

Identificação de Infraestruturas de Exploração Florestal em Uma Área de Manejo Sustentável por Meio de Imagens OLI/Landsat 8 e MSI/Sentinel-2

Identification of Forest Exploitation Infrastructures in a Sustainable Management Area Using OLI/Landsat 8 and MSI/Sentinel-2 Images

Arthur Gutemberg Andion Farias Moura¹, Evandro Ferreira da Silva², Quétila Souza Barros³, Fábio Miranda Leão⁴, Jeangelis Silva Santos⁵, Arien Hiusaki de Moura Santos⁶

RESUMO

As infraestruturas florestais são essenciais para as atividades de exploração de madeira, no entanto, geram impactos ambientais. Assim, esse trabalho buscou analisar a viabilidade de identificação de infraestruturas da exploração florestal em uma área de Manejo Florestal Sustentável (MFS) por meio de dados de sensoriamento remoto e técnicas de geoprocessamento. Foram aplicadas dez técnicas: cinco Índices de Vegetação (NDVI, TDVI, TVI, RATIO e SAVI), duas Componentes do Modelo Linear de Mistura Espectral (fração solo e vegetação) e dois componentes da Transformação Tasseled Cap (Wetness e Greenness), em imagens Landsat 8 e Sentinel-2, para detecção de infraestruturas florestais construídos em uma área de MFS na Floresta Nacional (FLONA) Saracá-Taquera, Pará. A componente Wetness da Transformação Tasseled Cap aplicada a imagem sentinel-2 teve melhor resultado para o índice kappa e acurácia global, com valor de 0,93 e 83,60, respectivamente. Em relação a fotointerpretação, as técnicas com melhor desempenho foram Wetness da Transformação Tasseled Cap e o NDVI aplicados a imagem Sentinel-2, o TVI na imagem Landsat 8 e a fração Solo do Modelo Linear de Mistura Espectral. Com base nesses resultados foi possível identificar com sucesso infraestruturas florestais como estradas primárias e secundárias, utilizando essas técnicas aplicadas em imagens de média resolução.

Palavras-chave: Exploração seletiva. Índices de vegetação. Transformação Tasseled Cap. Modelo linear de mistura espectral. Infraestruturas florestais.

ABSTRACT

Forest infrastructures are essential for logging activities, but they also generate environmental impacts. This study aimed to analyze the feasibility of identifying logging infrastructure in a Sustainable Forest Management (SFM) area using remote sensing data and geoprocessing techniques. Ten techniques were applied, including five Vegetation Index (NDVI, TDVI, TVI, RATIO and SAVI), two Linear Spectral Mixture Model components (soil and vegetation fraction) and two Tasseled Cap Transformation (Wetness and Greenness) components, on Landsat 8 and Sentinel-2 images, to detect forest infrastructures built in a SFM area in the Saracá-Taquera National Forest (FLONA), Pará. The Wetness Tasseled Cap Transformation applied to the Sentinel-2 image had the great results for the kappa index and overall accuracy, a value of 0.93 and 83.60 respectively. In relation photointerpretation, the best performing techniques were from the Tasseled Cap Transformation Wetness and NDVI applied to the Sentinel-2 image, TVI in the Landsat 8 image and the Linear Spectral Mixture Model Soil Fraction. Based on these results, it was possible to successfully identify forest infrastructures such as primary and secondary roads using these techniques applied to medium resolution images.

Keywords: Selective Exploration. Vegetation Index. Tasseled Cap Transformation. Linear Spectral Mixture Model. Forestry Infrastructures.

¹ Doutorando em Ciências Ambientais – Universidade Federal do Pará (UFPA).
E-mail: arthurandio@gmail.com

<https://orcid.org/0000-0002-2218-1266>

² Doutor em Ciências Florestais pela Universidade Federal do Espírito Santo.
E-mail: evandrofs@ufpa.br
<https://orcid.org/0000-0001-5948-6402>

³ Doutora em Ciências Florestais - Instituto Nacional de Pesquisas da Amazônia (INPA), Núcleo de estudos do Acre.
E-mail: quetilabarros@gmail.com
<https://orcid.org/0000-0001-7486-3384>

⁴ Doutor em Ciências Florestais pela Universidade Federal Rural da Amazônia.
E-mail: fabioleao@ufpa.br
<https://orcid.org/0000-0002-3258-8748>

⁵ Doutor em Ciências Florestais pela Universidade Federal do Espírito Santo.
<https://orcid.org/0000-0003-4785-7573>
jeangelis@gmail.com

⁶ Discente Programa de Pós-Graduação em Biodiversidade e Conservação (PPGBC).
<https://orcid.org/0000-0002-7474-7516>
moura.arien.hiu@gmail.com

1. INTRODUÇÃO

O Manejo Florestal Sustentável (MFS) consiste na administração da floresta para obtenção de benefícios econômicos, sociais e ambientais, respeitando-se os mecanismos de sustentação do ecossistema (BRASIL, 2006; FERRONATO et al., 2018; RODRIGUES et al., 2020). O MFS visa aplicar técnicas adequadas de manejo florestal e de Exploração de Impacto Reduzido para reduzir os danos negativos causados na área do empreendimento florestal (SILVA; ALMEIDA; POMPERMAYE, 2014; LOCKS e MATRICARDI, 2019; FAGUNDES, 2020; SILVA et al., 2020).

Na fase de implementação do manejo florestal, a abertura das infraestruturas florestais temporárias, ou seja, pátios de estocagem, estradas primárias e secundárias e trilhas de arraste de toras, geram impactos na floresta e causam alterações que afetam negativamente o funcionamento do ecossistema (KELLER; SILVA, 2004; EMMERT, 2014; PINAGÉ; MATRICARDI, 2015; FRANÇA, 2017; ASNER; MORETTI, 2018). Dessa forma, o monitoramento em áreas de floresta sob regime de manejo florestal pode ser realizado em tempo hábil e com baixo custo financeiro com o uso de geotecnologias (SALLO et al., 2014; MORETO ET AL., 2021).

Em áreas de florestas públicas sob regime de concessão florestal, que se refere à delegação onerosa dada pelo poder concedente, do direito de praticar manejo florestal sustentável e exploração de produtos e serviços, o Serviço Florestal Brasileiro (SFB), órgão responsável pela fiscalização, adota diversos mecanismos de monitoramento em áreas de manejo, dentre eles, o uso de sistemas de sensoriamento remoto e de imagens de satélites integradas em um sistema de informação geográfica (SIG) (Espírito-Santo; Santos; Silva, 2002; Brasil, 2006). As abordagens baseadas em sensoriamento remoto são de baixo custo, oferecem uma oportunidade para mapear mudanças florestais em áreas extensas, além de serem base para a elaboração políticas públicas ambientais (PINAGÉ e MATRICARDI, 2015; SILVEIRA et al., 2017; BILAR; PIMENTEL; CERQUEIRA, 2018).

Dentre as técnicas conhecidas, a mistura espectral é usada para detectar a exploração seletiva de madeira na floresta amazônica (MONTEIRO; SOUZA; BARRETO, 2003). Bullock et al. (2020) utilizaram um sistema de séries temporais de dados Landsat e análise de mistura espectral para detectar degradação e desmatamento em paisagens florestadas. A mistura espectral ocorre quando o mesmo pixel possui duas ou mais

classes espectrais (água e solo ou vegetação e solo, por exemplo), sendo que a resultante da resposta da reflectância refletida dessas classes em uma combinação de todas as respostas espectrais, destes membros de referência ou “end-members” (ROBERTS et al., 2002; FREITAS; HAERTEL; SHIMABUKURO, 2018; Ceccato et al., 2021).

Além disso, surgiu a técnica Tasseled Cap como um índice de vegetação, desenvolvido por Kauth e Thomas (1976), a qual as características de reflectância mais significativas para o estudo de vegetação, obtendo bandas correspondentes de brilho (brightness), verdor (greenness) e umidade (wetness) (VASCONCELOS; HADAD; MARTINS, 2014; LENCINAS; MOHR-BELL, 2007).

Os índices de vegetação (IV), são obtidos a partir da combinação da banda do vermelho e do infravermelho próximo para deduzir informações a respeito do estado da vegetação (BERTUCINI; SILVA, 2017; GAIDA et al., 2016; WANG et al., 2023). Os índices de vegetação são usados para analisar as propriedades espectrais da vegetação e calculados por operações aritméticas entre bandas, especificamente a vermelha na região do visível e a do infravermelho próximo, devido ao comportamento antagônico da reflectância da vegetação nestas regiões espectrais, além de serem utilizados para fins de pesquisa, planejamento e monitoramento da superfície terrestre.

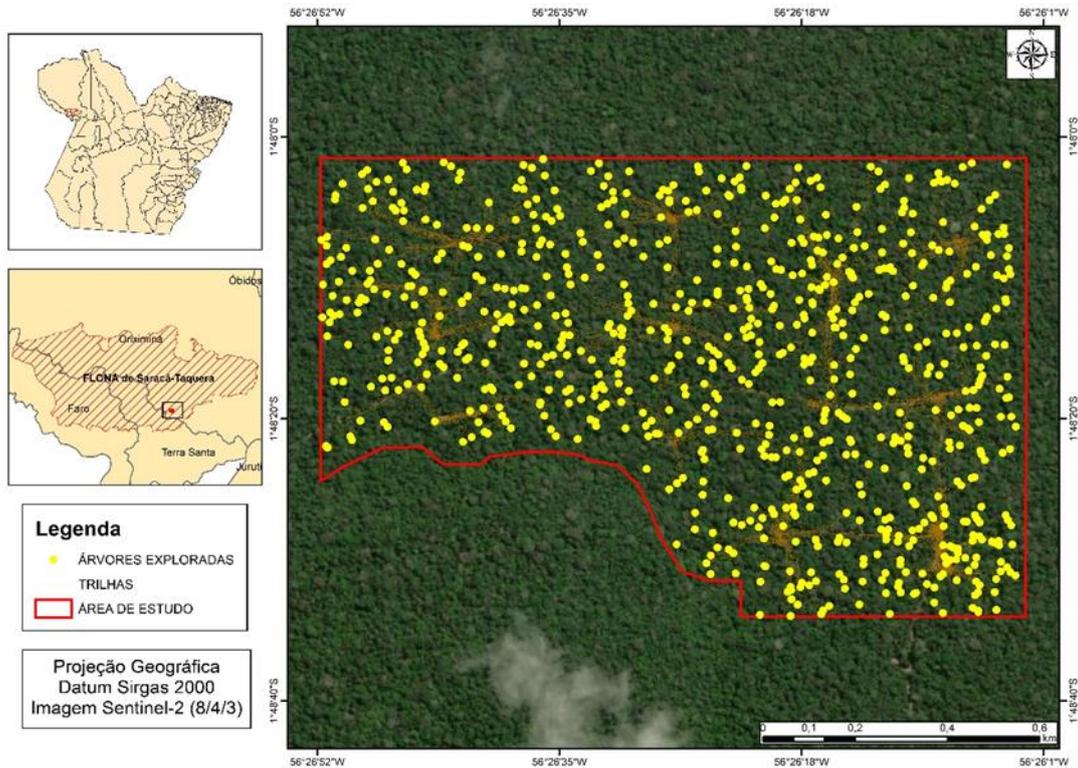
Segundo Barni et al. (2021) vários índices espectrais foram desenvolvidos ou adaptados para melhorar o mapeamento de áreas que sofreram ações antrópicas, como NDVI, SAVI, RATIO, TVI e o TDVI. Segundo Xue e Su (2017) e Bandeira e Cruz (2021) os índices de vegetação são algoritmos simples e eficazes para monitorar o vigor e a dinâmica da vegetação terrestre, os quais permitem uma melhor obtenção e compreensão dos parâmetros biofísicos da vegetação, tais como a biomassa e a cobertura de solo.

Portanto, este trabalho buscou identificar por meio de imagens de satélite e técnicas de geoprocessamento a viabilidade de identificação de infraestruturas da exploração florestal em uma área de Exploração de Impacto Reduzido.

2. MATERIAIS E MÉTODOS

Área de estudo

A área de estudo (Figura 1) está localizada na Floresta Nacional (FLONA) Saracá-Taquera, distrito de Porto Trombetas, município de Oriximiná, Pará. Situada entre as coordenadas geográficas 1°20' e 1°55' de latitude Sul e 56°00' e 57°15' de longitude Oeste,



Datum Sirgas 2000. A Unidade de manejo florestal (UMF)-1A foi cedida à empresa EBATA Produtos Florestais de forma legal através do instrumento de concessão florestal, concorrência N° 02/2012, promovida pelo Serviço Florestal Brasileiro (SFB), nos termos da Lei n° 11.284/2006 e do Decreto n° 6.063/2007 e detém certificação Forest Stewardship Council (FSC®).

Figura 1. Localização da área de estudo situada na FLONA Saracá-Taquera, Oriximiná, Terra Santa e Faro, Pará, Brasil.

A área de aplicação do estudo denominada de Área de Planejamento (AP), pertence a Unidade de Manejo Florestal 1A, está localizada na Unidade de Produção anual (UPA) 04/2018, na Unidade de Trabalho (UT) 02. A UT-2 possui 355,55 ha, dos quais 126,41 ha foram analisados por meio do monitoramento de 11 pátios explorados. No planejamento da infraestrutura de exploração e durante a exploração foram empregadas as técnicas de exploração de impacto reduzido.

Etapas metodológicas

O fluxograma metodológico representa as etapas necessárias para o desenvolvimento da pesquisa (Figura 2).

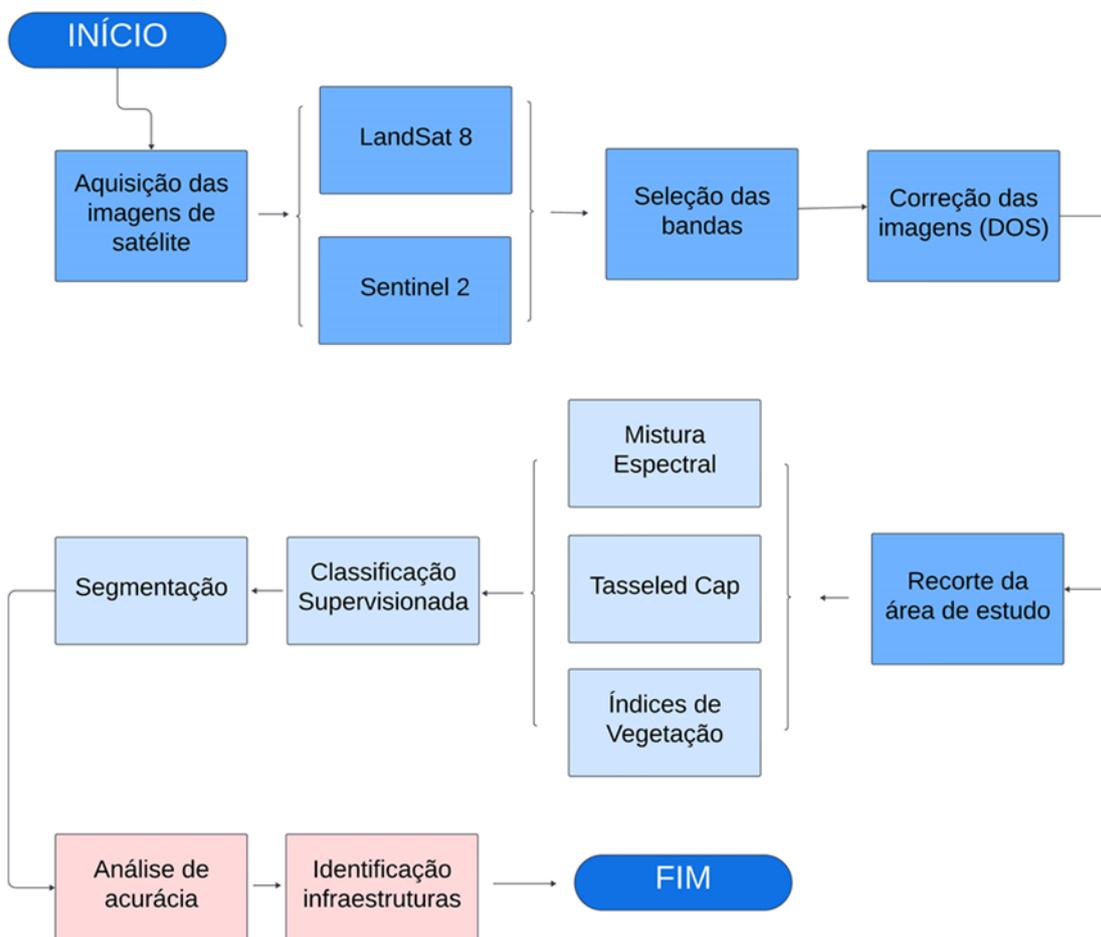


Figura 2. Esquematização da metodologia utilizada no estudo.

Dados GPS acoplado no Skkider

Para se avaliar a movimentação do Skidder (trator florestal) dentro da área de exploração, foi empregado um aparelho de Global Positioning System (GPS) modelo Garmin 76 CSx, o qual foi acoplado ao Skidder para monitorar seu percurso. Após a coleta dos dados, as informações obtidas pelo GPS foram transformadas em shapefile, o que permite produzir mapas que representam o percurso do arraste das árvores do local de corte até os pátios de estocagem e identificar com melhor precisão as infraestruturas alocadas.

Imagens de Satélite, Seleção das Bandas e Correção DOS

As imagens do satélite Sentinel-2 e Landsat 8 foram obtidas de forma gratuita na plataforma GloVis (Global Visualization Viewer) do United States Geological Survey (USGS) da NASA (National Aeronautics and Space Administration). As imagens de satélite foram adquiridas em duas datas distintas: uma antes do início da exploração florestal, que ocorreu em julho de 2018, e outra após a exploração. Duas resoluções espaciais foram utilizadas: as imagens Sentinel-2 em sua resolução de 10 metros, e as imagens Landsat-8 com 30 metros e 15 metros na banda pancromática. As informações das imagens Landsat 8 e Sentinel-2 utilizadas estão apresentadas na Tabela 1.

Tabela 1. Informações das imagens de satélite.

Satélite/Constelação	Órbita/ponto	Data de aquisição	Período
Landsat-8	228/061	15/06/2018	Antes da exploração
Sentinel-2	21MWJ	29/06/2018	Antes da exploração

A atmosfera diminui o contraste da imagem e dificulta a diferenciação e identificação de pequenos objetos na imagem (NOVO, 2010). Neste trabalho será abordado o método empírico de Subtração de Objetos Escuros (DOS, sigla em inglês Dark Object Subtraction), que é um método de correção atmosférica. Esse método assume que em qualquer imagem há uma grande probabilidade de existir alguns pixels completamente escuros, ou seja, com zero valor de reflectância. Além disso, este processo é utilizado para o cálculo dos índices de vegetação (MACHADO, 2020).

O processamento das imagens dos satélites foi realizado conforme a metodologia de Machado (2020). A correção atmosférica das imagens OLI/Landsat-8 e MSI/Sentinel-2 foram processadas aplicando o processamento DOS no software QGIS 3.10.4 com auxílio da ferramenta Preprocessing do *plugin* Semi-Automatic Classification, nesta etapa é adicionada as bandas das imagens de satélites para que sejam corrigidas pelo *plugin*. O recorte da área de estudo foi realizado por meio da ferramenta de recorte, deixando somente a feição da área de estudo.

Para as imagens LandSat 8 foi realizado a fusão das bandas multiespectrais e a banda pancromática com o objetivo de melhorar a resolução das imagens com o auxílio da ferramenta *Band set do plugin Semi-Automatic Classification*. Nas imagens do MSI/Sentinel-2 foi realizado o empilhamento das bandas de melhor resolução espacial (10 m, ou seja, as bandas 2, 3, 4 e 8).

Índice de Vegetação da Diferença Normalizada (NDVI)

O NDVI foi um dos primeiros índices de vegetação desenvolvidos nos estudos de caracterização e de monitoramento da vegetação e é amplamente utilizado em diferentes abordagens para estudos agrícolas, monitoramentos florestais e climáticos (Moraes et al., 2016; Ferreira, Ferreira, Ferreira, 2008). O índice varia de -1 a 1 e está diretamente relacionado com o vigor da vegetação, logo, valores próximos de 1 indicam vegetação mais vigorosa e valores próximos a 0 indicam solo exposto e/ou áreas urbanas e valores negativos a presença de água (GUEDES, 2018; MACHADO, 2020; COSTA; RIBEIRO; ALBUQUERQUE, 2020).

O NDVI é calculado por meio da Equação 1:

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

Índice de Razão Simples (RATIO)

O RATIO (Equação 2) foi desenvolvido por Rouse et al. (1974) com o objetivo de separar a vegetação do solo. O índice detecta o contraste existente entre as bandas do vermelho e do infravermelho para os pixels da vegetação (Coutinho et al., 2016). Quando o valor for elevado, entende-se que existe baixa reflectância no vermelho (ocasionado pela absorção da clorofila) e alta reflectância no infravermelho (devido a estrutura das folhas), produzindo um parâmetro que é altamente sensível à presença de vegetação (GONÇALVES, 2018; GALVANIN et al., 2014 e BERGER et al., 2019).

$$RATIO = \frac{NIR}{RED} \quad (2)$$

Índice de Vegetação da Diferença Transformado (TDVI)

TDVI é um índice de desenvolvimento de vegetação do NDVI, com maior correlação com a biomassa, para evitar valores negativos. Além disso, o TDVI pode minimizar o efeito da refletividade do solo e é capaz de corrigir todos os problemas radiométricos, como desvios de sensores e efeitos atmosféricos e tem sido usado como indicadores lineares da cobertura vegetal, ao contrário do NDVI e do SAVI, que ficam saturados com as propriedades ópticas do solo (RANJAN et al., 2019 e BANNARI; ASALHI; TEILLET, 2003), esse índice é representado pela Equação 3:

$$TVDI = \sqrt{0,5 + \frac{NIR - RED}{NIR + RED}} \quad (3)$$

Índice de Vegetação Transformado (TVI)

O TVI é um índice utilizado em cenas com baixa densidade de vegetação e a diferença normalizada pode resultar em valores negativos (GALVANIN et al., 2014). Os valores do TVI não costumam se diferenciar dos valores do NDVI, no caso do TVI é adicionado o fator 0,5, que gera valores positivos para os índices que serão gerados. Valores superiores a 0,6 refletem vegetação e enquanto esse valor próximo a 1 representará material vegetal com maior acúmulo de clorofila (BARAHONA et al., 2022). O TVI é obtido por meio da Equação 4:

$$TVI = \sqrt{NDVI + 0,5} \quad (4)$$

Índice de Vegetação Ajustada ao Solo (SAVI)

O SAVI tem o objetivo de minimizar os efeitos do solo no sinal da vegetação e incorporar uma constante de ajuste do solo (Rêgo et al., 2012). O índice é utilizado para quantificar a perda/ganho da cobertura vegetal e permite mensurar a densidade de fitomassa foliar fotossinteticamente ativa e o nível de umidade por unidade de área, além de enfatizar a influência de solo exposto, especialmente no período seco (SANTOS, 2018; BANDEIRA; CRUZ, 2021). O fator L (Equação 5) foi proposto por Huete (1985) e sugere o fator L de 1,0; para cobertura vegetal intermediária fator 0,5, e para altas densidades de vegetação fator 0,25. Quando o valor L for igual a zero, o índice SAVI equivalerá ao índice NDVI.

$$SAVI = \frac{NIR - RED}{NIR + RED + L} * (1 + L) \quad (5)$$

Transformação Tasseled Cap (TCT)

O Tasseled Cap (TCT) é técnica de sensoriamento remoto que seleciona as características de refletância mais significativas para o estudo de vegetação. O TCT fundamenta-se no contraste espectral entre a vegetação e os atributos de solos (Vasconcelos; Haddad; Martins, 2013). A TCT resulta da combinação linear de todas as bandas espectrais do satélite Landsat e é um método que permite a redução da informação espectral em menor número de bandas, que representam variáveis físicas (INSAURRALDE, 2019; SHI; XU, 2019). Para o satélite LandSat 8, os valores correspondentes em cada banda do satélite do sensor OLI foram retirados de Baig et al. (2014), que estabeleceu um coeficiente de transformação para cada banda (Tabela 2).

Tabela 2. Coeficiente de Transformação Tasseled Cap aplicados ao satélite Lansat 8.

Componente	Banda 2 (Blue)	Banda 3 (Green)	Banda 4 (Red)	Banda 5 (NIR)	Banda 6 (SWIRI)	Banda 7 (SWIRII)
Brightness	0,3290	0,2786	0,4733	0,5599	0,508	0,1872
Greenness	-0,2941	-0,243	-0,5424	0,7276	0,0713	-0,1608
Wetness	0,1511	0,1973	0,3283	0,3407	-0,7117	-0,4559

Fonte: Baig et al., 2014.

As equações para o cálculo das componentes para o sensor OLI (LandSat-8) estão representadas nas Equações 6, 7 e 8:

$$\text{Wetness} = (B2 * 0,1511) + (B3 * 0,1973) + (B4 * 0,3283) + (B5 * 0,3407) + (B6 * -0,7117) + (B7 * 0,4559) \quad (6)$$

$$\text{Greenness} = (B2 * -0,2941) + (B3 * -0,243) + (B4 * -0,5424) + (B5 * 0,7276) + (B6 * 0,0713) + (B7 * 0,1608) \quad (7)$$

$$\text{Brightness} = (B2 * 0,3029) + (B3 * 0,2786) + (B4 * 0,4733) + (B5 * 0,5599) + (B6 * 0,5080) + (B7 * 0,1872) \quad (8)$$

Para o sensor MSI Sentinel foram utilizados os valores do estudo de Shi (2019), conforme detalhado na Tabela 3.

Tabela 3. Coeficiente de transformação Tasseled Cap aplicados ao Sentinel-2.

Componente	Banda 2 (Blue)	Banda 3 (Green)	Banda 4 (red)	Banda 8 (NIR)	Banda 11 (SWIRI)	Banda 12 (SWIRII)
Brightness	0,3510	0,3813	0,3437	0,7196	0,2396	0,1949
Greenness	0,3599	-0,3533	-0,4734	0,6633	0,0087	-0,2856
Wetness	0,2578	0,2305	0,0883	0,1071	-0,7611	-0,5308

Fonte: Shi e Xu, 2019.

O cálculo das componentes SAR (Sentinel-2) foram utilizadas as equações 9, 10 e 11 **Erro! Fonte de referência não encontrada.:**

$\text{Wetness} = (B2 * 0,2578) + (B3 * 0,2305) + (B4 * 0,0883) + (B5 * 0,1071) + (B6 * -0,7611) + (B7 * 0,5308)$	(9)
$\text{Greenness} = (B2 * -0,3599) + (B3 * -0,3533) + (B4 * -0,4734) + (B5 * 0,6633) + (B6 * 0,087) + (B7 * 0,2856)$	(10)
$\text{Brightness} = (B2 * 0,3510) + (B3 * 0,3813) + (B4 * 0,3473) + (B5 * 0,7196) + (B6 * 0,2396) + (B7 * 0,1949)$	(11)

Modelo Linear de Mistura Espectral

O Modelo Linear de Mistura Espectral (MLME), proposto por Shimabukuro e Smith (1991), é uma técnica que permite realçar algumas feições da imagem por meio da geração das imagens fração, sendo mais usuais as frações do solo, da vegetação e de sombra. A utilização do MLME tem se mostrado uma técnica eficaz para o mapeamento de florestas degradadas, principalmente por possibilitar a separação entre as frações solo e vegetação.

De acordo com Shimabukuro et al. (2014) a fração de vegetação derivada do MLME apresenta características semelhantes ao NDVI, permitindo assim destacar a cobertura vegetal. Enquanto a fração solo permite realçar áreas de solo exposto, facilitando a

identificação de áreas onde ocorrem cortes seletivos e cortes rasos. Por outro lado, a fração sombra realça os corpos d'água e áreas cuja geometria visada contemplem sombreamentos (DINIZ, 2020). O MLME pode ser representada matematicamente pelas equações 12 e 13 apresentadas a seguir:

	$\sum F_i = F_1 + F_2 + F_3 = 1$	(12)
	$DN_\lambda = F_{1vegeta\lambda,1} + F_{2solo\lambda,2} + F_{3agua\lambda,3} + E_\lambda$	(13)

No presente trabalho foi utilizado o software TerraView 5.6.3 para processar as componentes do MLME. No TerraView, essa técnica permite a decomposição de um raster em imagens de frações, indicando a proporção de cada componente presente em um pixel. Essa técnica é utilizada em imagens de satélite, onde um único pixel pode conter mais de um alvo, como vegetação, sombra ou água e solo. Para realizar essa decomposição é necessário ter um arquivo raster, um mapa de *endmembers* puros (que são valores de pixel onde a proporção exata de um componente é conhecida) e informações do sensor para cada banda. Existem dois métodos disponíveis dentro desse software para o MLME: Linear e PCA. Nesta pesquisa foi utilizado o método Linear, que pode ser calculado por meio de um método de mínimos quadrados e restrito para 3 componentes e 4 bandas. O produto dessa técnica foi salvo como um novo *layer* no projeto do TerraView.

Segmentação das Imagens e Classificação Supervisionada

Após o cálculo dos índices de vegetação, MLME e do TCT, foi aplicado a técnica de segmentação. A segmentação de imagem é uma técnica de agrupamento de dados, na qual somente as regiões espacialmente adjacentes podem ser agrupadas (VIDAL; NETO; ALEIXO, 2018). A segmentação tem sido amplamente utilizada nos procedimentos de classificação de imagens de satélite (PEREIRA, 2018). Essas representações do comportamento médio das classes que serão mapeadas automaticamente, onde torna-se de suma importância que as amostras de treinamento sejam bastante homogêneas (MOURA, 2021). Dessa forma, para os índices de vegetação, TCT e MLME a segmentação foi aplicada com o objetivo de colher amostras nas variações dos resultados das técnicas calculadas e serão *input* no processo de classificação, sendo utilizadas as imagens de satélite na composição de cor verdadeira para validar as amostras de áreas de floresta e não floresta.

A metodologia de classificação supervisionada refere-se quando existe um conhecimento prévio de algumas áreas que deseja trabalhar, o que permite a seleção de amostras de treinamento confiáveis por meio da fotointerpretação manual, obtendo amostras por meio de técnicas como a segmentação (LAGE, 2021). A segmentação foi desenvolvida no plugin OTB (OrfeoToolbox provider), o qual identificou os recursos ou segmentos nas imagens, agrupando pixels adjacentes que tenham características espectrais semelhantes. Para tal, nos algoritmos de classificação são informados, previamente pelo analista, as áreas para extrair as feições de mesmo interesse em um espaço multidimensional (BRODT, 2022).

O método de classificação supervisionada foi processado no software QGIS 3.24 por meio do algoritmo Classificação da Máxima Verossimilhança no *plugin Semi-Automatic Classification* (LILLESAND e KIEFFER, 1994) que calcula o vetor médio, variância e a correlação para cada classe nos dados de treinamento (CURRAN, 1985). Essas técnicas foram empregadas para todos os índices de vegetação, TCT e no MLME. Após a aplicação da segmentação, foi gerado uma imagem com variações de cor, desde o branco ao cinza, em que foram criados 10 (dez) polígonos para a classe de floresta e 10 (dez) polígonos para a classe de solo exposto, e como produto, obteve-se a imagem com a classificação supervisionada.

Validação e Análise de Acurácia

O processamento da acurácia foi realizado utilizando a extensão AcATaMa disponível no software Qgis 3.14, que permite calcular a matriz confusão com base nas classes escolhidas pelo usuário (floresta e não floresta). Inicialmente é necessário selecionar a imagem ou área na qual serão analisados os padrões de acurácia (LLANO, 2023)., neste trabalho, foi utilizado o planejamento das infraestruturas florestais.

Em seguida é identificado o *raster* gerado dos índices de vegetação, do TCT e do MLME dentro da ferramenta, e posteriormente identificar a classe das amostras a serem geradas pelo próprio plugin acerca de cada classe da classificação validada pela imagem em cor natural, foram analisadas 396 amostras distribuídas de forma proporcional ao tamanho em área de cada categoria, gerando um mapa de pontos. Após esse processo, o mesmo *plugin* direciona estas informações para que seja realizado um processo de validação manual, resultando em informações do padrão de acurácia global.

Como produto dessas etapas, obtém-se a matriz confusão (MC). A MC foi construída através da informação verdadeira das amostras de teste, o que significa que se assume como verdade que todos os pixels das amostras de teste pertencem à classe a que foram atribuídos (DALPOSSO et al., 2021). Neste trabalho foram utilizadas duas classes: Floresta e não floresta. Os resultados foram analisados a partir da acurácia global, do erro de comissão (acurácia do usuário), omissão (acurácia do produtor) e índice kappa.

O índice kappa é uma medida estatística de concordância entre dois avaliadores que atribuem uma variável categórica a um conjunto de amostras. Os valores do coeficiente de Kappa variam de 0 a 1, sendo que, quanto mais perto de 1 representa uma concordância maior entre os pontos de referência e as categorias classificadas (CORREIA et al., 2007; SANTOS e LIMA, 2019). A confiança dos resultados adquiridos nesse artigo foi analisada de acordo com os intervalos dos valores de kappa propostos por Landis e Koch (1977), conforme detalhado na Tabela 4.

Tabela 4. Escala do Índice Kappa.

Índice Kappa	Concordância
< 0,00	Péssima
0,00 – 0,20	Ruim
0,21-0,40	Razoável
0,41-0,60	Moderada
0,61-0,80	Considerável
0,81-1,00	Excelente

Fonte: Adaptado de Landis e Koch (1977).

A acurácia global (Equação 14) expressa o total de acertos em relação ao total de amostras da imagem classificada (VIEIRA e VIANA, 2021).

	$Ag = \frac{a}{n} * 100$	(14)
--	--------------------------	------

Os erros de comissão (Equação 15) se referem aos pixels atribuídos a uma determinada classe, oriundos de erros de classificação das outras classes. A acurácia do produtor (Equação 16) refere-se aos erros de exclusão/ omissão; isto é, os erros de classificação de outras classes não são atribuídos a uma determinada classe. O índice Kappa (17) é usado para a verificação global de concordância entre as amostras de referência das classes usadas e os resultados dos classificadores usados (Silva; Andrade, Pacheco, 2016).

$$Ec = \frac{X + i - Xii}{X + i} \tag{15}$$

$$Eo = \frac{Xi_+ - Xii}{X_+} \quad (16)$$

$$k = \frac{N * \sum Xii - \sum Xi * X + i}{N^2 - \sum Xi_+ * X + i} \quad (17)$$

Fotointerpretação Manual

Posterior a classificação supervisionada, realizou-se uma fotointerpretação do resultado das técnicas de geoprocessamento aplicadas às imagens Landsat-8 e Sentinel-2. Foram criados arquivos vetoriais de estradas primárias, secundárias e pátios de estocagem, de acordo com cada técnica, no software QGIS 3.14. Para mapear as infraestruturas, utilizou-se critérios convencionais de fotointerpretação como a cor, tamanho, textura, posição, sombra, padrão e forma. Foi aplicada uma escala de 1:2.000 em todas as técnicas. Após o processamento da segmentação, classificação supervisionada e fotointerpretação manual, o método que obteve melhor detecção das infraestruturas florestais foi utilizado como método para a validação.

3. RESULTADOS

As classificações Supervisionadas geradas a partir das 16 técnicas aplicadas mostraram as infraestruturas florestais diferentes para cada métrica utilizada. Os resultados da classificação supervisionada mostraram que a técnica é viável para estudar a estimativa de impacto gerado na área de manejo, como por exemplo a abertura de clareiras decorrentes do abate das árvores exploráveis. No entanto, a ferramenta não é eficaz em detectar as infraestruturas florestais devido, geralmente, estarem localizadas abaixo do dossel. Dessa forma, para o processo de validação foi escolhida a fotointerpretação manual, porque apresentou melhor performance na identificação das infraestruturas.

A classificação supervisionada auxiliou na geração da acurácia de cada técnica. As classificações geradas a partir da aplicação das técnicas nos dois conjuntos de imagens de satélites mostraram resultados diferentes para as resoluções espaciais, entre as imagens Sentinel-2 e Landsat-8. O componente Wetness da transformação Tasseled Cap aplicado ao Sentinel-2 e o índice SAVI aplicada a imagem LandSat 8, apresentaram os melhores resultados para o índice Kappa (0,93 e 0,91 respectivamente). Em relação aos resultados (Figura 3), os menores valores foram os índices RATIO (Landsat 8) e TDVI (Sentinel-2), com 0,64 e 0,70 respectivamente. As demais técnicas tiveram valores intermediários.

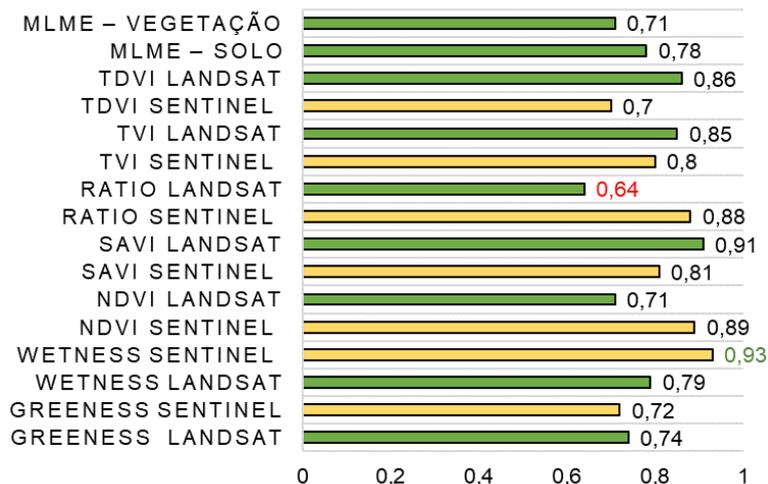


Figura 3. Valores máximos e mínimos para o Índice Kappa.

O melhor resultado para a acurácia global obtido com a componente Wetness e no NDVI aplicados ao Sentinel-2, com uma resposta de 97,47% em ambos, enquanto o menor resultado encontrado, discrimina o valor de 83,60 ao NDVI da imagem Landsat-8, conforme a Figura 4.

As demais estatísticas geradas apresentadas na matriz de confusão também seguiram esse padrão. Em relação a matriz de confusão gerada para a classe de interesse do mapeamento (não Floresta), os valores de acurácia do produtor em alguns casos foram menores que os valores da classe de floresta, variando de 94,86% (RATIO da Landsat-8) a 73,77% (Greeness do Sentinel-2). Já para a acurácia do usuário, os valores para a classe de interesse oscilaram os valores máximos e mínimos, se encontraram nas técnicas aplicadas ao sentinel-2, o valor mais alto foi de 98,36% (NDVI) e o mais baixo de 83,53 (TDVI).

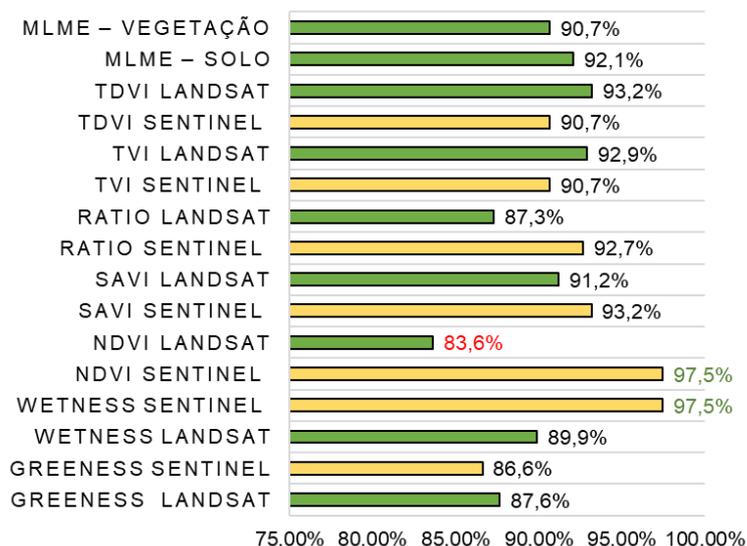


Figura 4. Valores máximos e mínimos para a acurácia global.

Além da análise estatística obtida com a matriz de confusão, é importante também analisar visualmente o resultado das classificações. Com base nos arquivos vetoriais fornecidos, foi possível quantificar o tamanho das estradas primárias, secundárias e a localização dos pátios de estocagem, que são 1,86 km, 1,84 km e 11 km, respectivamente. Embora a fotointerpretação manual exige maior tempo de processamento, o método garantiu uma precisão maior na interpretação das IF. Comparando-se às fontes de dados, as imagens de 10 m de resolução espacial (Sentinel-2) obtiveram identificação das infraestruturas mais eficiente.

As métricas extraídas das imagens de satélites que melhor identificaram visualmente as infraestruturas florestais foram o componente o TCT Wetness e o NDVI, aplicados ao Sentinel-2, TVI para o LandSat-8 e o MLME fração solo na imagem Landsat 8. As técnicas fizeram uma aproximação da quantidade real de pátios de estocagem (**Erro! Fonte de referência não encontrada.**), ainda assim, as imagens do Sentinel-2 com resolução de 10 m tiveram mais acertos em relação ao planejamento da exploração. A comparação na Figura 5 permite visualizar a identificação das estradas primárias, secundárias e os pátios de estocagem, no resultado respectivo de sua técnica de geoprocessamento utilizada.

Tabela 5. Valores das técnicas empregadas para cada Infraestrutura Florestal.

Técnica	Estrada Primária (km)	Diferença (km)	Estrada Secundária (km)	Diferença (km)	Pátio de Estocagem	Diferença (unid)
PE	1,86		1,84		11	
NDVI L8	1,89	0,03	1,61	-0,23	9	-2
SAVI L8	1,87	0,01	1,57	-0,27	9	-2
TVI L8	1,86	0,00	1,51	-0,33	9	-2
TDVI L8	1,87	0,01	1,63	-0,21	9	-2
RATIO L8	1,85	-0,01	2,09	0,25	12	1
NDVI S2	1,86	0,00	1,93	0,09	11	0
SAVI S2	1,90	0,04	1,48	-0,36	10	-1
TVI S2	1,84	-0,02	2,07	0,23	10	-1
TDVI S2	1,88	0,03	1,69	-0,15	12	1
RATIO S2	1,89	0,03	2,19	0,35	13	2
MLME Solo	1,86	0,00	1,78	0,06	10	-1
MLME Veg	1,89	0,03	1,66	-0,18	9	-1
TCT Wetness L8	1,85	-0,01	1,44	-0,40	8	-3
TCT Greenness L8	1,88	0,03	1,18	-0,66	13	2
TCT Wetness S2	1,86	0,00	2,46	0,62	13	2
TCT Greenness S2	1,89	0,03	2,04	0,20	11	0

Fonte: Autoria própria, 2023.

A fotointerpretação contempla a análise integrada de diversos fatores, em que profissionais especializados ponderam o conjunto de informações para identificar elementos pertinentes ao contexto. Em determinadas circunstâncias, observou-se a detecção de áreas adicionais em relação ao planejamento executado pela empresa. Tal ocorrência pode ser atribuída à interpretação equivocada das técnicas aplicadas devido à semelhança espectral entre a abertura de pátios de estocagem e abertura de dossel.

Além disso, pode ser observado o resultado do Modelo Linear de Mistura Espectral, embora não tenha apresentado resultados satisfatórios no índice kappa e na acurácia global, esta técnica é utilizada pelo SFB, no Sistema de Detecção da Exploração Seletiva (DETEX), que realiza o mapeamento de áreas abertas e da extração seletiva em florestas de manejo. Para isso são geradas as imagens fração do solo, vegetação e sombra (PINHEIRO; MUNIZ, 2019). Com o uso de imagens de média resolução espacial (Landsat-8), é possível detectar essas áreas usando a imagem fração solo gerada pelo modelo linear de mistura espectral. A fração solo gerada para a área de estudo (Figura 5 – MLME Solo), foi a que melhor representou a estrada primária e algumas secundárias o que permitiu o mapeamento manual e mais preciso dessas infraestruturas.

Foi possível identificar a estrada primária dentro da área de estudo com as feições do solo resultante do MLME. Essa técnica ainda permite que os órgãos de fiscalização mapeiem áreas onde houve supressão vegetal. A identificação de estradas primárias foi evidente, no entanto, a técnica não foi satisfatória para detectar as estradas secundárias e

pátios de estocagem. Foram identificados 10 (dez) pátios ao todo na técnica do MLME em relação ao total de pátios de estocagem no planejamento de exploração fornecido pela EBATA (11 pátios). Em relação às estradas secundárias, foi possível fazer um mapeamento manual com base nos atributos da fotointerpretação como coloração, pixel e área.

Figura 5. Comparação das técnicas na detecção da infraestrutura florestal com base na fotointerpretação.

4. DISCUSSÃO

Nos resultados encontrados no trabalho, os altos valores do índice Kappa sugerem que a detecção da infraestrutura florestal nas imagens Landsat 8 e Sentinel-2 tem alta concordância aos dados de referência, que representam a realidade de campo. A extensão dos alvos em relação à resolução espacial das imagens explica esses resultados, ou seja, muitos alvos apresentam dimensões inferiores a 15 metros, resolução espacial do sensor OLI. Contudo, as imagens de satélite são eficazes para identificar perturbações, como estradas e grandes operações de corte raso (WASSEIGE e DEFOURNY, 2004).

Alguns trabalhos corroboram que as imagens Sentinel-2 apresentam melhores resultados no índice kappa, na acurácia global e na fotointerpretação. No trabalho realizado por Monteiro (2005) foi observado ganho de informações sobre os pátios e as estradas à medida que a resolução espacial das imagens se tornou maior. O resultado obtido por Silva (2003) identificou que a alta resolução espacial está associada à maior discriminação dos elementos, portanto, maior número de observações.

A baixa performance de determinadas métricas em relação ao índice kappa e acurácia global, pode estar relacionada à complexidade da classificação dessas imagens. Em muitos trechos elas não apresentam largura suficiente para abrir o dossel florestal e mostrar a porção de solo exposto, como acontece nas estradas secundárias, pois os sensores passivos não são eficientes em áreas altamente vegetadas (BUJÁN et al., 2021).

Os valores de acurácia do produtor (A_p) e do usuário (A_u) indicam que o mapeamento da infraestrutura florestal foi constante, com baixas taxas de omissão para a classe área explorada concentradas nas áreas de estradas. Esses aspectos são de difícil detecção, especialmente na exploração de impacto reduzido, realizados em áreas de manejo florestal. A identificação do corte seletivo é consideravelmente mais desafiadora em comparação com o corte raso, devido a formação de um padrão de floresta interrompido por clareiras

decorrentes da derrubada de árvores, bem como por estradas principais, secundárias e pátios de estocagem (WASSEIGE e EFOURNY, 2004). Entretanto, os melhores resultados identificados nas métricas extraídas das imagens Sentinel-2 é explicado por apresentar resolução maior que as imagens do Landsat-8. Ainda segundo Wasseige e Defourny (2004) sensores de satélite com melhor resolução são fontes eficazes de informações na detecção e monitoramento de atividades de extração seletiva de madeira.

Nas imagens geradas a partir da classificação supervisionada, as infraestruturas se mostraram bastante descontínuas, apesar da acurácia global e do índice kappa elevados em algumas técnicas, devido a classificação supervisionada estar relacionada a identificação de áreas mais definidas e evidentes. Segundo Grande, Almeida e Cicerelli (2016), o processamento é orientado à objetos, que se baseia na segmentação e classificação supervisionada para fornecer subsídios à interpretação de imagens de sensoriamento remoto. Nessa classificação são usados, como unidade de processamento, objetos segmentados com base em características comuns de forma, textura, espectro, vizinhança e geometria. Estes atributos são incorporados na classificação. Apesar da fotointerpretação utilizar características semelhantes como forma, geometria e coloração, esta etapa possui o conhecimento prévio por parte do analista. Segundo Prendes et al. (2019), com o uso de técnicas de fotointerpretação e sensoriamento remoto, a principal dificuldade reside na resolução das imagens, que, em alguns casos, não é adequada para identificar faixas muito estreitas. Além disso, enfrenta-se o desafio de obter informações das áreas situadas abaixo das copas das árvores, resultando em descontinuidades nas linhas centrais das estradas florestais.

Ao analisar os resultados da fotointerpretação, o mapeamento das infraestruturas florestais é mais evidente, no entanto, demanda maior esforço de recursos humanos. Embora a fotointerpretação não elimine a subjetividade e, aparentemente, seja mais demorada do que um procedimento de classificação automática ou semiautomática, essa técnica adotada proporciona alta produtividade, significativa resolução de dúvidas e considerável precisão (MACEDO et al., 2018), além disso, o método mais acurado para identificar estradas (BRANDÃO e SOUZA, 2005).

Neste estudo, as imagens do tipo Sentinel-2 mostraram ter um ganho de informação quando se refere a perturbações causadas pelas infraestruturas florestais (Tabela 5), no qual as imagens Sentinel-2 tiveram maior acurácia quando comparado as imagens Landsat

8, corroborado pelo estudo desenvolvido por Varade e Dikshit (2018), onde os dados do Sentinel-2 resultaram imagens muito mais nítidas, especialmente devido às bandas de resolução de 10 m. Essa resolução espacial permitiu reconhecer melhor os elementos individuais, como florestas danificadas, e outras classes de cobertura da terra. Lastovicka et al, (2020) mostraram a comparação da resolução espacial do Landsat 8 (30 m) e Sentinel-2 (20 e 10 m), as áreas de interesse detectadas pelo Sentinel-2 com resolução espacial de 10 m permitiu reconhecer a estrutura mais detalhada da paisagem, como estradas, grupos de árvores e cortes rasos.

Dentre as três técnicas do MLME, o produto da fração solo foi a que melhor evidenciou as infraestruturas florestais, apesar de não terem apresentado um bom resultado no índice kappa e na Acurácia global. No trabalho de Souza et al. (2001), por meio de imagens Landsat, forneceram informações acuradas, atualizadas e de melhor escala para modelos de custo de superfície, além da interpretação visual de imagem de fração de solo e a metodologia aplicada reproduziu com maior perfeição as estradas. A metodologia do DETEX não visa a quantificação das infraestruturas florestais na área de manejo florestal, o sistema mapeia a exploração seletiva de madeira, utilizando técnicas de sensoriamento remoto, mesmo sendo uma tarefa mais complexa do que mapear o desmatamento, já que os sinais da exploração seletiva são menos evidentes.

Segundo Shimabukuro, Dutra e Arai (2020), na medida em que a floresta se torna degradada com a remoção das árvores, as proporções das frações de solo tornam-se mais visíveis, pois a perda da cobertura do dossel e as proporções de vegetação reduzem, quando comparados às proporções dessas frações em florestas intactas. Com isso, o uso das imagens fração solo auxiliaram na detecção de estradas de exploração devido ao comportamento espectral dessas áreas, permitindo a melhor discriminação dessas áreas (BRASIL, 2022).

Desse modo, o mapeamento da ocorrência de degradação e possíveis alterações em florestas naturais têm sido facilitada por meio das técnicas de sensoriamento remoto. Contudo, ao analisar as áreas exploradas, por meio de manejo florestal, a importância de identificação das infraestruturas é crucial para alinhar o planejamento apresentado ao órgão e o executado em campo, o que possibilita identificar possíveis desconformidades com o projeto inicial.

Na concessão florestal, as empresas concessionárias são escolhidas por processo de

concorrência pública, que avalia as propostas técnica e de preço recebidas. Em contrapartida ao direito de manejar a área, as concessionárias repassam periodicamente ao governo valores pré-estabelecidos pelo contrato firmado. A execução dos contratos é minuciosamente acompanhada pelo Serviço Florestal Brasileiro por meio de ferramentas de monitoramento florestal. O Brasil tem uma área de 1,050 milhão de hectares passíveis de ser manejadas, enfatizando os esforços para melhorar o monitoramento das operações florestais, bem como buscar compatibilizar o planejamento da exploração com a execução (BRASIL, 2022).

As imagens ópticas podem ser utilizadas no monitoramento, identificando o corte seletivo em florestas tropicais através da fotointerpretação, possibilitando a detecção de infraestruturas florestais. As estradas primárias e pátios de estocagem, são detectáveis em ambas as imagens de satélites através da fotointerpretação, no entanto, a detecção de estradas secundárias é reduzida devido estarem localizadas abaixo do dossel. As imagens Landsat-8 são adequadas para a análise de superfície e para o monitoramento de áreas de manejo. Contudo, quando se trata do âmbito da análise visual de imagens, nota-se que as imagens Sentinel-2 apresentam maior detalhamento em função da maior resolução espacial das imagens.

Demonstramos a identificação das infraestruturas utilizando sensores diferentes e técnicas de geoprocessamento variadas em conjunto com a fotointerpretação, para uma abertura florestal no ano de 2018. Embora a detecção das infraestruturas possa ser reduzida devido a resolução das imagens de satélite, é possível que o órgão gestor, com o conhecimento prévio da área de manejo, use a metodologia para validar a execução e fiscalizar as mudanças que possam ocorrer no planejamento da exploração licenciado

Porém, o monitoramento por imagem de satélite não substitui o monitoramento da exploração florestal realizado no campo, pois são complementares. A utilização de outros sensores como LIDAR, RADAR e Imagens Planet de 3m de resolução, podem melhorar a detecção das infraestruturas florestais, uma vez que os sensores ópticos tem suas limitações.

5. CONSIDERAÇÕES FINAIS

O uso integrado de sistemas de informação geográfica, sensoriamento remoto e geoprocessamento possibilita a obtenção e análise dos dados relacionados a paisagem, facilitando o monitoramento da cobertura florestal, a detecção de áreas degradadas, como ocorre na exploração de impacto reduzido em uma área de manejo florestal. A acurácia

global máxima obtida na detecção da infraestrutura florestal obtida nesta análise foi de aproximadamente 83,60%, com a utilização do índice de vegetação NDVI e do componente Wetness na imagem Sentinel-2, com resolução espacial de 10 metros. Em relação aos valores do índice Kappa, as técnicas mostraram uma boa avaliação, com uma máxima de 0,93 do componente Wetness aplicado ao Sentinel-2.

O monitoramento remoto tem a vantagem de localizar de forma rápida e precisa as áreas críticas, como as de exploração ilegal e de exploração com manejo de baixa qualidade. Quanto aos indicadores de manejo avaliados no campo neste estudo, eles demonstram ser úteis para validar o monitoramento remoto da exploração florestal e avaliar a qualidade das operações de manejo florestal pelas empresas concessionárias.

REFERÊNCIAS

- ASNER, G. P.; KELLER, M.; SILVA, J. N. M. Spatial and temporal dynamics of forest canopy gaps following selective logging in the eastern Amazon: Canopy Gaps in logged Amazon Forest. **Global change biology**, v. 10, n. 5, p. 765–783, 2004. <https://doi.org/10.1111/j.1529-8817.2003.00756.x>.
- BAIG, M. H. A. et al., Water mapping through Universal Pattern Decomposition Method and Tasseled Cap Transformation. **2014 IEEE Geoscience and Remote Sensing Symposium**, 2014, pp. 4758-4760,. <https://doi.org/10.1109/IGARSS.2014.6947557>.
- BANDEIRA, T. V.; DA CRUZ, M. L. B., Estudo da cobertura vegetal do município de Guaiuba/CE com base na utilização dos índices de vegetação SAVI e NDVI. **Geosul**, v. 36, n. 78, p. 410-433, 2021. <https://doi.org/10.5007/2177-5230.2021.e73138>.
- BANNARI, A.; ASALHI, H.; TEILLET, P. M. Transformed difference vegetation index (TDVI) for vegetation cover mapping. **International Geoscience and Remote Sensing Symposium**. Anais, 2003.
- BARAHONA, A. M. G. et al. Aplicación de índices vegetales (banda roja e infrarrojo cercano) en plantaciones de aguacate. **Siembra**, v. 9, n. 1, 2022. <https://doi.org/10.29166/siembra.v9i1.3371>.
- BARNI, P. E. et al., Logging Amazon forest increased the severity and spread of fires during the 2015–2016 El Niño. **Forest Ecology and Management**, v. 500, p. 119652, 2021. <https://doi.org/10.1016/j.foreco.2021.119652>.
- BERGER, Rute et al. Índices de vegetação para a estimativa do índice de área foliar em plantios clonais de *Eucalyptus saligna* Smith. **Ciência Florestal**, v. 29, p. 885-899, 2019. <https://doi.org/10.5902/1980509816942>.
- BERTUCINI J, J. J.; SILVA C, J. A. Detecção de alterações em alvos agrícolas e florestais empregando índices de vegetação em uma série multitemporal de imagens landsat. **Revista Brasileira de Cartografia**, v. 69, n. 6, 2017. <https://doi.org/10.14393/rbcv69n6-44306>.

BILAR, A. B. C.; PIMENTEL, R. M. DE M.; CERQUEIRA, M. A., Monitoramento da cobertura vegetal através de índices biofísicos e gestão de áreas protegidas. **Geosul**, v. 33, n. 68, p. 236–259, 2018. <https://doi.org/10.5007/2177-5230.2018v33n68p236>.

BUJÁN, S. et al. Forest road detection using LiDAR data and hybrid classification. **Remote sensing**, v. 13, n. 3, p. 393, 2021. <https://doi.org/10.3390/rs13030393>.

BRANDÃO, A. O. J.; SOUZA, C. M., Avaliação de imagens Landsat para identificação e extração de estradas madeireiras. Anais XII SBSR, Goiânia, Brasil, 16-21 abril 2005, INPE, p.3503-3509.

BRASIL, Lei nº 11.284, de 02 de março de 2006. Dispõe sobre a gestão de florestas para a produção sustentável; institui, na estrutura do Ministério do Meio Ambiente, o Serviço Florestal Brasileiro–SFB; 3 mar. 2006. Acesso em: 26 jul 2023.

BRODT, André Augusto. Processamento digital de imagens aplicado à análise dendrológica de *Araucaria angustifolia* (Bertol.) Dissertação (Mestrado) - Universidade Estadual do Rio Grande do Sul, Curso de Mestrado Profissional em Ambiente e Sustentabilidade, Unidade Hortênsias. 2022.

BULLOCK, E. L.; WOODCOCK, C. E.; OLOFSSON, P. Monitoring tropical forest degradation using spectral unmixing and Landsat time series analysis. **Remote sensing of Environment**, v. 238, p. 110968, 2020. <https://doi.org/10.1016/j.rse.2018.11.011>.

CECCATO, G. Z. et al. Avaliação dos valores de erro do modelo linear de mistura espectral em imagens etm+/landsat 7 a partir de reamostragens pelo vizinho mais próximo e convolução cúbica. **Geosciences/Geociências**, v. 40, n. 03, p. 795-810, 2021. <https://doi.org/10.5016/geociencias.v40i3.15071>.

COUTINHO, M A. N. et al. Análise comparativa dos índices de vegetação NDVI, SAVI, RATIO E IAF para identificação de queimadas. **Caderno de Ciências Agrárias**, v. 8, n. 1, p. 70-81, 2016.

CORREIA, V. R. de M., et al. Uma aplicação do sensoriamento remoto para a investigação de endemias urbanas. **Cadernos de Saúde Pública**, v. 23, p. 1015-1028, 2007. <https://doi.org/10.1590/S0102-311X2007000500004>.

COSTA, G. J. A.; RIBEIRO, K. V.; ALBUQUERQUE, E. L. S. Aplicação do Índice de Vegetação por Diferença Normalizada (NDVI) na avaliação da cobertura vegetal do município de Regeneração, Estado do Piauí, Brasil. **Revista Geonordeste**, n. 2, p. 230-246, 2020. <https://doi.org/10.35701/rcgs.v21n2.602>.

Curran, P. Principles of Remote Sensing, London: Longman, 1985, 282 pp.

DALPOSSO, G. H. et al. Comparison measures of maps generated by geostatistical methods. **Engenharia agrícola**, v. 32, n. 1, p. 174–183, 2012. <https://doi.org/10.1590/S0100-69162012000100018>.

DINIZ, J. M. F. de S. et al. Avaliação do Sentinel-2, NDVI e MLME para **Mapeamento do Uso e Cobertura da Terra**. Anuário do Instituto de Geociências - UFRJ, v. 43, n. 2, p. 381–391, 21 Ago 2020. <https://doi.org/10.1590/S0100-69162012000100018>.

EMMERT, F. (2014). COMBINAÇÃO DE DADOS DE CAMPO E MÉTODOS COMPUTACIONAIS PARA O PLANEJAMENTO DA EXPLORAÇÃO FLORESTAL NA

- AMAZÔNIA. Tese de Doutorado em Ciências Florestais, Publicação PPGEFL.TD – 041/2014. Departamento de Engenharia Florestal, Universidade de Brasília, DF, 190p.
- FAGUNDES, S. T. S. et al., Monitoramento da floresta a curto prazo em área de concessão florestal na Amazônia Ocidental. **Revista Ibero-Americana de Ciências Ambientais**, v. 11, n. 5, p. 55-62, 2020. <https://doi.org/10.6008/CBPC2179-6858.2020.005.0006>.
- FERREIRA, L. G.; FERREIRA, N. C.; FERREIRA, M. E. Sensoriamento remoto da vegetação: evolução e estado-da-arte. **Acta scientiarum. Biological sciences**, v. 30, n. 4, 2008. <https://doi.org/10.4025/actascibiolsci.v30i4.5868>.
- FERRONATO, M. L. et al. Manejo florestal Sustentável e a mastofauna amazônica: O caso da fazenda Manoa, Rondônia, Brasil. **Revista Brasileira de Ciências da Amazônia/Brazilian Journal of Science of the Amazon**, v. 7, n. 2, p. 9-18, 2018. <https://doi.org/10.47209/2317-5729.v.7.n.2.p.9-18>.
- FRANÇA, J. U. B. Biodiversidade arbórea e estoque de carbono em áreas verdes urbanas: contribuições para a infraestrutura verde de São Paulo, SP. 2017.
- FREITAS, R.; HAERTEL, V.; SHIMABUKURO, Y.E. Modelo linear de mistura espectral em imagem de moderada resolução espacial. **Boletim de Ciências Geodésicas**, v. 14, n. 1, p. 55-71, 2008.
- GALVANIN, E. A. S. et al. Avaliação dos índices de vegetação ndvi, sr e tvi na discriminação de fitofisionomias dos ambientes do pantanal de Cáceres/mt. **Ciência Florestal**, v. 24, n. 3, p. 707–715, 2014. <https://doi.org/10.5902/1980509815729>.
- GRANDE, T. O. DE; ALMEIDA, T. DE; CICERELLI, R. E. Classificação orientada a objeto em associação às ferramentas reflectância acumulada e mineração de dados. **Pesquisa Agropecuária Brasileira**, v. 51, n. 12, p. 1983–1991, 2016. <https://doi.org/10.1590/s0100-204x2016001200009>.
- GUEDES, J.; SILVA, S. M. P. Sensoriamento remoto no estudo da vegetação: princípios físicos, sensores e métodos. **Acta Geográfica**, v. 12, n. 29, p. 127-144, 2018. <https://doi.org/10.18227/2177-4307.acta.v12i29.4001>.
- GAIDA, W. et al. Variações da reflectância e dos índices de vegetação em função dos parâmetros da modelagem topográfica no Parque Estadual do Turvo, Rio Grande do Sul, Brasil. **Investigaciones Geograficas**, v. 2016, n. 91, p. 105–123, 2016. <https://doi.org/10.14350/rig.52159>.
- GONÇALVES, Anny Francielly Ataide. ESTIMAÇÃO DE CARACTERÍSTICAS DENDROMÉTRICAS PARA FLORESTA ESTACIONAL SEMIDECIDUAL SUBMONTANA COM O USO DE DADOS OLI E SRTM. Dissertação (Mestrado em Ciências Florestais) - Universidade Federal do Espírito Santo, Centro de Ciências Agrárias e Engenharias. Jerônimo Monteiro – ES, p. 98. 2018.
- HUETE, A. R.; JACKSON, R. D.; POST, D. F. Spectral response of a plant canopy with different soil backgrounds. **Remote sensing of environment**, v. 17, n. 1, p. 37-53, 1985. [https://doi.org/10.1016/0034-4257\(85\)90111-7](https://doi.org/10.1016/0034-4257(85)90111-7).
- INSAURRALDE, J. A. Aplicación de la transformación Tasseled Cap en la generación de información temática a partir de las imágenes satelitales del Lándsat 8 (OLI). **GeoFocus Revista Internacional de Ciencia y Tecnología de la Información Geográfica**, v. 24, p. 515–524, 30 Dez 2019. <https://doi.org/10.21138/GF.587>.

KAUTH, R. J.; THOMAS, G. S.. The Tasselled Cap — A Graphic Description of the Spectral-Temporal Development of Agricultural Crops as Seen by LANDSAT. In: Symposium On Machine Processing Of Remotely Sensed Data, 1, 1976, West Lafayette. Proceedings. West Lafayette: Purdue University, 1976. p. 41 - 51.

LAGE, Mariana de Oliveira. **Identificação e classificação de áreas urbanas propícias à existência de criadouros do mosquito *Aedes Aegypti* via sensoriamento remoto.** Tese de Doutorado. Universidade de São Paulo (2021).

LASTOVICKA, J., et al. Sentinel-2 data in an evaluation of the impact of the disturbances on forest vegetation. **Remote sensing**, v. 12, n. 12, p. 1914, 2020. <https://doi.org/10.3390/rs12121914>.

LLANO, X. C. **AcATaMa — QGIS Python Plugins Repository.** Disponível em: <<https://plugins.qgis.org/plugins/AcATaMa/>>. Acesso em: 23 ago. 2023.

LENCINAS, J. D.; MOHR-BELL, D. Estimación de clases de edad de las plantaciones de la provincia de Corrientes, Argentina, con base en datos satelitales Landsat. **Bosque (Valdivia)**, v. 28, n. 2, 2007. <https://doi.org/10.4067/S0717-92002007000200003>.

LILLESAND, T. M.; KIEFER, R. W. Remote sensing and image interpretation. 2. ed. Chichester: John Wiley & Sons, 1994. 750 p.

LOCKS, C. J.; MATRICARDI, E. A. T. Estimativa de impactos da extração seletiva de madeiras na Amazônia utilizando dados LIDAR. **Ciência Florestal**, v. 29, n. 2, p. 481–495, 2019. <https://doi.org/10.5902/1980509826007>.

MACEDO, R. DE C. et al. Land use and land cover mapping in detailed scale: a case study in santa rosa de lima-sc. **Boletim de Ciências Geodésicas**, v. 24, n. 2, p. 217–234, 2018. <https://doi.org/10.1590/s1982-21702018000200015>.

MACHADO, A. M. B. Comparação de Imagens OLI/LANDSAT-8 E MSI/SENTINEL-2 no Mapeamento de Uso e Cobertura da Terra na Ilha do Maranhão. **Revista Equador**, v. 9, n. 3, p. 209-232, 2020. <https://doi.org/10.26694/equador.v9i3.10451>.

MONTEIRO, A. L.; SOUZA, C. M., Jr; BARRETO, P. Detection of logging in Amazonian transition forests using spectral mixture models. **International journal of remote sensing**, v. 24, n. 1, p. 151–159, 2003. <https://doi.org/10.1080/01431160305008>.

MONTEIRO, André Luiz Silva. MONITORAMENTO DE INDICADORES DE MANEJO FLORESTAL NA AMAZÔNIA LEGAL UTILIZANDO SENSORIAMENTO REMOTO. 2005. 105 f. Dissertação (Mestrado) - Curso de Pós-Graduação em Ciências Florestais, Universidade Federal do Paraná, Curitiba, 2005.

MORAES, I. S. et al., Monitoramento da abertura no dossel a partir de fotografias hemisféricas com NDVI e MLME em área de concessão florestal: Mamuru-Arapiuns/PA. **Revista Brasileira de Cartografia**, v. 68, n. 7, p. 1303-15, 2016. <https://doi.org/10.14393/rbcv68n7-44361>.

MORETO, R. F. et al. Potencial das geotecnologias para monitoramento do impacto da colonização na floresta nativa na microbacia do rio Enganado, Amazônia Ocidental, Brasil. **RECIMA21-Revista Científica Multidisciplinar-ISSN 2675-6218**, v. 2, n. 7, p. e27588-e27588, 2021. <https://doi.org/10.47820/recima21.v2i7.588>.

- MORETTI, M. S. Extração seletiva e produção de madeira nativa no estado de Mato Grosso. 2018.
- MOURA, A. G. A. F. et al., Geoprocessamento: Utilização da técnica de classificação supervisionada para cálculo de remanescente florestal. **Brazilian Journal of Development**, v. 7, n. 5, p. 51722-51737, 2021. <https://doi.org/10.34117/bjdv7n5-528>.
- NOVO, E. M. L. M. **Sensoriamento remoto**: princípios e aplicações. São Paulo: Blucher, 2010.
- PINAGÉ, E. R.; MATRICARDI, E. A. T. Detecção da infraestrutura para exploração florestal em Rondônia utilizando dados de Sensoriamento Remoto. **Floresta e ambiente**, v. 22, p. 377-390, 2015. <https://doi.org/10.1590/2179-8087.064013>.
- PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLISH, T. M. Sensoriamento remoto da vegetação. 2. ed. São Paulo, Oficina de textos, 2012. 160p.
- PRENDES, C. et al., Large scale semi-automatic detection of forest roads from low density LiDAR data on steep terrain in Northern Spain. **IForest biogeosciences and forestry**, v. 12, n. 4, p. 366–374, 2019. <https://doi.org/10.3832/ifor2989-012>.
- RANJAN, R. et al. Irrigated pinto bean crop stress and yield assessment using ground based low altitude remote sensing technology. **Information Processing in Agriculture**, v. 6, n. 4, p. 502-514, 2019. <https://doi.org/10.1016/j.inpa.2019.01.005>.
- RÊGO, S. C. A. et al. Análise comparativa dos índices de vegetação NDVI e SAVI no município de São Domingos do Cariri-PB. **Revista geonorte**, v. 3, n. 5, p. 1217–1229-1217–1229, 2012.
- ROBERTS, D. A et al. Large area mapping of land-cover change in Rondônia using multitemporal spectral mixture analysis and decision tree classifiers. **Journal of Geophysical Research**, v. 107, n. D20, 2002. <https://doi.org/10.1029/2001JD000374>.
- RODRIGUES, M. I. et al. Concessão florestal na Amazônia brasileira. **Ciência Florestal**, v. 30, n. 4, p. 1299–1308, 2020. <https://doi.org/10.5902/1980509821658>.
- ROUSE, J. W. Jr. et al. Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation. 1974.
- SALLO, F. D. S. et al. Estimativa de componentes do balanço de radiação em diferentes tipos de uso e cobertura do solo. **Revista Ambiente e Água**, v. 9, n. 2, 2014. <https://doi.org/10.4136/ambi-agua.1273>.
- SANTOS, F. de A.. Uso de índice espectral para monitoramento da cobertura vegetal no município de Juazeiro do Piauí. **Revista de Geociências do Nordeste**, v. 4, p. 113-125, 2018. <https://doi.org/10.21680/2447-3359.2018v4n0ID16087>.
- ESPÍRITO-SANTO, F. D. B.; SANTOS, J. R.; SILVA, P. G. Técnicas de processamento de imagens e de análise espacial para estudo de áreas florestais sob a exploração madeireira. **Revista Árvore**, v. 28, n. 5, p. 699–706, set. 2004. <https://doi.org/10.1590/S0100-67622004000500009>.
- SHIMABUKURO, Y. E., SMITH, J. A. The least squares mixing models to generate fraction images derived from remote sensing multispectral data. **Transactions on Geoscience and Remote Sensing**, 29, 16-20, 1991. <https://doi.org/10.1109/36.103288>.

- SHI, T.; XU, H., Derivation of Tasseled Cap Transformation Coefficients for Sentinel-2 MSI At-Sensor Reflectance Data. **Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, vol. 12, no. 10, pp. 4038-4048, Oct. 2019, <https://doi.org/10.1109/JSTARS.2019.2938388>.
- 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, 30 dez. 2020. <https://doi.org/10.14393/rbcv72nespecial50anos-56559>.
- SHIMABUKURO, Y.E. et al., Assessment of forest degradation in Brazilian Amazon due to selective logging and fires using time series of fraction images derived from Landsat ETM+ images. **Remote Sensing Letters**, Vol. 5, No. 9, 773–782, 2014. <https://doi.org/10.1080/2150704X.2014.967880>.
- SOUZA, C. M. et al., **Extração de informações de imagens Landsat para modelos de alcance econômico da atividade madeireira**. Anais X SBSR, Foz do Iguaçu, 21-26 abril 2001, INPE, p. 509-516, Sessão Técnica Oral.
- SILVA, E. F. et al., Optimized forest planning: allocation of log storage yards in the Amazonian sustainable forest management area. **Forest Ecology and Management**, v. 472, p. 118231, 2020. <https://doi.org/10.1016/j.foreco.2020.118231>.
- SILVA, A. B., Sistema de Informações Geo-referenciadas: conceitos e fundamentos. Campinas, SP. Editora da UNICAMP. 1º ed. 2003. 232 p.
- SILVA, J. C.; ALMEIDA, A. N.; POMPERMAYE, R. de S. Análise estratégica do manejo florestal na Amazônia brasileira. **Floresta**, v. 44, n. 3, p. 341-348, 30 jan. 2014. <http://dx.doi.org/10.5380/rf.v44i3.33979>.
- SILVEIRA, E. M. de O. et al. Caracterização da heterogeneidade espacial da paisagem utilizando parâmetros do semivariograma derivados de imagens NDVI. **CERNE**, v. 23, n. 4, p. 413-422, 2017. <https://doi.org/10.1590/01047760201723042370> .
- VARADE, D.; DIKSHIT, O., Estimation of surface snow wetness using sentinel-2 multispectral data. **ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences**, v. 4, n. 5, 2018. <https://doi.org/10.5194/isprs-annals-IV-5-223-2018>.
- VASCONCELOS, V. V.; HADAD, R. M.; MARTINS, P. P. J., Mapeamento e análise da dinâmica de ocupação na Bacia de Entre-Ribeiros – MG, nos anos de 1975, 1989 e 2008. **Revista equador**, v. 2, n. 2, p. 131–152, 2014. <https://doi.org/10.26694/equador.v2i2.1397>.
- VIDAL, B. S.; SILVA, J. C. A. N.; ALEIXO, N. C. R., Análise temporal da cobertura vegetal e uso da terra na Rodovia BR-174: entre Manaus–AM e Presidente Figueiredo-AM. **Periódico Eletrônico Fórum Ambiental da Alta Paulista**, v. 14, n. 3, 2018. <https://doi.org/10.17271/1980082714320181941>.
- VIEIRA, C. V.; VIANA, P. Avaliação da acurácia de algoritmos de classificação de imagens orbitais na baía da babitonga, nordeste de Santa Catarina. **Revista Brasileira de Geografia Física**, v. 14, n. 6, p. 3577-3591, 2021. <https://doi.org/10.26848/rbgf.v14.6.p3599-3613>.
- XUE, J.; SU, B. Significant remote sensing vegetation indices: A review of developments and applications. **Journal of sensors**, v. 2017, p. 1–17, 2017. <https://doi.org/10.1155/2017/1353691>.