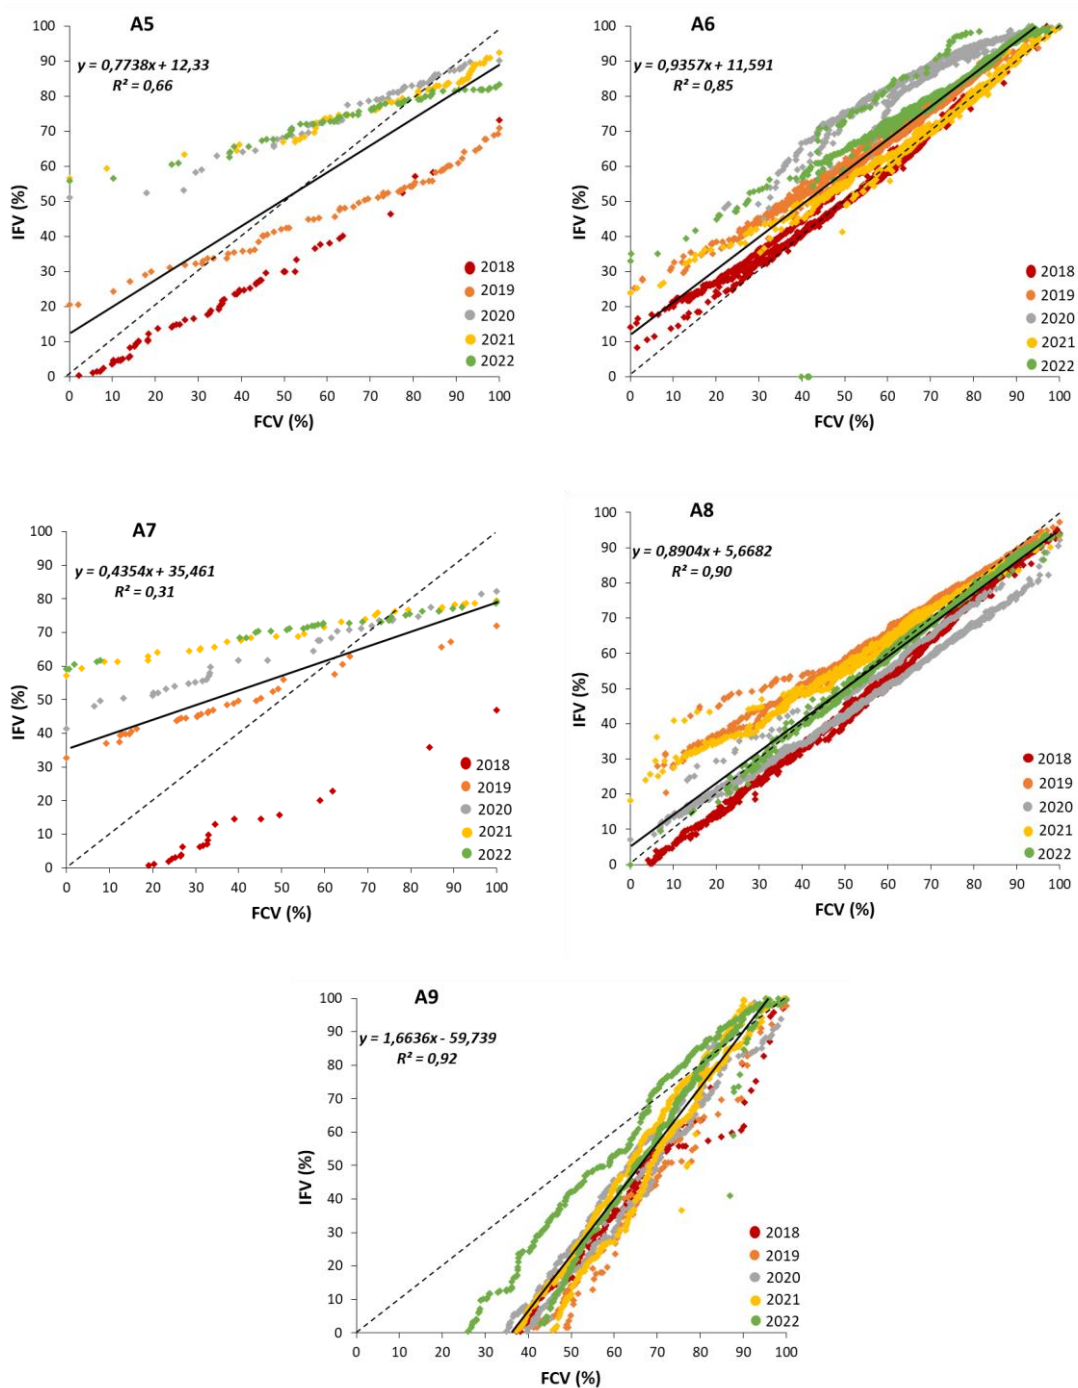


Figura 6. Relação entre porcentagem de fração de cobertura vegetal (FCV) e imagem-fração de vegetação (IFV) para cada uma das nove áreas de estudo no período de 2018 a 2022. A reta tracejada corresponde à reta 1:1 e a reta sólida à linha de tendência.

Regra geral, valores altos de R^2 desta figura indicam que a regeneração da cobertura vegetal inicialmente desmatada não foi acentuada no período 2018-2022, denotando que a velocidade de regeneração da vegetação secundária foi baixa. Outra possibilidade é a de que o estágio de regeneração no início do período (2018) já estivesse

alto. Por outro lado, valores baixos de R^2 indicam que a velocidade de regeneração no mesmo período foi alta, conforme mostrado na Área 7 ($R^2 = 0,31$), que apresentou variações de valores mais baixos de IFV e FCV de 0% em 2018 e aproximadamente 80% e 100% respectivamente em 2022.

Em determinados anos, os valores médios de FCV e/ou IFV foram inferiores aos do ano anterior, conforme resumido na **Tabela 2** das Informações suplementares. Nas situações em que ambos os modelos apresentaram valores inferiores ao ano anterior, supõe-se que o processo de regeneração da vegetação na área sofreu alguma alteração, impedindo o adensamento da vegetação. Nestes casos, provavelmente houve alguma intervenção humana, tais como um incêndio florestal no ano anterior após a data de passagem da imagem analisada, ou alguma alteração climática, como uma seca mais drástica no período de análise.

Nas **Figuras 1 a 9**, em Informações suplementares, observa-se o processo de regeneração da vegetação nas áreas amostrais de cada uma das áreas de estudo, no período de 2018 a 2022, em que se têm maior presença de solo exposto (em tons de rosa) no ano de 2018 e aumento de tons verdes (indicando presença de vegetação secundária) nos anos subsequentes (2019 a 2022).

Observa-se na **Figura 6** que, com exceção da área A1, todas as áreas apresentaram valores percentuais mais altos de FCV em 2018 e, em maioria, valores mais altos de IFV nos anos de 2019 a 2022. Isso pode ser devido à ausência de classificação de pixels de solo exposto pelo MLME no período inicial de análise, tendo em vista que neste estudo foi considerado apenas a IFV, ou seja, o modelo só classificou os pixels em que identificou alguma porcentagem de vegetação. Assim os pixels de solo exposto, mais frequentes no ano de 2018, não foram classificados nas imagens de IFV (Ressalta-se que os menores valores de FCV equivalentes ao número de pixels do IFV não classificados não são representados no diagrama e nos cálculos). A hipótese é que o MLME tenha uma resposta melhor em solo exposto se forem utilizadas na análise as imagens fração solo e sombra/água.

Nas áreas A3, A5 e A7, mesmo tendo apresentado o padrão de valores mais alto de FCV em 2018, diferente das demais áreas, apresentaram um acréscimo bem acentuado de percentuais de IFV comparando os valores de um ano para outro. Nessas áreas ocorreram os maiores incrementos de vegetação, partindo de solo exposto em 2018 para vegetação secundária em 2022. Vale destacar que os perímetros da A5 e da A7 são

referentes a áreas de preservação permanente (APP) de cursos d'água, conforme pode-se observar respectivamente nas **Figuras 5 e 7** das Informações suplementares.

O diferencial do modelo FCV é que permite escalar o NDVI entre solo descoberto e 100% de cobertura vegetal, classificando o NDVI entre uma cobertura vegetal total e parcial (CARLSON et al., 1997). O NDVI convertido em FCV é menos sensível ao efeito atmosférico em comparação com o próprio NDVI ou outros índices espectrais.

Contudo, a redução da sensibilidade sob alta biomassa e a contribuição do fundo do solo e da atmosfera limitam a aplicabilidade desses índices espectrais em determinadas áreas. (ADAMI et al., 2018). Outro ponto a considerar é a premissa de definir um único valor de NDVI de solo para toda a imagem pode não ser válida, a menos que a área de interesse consista em tipos de solos uniformes e constantes ao longo do tempo, com valores próximos de zero. Situação que não ocorre normalmente, considerando o efeito atmosférico e às mudanças nas condições de umidade da superfície, os valores de NDVI de solo variam substancialmente com o tempo e de local para local devido às diferenças nos tipos e cores do solo (QI et al., 2020). Essa variação do tipo de solo de um local para outro, pode justificar as falhas de classificação de alguns pixels de solo exposto apresentadas nas IFV.

Apesar da IFV fornecer informações semelhantes às dos índices de vegetação (SHIMABUKURO et al., 2020), Shimabukuro et al. (1998), ao comparar os dois métodos de determinação de fração de vegetação apresentados neste estudo, concluiu que, apesar de existir alta correlação entre IFV e FCV, a primeira é mais indicada para avaliar a cobertura vegetal por ser mais susceptível às variações de cobertura vegetal do solo. Chaves et al. (2013), a partir da estimativa de FCV, conclui que a saturação do NDVI em uma determinada fase de incremento da vegetação teve influência nos resultados apresentados na pesquisa. Em pesquisa mais recente, Sato et al. (2021) corroboraram os resultados obtidos por Shimabukuro et al. (1998), afirmando que a IFV é menos submetida às variações de fatores como condições de iluminação da cena e variações atmosféricas.

4.4 Conclusões

Nesse contexto, o objetivo deste trabalho é comparar o desempenho dos modelos FCV e IFV para o monitoramento da regeneração da vegetação em áreas desflorestadas e embargadas no bioma Amazônia.

Na comparação estatística do desempenho dos dois modelos, obteve-se uma forte correlação linear em todas as áreas de estudo. As diferenças encontradas entre as variáveis não foram estatisticamente diferentes a um nível de significância de 5%. O modelo FCV mostrou-se mais sensível para o registro da regeneração da vegetação no início do processo de recuperação, ou seja, para identificar mudanças na transição de solo exposto para a vegetação, com a ressalva da hipótese de que não haja essa diferença se for analisado conjuntamente com a IFV as imagens fração solo e sombra/água. Após um período de cinco anos, ambos os modelos apresentaram percentuais similares de acréscimo da resposta de fração de vegetação. Comparando-se os resultados de 2022, os dois modelos apresentaram uma correlação bastante alta. De forma geral, IFV registrou valores maiores que FCV em todos os anos avaliados.

Pelos resultados desta pesquisa, tem-se que o modelo FCV foi mais assertivo que o IFV para o monitoramento do processo inicial da regeneração da vegetação nativa, enquanto o modelo IFV mostrou-se melhor para a diferenciação de acréscimo de biomassa, sendo mais adequado para o monitoramento da vegetação secundária nos anos subsequentes.

Com relação à aplicação da equação de FCV proposta por Qi et al. (2000) em condições amazônicas, conclui-se que o modelo possui boa aplicabilidade, podendo ser utilizado para monitorar regeneração de vegetação nativa em áreas localizadas na Amazônia Brasileira.

Em resumo, ambos os modelos são eficientes no monitoramento da recuperação de áreas degradadas no bioma Amazônia, porém, há necessidade de expandir este estudo para outras regiões e com uma série temporal mais longa para poder corroborar os resultados obtidos nesta pesquisa. Outra abordagem que pode ser sugerida é o aprimoramento da aplicação metodológica do MLME e a proposta de uma adaptação da equação proposta por Qi et al. (2000) para as condições amazônicas.

4.5 Informações suplementares

Tabela 1. Órbita/ponto e datas de passagem das imagens Landsat 8 OLI selecionadas para cada área estudo.

Órbita ponto	Datas das imagens	Área de estudo
227/69	22.08.2018	A1 e A2
227/69	09.08.2019	
227/69	11.08.2020	
227/69	14.08.2021	
227/69	01.08.2022	
228/69	13.08.2018	A3
228/69	16.08.2019	
228/69	18.08.2020	
228/69	21.08.2021	
228/69	24.08.2022	
227/68	22.08.2018	A4
227/68	09.08.2019	
227/68	11.08.2020	
227/68	14.08.2021	
227/68	17.08.2022	
226/69	31.08.2018	A5 e A6
226/69	18.08.2019	
226/69	04.08.2020	
226/69	23.08.2021	
226/69	11.09.2022	
226/68	31.08.2018	A7
226/68	18.08.2019	
226/68	04.08.2020	
226/68	23.08.2021	
226/68	18.08.2022	
225/67	24.08.2018	A8
225/67	11.08.2019	
225/67	29.08.2020	
225/67	16.08.2021	
225/67	19.08.2022	
230/66	27.08.2018	A9
230/66	30.08.2019	
230/66	01.09.2020	
230/66	03.08.2021	
230/66	22.08.2022	

Tabela 2. Descrição dos anos em que ocorreram decréscimo nas porcentagens de fração de cobertura vegetal (FCV) e imagem-fração de vegetação (IFV) em relação ao ano anterior.

Área de estudo	Modelo	Ano de decréscimo
A2	FCV	2019 < 2018
A3	FCV	2021 < 2020
A5	FCV e IFV	2022 < 2021
A6	IFV	2021 < 2020
A8	FCV e IFV	2020 < 2019
A9	FCV	2019 < 2018

Figura 1. Ilustração da evolução do processo de regeneração da vegetação nas áreas amostrais da área de estudo A1. As imagens correspondem a composições coloridas RGB das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI, fusionadas com a banda pancromática 8, de (A) 2018, (B) 2019, (C) 2020, (D) 2021 e (E) 2022.

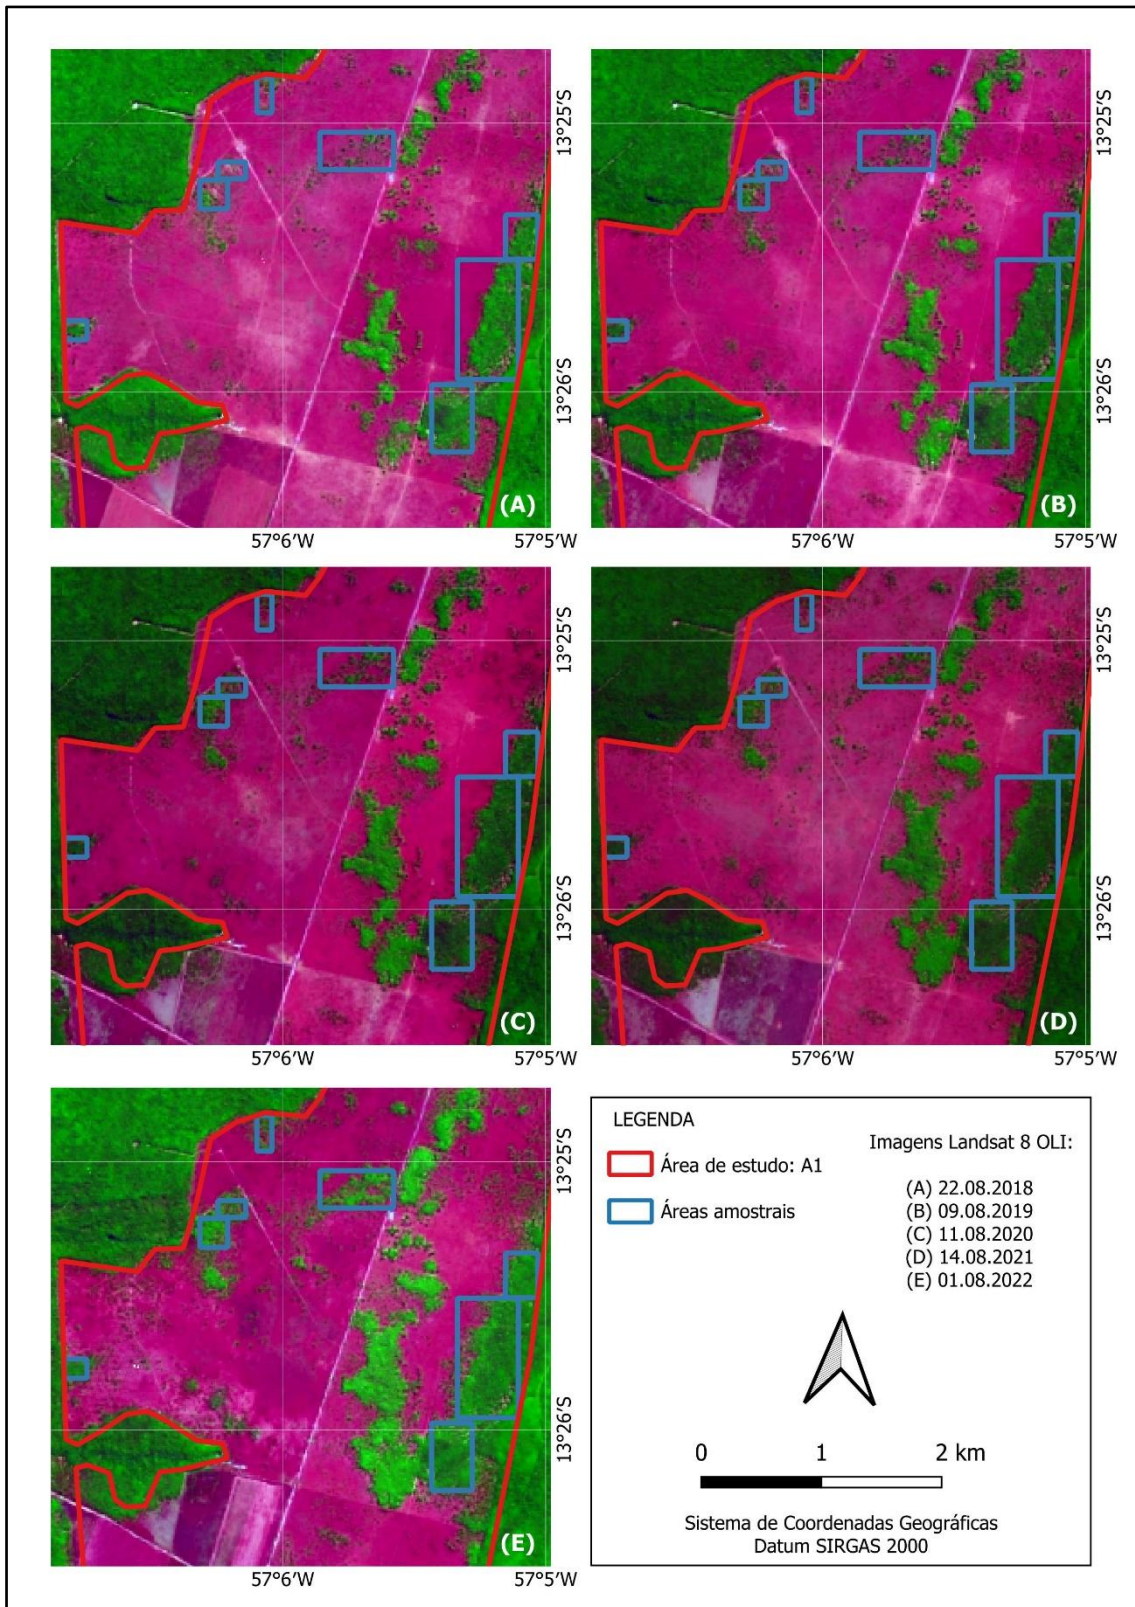


Figura 2. Ilustração da evolução do processo de regeneração da vegetação nas áreas amostrais da área de estudo A2. As imagens correspondem a composições coloridas RGB das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI, fusionadas com a banda pancromática 8, de (A) 2018, (B) 2019, (C) 2020, (D) 2021 e (E) 2022.

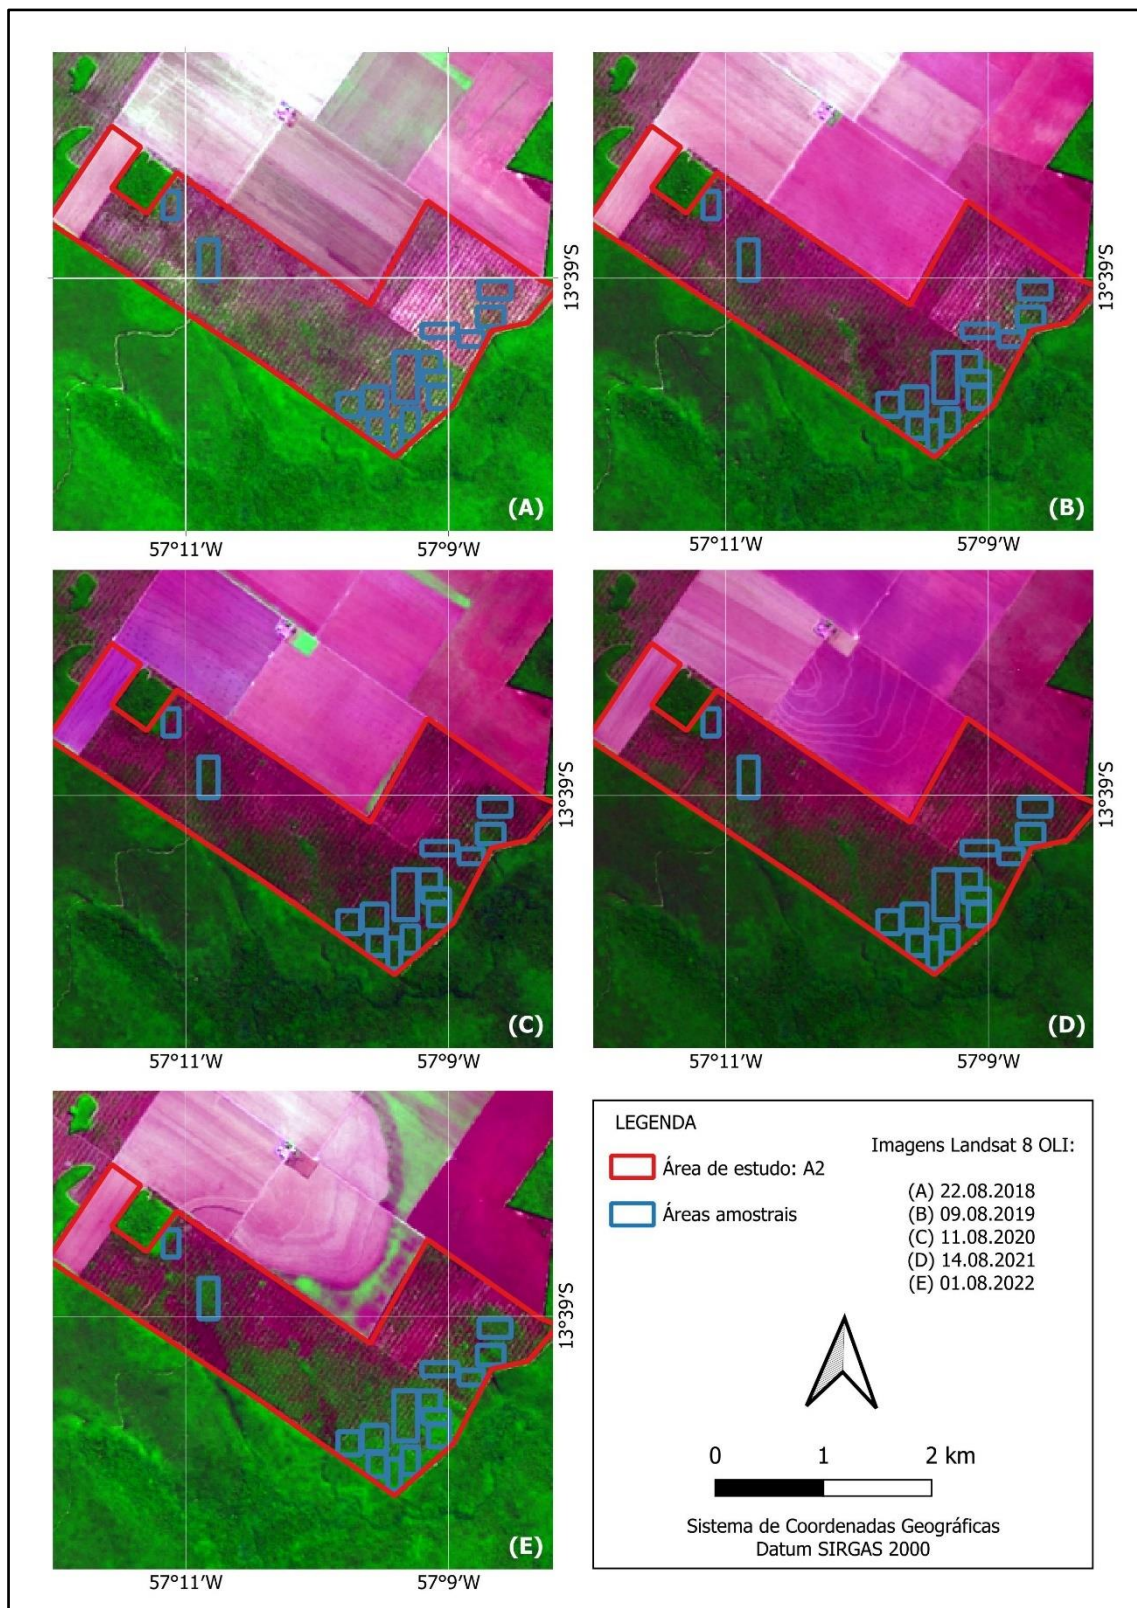


Figura 3. Ilustração da evolução do processo de regeneração da vegetação nas áreas amostrais da área de estudo A3. As imagens correspondem a composições coloridas RGB das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI, fusionadas com a banda pancromática 8, de (A) 2018, (B) 2019, (C) 2020, (D) 2021 e (E) 2022.

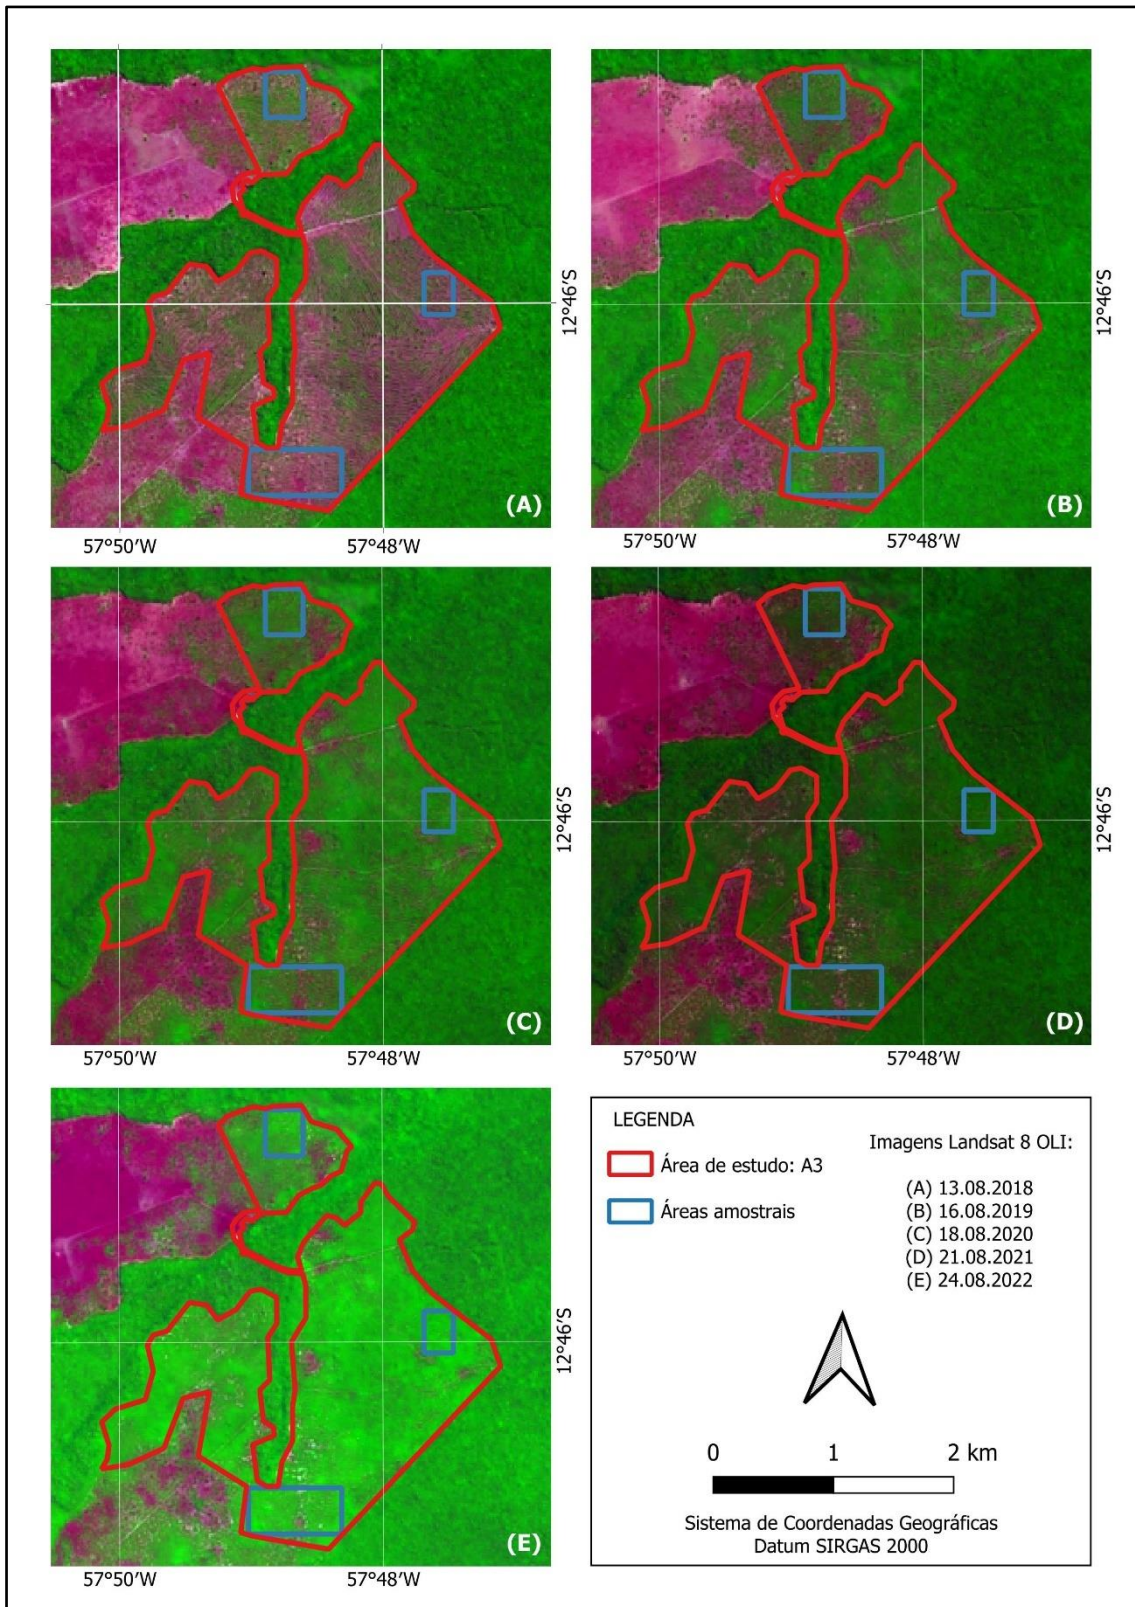


Figura 4. Ilustração da evolução do processo de regeneração da vegetação nas áreas amostrais da área de estudo A4. As imagens correspondem a composições coloridas RGB das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI, fusionadas com a banda pancromática 8, de (A) 2018, (B) 2019, (C) 2020, (D) 2021 e (E) 2022.

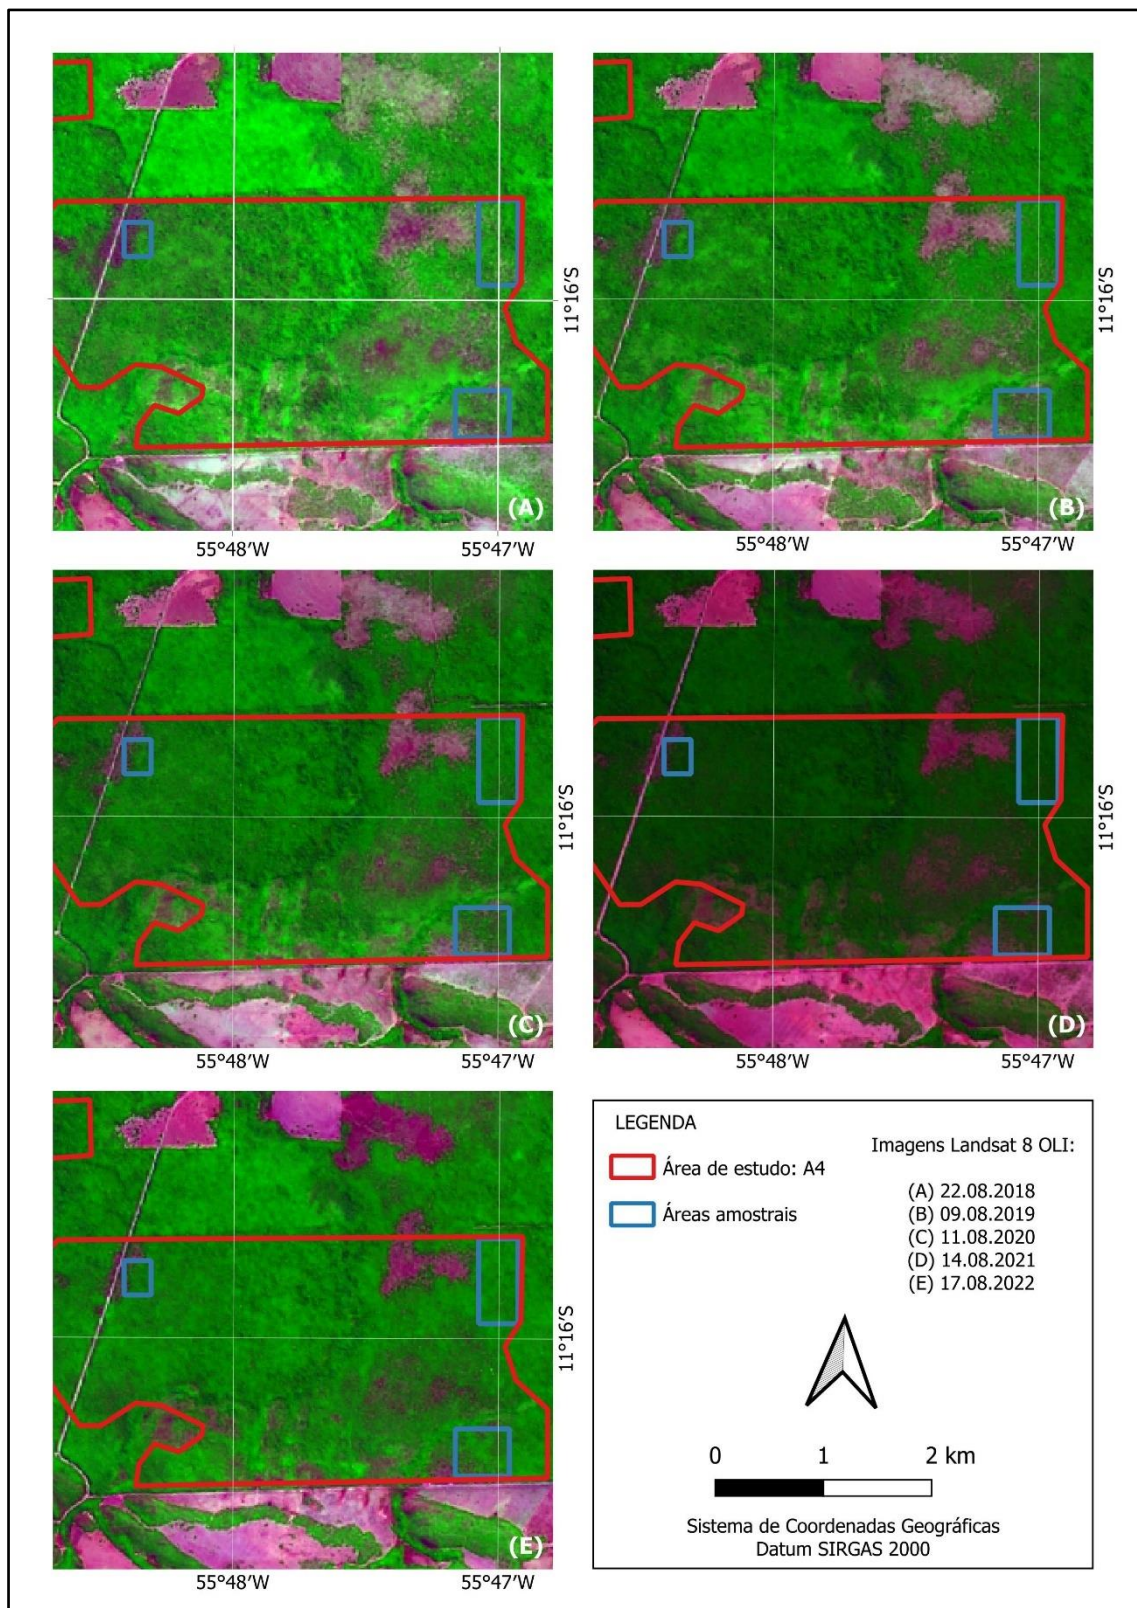


Figura 5. Ilustração da evolução do processo de regeneração da vegetação nas áreas amostrais da área de estudo A5. As imagens correspondem a composições coloridas RGB das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI, fusionadas com a banda pancromática 8, de (A) 2018, (B) 2019, (C) 2020, (D) 2021 e (E) 2022.




Figura 6. Ilustração da evolução do processo de regeneração da vegetação nas áreas amostrais da área de estudo A6. As imagens correspondem a composições coloridas RGB das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI, fusionadas com a banda pancromática 8, de (A) 2018, (B) 2019, (C) 2020, (D) 2021 e (E) 2022.

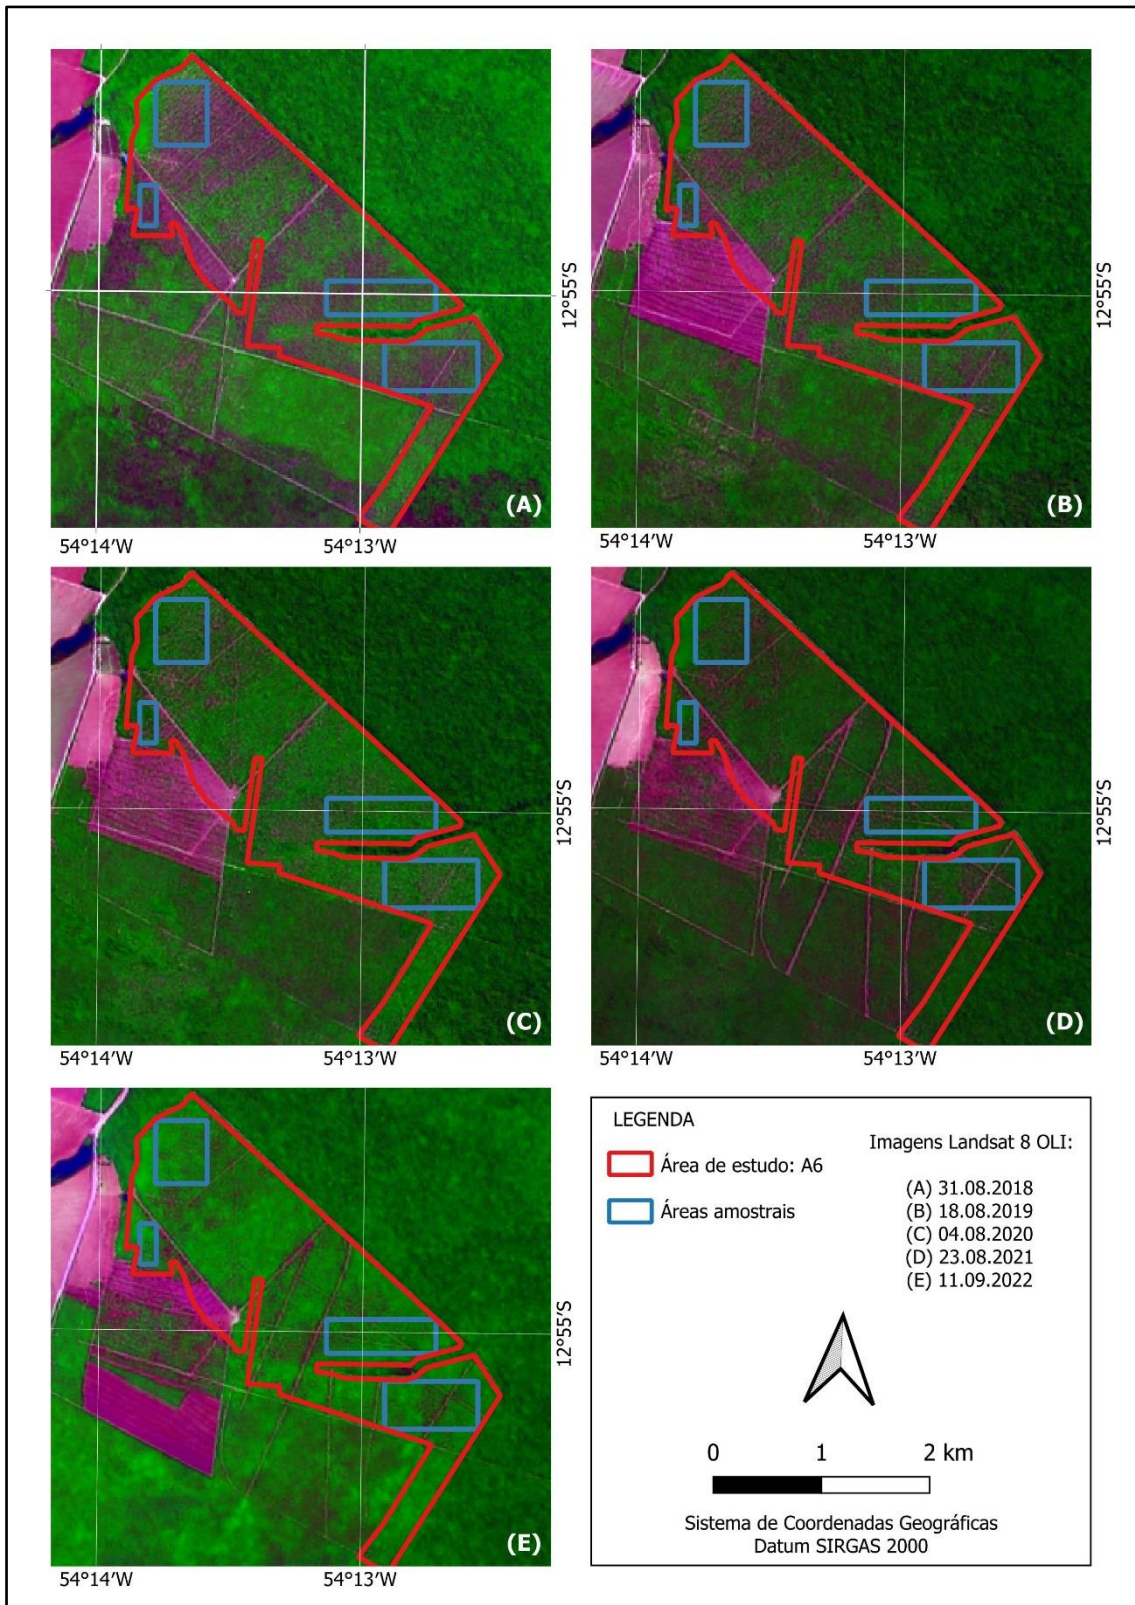


Figura 7. Ilustração da evolução do processo de regeneração da vegetação nas áreas amostrais da área de estudo A7. As imagens correspondem a composições coloridas RGB das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI, fusionadas com a banda pancromática 8, de (A) 2018, (B) 2019, (C) 2020, (D) 2021 e (E) 2022.

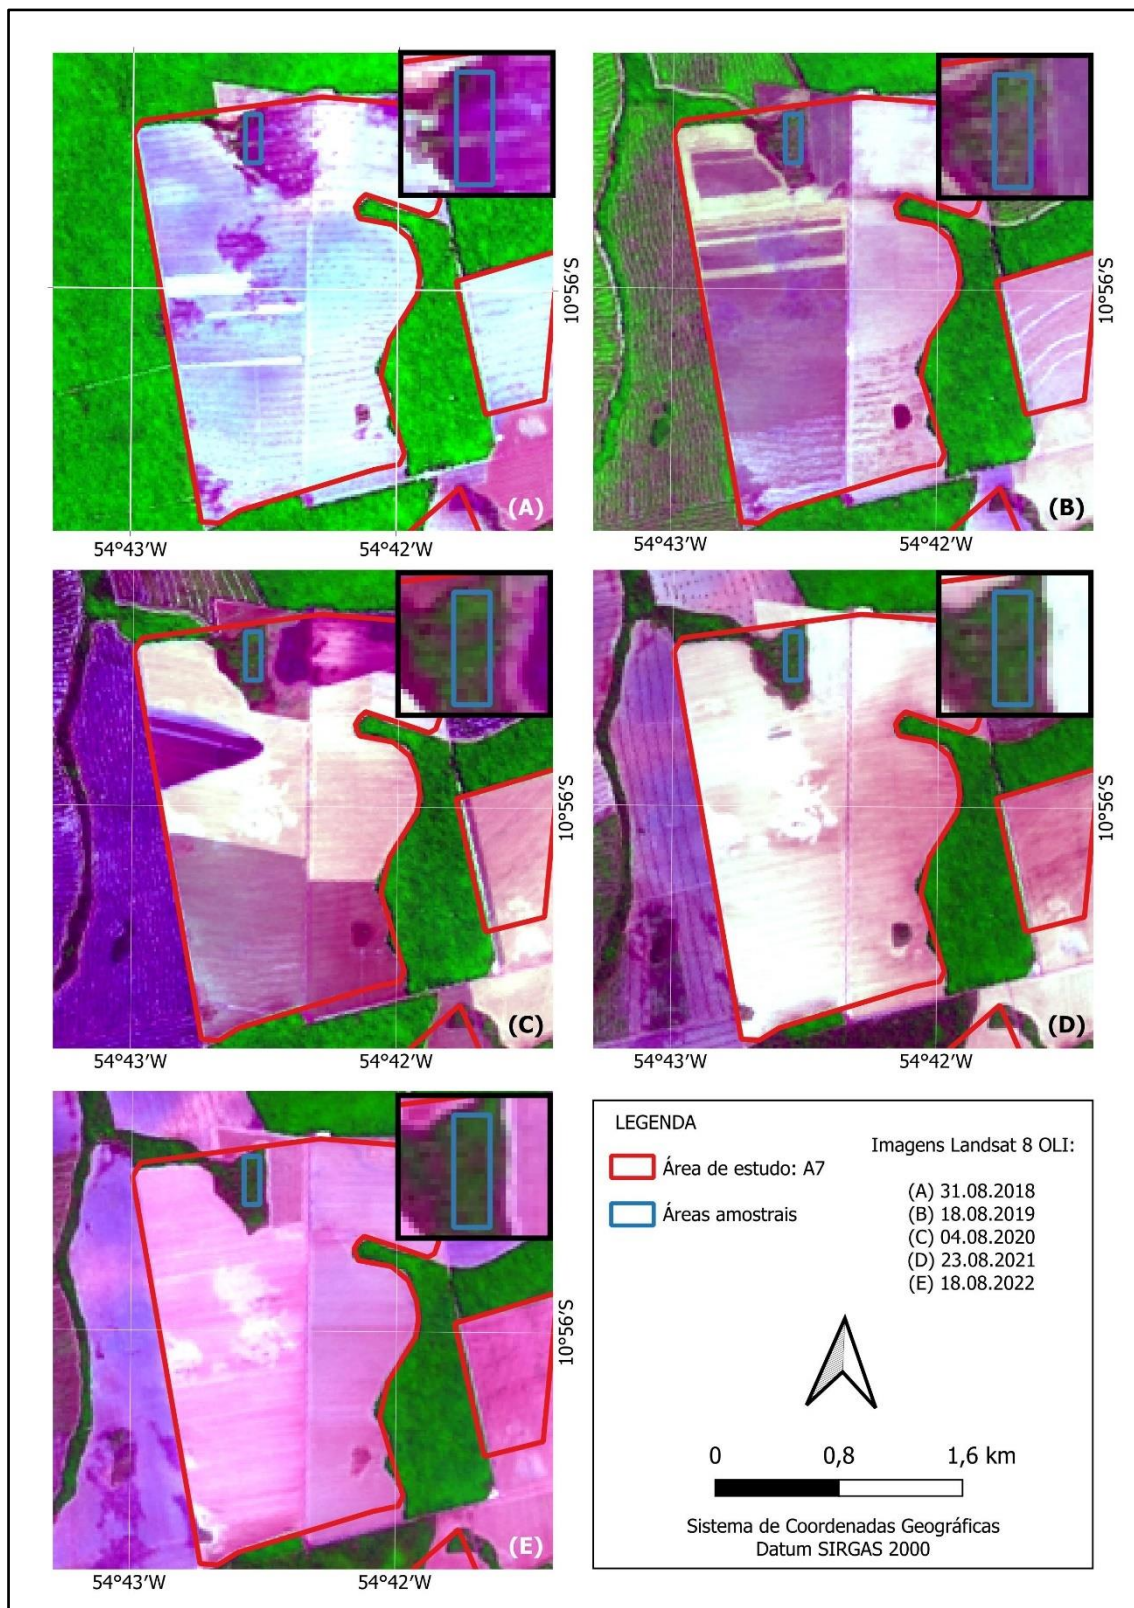


Figura 8. Ilustração da evolução do processo de regeneração da vegetação nas áreas amostrais da área de estudo A8. As imagens correspondem a composições coloridas RGB das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI, fusionadas com a banda pancromática 8, de (A) 2018, (B) 2019, (C) 2020, (D) 2021 e (E) 2022.

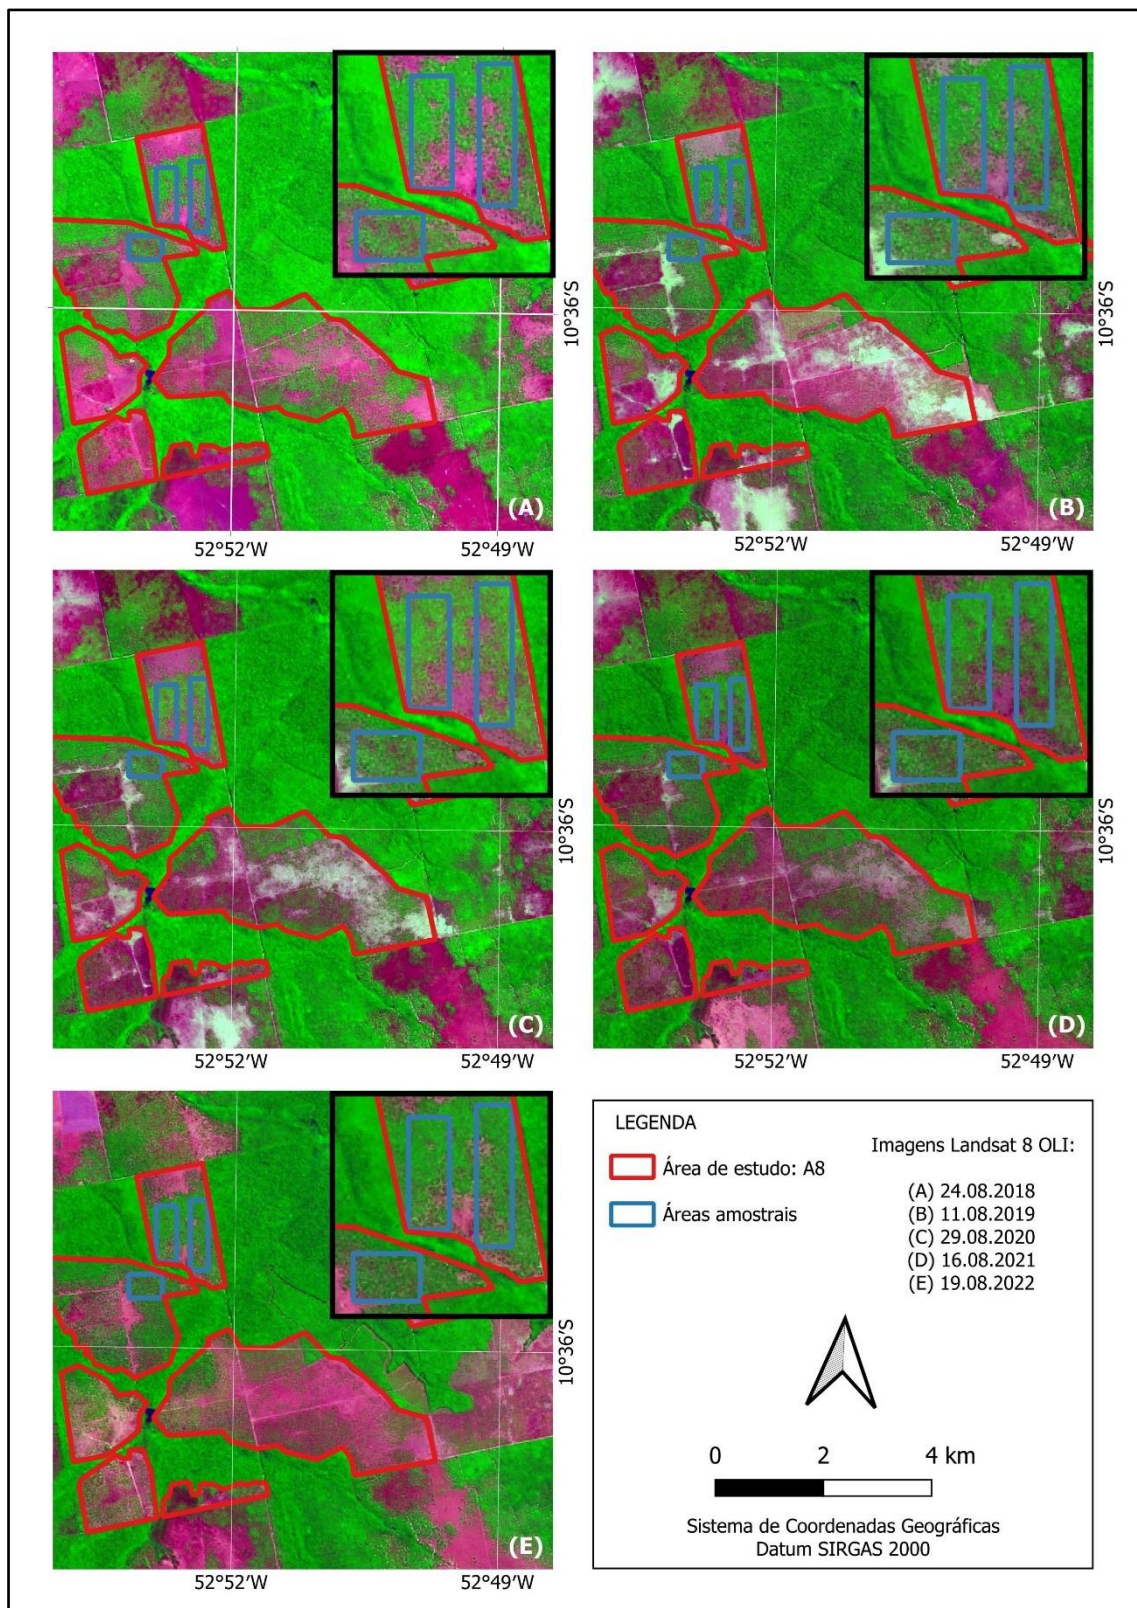
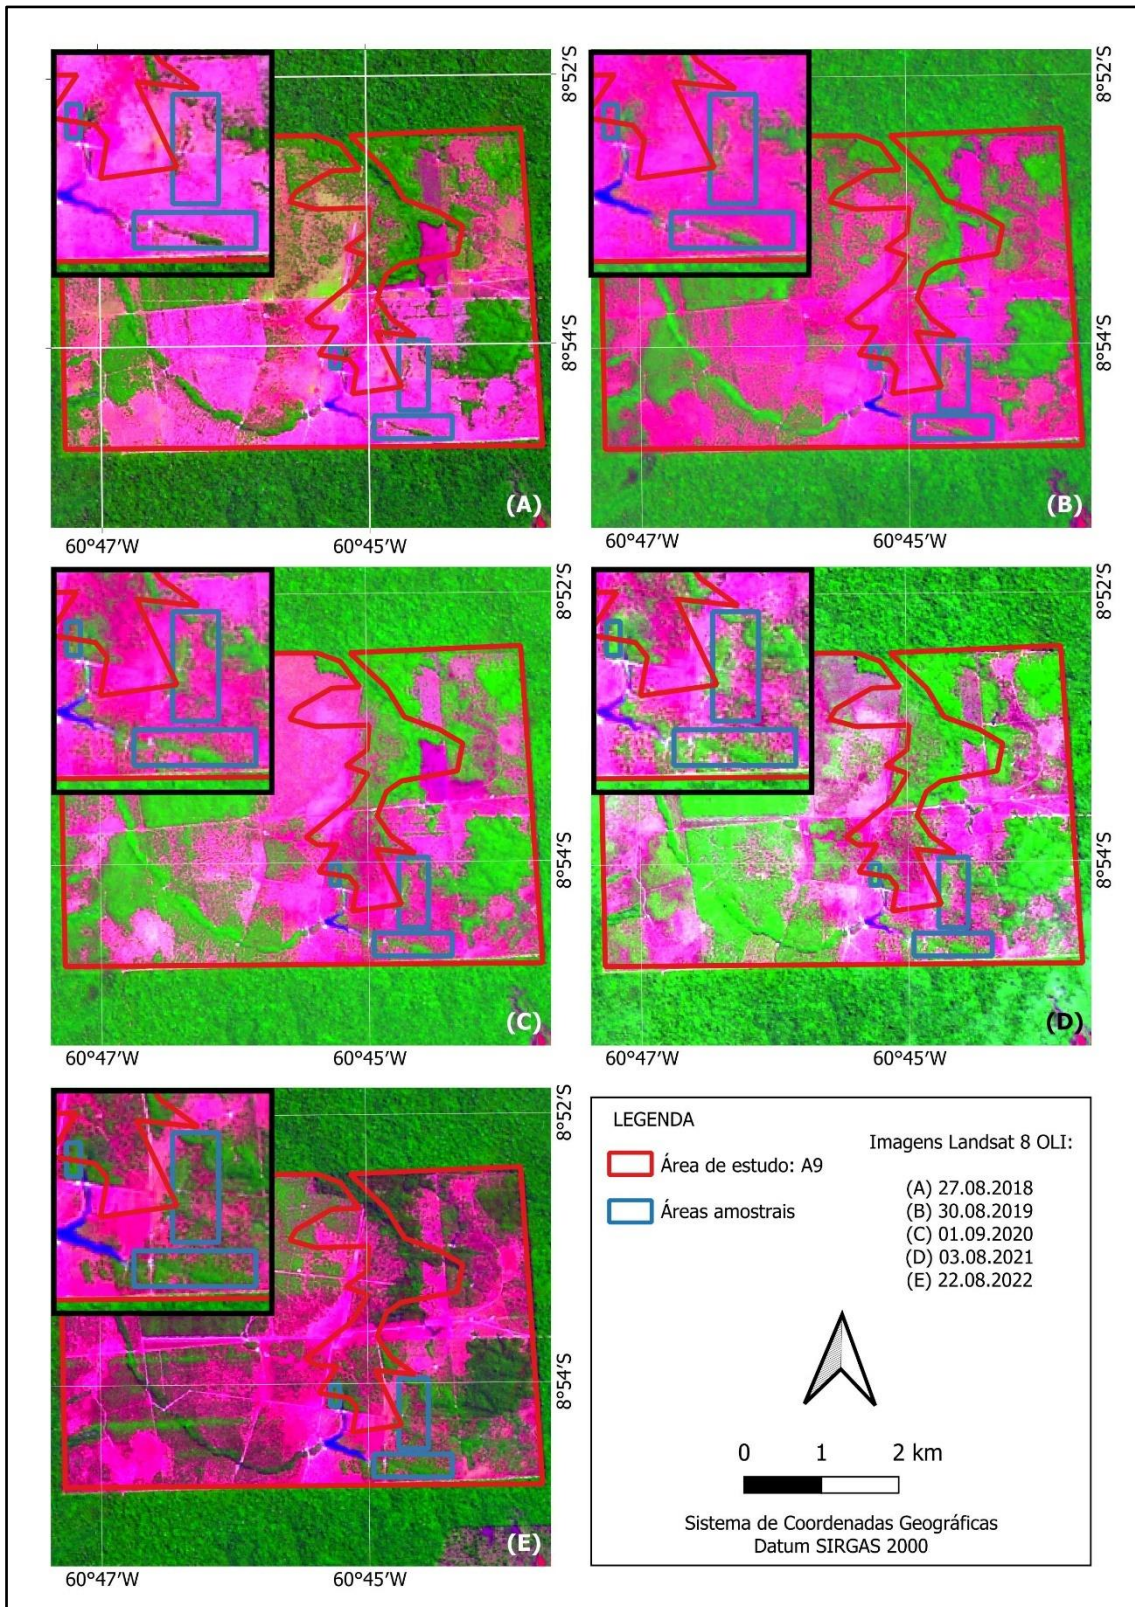


Figura 9. Ilustração da evolução do processo de regeneração da vegetação nas áreas amostrais da área de estudo A9. As imagens correspondem a composições coloridas RGB das bandas multiespectrais 6, 5 e 4 do satélite Landsat 8 OLI, fusionadas com a banda pancromática 8, de (A) 2018, (B) 2019, (C) 2020, (D) 2021 e (E) 2022.



CAPÍTULO 5

CONSIDERAÇÕES FINAIS

Nesse trabalho, realizou-se uma comparação estatística da radiometria do sensor OLI embarcado nos satélites Landsat 8 e Landsat 9 e do desempenho do NDVI convertido para Fração de Cobertura Vegetal (FCV) e da imagem-fração de vegetação (IFV) derivada de Modelo Linear de Mistura Espectral (MLME) para o monitoramento da regeneração da vegetação em áreas degradadas e embargadas pelo Ibama no bioma Amazônia.

Na comparação radiométrica do sensor OLI do Landsat 8 e 9, os resultados mostraram que os dados obtidos pelos dois satélites são, regra geral, estatisticamente similares, mas podem ser diferentes dependendo da estação do ano e da classe de uso e cobertura de terras. Os dois satélites não reproduziram os mesmos valores de NDVI. As diferenças máximas nos maiores e menores valores de NDVI foram significativamente maiores na estação chuvosa do que na estação seca.

Na comparação das imagens convertidas em FCV e IFV, observou-se uma forte correlação linear entre os modelos em todas as áreas de estudo. Em geral, foi constatado que ambos os modelos aplicados são eficientes no monitoramento da recuperação de áreas degradadas no bioma Amazônia. Entretanto, sugere-se ampliar o estudo para outras regiões utilizando-se uma série temporal maior para se obter resultados mais conclusivos. Essa ampliação poderia envolver comparação em outras áreas localizadas em biomas não-amazônicos.

Ressalta-se que as diferenças no tipo de uso pretérito das áreas amostrais com características diferentes como área de pastagem, agricultura ou bordas de áreas de preservação permanente, podem ter influenciado nas diferenças de resposta e comportamento espectral observado nos resultados. Com relação à praticidade e facilidade de uso dos modelos, o MLME depende de pós-classificação visual para melhor qualificar os erros/ausências de classificação que ocorrem no processamento, em maior ou menor escala, a depender da experiência do analista no processo de classificação dos *endmembers* e da qualidade dos dados multiespectrais analisados, o que torna sua aplicação de forma automatizada um pouco mais complicada.

REFERÊNCIAS

ADAMI, M.; BERNARDES, S.; ARAI, E.; FREITAS, R. M.; SHIMABUKURO, Y. E.; ESPÍRITO-SANTO F. D. B.; RUDORFF, B. F. T.; ANDERSON, L. O. Seasonality of vegetation types of South America depicted by moderate resolution imaging spectroradiometer (MODIS) time series. **International Journal of Applied Earth Observation and Geoinformation**, v. 69, p. 148–163, 2018.

ALENCAR, L.; ESCADA, M. I. S.; CAMARGO, J. L. C. Forest regeneration pathways in contrasting deforestation patterns of Amazonia. **Frontiers in Environmental Science**, v. 11, 991695, 2023.

ALMEIDA, C. A.; VALERIANO, D. M.; ESCADA, M. I. S.; RENNÓ, C. D. Estimativa de área de vegetação secundária na Amazônia Legal Brasileira. **Acta Amazonica**, v. 40, n. 2, p. 289-302, 2010.

ALMEIDA, C. A.; COUTINHO A. C.; ESQUERDO J. C. D. M.; ADAMI, M.; VENTURIERI, A.; DINIZ, C. G.; DESSAY, N.; DURIEUX, L.; GOMES, A. R. High spatial resolution land use and land cover mapping of the Brazilian legal Amazon in 2008 using Landsat-5/TM and MODIS data. **Acta Amazonica**, v. 46, n. 3, p. 291–302, 2016.

ASSUNÇÃO, J., GANDOUR, C., ROCHA, R. DETERring Deforestation in the Brazilian Amazon: Environmental Monitoring and Law Enforcement. **Climate Policy Initiative**. 2013.

BRASIL. **Lei nº 9.605, de 12 de fevereiro de 1998**. Disponível em: <https://www.planalto.gov.br/ccivil_03/leis/19605.htm>. Acesso em: 31 julho 2023.

BRASIL. **Decreto nº 6.514, de 22 de julho de 2008**. Disponível em: <https://www.planalto.gov.br/ccivil_03/_ato2007-2010/2008/decreto/d6514.htm>. Acesso em: 14 maio 2023.

BRASIL. **Lei nº 12.651, de 25 de maio de 2012**. Disponível em: <https://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/112651.htm>. Acesso em: 14 maio 2023.

BRASIL. **Planaveg - Plano Nacional de Recuperação da Vegetação Nativa**. 76 p. 2017. Disponível em: <https://www.gov.br/mma/pt-br/assuntos/servicosambientais/ecossistemas-1/conservacao-1/politica-nacional-de-recuperacao-da-vegetacao-nativa/planaveg_plano_nacional_recuperacao_vegetacao_nativa.pdf>. Acesso em: 14 maio 2023.

BRASIL. **PPCDAm - Plano de Ação para a Prevenção e Controle do Desmatamento na Amazônia Legal**. Brasília, DF, 2004, 156 p. Disponível em: <http://redd.mma.gov.br/images/publicacoes/PPCDAM_fase1.pdf>. Acesso em: 14 maio 2023.

BRASIL. **PPCDAm - Plano de Ação para a Prevenção e Controle do Desmatamento na Amazônia Legal. Versão Preliminar**. Brasília, DF, Documento em Consulta Pública, 2023, 82 p. Disponível em: <<https://www.gov.br/participamaisbrasil/consulta-publica-ppcdam>>. Acesso em: 14 maio 2023.

BRASIL. **Relatório de Qualidade do Meio Ambiente - RQMA Brasil 2020**. Brasília, DF, 2022, 558 p. Disponível em: <<https://www.gov.br/ibama/pt-br/servicos/relatorios/qualidade-ambiental>>. Acesso em: 14 maio 2023.

CAMARA, G.; SIMOES, R.; RUIVO, H. M.; ANDRADE, P. R.; SOTERRONI, A. C.; RAMOS, F. M.; RAMOS, R. G.; SCARABELLO, M.; ALMEIDA, C.; SANCHES, I.; MAURANO, L.; COUTINHO, A.; ESQUERDO, J.; ANTUNES, J.; VENTURIERI, A.; ADAMI, M. Impact of land tenure on deforestation control and forest restoration in Brazilian Amazonia. **Environmental Research Letters**, v. 18, 065005, 2023.

CARLSON, T. C.; RIPLEY, D. A. On the Relation between NDVI, Fractional Vegetation Cover, and Leaf Area Index. **Remote Sensing of Environment**, v. 62, p. 241-252, 1997.

CHAVES, M. E. D.; LÁZARO, A. S.; NASSUR, O. A. C.; CONCEIÇÃO, F. G. Estimativa da fração de cobertura vegetal para o ano de 2010 em Minas Gerais a partir do NDVI gerado pelos sensores MODIS e VEGETATION-2. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., Foz do Iguaçu, PR. **Anais...** São José dos Campos: INPE, 2013.

CHAZDON, R. L.; BRANCALION, P. H. S.; LAMB, D.; LAESTADIUS, L.; CALMON, M.; KUMAR, C. A policy-driven knowledge agenda for global forest and landscape restoration. **Conservation Letters**, v. 10, n. 1, p. 125–132, 2017.

CHAZDON, R. L.; LINDENMAYER, D.; GUARIGUATA, M. R.; CROUZEILLES, R.; BENAYAS, J. M. R.; CHAVERO, E. L. Corrigendum: Fostering natural forest regeneration on former agricultural land through economic and policy interventions **Environmental Research Letters**, v. 15, 099501, 2020.

CHOATE, M. J.; RENGARAJAN, R.; STOREY, J. C.; LUBKE, M. Landsat 9 geometric characteristics using underfly data. **Remote Sensing**, v. 14, 3781, 2022.

COUTINHO, A. C.; ALMEIDA, C.; VENTURIERI, A.; ESQUERDO J. C. D. M.; SILVA, M. **TerraClass 2008: Uso e cobertura da terra nas áreas desflorestadas da Amazônia Legal**. Campinas: Embrapa Informática Agropecuária; Belém: INPE. 2013, 108 p.

COUTINHO, L. M. **Biomass Brasileiros**. São Paulo: Oficina de Textos, 2016.

DA SILVA V. C. S.; VIEIRA, I. C. G.; GALBRAITH, D.; POTAPOV, P.; RIVERO, S. L. M.; LIMA, A. M. M.; PIMENTEL, M. A. S.; ADAMI, M. Marked non-compliance with deforestation embargoes in the Brazilian Amazon. **Environmental Research Letters**. V. 17, 054033, 2022.

DEMARCHI, G.; SUBERVIE, J.; CATRY, T.; TRITSCH, I. Using publicly available remote sensing products to evaluate REDD+ projects in Brazil. **Global Environmental Change**, v. 80, 102653, 2023.

DINIZ, C. G.; SOUZA, A. A. A.; SANTOS, D. C.; DIAS, M. C.; LUZ, N. C.; MORAES, D. R. V.; MAIA, J. S. A.; GOMES, A. R.; NARVAES, I. S.; VALERIANO, D. M.; MAURANO, L. E. P.; ADAMI, M. DETER-B: The new Amazon near real-time deforestation detection system. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 8, n. 7, 2015.

ESQUERDO, J. C. D. M.; ANTUNES, J. F. G.; COUTINHO, A. C.; SPERANZA, E. A.; KONDO, A. A. SATVeg: A web-based tool for visualization of MODIS vegetation indices in South America. **Computers and Electronics in Agriculture**. v. 175, 105516, 2020.

FISCH, G.; MARENGO, J. A.; NOBRE, C. A. **Clima da Amazônia**. São José dos Campos: CTA/IAE; Cachoeira Paulista: INPE/CPTEC, 1992, 12 p.

GAO, L.; WANG, X.; JOHNSON, B. A.; TIAN, Q.; WANG, Y.; VERRELST, J.; MU, X.; GU, X. Remote sensing algorithms for estimation of fractional vegetation cover using pure vegetation index values: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**. V. 159, 364–377, 2020.

GLOBAL FOREST CHANGE. **Global Forest Change 2000-2021**. Disponível em: <[https://glad.earthengine.app/view/global-forest-change#dl=1;old=off;bl=off;lon=-53.65143310415432;lat=-2.5206503380584944;zoom=7](https://glad.earthengine.app/view/global-forest-change#dl=1;old=off;bl=off;lon=-53.65143310415432;lat=-2.5206503380584944;zoom=7;)>. Acesso em: 14 maio 2023.

GROSS, G.; HELDER, D.; BEGEMAN, C.; LEIGH, L.; KAEWMANE, M.; SHAH, R. Initial cross-calibration of Landsat 8 and Landsat 9 using the simultaneous underfly event. **Remote Sensing**, v. 14, n. 10, 2418, 2022.

HEINRICH, V. H. A.; DALAGNOL, R.; CASSOL, H. L. G.; ROSAN, T. M.; ALMEIDA, C. T.; SILVA JÚNIOR, C. H. L.; CAMPANHARO, W. A.; HOUSE, J. I.; SITCH, S.; HALES, T. C.; ADAMI, M.; ANDERSON, L. O.; ARAGÃO, L. E. O. C. Large carbon sink potential of secondary forests in the Brazilian Amazon to mitigate climate change. **Nature Communications**, v. 12, n. 1, 1785, 2021.

HUA, J.; CHEN, G.; YU, L.; YE, Q.; JIAO, H.; LUO, X. Improved mapping of long-term forest disturbance and recovery dynamics in the subtropical China using all available Landsat time-series imagery on Google Earth Engine platform. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 14, p. 2754–2768, 2021.

HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1-2, p. 195-213, 2002.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, p. 295-309, 1988.

HUETE, A. R.; LIU, H. Q.; BATCHILY, K.; VAN LEEUWEN, W. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v. 59, p. 440–451, 1997.

IBAMA. **Ibama - Histórico da política ambiental**. Brasília, DF, 2019. Disponível em: <<https://www.ibama.gov.br/cif/186-acesso-a-informacao/institucional/1306-sobreibama>>. Acesso em: 14 maio 2023.

IMAZONGEO. **ImazonGeo**. Belém, PA. Disponível em: <<https://imazongeo.org.br/#/>>. Acesso em: 14 maio 2023.

INPE. **TerraClass**. São José dos Campos, SP, 2019. Disponível em: <http://www.inpe.br/cra/projetos_pesquisas/dados_terraclass.php>. Acesso em: 14 maio 2023.

INPE. Instituto Nacional de Pesquisas Espaciais. **Metodologia para monitoramento da floresta usada nos projetos PRODES e DETER**. São José dos Campos, SP, 2021, 35 p., 2021.

JIMÉNEZ-MUÑOZ, J. C.; SOBRINO, J. A.; PLAZA A.; GUANTER L.; MORENO, J.; MARTINEZ, P. Comparison between fractional vegetation cover retrievals from vegetation indices and spectral mixture analysis: Case study of PROBA/CHRIS data over an agricultural area. **Sensors**, v. 9, n. 2, p. 768–793, 2009.

KONG, J.; RYU, Y.; JEONG, S.; ZHONG, Z.; CHOI, W.; KIM, J.; LEE, K.; LIM, J.; JANG, K.; CHUN, J.; KIM, K.; HOUBORG, R. Super resolution of historic Landsat imagery using a dual generative adversarial network (GAN) model with CubeSat

constellation imagery for spatially enhanced long-term vegetation monitoring. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 200, p. 1–23, 2023.

LANDIM, P. M. B. **Análise Estatística de Dados Geológicos**. Editora UNESP, 2a. ed. 2003, 256 p.

LI, L.; MU, X.; JIANG, H.; CHIANUCCID, F.; HU, R.; SONG, W.; QI, J.; LIU, S.; ZHOU, J.; CHEN, L.; HUANG, H.; YAN, G. Review of ground and aerial methods for vegetation cover fraction (fCover) and related quantities estimation: Definitions, advances, challenges, and future perspectives. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 199, p. 133-156, 2023.

LOURENÇONI, T.; SILVA JÚNIOR, C. A.; LIMA, M.; TEODORO, P. E.; PELISSARI, T. D.; SANTOS, R. G.; TEODORO, L. P. R.; LUZ, I. M.; ROSSI, F. S. Advance of soy commodity in the southern Amazonia with deforestation via PRODES and ImazonGeo: a moratorium-based approach. **Scientific Reports**, v. 11, n. 1, 21792, 2021.

MA, B.; YANG, X.; CHE, D.; SHU, Y.; LIU, Q.; SU, M. Spectral simulation and error analysis of dusty leaves by fusing the hapke two-layer medium model and the linear spectral mixing model. **Remote Sensing**, v. 15, n. 5, 1220, 2023.

MAPBIOMAS. **MapBiomass v. 7.0**. Disponível em: <<https://mapbiomas.org>>. Acesso em: 19 out. 2022.

MASEK, J. G.; WULDER, M. A.; MARKHAMA, B.; MCCORKEL, J.; CRAWFORD, C. J.; SOTREY, J.; JENSTROM, D. T. Landsat 9: Empowering open science and applications through continuity. **Remote Sensing of Environment**, v. 248, 111968, 2020.

MAURANO, L. E. P.; ESCADA, M. I. S.; RENNO, C. D. Padrões espaciais de desmatamento e a estimativa da exatidão dos mapas do PRODES para Amazônia Legal Brasileira. **Ciência Florestal**, v. 29, n. 4, p. 1763–1775, 2019.

MENG, S.; ZHONG, Y.; LUO, C.; HU, X.; WANG, X.; HUANG, S. Optimal temporal window selection for winter wheat and rapeseed mapping with Sentinel-2 Images: A case study of Zhongxiang in China. **Remote Sensing**, v. 12, n. 2, 226, 2020.

MENG, X.; CHENG, J.; GUO, H.; GUO, Y.; YAO, B. Accuracy evaluation of the Landsat 9 land surface temperature product. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 15, p. 8694–8703, 2022.

MMA. Ministério do Meio Ambiente. **Consulta Pública – Plano de Ação para a Prevenção e Controle do Desmatamento na Amazônia Legal - PPCDAm**. Disponível em: <<https://www.gov.br/participamaisbrasil/consulta-publica-ppcdam>>. Acesso em: 14 maio 2023.

NEVES, A. K.; KÖRTING¹, T. S.; FONSECA, L. M. G.; ESCADA, M. I. S. Assessment of TerraClass and MapBiomas data on legend and map agreement for the Brazilian Amazon biome. **Acta Amazonica**, v. 50, n. 2, p. 170–182, 2020.

OLIVEIRA FILHO, F. J. B. **Impact of environmental law enforcement on deforestation, land use and natural regeneration in the Brazilian Amazon** (tese de doutorado em filosofia). Inglaterra: Universidade de Cambridge, 2020, 214 p.

PINTO, A.; AMARAL, P.; SALOMÃO, R.; OLIVEIRA JÚNIOR, L.; CUNHA, C. A.; FIGUEIREDO, L. **Restauração florestal em larga escala na Amazônia: O potencial da vegetação secundária**. Belém: Imazon. 2021, 32 p.

PRODES. **TerraBrasilis - Prodes/Inpe**. Disponível em: <http://terrabrasilis.dpi.inpe.br/app/dashboard/deforestation/biomes/legal_amazon/rates>. Acesso em: 14 maio 2023.

QI, J.; MARSETT, R. C.; MORAN, M. S.; GOODRICH, D. C.; HEILMAN P.; KERR, Y. H.; DEDIEU, G.; CHEHBOUNI, A.; ZHANG, X. X. Spatial and temporal dynamics of vegetation in the San Pedro River basin area. **Agricultural and Forest Meteorology**, v. 105, p. 55-68, 2000.

RAJÃO, R.; SOARES-FILHO, B.; NUNES, F.; BÖRNER, J.; MACHADO, L.; ASSIS, D.; OLIVEIRA, A.; PINTO, L.; RIBEIRO, V.; RAUSCH, L.; GOBBS, J.; FIGUEIRA, D. The rotten apples of Brazil's agribusiness. **Science**, v. 369, n. 6501, p. 246–248, 2020.

RAJÃO, R.; SCHMITT, J.; NUNES, F.; SOARES-FILHO, B. Dicotomia da impunidade do desmatamento ilegal. **Policy Brief**, 2021, 12 p.

RISSO, J.; RIZZI, R.; EPIPHANIO, R. D. V.; RUDORFF, B. F. T.; FORMAGGIO, A. R., *et al.* Potencialidade dos índices de vegetação EVI e NDVI dos produtos MODIS na separabilidade espectral de áreas de soja. *In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO*, 5., Natal, RN, **Anais...** São José dos Campos: INPE, 2009.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W.; HARLAN J. C. **Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation** (Relatório técnico). College Station, Texas A&M, 1974.

SATO, M. K.; SOARES, J. A. C.; ROCHA, B. N.; LIMA, C. F. Use of the linear spectral mixture model in the Saracá-Taquera National Forest. **Revista de Ciências Agrárias**, v. 64, p. 1-10, 2021.

SCHMITT, J. **Crime sem castigo: A efetividade da fiscalização ambiental para o controle do desmatamento ilegal na Amazônia** (tese de doutorado). Brasília: UnB, 2015, 187 p.

SCHMITT, J.; SCARDUA, F. P. A descentralização das competências ambientais e a fiscalização do desmatamento na Amazônia. **Revista de Administração Pública**, v. 49, n. 5, p. 1121–1142, 2015.

SHA, L.; ZHANG, W.; ZHANG, B.; LIU, Z.; LI, Z. Spectral mixing theory-based double-branch network for spectral super-resolution. **Remote Sensing**, v. 15, n. 5, 1308, 2023.

SHIMABUKURO, Y. E.; NOVO, E. M.; PONZONI, F. J. Índice de vegetação e modelo linear de mistura espectral no monitoramento da região do pantanal. **Pesquisa Agropecuária Brasileira**. v. 33, p. 1729-1737, 1998.

SHIMABUKURO, Y. E.; PONZONI, F. J. **Mistura Espectral: Modelo Linear e Aplicações**. São Paulo: Oficina de Textos, 2017.

SHIMABUKURO, Y. E.; DUTRA, A. C.; ARAI, E. Modelo linear de mistura espectral: Conceitos teóricos, algoritmos e aplicações em estudos na Amazônia Legal. **Revista Brasileira de Cartografia**, v. 72, p. 1140–1169, 2020.

SHIMABUKURO, Y. E.; ARAI, E.; DUARTE, V.; DUTRA, A. C.; CASSOL, H. L. G.; SANO, E. E.; HOFFMANN, T. B. Discriminating land use and land cover classes in Brazil based on the annual PROBA-V 100 m time series. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 13, p. 3409–3420, 2020a.

SHIMABUKURO, Y. E.; DUTRA, A. C.; ARAI, E.; DUARTE, V.; CASSOL, H. L. G.; PEREIRA, G.; CARDOZO, F. S. Mapping burned areas of Mato Grosso State Brazilian Amazon using multisensory datasets. **Remote Sensing**, v. 12, n. 22, 3827, 2020b.

SILVA, G. M.; ADAMI, M.; GALBRAITH, D.; NASCIMENTO, R. G. M.; WANG, Y.; SHIMABUKURO, Y. E.; EMMERT, F. Spatial distribution of secondary forests by age group and biomass accumulation in the Brazilian Amazon. **Forests**, v. 14, n. 5, 924, 2023.

SILVA JÚNIOR, C. H. L.; HEINRICH, V. H. A.; FREIRE, A. T. G.; BROGGIO, I. S.; ROSAN, T. M.; DOBLAS, J.; ANDERSON, L. O.; ROUSSEAU, G. X.; SHIMABUKURO, Y. E.; SILVA, C. A.; HOUSE, J. I.; ARAGÃO, L. E. O. C. Benchmark maps of 33 years of secondary forest age for Brazil. **Scientific Data**, v. 7, n. 1, 269, 2020.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**. v. 8, p. 127-150, 1979.

USGS. United States Geological Survey. **Common Landsat band combinations**. Disponível em: <<https://www.usgs.gov/media/images/common-landsat-band-combinations>>. Acesso em: 14 maio 2023.

VALDIONES, A. P.; BERNASCONI, P.; SILGUEIRO, V.; GUIDOTTI, V.; MIRANDA, F.; COSTA, J.; RAJÃO, R.; MANZOLLI, B. **Desmatamento ilegal na Amazônia e no Matopiba: falta transparência e acesso à informação**. 2021. Disponível em:

<https://wwfbr.awsassets.panda.org/downloads/desmatamento_ilegal_na_amazonia_e_no_matopiba___estudo_completo.pdf>. Acesso em: 14 maio 2023.

VEIGA, J. B.; TOURRAND, J. F.; POCCARD-CHAPUIS, R.; PIKETTY, M. G. Cattle ranching in the amazon rainforest. In: WORLD FORESTRY CONGRESS, 12., Québec-Canada. **Anais...** 2003. Disponível em: <<https://www.fao.org/3/xii/0568-b1.htm>>. Acesso em: 14 maio 2023.

WULDER, M. A.; LOVELAND, T. R.; ROY, D. P.; CRAWFORD, C. J.; MASEK, J. G. *et al.* Current status of Landsat program, science, and applications. **Remote Sensing of Environment**, v. 225, p. 127–147, 2019.

WULDER, M. A.; HERMOSILLA, T.; WHITE, J. C.; HOBART, G.; MASEK, J. G. Augmenting Landsat time series with Harmonized Landsat Sentinel-2 data products: Assessment of spectral correspondence. **Science of Remote Sensing**, v. 4, 100031, 2021.

ZHOU, M.; LI, D.; LIAO K.; LU., D. Integration of Landsat time-series vegetation indices improves consistency of change detection. **International Journal of Digital Earth**, v. 16, n. 1, p. 1276–1299, 2023.

ZHU, Z.; WULDER, M. A.; ROY, D. P.; WOODCOCK, C. E.; HANSEN, M. C.; RADELOFF, V. C.; HEALEY, S. P.; SCHAAF, C.; HOSTERT, P.; STROBL, P.; PEKEL, J. F.; LYMBURNER, L.; PAHLEVAN, N.; SCAMBOS, T. A. Benefits of the free and open Landsat data policy. **Remote Sensing of Environment**, v. 224, p. 382–385, 2019.