



# Revista Brasileira de Geografia Física

Homepage: <https://periodicos.ufpe.br/revistas/rbgfe>



## Modelo Linear de Mistura Espectral: Análise das potencialidades do sensor WFI na detecção de corte seletivo

Nelton Cavalcante da Luz<sup>1</sup>; Nicole Rodrigues de Magalhães<sup>2</sup>, Jeremias Vitório Pinto Feitosa<sup>3</sup>; Daniele Alencar Gonçalves<sup>4</sup>, Breno Eduardo dos Santos Alves<sup>5</sup>, Arlesson Antônio de Almeida Souza<sup>6</sup>, Alessandra Rodrigues Gomes<sup>7</sup>, David Roberto Galbraith<sup>8</sup>, Marcos Adami<sup>9</sup>

<sup>1</sup> Mestre em Gestão de Recursos Naturais e Desenvolvimento Local na Amazônia pelo Programa de Pós-Graduação em Gestão de Recursos Naturais e Desenvolvimento Local na Amazônia, Universidade Federal do Pará (UFPA), e-mail: [neltonluz@gmail.com](mailto:neltonluz@gmail.com) (autor correspondente); <sup>2</sup> Mestra em Gestão de Recursos Naturais e Desenvolvimento Local na Amazônia pelo Programa de Pós-Graduação em Gestão de Recursos Naturais e Desenvolvimento Local na Amazônia, Universidade Federal do Pará (UFPA), e-mail: [nicole.rodrigues.magalhaes@gmail.com](mailto:nicole.rodrigues.magalhaes@gmail.com); <sup>3</sup> Mestre em Geoquímica e Petrologia pelo Programa de Pós-Graduação em Geologia e Geoquímica, Universidade Federal do Pará (UFPA), e-mail: [jeremiasvitorio@gmail.com](mailto:jeremiasvitorio@gmail.com); <sup>4</sup> Mestra em Biodiversidade Tropical pelo Programa Pós-Graduação em Biodiversidade Tropical, Universidade Federal do Amapá (UNIFAP), e-mail: [danielealencarap@gmail.com](mailto:danielealencarap@gmail.com); <sup>5</sup> Graduado em Engenharia Cartográfica e de Agrimensura pela Universidade Federal Rural da Amazônia (UFRA); <sup>6</sup> Mestre em Ciências Ambientais pelo Programa de Pós-Graduação em Ciências Ambientais, Universidade Estadual do Pará (UEPA), e-mail: [arlessonantonio@gmail.com](mailto:arlessonantonio@gmail.com); <sup>7</sup> Doutora em Geociências pelo Programa de Pós-Graduação em Geociências e Meio Ambiente, Universidade Estadual Paulista Júlio de Mesquita Filho (UNESP), e-mail: [alessandra.gomes@inpe.br](mailto:alessandra.gomes@inpe.br); <sup>8</sup> Doutor em Biogeociências pela Universidade de Edimburgo, e-mail: [david.roberto.galbraith@gmail.com](mailto:david.roberto.galbraith@gmail.com); <sup>9</sup> Doutor em Sensoriamento Remoto pelo Programa de Pós-Graduação em Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais (INPE), e-mail: [marcos.adami@inpe.br](mailto:marcos.adami@inpe.br).

Artigo recebido em 21/06/2024 e aceito em 16/09/2025

### RESUMO

O objetivo do trabalho consistiu em analisar a Exploração Seletiva de Madeira (ESM) em uma região no Estado de Mato Grosso, utilizando imagens de satélites com diferentes resoluções espaciais, a fim de quantificar os polígonos detectados e consequentemente, realizar o cálculo de área (ha) para as clareiras resultantes dessa atividade, evidenciando a proporção de pixels de solo exposto obtidos para as cenas dos sensores OLI-Landsat-8, MSI-Sentinel-2, PAN5M-CBERS-4, MUX-CBERS-4 e WFI-CBERS-4. A metodologia consistiu no processamento digital de imagens, envolvendo a composição colorida e a aplicação do Modelo Linear de Mistura espectral (MLME). O ano selecionado para o estudo foi 2019, que de acordo com os dados apontados pelo INPE, houve elevada emissão de alertas de danos florestais e também a disponibilidade de imagens sem a cobertura de nuvens para a região analisada. Os resultados mostram que os polígonos registrados se distinguiram conforme cada sensor, apresentando área proporcional ao pixel, ou seja, aumentou à medida que a resolução espacial diminuiu. Os polígonos e áreas para a região de estudo na imagem PAN5M fusionada com a MUX foi de 2884 polígonos e representou área de 101,994 ha; Sentinel-2 foi de 2810 e 174,826 ha; MUX foi de 2125 e 295,0335 ha; Landsat-8 OLI foi de 2116 e 553,1613 ha e WFI foi de 856 e 1144,972 ha. Ainda que haja ampliação da área, o MLME possibilita um ganho nas detecções, em especial para imagens de média resolução espacial, em que pequenas clareiras parcialmente coberta por vegetação se tornam evidentes, pois ele realça regiões que estão perdendo a cobertura florestal, tornando a detecção possível de ESM em imagens com diferentes resoluções espaciais.

Palavras-chave: Exploração Seletiva de Madeira, Modelo Linear de Mistura Espectral, Inteligência Artificial, Amazônia.

## Introdução

As ações de exploração seletiva de madeira (ESM) na floresta amazônica desempenham um papel significativo no processo de ocupação e uso da terra no local onde ocorre. Esse tipo de exploração, frequentemente associado à expansão das atividades econômicas e, sendo mais intensa próximo às estradas e cursos d'água, que historicamente funcionam como eixos de transporte e escoamento de produção madeireira (Cardoso *et al.*, 2023). Inicialmente, essa exploração estava concentrada em florestas de várzeas, ao longo dos principais rios da região, onde espécies de alto valor comercial eram retiradas. Os rios desempenharam um papel crucial nesse processo de ocupação, como meios de acesso e transporte das toras de madeira, facilitando a exploração e a comercialização da madeira extraída (Homma, 2011).

Na segunda metade do século XX, a construção de estradas estratégicas facilitou o acesso às áreas de terra firme na Amazônia. Essa nova realidade proporcionou o surgimento de novas frentes de exploração vegetal, especialmente devido à escassez de madeira nas regiões de várzea. Isso possibilitou a intensificação de ESM sobre fitofisionomias com a predominância de espécies como jatobá (*Hymenaea courbaril*), cedro (*Cedrela odorata*), ipê (*Handroanthus impetiginosus*) que são espécies encontradas em regiões de florestas afastadas dos rios, que possuem interesse econômico e com relevante estoque de carbono, o qual pode ser mensurado indiretamente por meio de imagens de satélite (Romero *et al.*, 2021).

Vale ressaltar que apesar de algumas ESM ocorrerem em desacordo com a legislação florestal vigente (Kirby *et al.*, 2006), o avanço proporcionou, à época, a formação de uma das principais atividades econômicas nos estados da Amazônia Legal. A ESM atingiu a terceira posição na pauta das exportações, logo atrás dos minérios de ferro, ouro, cobre e outros. Além disso, teve um papel importante ao abrir caminho para avanços na fronteira do conhecimento científico e tecnológico sobre os recursos florestais, revelando a fragilidade e a necessidade de maiores investimentos em ciência, tecnologia e educação na região (Homma, 2011).

Diante da complexidade da ESM, a identificação de padrões e seu monitoramento representam um desafio técnico e metodológico. Os padrões resultantes da exploração variam de acordo com as características locais, como o relevo

e a densidade da vegetação, que influenciam na formação de clareiras e na exposição do solo. A detecção dessas alterações por meio de imagens de satélite pode ser dificultada pela regeneração da vegetação e pelas condições atmosféricas, como a presença de nuvens e influência da iluminação solar, alterando as características das áreas, o que pode levar à interpretações incorretas e comprometendo a acurácia das detecções (Asner *et al.*, 2006, Diniz *et al.*, 2015; Ponzoni; Shimabukuro; Kuplich, 2012).

Nesse contexto, o Sensoriamento Remoto (SR) tem se consolidado como uma ferramenta importante para mapear, monitorar e identificar a ESM em grandes escalas. Possui aplicação ampla e a capacidade de fornecer um conjunto de ferramentas para análises diversas e a realização de operações espaciais, possibilitando mapear em imagens de satélite com diferentes tipos de alterações ambientais com precisão (Ponzoni; Shimabukuro; Kuplich, 2012; Helthcoat *et al.*, 2022). Para o contexto da ESM, o uso de técnicas como a decomposição espectral dos pixels nas imagens de satélites, por meio do Modelo Linear de Mistura Espectral (MLME), permite discriminar frações de solo exposto, vegetação e sombra, tornando possível a identificação de padrões associados à exploração seletiva (Ponzoni; Shimabukuro; Kuplich, 2012; Shimabukuro; Dutra; Arai, 2020), como destaque, as estradas associadas aos pátios de estocagem de madeira.

Além disso, a integração de abordagens interdisciplinares é essencial para a ampla compreensão dos impactos da ESM localmente, que podem ser enriquecidos com informações inerentes ao alvo e com isso, fornecendo elementos adicionais que corroboram para a qualificação de outras atividades desenvolvidas em uma determinada região, a avaliação e monitoramento de diferentes danos ambientais e além de outros elementos de importância socioambientais (Myers, 1988; Howard, 1991; Achard *et al.*, 2002; Ehlers, 2007). As informações complementares sobre a dinâmica florestal e a participação de atores locais no monitoramento ambiental, por exemplo, são fundamentais para garantir um aproveitamento sustentável dos recursos florestais da Amazônia (Fearnside, 2022; Becker, 2000).

Dessa forma, este estudo tem como objetivo analisar uma área florestada no Estado de Mato Grosso submetida à ESM, utilizando imagens de satélite multiespectrais de alta e média resolução espacial para identificar os polígonos de solo

exposto e calcular a extensão das clareiras resultantes em hectares, a partir da aplicação do MLME.

## Metodologia

### Área de estudo

A região analisada está situada nos municípios de Santa Carmem e Feliz Natal, no estado de Mato Grosso, inserida no bioma Amazônico. A área se caracteriza pela predominância de Floresta Ombrófila Densa, uma fitofisionomia de elevada complexidade estrutural, com dossel emergente que ultrapassa 30 metros de altura e alta densidade de biomassa (Borges; Silveira e Vendramin, 2014). Essa formação florestal é reconhecida por sua biodiversidade única e por desempenhar um papel fundamental no armazenamento de carbono e na regulação dos ciclos hidrológicos regionais, fatores essenciais para a manutenção do equilíbrio climático e ecológico da Amazônia (Silva *et al.*, 2021; Almeida *et al.*, 2022).

Em 2019, a área foi alvo de alertas de ESM emitidos pelo Sistema de Detecção do Desmatamento em Tempo Quase Real (DETER), do Instituto Nacional de Pesquisas Espaciais (INPE), dados disponíveis na plataforma TerraBrasilis (INPE, 2024). Esses alertas indicaram a ocorrência de atividades madeireiras, motivando a seleção de um recorte espacial de 279.092,17 hectares para a aplicação da metodologia proposta. A escolha dessa área foi baseada na disponibilidade de imagens de satélite multiespectrais com diferentes resoluções espaciais, que permitem a detecção e quantificação das alterações na cobertura florestal, bem como mapeamento de áreas degradadas (Shimabukuro *et al.*, 2020). A Figura 01 ilustra a localização e os limites da área, destacando sua relevância para o monitoramento ambiental e a gestão sustentável dos recursos florestais.




Figura 1. Mapa de localização da área de estudo

As características ombrotérmicas para a área amostral evidenciam a partir de fatores climáticos temperaturas médias de 25°C e alta precipitação durante o ano, uma vez que, encontra-se na Bacia Sedimentar dos Parecis, que tem como destaque um potencial hídrico subterrâneo e sobretudo, compreender essa estrutura estratigráfica é de grande importância para estudos futuros e gerenciamento de recursos florestais (Pedreira; Bahia, 2004; Marengo *et al.*, 2001). Além disso, a região apresenta clima Tropical Estacional com período de estiagem chegando à duração média em torno de três a quatro meses por ano (IBGE, 2012).

Outro fator marcante para a região se deve aos solos, os quais apresentam baixa fertilidade natural, constituídos basicamente por latossolos e podzólicos (Santos *et al.*, 2023). Por outro lado, essa tipologia favorece o desenvolvimento da vegetação local, pois permite às árvores acessarem águas subterrâneas e ao mesmo tempo atenuando o estresse hídrico durante o período de seca (IBGE, 2012).

### Material

A realização dessa etapa compreendeu a seleção de imagens gratuitas e multiespectrais disponíveis para a área de interesse sendo que, para isso, procurou-se por cenas com o menor intervalo de tempo entre os ciclos de passagem para área de estudo, de modo que, os efeitos continuados das atividades de ESM não comprometessem as análises propostas. Portanto, descartou-se as cenas com ciclos de revisitas superior a cinco dias, procurando evitar que esse intervalo temporal possa influenciar diretamente na dimensão de área obtida por cada sensor.

Dessa forma, os períodos selecionados foram entre os dias 16 e 17 de setembro de 2019,

obtidos diretamente do catálogo público de imagens do INPE<sup>1</sup>. Selecionou-se as imagens captadas pelos satélites CBERS 4 compreendendo os sensores do satélite WFI (bandas 16, 15, 14 com 64 metros de resolução espacial e ciclo de revisita de 5 dias), MUX (bandas 8,7,6 com 20 m, ciclos com intervalos de 26 dias) e a PAN5M com 5 m (ambas as três cenas foram para a mesma data, dia 17); para o satélite Landsat 8 referente o sensor OLI (bandas 5,4,3 com 30 m, ciclos com intervalos de 16 dias) e por último imagens Sentinel-2 (*Sentinels Scientific Data Hub*)<sup>2</sup>, sensor MSI (bandas 8, 4, 3 com 10 m, ciclos com intervalos de 10 dias) sendo essas duas últimas para o dia 16 do mês analisado.

Para a manipulação dos arquivos em formato raster e produção dos dados vetoriais foram utilizados os softwares TerraAmazon<sup>3</sup> e QGIS<sup>4</sup> possibilitando a tabulações e análises estatísticas a partir do aplicativo Bioestat<sup>5</sup>.

### Processamento das imagens e análise dos dados

Para a realização dessa fase, foi realizada a composição das bandas infravermelho (R), vermelho (G) e verde (B), para a obtenção de uma imagem visualmente colorida conforme cada sensor analisado. Sendo que inicialmente realizou-se, o fusão de bandas por meio do método vizinho mais próximo, no qual se utilizou os dados do sensor MUX e a imagem Pancromática, ambas cenas disponibilizadas pelo satélite CBERS 4. Em seguida, para a geração de imagem RGB com a resolução espacial de 5 m formando assim a imagem PAN5M, a qual aplicou a calibração radiométrica para 8 bits, permitindo assim, reamostrar os intervalos digitais entre 0 a 255 para cada canal de cor do pixel. Concluído a etapa, foi atribuído também este procedimento para as demais cenas RGB utilizadas no presente trabalho.

Com o aplicativo TerraAmazon, realizou-se a combinação ponderada das respostas espectrais para evidenciar os valores digitais dos pixels contidos em cada cena, os quais podem ser entendidos como a mistura de três componentes, isto é, solo, vegetação e água/sombra, onde o fator de ponderação possibilita a partir da decomposição da cena a obtenção de amostras, em suma, compreendendo o Modelo Linear de Mistura Espectral (MLME) e ao mesmo tempo aplicando o método Componentes Principais (PCA), a partir da extração de amostras de pixels puros de vegetação,

solo e sombra/água (Figura 02). Isso proporciona a geração de três imagens fração, cada uma com informações de um dos três componentes informados (Moreira, 2007; Ponzoni e Shimabukuro, 2007; Ponzoni; Shimabukuro; Kuplich, 2012).



Figura 2. Ilustração dos pixels em imagem RGB: a) amostra de vegetação; b) sombra/água; c) solo.

O MLME pode ser descrito pela expressão:

$$R_k = \sum_{n=1}^m \cdot (r_{n,k}) \quad (1)$$

Onde,  $R_k$  corresponde à resposta espectral de um pixel na banda,  $k$ ,  $r_{n,k}$  representa a resposta espectral do componente de referência  $n$  na banda,  $k$ ,  $f_n$  a fração da área do pixel ocupada pelo componente de referência  $n$ ,  $m$  ao número de componentes de referência,  $v_k$  ao valor do erro residual,  $k$  e  $p$  ao número de bandas utilizadas.

Com isso, ressalta-se que as respostas espectrais  $R_k$  e  $r_{j,k}$  podem ser expressas em refletância, radiância ou número digital (ND) (Ponzoni; Shimabukuro; Kuplich, 2012). Sendo que neste estudo optou-se pela representação em ND, procurando analisar os valores digitais a partir da resolução radiométrica informada anteriormente, conforme Diniz *et al.* (2015). Desse modo, buscou-se por amostras de pixels em regiões da cena com maior pureza para cada componente.

Considerando a resolução de maior proximidade com a realidade local, para as aberturas na floresta provocadas pelas ESM, atribuiu-se como verdade para o cálculo de área e

<sup>1</sup> Disponível em: <http://www.dgi.inpe.br/catalogo/>

<sup>2</sup> Disponível em: <https://scihub.copernicus.eu/dhus/#/home>

<sup>3</sup> Disponível em: <http://www.terraamazon.dpi.inpe.br/downloads>

<sup>4</sup> Disponível em: <https://qgisbrasil.org/>

<sup>5</sup> Disponível em: <https://www.mamiraua.org.br/downloads/programas/>

com isso, aferir o percentual de detecção de polígonos e ampliação de área evidenciada pelos pixels nas imagens frações solos, adicionalmente aplicando tratamento a partir da operação aritmética, dividindo as frações solo com a vegetação, extraídas da imagem PAN5M de alta resolução (5 m) e, no resultado desta operação aritmética, aplicou-se fatores de ponderação como ganho um peso de 50 e perda/offset de 90, esses parâmetros além de realçar as feições de interesse, como áreas de solo exposto envolto por áreas de floresta, eles contribuem para atenuar os efeitos da ampliação do pixel obtido pelo MLME e com isso, possibilitando assim, expandir as análises e ao mesmo tempo definir o percentual de área aberta pela ESM para cada satélite/sensor trabalhado. Essa expressão pode ser evidenciada pela fórmula abaixo:

$$C = G * \left(\frac{A}{B}\right) + offset \quad (2)$$

Em que, C= Imagem resultando, G= (Fator de ganho) = 90, Offset= 50, A= Fração solo, B= Fração vegetação.

Vale salientar que a operação entre as frações foi atribuída apenas para a imagem PAN5M, ocorrendo de forma intencional, uma vez que, para as frações de menor resolução as decomposições resultantes do MLME, ao aplicar essa operação, minimizem a detecção de ESM. A fração solo foi utilizada para os demais sensores, a fim de servir como parâmetro para analisar o número de polígonos captados e ao mesmo tempo calcular a área do solo exposto na floresta e sua representação conforme a resolução espacial do *raster*, para representar os dados e, analisá-los utilizou-se as medidas de dispersão, como:

- Média: (3)

$$\underline{X} = \frac{\sum X}{n}$$

Onde,  $\underline{X}$  média aritmética da amostra,  $X$  corresponde a somatória dos elementos da amostra e  $n$  ao número de elementos dentro da amostra.

O uso da média representa o valor central dos dados obtidos para a fração solo nos diferentes sensores, o que permite uma comparação direta entre eles (Bussab e Morettin, 2024; Moreira, 2007). No que se refere às áreas de ESM, a média dos valores de ND por pixel fornece uma referência para avaliar o nível médio de exposição do solo na

floresta. A média também serve para identificar se os valores das frações diferem significativamente entre os sensores utilizados. Vale ressaltar que o cálculo da média foi realizado a partir da extração dos valores da fração solo resultantes do MLME já aplicado.

- Variância: (4)

$$S^2 = \frac{n(\sum X^2) - (\sum X)^2}{n(n-1)}$$

Em que,  $S^2$  variância da amostra,  $X$  corresponde à medida tomada dos elementos da amostra e  $n$  ao número de repetições e  $\sum$  ao somatório.

O cálculo da variância mede a dispersão dos valores em relação à média, ou seja, o valor obtido demonstra se há heterogeneidade nos dados (Bussab e Morettin, 2024). Para o contexto da análise da fração solo, uma variância elevada pode indicar variações espaciais significativas na distribuição das áreas de solo exposto, enquanto uma variância baixa sugere maior homogeneidade. Este parâmetro estatístico também permite avaliar diferenças na detecção de polígonos de ESM entre sensores, observando se há variações expressivas, conforme resolução espacial utilizada.

- Desvio Padrão

$$DP = \frac{\sqrt{\sum (Xi - \underline{X})^2}}{n} \quad (5)$$

Onde,  $Xi$  corresponde ao valor individual,  $\underline{X}$  média dos valores e  $n$  ao número de valores.

O desvio padrão quantifica a dispersão dos valores de ND por pixel, indicando se os dados estão mais concentrados próximos da média ou se apresentam maior variabilidade (Bussab e Morettin, 2024). Um valor de desvio padrão elevado sugere heterogeneidade na detecção da ESM e que pode indicar inconsistências entre sensores ou a presença de regiões com padrões distintos de exploração seletiva. O uso do desvio padrão no modelo ajuda a avaliar a fidelidade dos sensores na captura de áreas de solo exposto, pois sensores de menor resolução podem apresentar maior desvio padrão devido à generalização dos pixels.

As medidas de dispersão utilizadas são essenciais para avaliar a consistência dos resultados



obtidos com o MLME, garantindo que as áreas de ESM detectadas sejam estatisticamente representativas e confiáveis. Essas métricas possibilitam não apenas uma verificação da acurácia da detecção, mas também uma comparação objetiva entre sensores de diferentes resoluções (Blaschke; Lang; Hay, 2008).

As medidas estatísticas aplicadas ao sensoriamento remoto são importantes aliadas para a análise das dinâmicas florestais, como é o caso da utilização combinada das medidas de dispersão aos índices de vegetação, como o NDVI (*Normalized Difference Vegetation Index*) e EVI (*Enhanced Vegetation Index*). Essa combinação possibilita uma análise mais detalhada da variabilidade espacial e temporal da cobertura vegetal, enquanto a média de um índice de vegetação em uma determinada área fornece uma visão geral da densidade de biomassa ou saúde da vegetação, a variância e o desvio padrão indicam o grau de heterogeneidade da paisagem. Áreas com baixo desvio padrão tendem a apresentar cobertura vegetal mais uniforme, já os valores elevados podem indicar mosaicos de vegetação alterada, bordas de fragmentos florestais ou processos de degradação em andamento (Pettorelli *et al.*, 2005). Além disso, a análise estatística da dispersão dos índices permite identificar padrões sazonais e avaliar impactos ambientais, como secas ou ESM, de maneira mais robusta (Huete *et al.*, 2002; Pettorelli *et al.*, 2005).

A partir dessa concepção, torna-se possível a verificação estatística também para os valores de ND para cada pixel de ESM na amostra em estudo e com isso, analisar o quanto eles se encontram dispersos ou não, e quão distantes um do outro para cada sensor, seguindo assim, os preceitos sugeridos por Lang e Blaschke (2009), em que para determinado cálculo matemático-estatístico ou semântico os critérios devem ser levados em consideração como o ponto de vista do usuário, pois existem vários índices e medidas que apresentam situações similares, por isso é fundamental identificar as variáveis que possuem as maiores cargas, ou seja, as mais representativas, para determinar sua importância na análise, neste caso para as áreas de ESM.

Portanto, utilizou-se uma base *raster* para estruturar os passos fundamentais para as análises estatísticas, como:

- Frequência de ND detectados de ESM correspondente ao número de células conforme o sensor;
- A área calculada em relação ao número de polígonos e relacionados com os sensores;
- O volume correspondente à soma do número de polígonos e área calculados de acordo com a resolução espacial de cada *raster*;
- Centróides foram obtidos a partir do valor médio da posição das linhas e colunas que são partes das camadas do polígono de ESM;
- Elevação de área de atividades de ESM em relação à região amostral a partir de dados provenientes do modelo digital de elevação (DEM);
- Distância média obtida a partir de conversão das áreas de ESM em centróides de modo a mensurar a distância média entre os pontos para o sensor PAN5M de maior resolução espacial.

Além disso, visando maior representatividade para os valores de ND obtidos a partir do MLME, utilizou-se o diagrama de caixa (*Box-Plot*), o qual possui ampla aplicabilidade na ciência. Uma vez que ele possibilita a partir de um Box, ilustrar graficamente a mediana, o primeiro e o terceiro quartil, além de exibir os valores mínimo e máximo da amostra (Ayres *et al.* 2007).

Como ferramenta auxiliar, foi utilizado o recurso *Conect View* para otimizar as análises dos dados. A ferramenta permite carregar diferentes imagens no aplicativo TerraAmazon para trabalhá-las com alternância entre as telas. Isso possibilita operar os dados em uma janela principal para a edição vetorial e os demais dados em outras janelas auxiliares como suporte para os mapeamentos, sendo que para isso, na primeira janela foi inserida imagem fração solo proveniente do MLME e as imagens coloridas com e sem realce carregadas em outras janelas auxiliares para serem utilizadas de forma alternada.

Os valores de elevação de terreno gerados a partir dos centróides de ESM foram extraídos do Modelo Digital de Elevação (DEM) proveniente do TOPODATA<sup>6</sup>, buscando assim, verificar a elevação da área de dano mapeada na cena PAN5M em relação à região de estudo, a exemplo, considerando que na região de estudo possui áreas

<sup>6</sup> Disponível em: <http://www.dsr.inpe.br/topodata/>

de proteção permanente que podem ser mapeadas no DEM e com isso, valores de elevação da vegetação nesse tipo de terreno podem ser evidenciados e ao mesmo tempo comparados com as vegetações localizadas em terra firme, servindo assim, como um método de apoio às fiscalizações e monitoramento de áreas que estão ocorrendo ESM. Adicionalmente, os centróides foram gerados para obtenção de distância média entre as áreas de exploração.

## Resultados e discussões

Os intervalos obtidos a partir da leitura digital dos valores de NDs para os pixels correspondentes às regiões de ESM, conforme os dados de cada satélite/sensor podem ser evidenciados na Tabela 01:

**Tabela 01.** Valores mínimo e máximo de NDs registrados para os pixels de ESM a partir das imagens fração solo para cada sensor analisado.

| Satélite    | Sensor | Intervalo Digital (ND) |
|-------------|--------|------------------------|
| CBERS 4     | PAN5M  | 8 - 43                 |
| SENTINE L 2 | MSI    | 34 - 100               |
| CBERS 4     | MUX    | 4 - 56                 |
| LANDSAT 8   | OLI    | 62 - 162               |
| CBERS 4     | WFI    | 81 - 94                |

A partir dessas informações registrou-se o número de polígonos e consequentemente, aferiu-se as áreas mapeadas de ESM em hectares, conforme tabela 2:

**Tabela 2.** Nº de polígonos e área de ESM mapeadas para cada sensor analisado para a região de estudo








| Sensor | Nº de polígonos | Polígonos (%) | Área (ha) | Incremento de área (%) |
|--------|-----------------|---------------|-----------|------------------------|
| PAN5M* | 2884            | -             | 101,99    | -                      |
| MSI    | 2810            | 2,57          | 174,83    | 1,71                   |
| MUX    | 2125            | 26,32         | 295,03    | 2,89                   |
| OLI    | 2116            | 26,63         | 553,16    | 5,42                   |

|       |       |        |         |       |
|-------|-------|--------|---------|-------|
| WFI   | 856   | 70,32  | 1144,98 | 11,23 |
| Total | 10791 | 125,83 | 2269,99 | 21,26 |

\*Cena de maior resolução espacial assumida como verdade para efeito comparativo e realização do percentual de incremento de área de acordo com cada sensor.

Com a utilização dessas informações realizou-se um recorte de uma região de ESM para melhor exemplificar visualmente, as informações geradas a partir do MLME (Tabela 3).

**Tabela 3.** Mapeamento de ESM nas imagens de satélite em RGB e sua detecção a partir da fração solo.

| Sensor                                                | Composição RGB                                                                       | Fração-solo                                                                           |
|-------------------------------------------------------|--------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------|
| WFI Nº de polígonos: 89; Área total em ha: 87,8034    |    |    |
| OLI Nº de polígonos: 105; Área total em ha: 46,0046   |   |   |
| MUX Nº de polígonos: 113; Área total em ha: 26,1152   |  |  |
| MSI Nº de polígonos: 118; Área total em ha: 16,6747   |  |  |
| PAN5M Nº de polígonos: 120; Área total em ha: 14,1756 |  |  |

A partir dos polígonos das áreas de aberturas na floresta resultantes das atividades de ESM, foi gerado na área de estudo a elevação do terreno a partir da interpolação dos polígonos de ESM com a imagem DEM (tabela 4). Esse processo permitiu visualizar como as atividades de ESM estão relacionadas com as características do terreno, além de compreender o relevo e a topografia nas áreas afetadas e avaliar os impactos dessa atividade no ambiente florestal.

Os resultados da interpolação podem ser visualizados na tabela 4:

**Tabela 4.** Análise de medida de dispersão referente à elevação da área de estudo e da área de ESM

| Local          | Elevação     |        |              |               |
|----------------|--------------|--------|--------------|---------------|
|                | Valor Mínimo | Média  | Valor Máximo | Desvio Padrão |
| ESM            | 300          | 364    | 398          | 16,246869     |
| Área de Estudo | 284          | 355,95 | 408          | 21,940747     |

Além disso, foi possível obter a distribuição espacial nestas áreas resultantes de ESM, a partir dos centróides referentes aos pátios de estocagem de madeira. As distribuições espaciais apresentaram distância mínima de 42,4 m, média de 172,8 m, máxima de 2.083,8 m e desvio padrão de 135,04 m. Estes valores indicam uma variabilidade na disposição desses pátios, o que pode estar relacionado a diferentes práticas de exploração e logística de transporte de madeira nessa região.

Vale reforçar a importância em analisar e avaliar os recursos disponíveis a serem utilizados em SR, em especial, aqueles destinados para mapear e monitorar áreas de ESM. Isso garante que os resultados obtidos remotamente, sejam coerentes com a realidade em campo, de modo a inferir as intervenções antrópicas na floresta.

É importante utilizar dados adequados para a finalidade pretendida (Matricardi *et al.*, 2005), pois as clareiras abertas na floresta podem ser recobertas pelos estratos inferiores vegetais ou pela regeneração, ou até mesmo serem convertidas em outros tipos, como o desflorestamento. Isso pode modificar as características dos danos iniciais no momento de detecção da feição, destacando a

importância da escolha cuidadosa dos recursos de SR para a análise de ESM.

Os autores Diniz *et al.* (2015) destacam que a presença de nuvens, comuns em algumas áreas da Amazônia, associado ao tempo e grau de intervenção ao adquirir imagens, podem ocasionar na falta de detecção de atividades de ESM durante o monitoramento. Isso se deve à regeneração da floresta e ao fechamento das aberturas na copa das árvores por espécies vegetais pioneiras e clímax remanescentes, podendo acontecer em menos de quatro meses. Eles também enfatizam a importância de um sistema de imageamento por satélite contínuo, de alta resolução espacial e temporal, no intuito de compreender e avaliar os impactos na dinâmica florestal causados por esse tipo de evento.

Segundo Matricardi *et al.*, (2010), quando as atividades de ESM são realizadas de forma sustentável, respeitando os limites estabelecidos no plano de manejo, a área geralmente é utilizada exclusivamente para esse fim. Esse processo remove parte da cobertura vegetal, deixando o solo exposto, mas a intervenção na floresta é temporária e não é mais visível em imagens da série Landsat após quatro meses, devido ao rápido aumento de 3,1% na cobertura do dossel florestal. Na figura (3) mostra a mediana das áreas em m<sup>2</sup> mapeadas de acordo com o senso utilizado.




Figura 3. Diagrama de caixa ilustrando a dispersão dos dados (*outliers*).

Esse diagrama permite visualizar como os dados variam de acordo com cada sensor para a exploração seletiva de madeira, e em conjunto com o SR, oferece alternativas para entender como os pixels se comportam nas imagens de satélite. Portanto, é útil para determinar a resolução espacial mais adequada a fim de detectar as atividades em questão. De acordo com Moreira (2007), essa tecnologia é uma ferramenta que possibilita também mapear diversas áreas, como agricultura, formações florestais e geologia, devido à sua capacidade de abranger uma ampla gama de



trabalhos e objetivos, compreendendo assim, como elemento de grande importância em trabalhos com essa finalidade.

Além disso, a utilização de diferentes sensores e resoluções espaciais pode ser bastante vantajosa para visualizar um alvo específico e sua evolução ao longo do tempo (Small e Sousa, 2024). Isso pode ajudar a estabelecer parâmetros específicos que podem ser usados na detecção, qualificação e medição das intervenções na floresta provenientes de ESM.

Considerando-se que, no início das atividades de ESM, é difícil detectar os danos, uma vez que, as aberturas iniciais na paisagem são pequenas e os danos podem ser rapidamente cobertos pelas copas das árvores vizinhas. Isso ocorre devido à interação com elementos da floresta local, conforme pode ser evidenciado na figura (04) abaixo. Na imagem RGB, não é possível detectar as intervenções, enquanto no produto do MLME, isso é viável.




Figura 4. Polígono de ESM: a) Imagem colorida (RGB); b) fração solo.

Os autores Small e Sousa (2024) também utilizaram o MLME para projetar uma mistura e identificar desflorestamento em uma área, e foi evidenciado que o modelo obteve bons resultados para separar feições de dossel, solo e outros substratos.

Utilizando dados do MLME, os autores realizaram sobrevoos em áreas de exploração seletiva de madeira identificadas em imagens capturadas pelo sensor WFI do satélite CBERS 4. Foi observado que as aberturas no dossel de floresta ombrófila, que eram usadas como pátios de estocagem de troncos, apresentavam áreas superiores a 40 m<sup>2</sup> (Figura 05).



Figura 5. Fotografia aérea obtida pelos autores no mês de julho de 2014.

No estudo realizado por Asner *et al.* (2002), foi realizada uma análise da reflectância e a textura de imagens do satélite Landsat 7 ETM + com o objetivo de mapear a ESM na Amazônia. Essas imagens, com resolução espacial de 30 metros, permitiram o mapeamento de áreas de estocagem e estradas utilizadas para o transporte de madeiras.

Em Souza *et al.* (2024) foi utilizada imagens Landsat para analisar a dinâmica espacial e temporal das florestas perturbadas pela exploração seletiva de madeiras no estado do Pará, utilizando uma série temporal (1992 a 2018), os resultados obtidos por Souza *et al.* (2024) mostraram que aproximadamente 20% das florestas exploradas seletivamente para fins madeireiros foram desmatadas na área e período de estudo.

Outros estudos com análises semelhantes também destacam a importância do SR no mapeamento da ESM, considerando-o como um recurso valioso de baixo custo que fornece resultados satisfatórios e rápidos (Asner *et al.* 2009; Peres *et al.* 2006; Botelho *et al.*, 2022; Souza *et al.* 2024). No entanto, é importante ressaltar que se os autores utilizassem o MLME, os resultados poderiam ser de 20 a 30% maiores, devido à ampliação das detecções desse tipo de alvo na imagem da fração solo. Informação que pode ser ratificada pelos dados produzidos pelo sistema de monitoramento do INPE o DETER-Amazônia, que além de detectar alterações antrópicas na floresta os qualifica em classes de danos, sendo um suporte relevante para ações de fiscalizações de órgãos ambientais como o IBAMA.

A eficácia no uso do MLME no estudo de cobertura florestal, não exclusivamente em ESM, também pode ser observada aplicações combinadas a outras ferramentas. Como no estudo de Basuki *et al.* (2012), os autores observaram limitações na aplicação de índices de vegetação (NDVI - *Normalized Difference Vegetation Index*, EVI - *Enhanced Vegetation Index* e MSAVI - *Modified Soil Adjusted Vegetation Index*) para calcular a estimativa de BMAS (biomassa florestal acima do solo) em uma floresta tropical na Indonésia. Os índices de vegetação aplicados foram considerados inadequados pois, segundo os autores, quando um sensor registra um pixel, na verdade, é uma mistura espectral de radiação ou reflectância de todos os componentes na superfície da Terra coberta por um pixel. No uso do MLME, com a decomposição dos componentes mistos do pixel, foi possível obter a proporção da vegetação (variável necessária para estimar a BMAS), além de facilitar na interpretação visual da imagem-fração gerada, onde foram destacadas a heterogeneidade da cobertura florestal, indicando uma sensibilidade do MLME ao detectar áreas exploradas em diferentes momentos e áreas não exploradas.

Ressalta-se, no âmbito da ESM, a mistura de componentes espectrais é mais complexa pois, além dos elementos encontrados na superfície da Terra, os pixels representam uma mistura da cobertura do dossel da floresta e solo descoberto (Shimabukuro; Dutra; Arai, 2020). Diante do pressuposto, é possível afirmar que o uso do MLME tanto para estimativa de BMAS, conforme aponta Basuki *et al.* (2012), quanto para a ESM é altamente eficaz.

Além da importância do sensoriamento remoto e suas ferramentas para identificação da ESM, o avanço significativo no uso de inteligência artificial (IA) no SR, também pode ser utilizado para o mapeamento de estradas na Amazônia brasileira, utilizando um modelo de U-Net modificado e imagens do Sentinel-2, conforme demonstra estudo de Botelho *et al.* (2022). Apesar das limitações, como a detecção de falsos positivos próximos a rios e áreas agrícolas, o modelo alcançou uma precisão de 71% e um *recall* de 65%, superando métodos tradicionais de mapeamento manual. A automação do processo permitiu mapear 3,46 milhões de quilômetros de estradas em apenas 7 horas, algo que demandaria meses de trabalho manual. O modelo também foi capaz de identificar estradas "parcialmente visíveis" que não foram captadas no conjunto de dados de referência, o que evidencia a capacidade da IA em detectar padrões

sutis em imagens de média resolução. Apesar dos desafios, como a desconexão de segmentos de estradas e a necessidade de melhorias no conjunto de dados de treinamento, o estudo abre caminho para a operacionalização do monitoramento de estradas em larga escala, com aplicações importantes para a conservação e o planejamento regional.

As estradas desempenham um papel fundamental em áreas de ESM, servindo como vetores de acesso a regiões florestais remotas e facilitando o transporte de toras de madeira e equipamentos. Conforme destacado por Botelho *et al.* (2022), a expansão de estradas não oficiais está diretamente associada ao aumento do desmatamento e da degradação florestal, especialmente em áreas de floresta ombrófila densa. A presença de estradas em áreas de ESM não apenas intensifica a pressão sobre os recursos florestais, mas também aumenta o risco de incêndios e fragmentação da paisagem. Portanto, o mapeamento preciso dessas estradas, como realizado no estudo de Botelho *et al.* (2022), é essencial para monitorar e mitigar os impactos da ESM, além de fornecer subsídios para políticas de conservação e gestão sustentável das florestas. A detecção precoce de estradas em áreas de ESM pode ajudar a identificar regiões sob risco de desmatamento, permitindo ações preventivas para proteger a biodiversidade e os estoques de carbono.

Os estudos vêm mostrando que a integração de redes neurais convolucionais com MLME aumenta a acurácia na detecção da ESM, uma vez que a IA é capaz de aprender padrões espaciais e espectrais complexos, enquanto o MLME melhora a separação entre áreas de degradação recente e vegetação preservada (Oliveira *et al.*, 2021). Isso pode ser entendido como processo de sinergia tecnológica que não só aprimora a identificação automática da ESM, como também reduz significativamente a necessidade de validação manual (Nepstad *et al.*, 2020).

Nesse contexto, a combinação entre aprendizado de máquina e modelos de mistura espectral se destaca como um recurso essencial, permitindo que a IA separe os componentes espectrais em pixels de baixa resolução da ESM e aprimore a detecção de sinais sutis de exploração seletiva. Essa abordagem otimiza a identificação de padrões em áreas de floresta, reduzindo o tempo e os recursos necessários para análises detalhadas e tornando o monitoramento mais eficiente e acessível em grandes regiões da Amazônia.

Dessa forma, o avanço no uso de SR aliado à IA e aos modelos de mistura espectral representa um passo fundamental para tornar o monitoramento da Amazônia mais rápido, eficiente e acessível, permitindo respostas mais precoces e assertivas na mitigação dos impactos da exploração seletiva.

Por outro lado, ressalta-se à medida que as atividades de ESM se intensificam, as áreas destinadas para o depósito, manobra dos veículos e carga dos troncos tornam-se mais evidentes. Isso possibilita a detecção de ESM e representa parte das informações importantes que podem ser utilizadas como parâmetros para definir as imagens de satélite e a resolução espacial adequada para evidenciá-las. A figura 06 ilustra o percentual de área registrado para ESM, conforme o sensor analisado no presente estudo.




Figura 6. Área em m<sup>2</sup> compilada para a região amostrada.

Ainda que o sensor WFI apresente uma resolução espacial menor em comparação com os demais sensores, o MLME contribuiu para obter as áreas dos polígonos referentes à ESM. Além disso, ele dispõe de resolução temporal de cinco dias e largura de faixa imageada de 866 km que permitem uma revisita mais frequente à mesma região, o que possibilita o monitoramento em intervalos menores de tempo e cobrindo uma área considerável da floresta Amazônica. Isso demonstra a eficácia do sensor WFI no auxílio à detecção e monitoramento da ESM.

Em um futuro próximo, isso pode fornecer suporte às instituições públicas e privadas que atuam nos segmentos ambientais do Brasil, enriquecendo os protocolos e diretrizes para as ações de ESM. Ao identificar as áreas que estão ocorrendo esse tipo de intervenção, permite o uso de imagens com maior resolução espacial, a fim de direcionar os esforços para mapear e monitorar as

áreas alteradas desde os estágios iniciais e aplicação de sinergias tecnológicas para esta finalidade.

Entretanto, é de suma importância considerar a relação entre a resolução espacial do sensor e a dimensão do impacto ao calcular a área danificada pela ESM, para evitar a superestimação da área afetada. Conforme evidencia-se na figura 07, que mostra o aumento percentual da área do pixel na fração solo para cada sensor analisado. É visível a evolução do SR para a detecção e monitoramento de áreas degradadas na Amazônia, tal ferramenta possibilita avanços incontestáveis no monitoramento do bioma (Silva e Orlanda, 2024).




Figura 7. Percentual de área em m<sup>2</sup> de ESM detectada de acordo com o sensor analisado para a região de estudo

Conforme Peres *et al.* (2006), explicam que a ESM em regiões tropicais é caracterizada pela remoção de árvores com copas predominantes na floresta, de modo a afetar principalmente as regiões de floresta ombrófila. Além disso, Russel *et al.* (1988) afirma que a distribuição da área foliar pode ser medida pela densidade de copas por unidade de volume de espaço no dossel, pois apresentam área de circunferência da copa superior a 40 m<sup>2</sup>. Portanto, com a sua diminuição, aumenta a probabilidade de um feixe de luz chegar ao solo e gerar efeitos de borda devido a fragmentação do bioma.

Esses efeitos de borda indicam que o aumento de luminosidade associado ao estresse hídrico, pode afetar na taxa de crescimento e manutenção do dossel. Isso ocorre, pois, a quantidade de radiação solar absorvida contribui para a perda de umidade local, sendo um fator que facilita a detecção e a ampliação da área de solo mapeada na imagem de fração solo obtida pelo MLME.

Santos e Manzatto (2024) utilizaram imagens de VANT para analisar os efeitos de borda e fragmentação em uma área na Amazônia, e foi evidenciado que esses efeitos intensificam o

estresse foliar nas espécies durante a estação seca, devido à grande luminosidade que entra na área, especialmente no dossel, enquanto, no subdossel a resposta é menos sazonal.

Em alguns trabalhos foram utilizados tecnologia adicional, como é o caso do LIDAR (*Light Detection And Ranging*) no qual os autores (Figueiredo *et al.*, 2014; Papa *et al.*, 2016; Oliveira *et al.*, 2019; Perpétuo *et al.*, 2024), fizeram a incorporação de variáveis como morfometria de copa, que revela elementos importantes para a definição do fuste, com correlação positiva com a área foliar no espaço, obtidos através dessa tecnologia de SR. Esses resultados permitem a obtenção do fuste de árvores para a área amostral, representando a área de cobertura do solo pelo dossel florestal. Portanto, essa técnica pode ser um recurso adicional às técnicas de monitoramento de ESM para avaliar os impactos que podem ocorrer sobre a floresta.

O presente estudo destaca que a radiação solar incidente sobre o dossel florestal, resultante das variações na distribuição da luz em uma área ao longo do tempo, tende a influenciar a variação em seu percentual de resposta. Observou-se através das imagens que a maior concentração de espécies ocorreu em áreas com menor abertura do dossel e maior índice da área foliar. As espécies florestais podem criar micrositios específicos sob suas copas, atuando como filtros para espécies que tentam regenerar abaixo delas. Em função de sua permeabilidade ou impermeabilidade desses micrositios, podem determinar parcialmente a composição e a estrutura da comunidade de plantas sob a projeção da sua copa.

Neste contexto, destaca-se a importância do dossel na influência sobre o ambiente local. A influência indireta na umidade e temperatura do solo também podem afetar o crescimento radicular, as perdas de água por evaporação do solo, a decomposição de resíduos e outros processos, tornando a floresta mais suscetível a incêndios, conforme afirma Nepstad, Moreira e Alencar (1999). Essas informações são significativas e necessitam de uma avaliação mais aprofundada, pois podem auxiliar na definição da resolução espacial a ser utilizada no trabalho em questão.

Entretanto, os impactos provenientes da atividade madeireira ainda permanecem mal compreendidos e requerem uma análise mais detalhada. É crucial a verificação em campo para avaliar os dados obtidos por Sensoriamento Remoto, pois ajuda a estabelecer parâmetros que minimizem a possibilidade de confusão entre as

feições mapeadas em diferentes áreas ou biomas. Essa abordagem pode auxiliar os órgãos governamentais responsáveis pela fiscalização ambiental na região amazônica, bem como no controle e planejamento de áreas destinadas à concessão florestal pelas empresas, conforme destacado por Asner *et al.* (2002), Bensusan (2015), Peres *et al.* (2006) e Aubad *et al.* (2008).

## Conclusão

Com base nos dados analisados, foi possível concluir que os sensores de média resolução espacial, como o OLI e o WFI, apresentaram áreas maiores em comparação com os sensores de menor resolução, o que resultou numa variação de números de polígonos detectados, porém não prejudicando o objetivo do estudo. Isso pode ser atribuído à distância entre as áreas de clareiras causadas pelas ESM, as quais apresentaram um distanciamento de alguns metros. Essa situação pode levar a registros que compreendem o mesmo pixel, podendo englobar áreas adjacentes em um único registro.

A detecção da ESM em grandes áreas da Amazônia por meio de imagens de satélite apresenta desafios técnicos devido à escala da atividade e às características dos sensores orbitais. A extração de árvores individuais ou pequenos grupos não resulta em grandes clareiras, tornando a identificação desse tipo de degradação florestal mais complexa. Fatores como resolução espacial, resolução temporal e largura da faixa de imageamento influenciam diretamente a capacidade de monitoramento remoto da ESM. Entretanto, à medida que essas atividades se intensificam, a sua detecção é perceptível.

Sensores como o WFI apresentam baixa resolução espacial (64 metros), mas possuem alta resolução temporal (frequência de revisita de até cinco dias) e grande cobertura espacial (largura da faixa de imageamento superior a 800 km). Essa combinação permite um monitoramento contínuo e em larga escala, essencial para a detecção de distúrbios florestais na Amazônia. No entanto, a resolução espacial limitada, no âmbito deste trabalho e sem o uso do MLME, dificultaria a identificação dos padrões dos danos decorrentes dessa atividade, como as estradas/trilhas e pátios para estoque/carga das toras de árvores removidas e, inclusive evidenciar a extração seletiva no interior da floresta.

Outro fator que interferiria na detecção da ESM sem a decomposição de pixels, é o

sombreamento gerado pelas copas das árvores remanescentes. Como a extração seletiva mantém grande parte da cobertura florestal, as clareiras resultantes são pequenas e frequentemente obscurecidas pela vegetação ao redor, reduzindo a visibilidade do impacto na imagem de satélite. Além disso, a variação espectral entre vegetação intacta e áreas degradadas é sutil, dificultando a distinção por meio de técnicas convencionais de classificação de imagens.

A interferência de fatores sazonais e eventos naturais também impactaria na análise. A queda natural de folhas, processos de sucessão ecológica e distúrbios como tempestades e deslizamentos de terra poderiam gerar padrões espectrais semelhantes aos da exploração seletiva, aumentando a incerteza na classificação dos dados orbitais.

A aplicação do Modelo Linear de Mistura Espectral (MLME) neste estudo, com o intuito de superar as limitações das ferramentas convencionais, permitiu a extração de frações espectrais representando componentes específicos da cena, como solo exposto, vegetação e sombra. Essa abordagem reduziu os efeitos da resolução espacial limitada ao decompor os pixels mistos, encontrados em regiões de degradação florestal, pois realçam áreas de exposição do solo e variações estruturais associadas ao corte seletivo.

A combinação do sensor WFI com MLME possibilitou a identificação preliminar da exploração seletiva em grandes áreas, permitindo o direcionamento de análises mais detalhadas com sensores de alta resolução. Esse método não se restringe a áreas específicas da Amazônia, podendo ser aplicado a outras regiões de floresta tropical para monitoramento contínuo e além disso, compõe um recurso exitoso de baixo custo com aplicação e análises diversas.

## Agradecimentos

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), à Fundação de Ciência, Aplicações e Tecnologia Espaciais (FUNCATE), à Coordenação Espacial da Amazônia do Instituto Nacional de Pesquisas Espaciais (COEAM/INPE) e ao Programa de Pós-Graduação em Ciências Ambientais do Instituto de Geociências da Universidade Federal do Pará (PPGCA/IG/UFPa).

## Referências

- Achard, F., Eva, H. D., Stibig, H.-J., Mayaux, P., Gallego, J., Richards, T., & Malingreau, J.-P. (2002). Determination of deforestation rates of the world's humid tropical forests. *Science*, 297(5583), 999–1002. <https://doi.org/10.1126/science.1070656>. Acesso: 09 nov. 2023.
- Asner, G. P. (2009). Automated mapping of tropical deforestation and forest degradation: CLASlite. *Journal of Applied Remote Sensing*, 3(1), 033543. <https://doi.org/10.1117/1.3223675>. Acesso: 12 dez. 2023.
- Asner, G. P., Broadbent, E. N., Oliveira, P. J. C., Keller, M., Knapp, D. E., & Silva, J. N. M. (2006). Condition and fate of logged forests in the Brazilian Amazon. *Proceedings of the National Academy of Sciences*, 103(34), 12947–12950. <https://doi.org/10.1073/pnas.0604093103>. Acesso: 02 dez. 2023.
- Asner, G. P., Keller, M., Pereira, R., Jr., & Zweede, J. C. (2002). Remote sensing of selective logging in Amazonia. *Remote Sensing of Environment*, 80(3), 483–496. [https://doi.org/10.1016/S0034-4257\(01\)00326-1](https://doi.org/10.1016/S0034-4257(01)00326-1). Acesso: 11 mai. 2024.
- Aubad, J., Aragón, P., Olalla-Tárraga, M. Á., & Rodríguez, M. Á. (2008). Illegal logging, landscape structure and the variation of tree species richness across North Andean forest remnants. *Forest Ecology and Management*, 255(5–6), 1892–1899. <https://doi.org/10.1016/j.foreco.2007.12.0>. Acesso: 12 dez. 2023.
- Ayres, M., Jr, M. A., Ayres, D. L., & Santos, A. D. A. S. D. (2007, January 15). BIOESTAT – aplicações estatísticas nas áreas das Ciências Bio-Médicas. CNPq. [https://www.researchgate.net/publication/263608962\\_BIOESTAT\\_-\\_aplicacoes\\_estatisticas\\_nas\\_areas\\_das\\_Ciencias\\_Bio-Medicas](https://www.researchgate.net/publication/263608962_BIOESTAT_-_aplicacoes_estatisticas_nas_areas_das_Ciencias_Bio-Medicas). Acesso: 12 dez. 2023.
- Basuki, T. M., Skidmore, A. K., van Laake, P. E., van Duren, I., & Hussin, Y. A. (2012). The potential of spectral mixture analysis to improve the estimation accuracy of tropical forest biomass. *Geocarto International*, 27(4), 329–345. <https://doi.org/10.1080/10106049.2011.634928>. Acesso: 02 mar. 2025.
- Becker, B. (2000). Cenários de Curto Prazo para o Desenvolvimento da Amazônia. *Cadernos IPPUR* [online] 1. Disponível: <https://ippur.com.br/wp->



- content/uploads/2016/05/CI\_Ano\_XIV\_n1\_jan-jul\_2000.pdf. Acesso: 12 dez. 2023
- Bensusan, N. (2015). Conservação da biodiversidade em áreas protegidas. Editora FGV. Acesso: 05 out. 2023
- Blaschke, T., Lang, S., & Hay, G. (2008). Object-Based image analysis: Spatial concepts for knowledge-driven remote sensing applications. Springer Science & Business Media.
- Borges, H. B. N.; Silveira, E. A.; Vendramin, L. N. (2014). Flora Arbórea de Mato Grosso: Tipologias vegetais e suas espécies. Cuiabá-MT: Entrelinhas [digital]. ISBN: 9788579920721. Disponível: [https://www.agroicone.com.br/wp-content/uploads/2019/11/Flora\\_Arborea\\_de\\_Mato\\_Grosso.pdf](https://www.agroicone.com.br/wp-content/uploads/2019/11/Flora_Arborea_de_Mato_Grosso.pdf). Acesso: 05 out. 2023
- Brasil. Grupo de Trabalho Interministerial Plano BR-163 Sustentável, 2006. Plano de Desenvolvimento Regional Sustentável para a Área de Influência da Rodovia BR-163 (Cuiabá-Santarém). Brasília, 2006. Plano BR-163 Sustentável.
- Diniz, C. G., Souza, A. A. de A., Santos, D. C., Dias, M. C., Luz, N. C. da, Moraes, D. R. V. de, Maia, J. S. A., Gomes, A. R., Narvaes, I. da S., Valeriano, D. M., Maurano, L. E. P., & Adami, M. (2015). DETER-B: The new amazon near real-time deforestation detection system. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(7), 3619–3628. <https://doi.org/10.1109/jstars.2015.243707>. Acesso: 05 out. 2023.
- Ehlers, R. S. (2007). Análise de Séries Temporais. Departamento de Estatística, UFPR.
- Fearnside, P. M. (2022). Fogo na Amazônia: Impactos ambientais e sociais (pp. 479–485). In C. W. N. Moura & G. H. Shimizu (Eds.), *Botânica: Para que e para quem?: Desafios, avanços e perspectivas na sociedade contemporânea* (p. 517). Sociedade Botânica do Brasil.
- Figueiredo, E. O., d'Oliveira, M. V. N., Fearnside, P. M., & Papa, D. de A. (2014). Modelos para estimativa de volume de árvores individuais pela morfometria da copa obtida com lidar. *CERNE*, 20(4), 621–628. <https://doi.org/10.1590/01047760201420041693>. Acesso: 05 out. 2023.
- Hethcoat, M. G., Carreiras, J. M. B., Bryant, R. G., Quegan, S., & Edwards, D. P. (2022). Combining Sentinel-1 and Landsat 8 Does Not Improve Classification Accuracy of Tropical Selective Logging. *Remote Sensing*, 14(1), 179. <https://doi.org/10.3390/rs14010179>.
- Homma, Alfredo K. O., 2011. Madeira na Amazônia: extração, manejo ou reflorestamento?. *Amazônia: Ciência & Desenvolvimento* [online] 7. Disponível: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/74185/1/HommaAmazonia.pdf>. Acesso: 12 dez. 2023
- Howard, J. A. (1991). Remote sensing of forest resources: Theory and application. Springer.
- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1–2), 195–213. [https://doi.org/10.1016/s0034-4257\(02\)00096-2](https://doi.org/10.1016/s0034-4257(02)00096-2)
- IBGE. Instituto Brasileiro de Geografia e Estatística (2012). Manual técnico da vegetação brasileira. Rio de Janeiro.
- INPE. Instituto Nacional de Pesquisas Espaciais (2019). Image Catalog. Basic Parameters: seasonal 2019. São José dos Campos.
- INPE. Instituto Nacional de Pesquisas Espaciais (2019). Banco de dados PRODES 2019. São José dos Campos.
- Kirby, K. R., Laurance, W. F., Albernaz, A. K., Schroth, G., Fearnside, P. M., Bergen, S., Venticinque, E. M., & da Costa, C. (2006). The future of deforestation in the Brazilian Amazon. *Futures*, 38(4), 432–453. <https://doi.org/10.1016/j.futures.2005.07.011>. Acesso: 05 out. 2023.
- Lambin, E. F., Geist, H. J., & Lepers, E. (2003). Dynamics of land-use and land-cover change in tropical regions. *Annual Review of Environment and Resources*, 28(1), 205–241. <https://doi.org/10.1146/annurev.energy.28.050302.105459>. Acesso: 09 nov. 2023.
- Lang, S.; Blaschke, T. (2009). Análise da Paisagem com SIG. Tradução Hermann Kux. São Paulo. Oficina de Textos.
- Marengo, J. A., Liebmann, B., Kousky, V. E., Filizola, N. P., & Wainer, I. C. (2001). Onset and end of the rainy season in the Brazilian Amazon Basin. *Journal of Climate*, 14(5), 833–852. [https://doi.org/10.1175/1520-0442\(2001\)014<0833:OAEOTR>2.0.CO;2](https://doi.org/10.1175/1520-0442(2001)014<0833:OAEOTR>2.0.CO;2)
- Matricardi, E. A. T., Skole, D. L., Cochrane, M. A., Qi, J., & Chomentowski, W. (2005). Monitoring selective logging in tropical evergreen forests using landsat: Multitemporal regional analyses in Mato Grosso, Brazil. *Earth Interactions*, 9(24), 1–

24. <https://doi.org/10.1175/ei142.1>. Acesso: 05 out. 2023.
- Matricardi, E. A. T., Skole, D. L., Pedlowski, M. A., Chomentowski, W., & Fernandes, L. C. (2010). Assessment of tropical forest degradation by selective logging and fire using Landsat imagery. *Remote Sensing of Environment*, 114(5), 1117–1129. <https://doi.org/10.1016/j.rse.2010.01.001>. Acesso: 05 out. 2023.
- Moreira, M. A. (2007). Fundamentos do sensoriamento remoto e metodologias de aplicação. Editora da UFV.
- Morettin, P. A., & Bussab, W. O. (2024). Estatística básica (10ª ed., rev. e amp.). Editora Saraiva.
- Myers, N. (1988). Tropical deforestation and remote sensing. *Forest Ecology and Management*, 23(2–3), 215–225. [https://doi.org/10.1016/0378-1127\(88\)90083-7](https://doi.org/10.1016/0378-1127(88)90083-7).
- Nepstad, D. C., Verssimo, A., Alencar, A., Nobre, C., Lima, E., Lefebvre, P., Schlesinger, P., Potter, C., Moutinho, P., Mendoza, E., Cochrane, M., & Brooks, V. (1999). Large-scale impoverishment of Amazonian forests by logging and fire. *Nature*, 398(6727), 505–508. <https://doi.org/10.1038/19066>. Acesso: 05 out. 2023.
- Nepstad, D. C., Moreira, A. G., & Alencar, A. A. (1999). A floresta em chamas: Origens, impactos e prevenção de fogo na Amazônia.
- Oliveira, M. V. N. d', Figueiredo, E. O., Papa, D. de A., & Pantoja, N. (2019). Obtaining information to subsidize annual production units definition in forest management plans through the combination of ground plots, LiDAR data and satellite images. <http://www.alice.cnptia.embrapa.br/alice/handle/doc/1113336>. Acesso: 27 fev. 2025
- Papa, D. d. A., Figueiredo, E. O., Oliveira, M. V. N. d. (2015). Volumetria de árvores dominantes e co-dominantes a partir de dados LiDAR aerotransportado. <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1038722/1/25957.pdf>. Acesso: 02 mar. 2025.
- Peres, C. A., Barlow, J., & Laurance, W. F. (2006a). Detecting anthropogenic disturbance in tropical forests. *Trends in Ecology & Evolution*, 21(5), 227–229. <https://doi.org/10.1016/j.tree.2006.03.007>. Acesso: 05 out. 2023
- Pettorelli, N., Vik, J. O., Mysterud, A., Gaillard, J.-M., Tucker, C. J., & Stenseth, N. Chr. (2005). Using the satellite-derived NDVI to assess ecological responses to environmental change. *Trends in Ecology & Evolution*, 20(9), 503–510. <https://doi.org/10.1016/j.tree.2005.05.011>
- Ponzoni, F. J., Shimabukuro, Y. E., & Kuplich, T. M. (2012). Sensoriamento remoto da vegetação. Oficina de Textos.
- Romero, F. M. B., Jacovine, L. A. G., Torres, C. M. M. E., Ribeiro, S. C., de Moraes Junior, V. T. M., da Rocha, S. J. S. S., Romero, R. A. B., Gaspar, R. de O., Velasquez, S. I. S., Staudhammer, C. L., Ferreira Neto, J. A., Vidal, E., & Fearnside, P. M. (2021). Forest management with reduced-impact logging in Amazonia: Estimated aboveground volume and carbon in commercial tree species in managed forest in Brazil's state of acre. *Forests*, 12(4), 481. <https://doi.org/10.3390/f12040481>. Acesso: 12 dez. 2023.
- Russell, G.; Jarvis, P. G.; Monteith, J. L. (1988). Absorption of radiation by canopies and stand growth. In: Russell, G., Marshall, B., Jarvis, P.G. (Eds.), *Plant Canopies: Their Growth, Form and Function*. Cambridge University Press, Cambridge, UK.
- Santos, J. R.; Krug, T.; Araujo, L. S. (2002). Corte de árvores vistas do espaço. *Ciência Hoje [digital]* 30. Disponível: <https://cienciahoje.org.br/edicao/179/>. Acesso: 05 out. 2023
- Santos, H. G., et al. (2023). Proposta de atualização da 5ª edição do Sistema Brasileiro de Classificação de Solos. Embrapa Solos. ISSN 1517-2627.
- Santos, R. P. dos, & Manzatto, A. G. (2024). Monitoramento fenológico em um fragmento de floresta de terra firme em Porto Velho (RO): Efeitos de borda e da fragmentação. *OBSERVATÓRIO DE LA ECONOMIA LATINOAMERICANA*, 22(10), e7141. <https://doi.org/10.55905/oelv22n10-090>. Acesso: 28 fev. 2025
- Shimabukuro, Y. E., Dutra, A. C., & Arai, E. (2020). Modelo Linear de Mistura Espectral: Conceitos Teóricos, Algoritmos e Aplicações em Estudos na Amazônia Legal. *Revista Brasileira de Cartografia*, 72, 1140–1169. <https://doi.org/10.14393/rbcv72nespecial50anos-56559>. Acesso: 12 dez. 2023
- Shimabukuro, Y. E., & Smith, J. A. (1991). The least-squares mixing models to generate fraction images derived from remote sensing multispectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 29(1), 16–20. <https://doi.org/10.1109/36.103288>. Acesso: 05 out. 2023.

- Souza Barros, Q., Linhares Ferreira, E. J., Mafra Rodrigues, N. M., Barros de Oliveira, E. K., & de Mesquita Pinheiro, R. (2024). Análise Bibliométrica sobre a Aplicação do LiDAR Aerotransportado no Manejo de Impacto Reduzido na Amazônia. *Revista Cereus*, 16(1), 131–146. <https://doi.org/10.18605/2175-7275/cereus.v16n1p131-146>. Acesso: 26 fev. 2025
- Souza, C. M., Jr., Roberts, D. A., & Cochrane, M. A. (2005). Combining spectral and spatial information to map canopy damage from selective logging and forest fires. *Remote Sensing of Environment*, 98(2–3), 329–343. <https://doi.org/10.1016/j.rse.2005.07.013>. Acesso: 05 out. 2023.
- Souza, J. V. de, Matricardi, E. A. T., Pedlowski, M. A., Miguel, E. P., & Pereira, R. S. (2024). Avaliação espaço-temporal da exploração seletiva de madeiras no estado do Pará, Brasil. *Ciência Florestal*, 34(2), e71255. <https://doi.org/10.5902/1980509871255>. Acesso: 23 fev. 2025
- Silva, V. P. da, & Orlanda, J. F. F. (2024). Evolução temporal do sensoriamento remoto no contexto da detecção de áreas degradadas na Amazônia: uma revisão sistemática. *Revista Da Casa Da Geografia de Sobral (RCGS)*, 26(1), 169–182. <https://doi.org/10.35701/rcgs.v26.922>. Acesso em: 27 fev. 2025.
- Stone, T. A., & Lefebvre, P. (1998). Using multi-temporal satellite data to evaluate selective logging in Para, Brazil. *International Journal of Remote Sensing*, 19(13), 2517–2526. <https://doi.org/10.1080/014311698214604>. Acesso: 09 mai. 2024.
- Su, S.-C. (2001). Efficient intensity-hue-saturation-based image fusion with saturation compensation. *Optical Engineering*, 40(5), 720. <https://doi.org/10.1117/1.1355956>. Acesso: 09 mai. 2024.
- Wang, C., Qu, L., Yang, L., Liu, D., Morrissey, E., Miao, R., Liu, Z., Wang, Q., Fang, Y., & Bai, E. (2021). Large-scale importance of microbial carbon use efficiency and necromass to soil organic carbon. *Global Change Biology*, 27(10), 2039–2048. <https://doi.org/10.1111/gcb.15550>. Acesso: 27 fev. 2025.