



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO ACADÊMICO DE RECIFE

LAÍS BARREIROS PINTO

**Mapeamento da Degradação Ambiental no Território Indígena
Apyterewa: Aplicação do SAVI e kNN em Imagens de Satélite
PlanetScope**

RECIFE

2024

UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO ACADÊMICO DE RECIFE
ENGENHARIA CARTOGRÁFICA E DE AGRIMENSURA

LAÍS BARREIROS PINTO

**Mapeamento da Degradação Ambiental no Território Indígena
Apyterewa: Aplicação do SAVI e kNN em Imagens de Satélite
PlanetScope**

TCC apresentado ao Curso de Graduação de Engenharia Cartográfica e de Agrimensura da Universidade Federal de Pernambuco, Centro Acadêmico de Recife, como requisito para a obtenção do título de Bacharel em Engenharia.

**Orientador(a): Prof. Dr. Admilson da
Penha Pacheco**

RECIFE

2024

FICHA CATALOGRÁFICA

Pinto, Laís Barreiros.

Mapeamento da Degradação Ambiental no Território Indígena Apyterewa:
Aplicação do SAVI e kNN em Imagens de Satélite PlanetScope / Laís Barreiros
Pinto. - Recife, 2024.

92 p. : il., tab.

Orientador(a): Admilson da Penha Pacheco

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de
Pernambuco, Centro de Tecnologia e Geociências, Engenharia Cartográfica e
de Agrimensura - Bacharelado, 2024.

Inclui referências.

1. PlanetScope. 2. Terra Indígena Apyterewa. 3. KNN. 4. SAVI. I. Pacheco,
Admilson da Penha . (Orientação). II. Título.

550 CDD (22.ed.)

LAÍS BARREIROS PINTO

Mapeamento da Degradação Ambiental no Território Indígena Apyterewa: Aplicação do SAVI e kNN em Imagens de Satélite PlanetScope

TCC apresentado ao Curso de Graduação de Engenharia Cartográfica e de Agrimensura da Universidade Federal de Pernambuco, Centro Acadêmico de Recife, como requisito para a obtenção do título de Bacharel em Engenharia.

Aprovado em: 28/08/2024

BANCA EXAMINADORA

Documento assinado digitalmente
 **ADMILSON DA PENHA PACHECO**
Data: 07/12/2024 18:03:14-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. Admilson da Penha Pacheco (Orientador)
Universidade Federal de Pernambuco

Documento assinado digitalmente
 **DEBORA NATALIA OLIVEIRA DE ALMEIDA**
Data: 30/09/2024 13:10:10-0300
Verifique em <https://validar.itl.gov.br>

Prof^ª. MSc. Débora Natália Oliveira de Almeida (Examinador Interno)
Universidade Federal de Pernambuco

Documento assinado digitalmente
 **UBIRATAN JOAQUIM DA SILVA JUNIOR**
Data: 27/09/2024 17:10:14-0300
Verifique em <https://validar.itl.gov.br>

Prof. MSc. Ubiratan Joaquim da Silva Júnior (Examinador Externo)
Universidade Federal de Pernambuco

Com imensa gratidão, dedico este trabalho aos meus pilares, meus pais, Augusto e Sarita, minha irmã Marília e meu esposo Cody. Também dedico a todos os familiares e amigos que, desde o primeiro momento, depositaram fé e apoio incondicional neste sonho.

AGRADECIMENTOS

Em primeiro lugar, agradeço a Deus, a quem devo toda minha existência e a quem sou profundamente grata pelo dom da vida e pela chance de conquistar mais essa etapa crucial na minha trajetória profissional.

Aos meus pais, Augusto e Sarita, que são o alicerce da minha vida, meus exemplos e fontes de inspiração. Vocês me ensinaram a ser resiliente, a acreditar nos meus sonhos e nunca desistir. Amo vocês incondicionalmente e sem o apoio de vocês, eu não teria chegado até aqui.

À minha irmã Marília, meu mais sincero agradecimento por estar sempre ao meu lado, me apoiando e incentivando. Sua força e coragem me inspiram todos os dias. Muito obrigada por tudo.

Ao meu esposo Cody, que, mesmo distante fisicamente, esteve presente em cada passo dessa jornada. Sou grata por seu apoio inabalável, por nunca me deixar desistir, e por suportar pacientemente os desafios que surgiram ao longo do caminho. Você é meu maior incentivador e o amor e companheirismo que compartilhamos me impulsionam sempre. Amo você.

Aos meus familiares, que desde o início da minha jornada acadêmica até o momento da conclusão, torceram por mim. A palavra "gratidão" não é suficiente para expressar o quanto vocês são importantes para mim.

Aos meus amigos, que entenderam as minhas ausências nos momentos mais importantes de suas vidas, eu agradeço de coração. Em especial, Drielly e Gabi, que sempre me apoiaram e me ajudaram a continuar nessa árdua caminhada acadêmica.

Aos amigos que o Decart me trouxe, especialmente Artur, que esteve comigo desde o início do curso. Em 2019 éramos 30, hoje somos apenas nós dois completando essa jornada juntos. Vivenciamos muitas experiências, boas e ruins, mas sempre pude contar com sua amizade e dedicação para seguir adiante. Muito obrigada.

Ao meu orientador, Prof. Dr. Admilson da Penha Pacheco, uma pessoa de enorme gentileza e coração, que me proporcionou essa oportunidade desde o começo e me guiou na realização deste trabalho de conclusão de curso. Agradeço profundamente por sua dedicação em ensinar e por acalmar meu coração com suas palavras sábias e encorajadoras. MUITÍSSIMO obrigada.

Por fim, agradeço aos professores do Departamento de Engenharia Cartográfica e de Agrimensura, minha sincera gratidão por me orientarem e fornecerem a base sólida que foi essencial para minha formação profissional.

“Agir, eis a inteligência verdadeira. Serei o que quiser. Mas tenho que querer o que for. O êxito está em ter êxito, e não em ter condições de êxito. Condições de palácio tem qualquer terra larga, mas onde estará o palácio se não o fizerem ali?”

Fernando Pessoa

RESUMO

A Terra Indígena Apyterewa, situada no município de São Felix do Xingú, no estado do Pará, Brasil, tem sido submetida a degradações antropogênicas cada vez mais intensas. Neste contexto, o objetivo deste trabalho foi realizar um mapeamento de uso e cobertura na área Indígena Apyterewa, para identificar mudanças na paisagem, por meio do algoritmo classificador de imagem kNN, k-vizinho mais próximo, baseado em machine learning, e o SAVI, Soil-Adjusted Vegetation Index, num intervalo temporal entre 2018 a 2023. Como resultado, observou-se por meio do SAVI um aumento significativo no corte raso, também identificado como solo exposto após o desmatamento, de 1761,10%. Ademais, houve um expressivo crescimento na extração mineral, de 533,33%, e uma redução de 11,57% na vegetação arbórea nativa, acompanhada de um aumento de 80,11% na regeneração vegetal, o que, ao analisar as imagens RGB, indicou um incremento no corte raso. Pelo método kNN, também no período de 2018 a 2023, verificou-se um aumento de 2156,19% no corte raso e de 2390,24% na extração mineral, além de uma redução de 3,60% na vegetação arbórea nativa e uma diminuição de 33,26%, apontando para um aumento no corte raso. Devido à susceptibilidade do kNN ao overfitting, apesar do seu sucesso estatístico, ainda persistem muitos desafios na sua aplicação, como a determinação do valor de K, a escolha do vizinho mais próximo, a busca eficiente dos vizinhos e as regras de classificação, tornando o SAVI uma opção mais eficaz para o monitoramento de florestas densas. Em 2023, a área de estudo apresentou um volume de biomassa de 6468,16 m³/ha pelo método SAVI, considerando a vegetação arbórea e rasteira, enquanto o kNN registrou 8309,63 m³/ha. Em 2018, o SAVI indicou 8041,44 m³/ha, e o kNN, 8624,49 m³/ha. Quanto ao volume de degradação em 2023, o SAVI apresentou 217,36 m³/ha, e o kNN, 259,35 m³/ha. Para 2018, obteve-se 259,35 m³/ha para ambos os métodos. Sendo apenas descritivo, é de baixo custo, mas sua precisão depende da experiência e habilidade do operador, sendo a conversão dos padrões de vegetação descritos por essa classificação em índices de biomassa da vegetação lenhosa (IBVL), permitindo a utilização desses dados em equações e modelos que descrevem processos hidrológicos, erosivos, sedimentológicos, agroclimáticos e de impactos ambientais.

Palavras-chave: Planetscope, Terra Indígena Apyterewa, KNN, SAVI.

ABSTRACT

The Apyterewa Indigenous Land has been subjected to increasingly intense anthropogenic degradation. For the analysis of this situation, two methods were employed: kNN, based on machine learning, and SAVI, a spectral index sensitive to vegetation and soil. Over the five-year study period from 2018 to 2023, the SAVI method observed a significant increase in clear-cutting, also identified as exposed soil following deforestation, of 1761.10%. Additionally, there was a substantial increase in mineral extraction of 533.33%, and an 11.57% reduction in native arboreal vegetation, accompanied by an 80.11% increase in vegetation regeneration, indicating, upon analysis of RGB images, an increase in clear-cutting. Using the kNN method, also over the period from 2018 to 2023, an increase of 2156.19% in clear-cutting and 2390.24% in mineral extraction was observed, along with a 3.60% reduction in native arboreal vegetation and a 33.26% decrease, indicating an increase in clear-cutting. However, due to kNN's susceptibility to overfitting, despite its statistical success, many challenges in its application remain, such as determining the value of K, selecting the nearest neighbor, efficiently searching for neighbors, and classification rules, making SAVI a more effective option for monitoring dense forests. In 2023, the study area showed a biomass volume of 6468.16 m³/ha using the SAVI method, considering both arboreal and ground vegetation, while kNN recorded 8309.63 m³/ha. In 2018, the SAVI method indicated 8041.44 m³/ha, and kNN recorded 8624.49 m³/ha. Regarding the degradation volume in 2023, SAVI showed 217.36 m³/ha, and kNN showed 259.35 m³/ha. For 2018, both methods showed 259.35 m³/ha. Being only descriptive, it is low-cost, but its accuracy depends on the operator's experience and skill. The conversion of vegetation patterns described by this classification into indices of woody vegetation biomass (IBVL) allows the use of these data in equations and models that describe hydrological, erosive, sedimentological, agroclimatic, and environmental impact processes.

Keywords: Planetscope, Apyterewa Indigenous Land, KNN, SAVI.

LISTA DE ILUSTRAÇÕES

Figura 1 – Estados e Municípios que compõem a Amazônia Legal no Brasil	18
Figura 2 – Representação da Imagem do Instrumento PS2	27
Figura 3 – Imagens do Instrumento PS2	27
Figura 4 – Representação da Imagem do Instrumento PS2.SD	28
Figura 5 – Imagens do Instrumento PS2.SD	28
Figura 6 – Esquema de Classificação k-Vizinho Mais Próximo	30
Figura 7 - Exemplo do Método kNN	31
Figura 8 – Células de Voroni	31
Figura 9 – Exemplo dos Termos que Compõem o SIG	40
Figura 10 – Vetores e Rasters Representando o Mundo Real Através do SIG	41
Figura 11 – Mapa de Localização da Terra Indígena Apyterewa	46
Figura 12 – Área de Estudo – T.I. Apyterewa	48
Figura 13 – Mapa das Imagens RGB e SAVI Para o Ano de 2018	57
Figura 14 – Mapa das Imagens RGB e SAVI Para o Ano de 2023	58
Figura 15 – Imagem kNN Para o Ano de 2018	60
Figura 16 – Imagem kNN Para o Ano de 2023	61
Quadro 1 - Justificativa das Técnicas para a Análise do Uso e Ocupação do Solo	17
Quadro 2 - Elementos Para a Análise do Uso e Ocupação do Solo	17
Quadro 3 - Ordem de Banda e Frequência dos Sensores	29
Quadro 4 - Matriz de Confusão	34
Quadro 5 - Valores do Total Estimado, Total Real, Probabilidade do Estimado e Real ¹	63
Quadro 6 - Multiplicação das probabilidades para cada classe	64

Quadro 7 - Valores do Total Estimado, Total Real, Probabilidade do Estimado e Real2	65
Quadro 8 - Multiplicação das probabilidades para cada classe	65
Gráfico 1 - Taxa de desmatamento na Amazônia Legal, 2011 a 2021 (Em km ² /Ano).....	19
Gráfico 2 - Taxa de desmatamento por estado da Amazônia Legal, 2010- 2021 (Por estado - km ²)	20
Gráfico 3 - Terras Indígenas Por Estado na Amazônia Legal (km ²)	22
Gráfico 4 - Dados Obtidos das Análises do SAVI entre 2023 e 2018	67
Gráfico 5 - Dados Obtidos das Análises do kNN entre 2023 e 2018	68

LISTA DE TABELAS

Tabela 1 - Evolução do Desmatamento nos Estados da Amazônia Legal até 2021	20
Tabela 2 - Situação Territorial na Amazônia Legal	21
Tabela 3 - Áreas Protegidas e Categoria por Estados da Amazônia Legal	21
Tabela 4 - Temperaturas Máximas e Mínimas Médias	45
Tabela 5 - Especificações das Imagens de 2018 e 2023 Neste Estudo	48
Tabela 6 - Dados dos Sensores do Satélite PlanetScope	50
Tabela 7 - Classes e Desempenho do Índice Kappa	52
Tabela 8 - Matriz de Erros (ou matriz de confusão) da Classificação	52
Tabela 9 - Índice de Porte da Biomassa Para as Diferentes Classes	54
Tabela 10 - Índices de Recobrimento da Biomassa Para as Diferentes sub-classes	55
Tabela 11 - Valores de volume, Biomassa e Carbono por Hectare, FCEB, R e TC Deduzidos a Partir do FRA2015	56
Tabela 12 - Áreas do ano de 2018 adquirido a partir do SAVI	58
Tabela 13 - Áreas do ano de 2023 adquirido a partir do SAVI	59
Tabela 14 - Área do ano de 2018 adquirido a partir do kNN	60
Tabela 15 - Área do ano de 2023 adquirido a partir do kNN	15
Tabela 16 - Matriz de confusão para o ano de 2018	62
Tabela 17 - Classes e desempenho do Índice Kappa	62
Tabela 18 - Matriz de confusão para o ano de 2023	64
Tabela 19 - IBVL, volume de biomassa e volume de degradação para o ano de 2018.....	70
Tabela 20 - IBLV, volume de biomassa e volume de degradação para a ano de 2023 - SAVI	71
Tabela 21 - Dados e estimativa da degradação da vegetação	72
Tabela 22 - IBLV, volume de biomassa e volume de degradação para a ano de 2023 - kNN	72

LISTA DE ABREVIações

APA	Áreas de Proteção Ambiental
ESEC	Estação Ecológica
FAO	Organização das Nações Unidas para Alimentação e Agricultura
FLONAS	Florestas Nacionais
FLOTAS	Florestas Estaduais
FRA	Forest Resources Assessment
FUNAI	Fundação Nacional dos Povos Indígenas
IBGE	Instituto Brasileiro de Geografia e Estatística
IBVL	Índice de Biomassa de Vegetação Lenhosa
INPE	Instituto Nacional de Pesquisas Espaciais
Ip	Índice de Porte
Ir	Índice de Recobrimento
IV	Índice de Vegetação
knn	k-Nearest Neighbors
NDVI	Índice de Vegetação da Diferença Normalizada
NIR	Infravermelho Próximo
PARNA	Parque Nacional
PES	Parque Estadual
PIB	Produto Interno Bruto
RESEX	Reservas Extrativistas
RGB	Red, Green, Blue
SAVI	Índice de Vegetação Ajustada ao Solo
SIG	Sistemas de Informação Geográfica
SINAC	Sistema Nacional de Áreas de Conservação
SPI	Serviço de Proteção ao Índio
SR	Sensoriamento Remoto
TCQ	Terras de Comunidades Quilombolas
TI	Terras Indígenas
TPO	Terras dos Povos Originários
UC	Unidades de Conservação
Vmáx	Volume Máximo

Sumário	
1 INTRODUÇÃO	13
2 FUNDAMENTAÇÃO TEÓRICA	17
2.1. Amazônia Legal e Territórios Indígenas	17
<i>2.1.1. Terras Indígenas e Extração Mineral</i>	<i>24</i>
2.2. Sensoriamento Remoto e Mapeamento Ambiental das Áreas Suscetíveis a Desmatamento	25
<i>2.2.1. PlanetScope</i>	<i>26</i>
<i>2.2.1.1. O Instrumento PS2.SD</i>	<i>28</i>
<i>2.2.1.2. O Instrumento PSB.SD</i>	<i>29</i>
2.3 Classificação de Imagens	30
<i>2.3.1. Classificação Supervisionada kNN</i>	<i>30</i>
<i>2.3.2. Matriz de Confusão</i>	<i>33</i>
<i>2.3.3. Categorias de Acurácia</i>	<i>36</i>
<i>2.3.3.1. Acurácia Total</i>	<i>36</i>
<i>2.3.3.2. Kappa Cohen</i>	<i>36</i>
<i>2.3.3.3. Pi de Scott</i>	<i>37</i>
<i>2.3.3.4. Índice Tau</i>	<i>38</i>
<i>2.3.3.5. Pabak</i>	<i>38</i>
2.4. Volume de Biomassa e de Degradação	39
2.5. Sistema de Informação Geográfica	40
3. OBJETIVOS	42
3.1. Objetivo Geral	42
3.2. Objetivos Específicos	42
4. METODOLOGIA	43
4.1. Caracterização da Área de Estudo	44

4.2. Aquisição de Dados	47
4.3 Processamento	49
4.3.1. <i>SAVI</i>	49
4.3.2. <i>kNN</i>	51
4.3.3. <i>Validação dos Dados</i>	51
4.4. Volume de Biomassa e Volume Degradado	54
4.4.1. <i>Cálculo do Volume</i>	54
5. RESULTADOS E DISCUSSÕES	57
5.1. Análise do SAVI	57
5.2. Análise do kNN	59
5.2.1. <i>Validação dos Dados</i>	62
5.3. Volume de Biomassa e de Degradação	69
5.3.1. <i>SAVI</i>	69
5.3.2. <i>kNN</i>	71
6. CONCLUSÃO	75
REFERÊNCIAS	77

1 INTRODUÇÃO

A interação entre a ocupação do território e a cobertura do solo é um problema global amplamente reconhecido, impulsionado pelas ações humanas. Esse processo tem causado o fracionamento das áreas florestais, degradação dos recursos naturais e perda da biodiversidade (ABDI, 2019).

O desmatamento elevado é resultado de diversos fatores, como práticas agrícolas, incêndios florestais, deslocamento populacional, exploração ilegal de madeira e mineração, além de uma gestão ineficaz dos recursos naturais (TOLESSA et al, 2020). Esse cenário se agrava com o aumento demográfico e o avanço da industrialização, que intensificam a pressão sobre os ecossistemas.

À medida que a população global persiste em sua trajetória de crescimento, concomitantemente ao processo de industrialização, a demanda pela exploração mineral experimenta um incremento diário. Os desdobramentos dessas atividades mineradoras no meio ambiente e nas comunidades circunvizinhas manifestam-se por meio de impactos tanto adversos quanto benéficos (HADDAWAY et al, 2019)

Pesquisas têm investigado os impactos da ocupação territorial e da mineração em comunidades indígenas e ecossistemas. A atividade mineradora desempenha também um papel crucial e duradouro no avanço econômico, na geração de empregos, no desenvolvimento de infraestruturas e no fornecimento de matérias-primas essenciais para a sociedade (HADDAWAY et al, 2019; WORLANYO e JIANGFENG, 2021).

No Brasil, no entanto, as pressões políticas estão impelindo a prática ilícita de extração de ouro na região amazônica do país, tendo em vista que tal prática coloca em risco as áreas florestais, as comunidades indígenas e a preservação da biodiversidade em zonas protegidas. O índice de desmatamento decorrente da mineração ilegal registrou um aumento superior a 90% entre 2017 e 2020, alcançando 101,7 km² anualmente em 2020, em contraste com os 52,9 km² anuais em 2017 (GAY e SANCHEZ, 2021).

Nesse intervalo temporal, a taxa de desmatamento associada à extração ilegal de minerais expandiu-se de forma mais acentuada em comparação com a taxa de desmatamento observada nas áreas destinadas à exploração mineradora legalizada (GAY e SANCHEZ, 2021). A extração ilegal de ouro, por exemplo, experimentou um notório crescimento na Amazônia ao longo da última década,

alcançando taxas de expansão anual de até 18% em determinadas áreas (ASNER e TUPAYACHI, 2017).

A incursão de garimpeiros ilegais tem penetrado em territórios designados como áreas protegidas (ESPEJO et al, 2018), comprometendo o bem-estar das comunidades indígenas (CALVIMONTES et al, 2020). Para além das ramificações em escala local, impactos como a poluição da água e o acréscimo da sedimentação podem ser rastreados muito além das áreas de atividade mineradora, representando uma ameaça a comunidades e ecossistemas a centenas de quilômetros de distância (SANCHEZ-CUERVO et al, 2020).

A extração clandestina de recursos no Bioma Amazônia tornou-se, então, uma preocupação em ascensão ao longo dos últimos decênios (MENESES, 2022), acarretando prejuízos ambientais de magnitude considerável e desdobramentos sociais adversos nas Terras Indígenas (TIs) e Unidades de Conservação (UCs) (BAKKER et al, 2022).

Atualmente sistemas de monitoramento via satélite são aplicados para monitorar integralmente a região amazônica (ASSIS et al, 2019). Devido à sua extensa abrangência e informações espectrais, os dados provenientes de imagens orbitais surgem como uma ferramenta amplamente utilizada na gama de recursos disponíveis para o monitoramento ambiental (ADIRI et al, 2020).

Nos últimos anos, têm-se empregado uma variedade de abordagens para investigar os impactos ambientais em Terras Indígenas da Amazônia Legal Brasileira (SILVA et al, 2023), sendo tais técnicas utilizadas para analisar e quantificar a ampliação temporal e espacial da atividade de impacto ambiental em TIs no bioma em estudo (MATAVELI et al, 2022).

Dessa forma, para analisar a dinâmica do uso e ocupação do solo é preciso contemplar a utilização de sensores diversos em conjunto e a periodicidade entre observações consecutivas que pode apresentar uma variação global complexa, tanto no espaço quanto no tempo. Essa dinâmica, influenciada pela interação de múltiplos sensores, cria um cenário onde a frequência de revisita aos locais específicos varia de maneira intrincada e abrangente (LI & ROY, 2017).

A constelação PlanetScope, formada por mais de 180 CubeSats em órbitas sincronizadas com o sol, capazes de capturar imagens multiespectrais com resolução variável entre 3,7 m a 4,1 m, dependendo da altitude (Planet Labs a, 2024), possui uma revisita diária, sendo fundamental para a detecção imediata de

mudanças no solo, bem como o monitoramento da expansão ou manutenção de atividades já existentes.

Nos últimos anos, portanto, as imagens provenientes de satélites e o uso de Sistemas de Informação Geográfica (SIG) demonstraram ser meios eficazes na vigilância e antecipação das transformações morfológicas em cursos d'água (SAPRATHET, LOSIRI, & SITTHI 2022). Combinações de refletância em diferentes faixas espectrais, conhecidas como índices espectrais, desempenham um papel fundamental na análise de imagens temporais de satélite.

A utilização de técnicas avançadas de Sensoriamento Remoto (SR) e o SIG não apenas proporciona uma visão holística dos dados, abrangendo dimensões espaciais e temporais, mas também oferece oportunidades de otimização mediante a integração de informações terrestres e outros dados geográficos. Essa abordagem aprimorada eleva a precisão e utilidade das análises, conferindo uma compreensão mais aprofundada das transformações da vegetação, do solo e dos cursos d'água (LAONAMSAI et al, 2023).

Ao compreender a valiosa contribuição dos dados das imagens de satélite para a geração de classificações atualizadas de uso e ocupação do solo, se faz necessário aplicar o Índice de Vegetação Ajustado ao Solo (SAVI), em que minimiza as influências do brilho do solo através de um fator de correção incorporado na fórmula do NDVI (CHAVES, PICOLI & SANCHES, 2020).

Com base nisso, diversos métodos estão disponíveis para a geração de mapas de Uso e Cobertura do Solo, cada um apresentando vantagens e desvantagens distintas. Abordagens manuais, embora simples e diretas, tornam-se impraticáveis em estudos que envolvem vastas áreas e um grande número de categorias.

Nestes casos, recorrer a algoritmos de inteligência artificial emerge como uma alternativa mais eficaz. Dentro desse conjunto de algoritmos, o tradicional aprendizado de máquina ganha destaque devido à sua precisão, robustez e habilidade para analisar extensos conjuntos de dados com características complexas. A utilização dessa técnica proporciona uma abordagem eficiente e escalável para a geração de mapas em contextos que demandam análises mais abrangentes e precisas (ARRECHEA-CASTILLO et al, 2023).

A aplicação deste método possibilita a obtenção de mapas de alta qualidade com um investimento de tempo e esforço relativamente menor (LILAY & TAYE,

2023). A pesquisa em classificações utilizando algoritmos de aprendizado de máquina tem sido proeminente nos últimos anos, com inúmeros artigos explorando essa área (KESHTKAR, VOIGT & ALIZADEH, 2017).

Um exemplo notável de eficácia é o algoritmo K-Nearest Neighbors (kNN). Este algoritmo de aprendizado de máquina frequentemente apresenta excelente desempenho em áreas de estudo mais restritas, especialmente quando há um número limitado de classes a serem mapeadas. Esse enfoque destaca-se pela sua eficiência na geração de mapas com precisão e rapidez em contextos específicos (ARRECHEA-CASTILLO et al, 2023).

Este estudo teve como principal intuito, portanto, explorar e quantificar a expansão do uso e ocupação do solo em uma pequena parte da Terra Indígena Apyterewa, localizada no município de São Félix do Xingu, no estado do Pará, bem como o volume de biomassa degradado, utilizando a técnica do K-vizinho mais próximo em conjunto com análises do índice espectral SAVI (Índice de Vegetação Ajustado ao Solo), a partir de dados adquiridos por meio de imagens dos satélites PlanetScope.

JUSTIFICATIVA

A elaboração cartográfica do uso e cobertura do solo desempenha um papel fundamental ao fornecer informações cruciais que direcionam os elaboradores de políticas e os responsáveis pela tomada de decisões na formulação de estratégias e diretrizes para a gestão eficiente dos recursos naturais. O mapeamento do desmatamento na região da Amazônia Legal, por meio da utilização de imagens de satélite e diferentes técnicas de análises (quadro 1), tem o propósito de registrar e quantificar as seguintes categorias: corte raso, que abarca o desmatamento com exposição do solo e atividades de extração mineral; áreas de vegetação primária e secundária (quadro 2) (DINIZ et al, 2015).

Quadro 1: Justificativa das Técnicas para a Análise do Uso e Ocupação do Solo

CRITÉRIO	JUSTIFICATIVA
COBERTURA DO SOLO	As causas primordiais do desmatamento na região amazônica brasileira são motivadas pela crescente demanda global por produtos agropecuários, o que tem promovido a substituição de vastas extensões de terra por pastagens e cultivos agrícolas, resultando na remoção anual de milhares de hectares de florestas (HANSEN et al, 2013). No estado do Pará, onde as taxas de desmatamento estão entre as mais elevadas do país, a atividade agropecuária e a exploração mineral são identificadas como os principais catalisadores desse processo (OLIVEIRA et al, 2021)
SAVI	O emprego do Índice de Vegetação Ajustado ao Solo (SAVI) viabiliza uma análise mais aprimorada e compreensível dos parâmetros biofísicos inerentes à vegetação, tais como sua biomassa e proporção de solo exposto. Salienta-se particularmente a importância de certos canais específicos do espectro eletromagnético: a região visível e o infravermelho próximo, os quais capturam mais de 90% da resposta espectral da vegetação (ROSA, 2007).
kNN	O algoritmo kNN é empregado para classificar grupos de pixels com base na similaridade com seus vizinhos mais próximos. Ao adotar a abordagem de classificação por regiões, torna-se necessário segmentar as imagens para facilitar a coleta de amostras representativas das diferentes classes. Essa técnica envolve o agrupamento de regiões (compostas por pixels individuais ou conjunto de pixels) contíguas que apresentam uma similaridade conforme um critério pré-estabelecido (GAROFALO et al, 2015).

Fonte: autora, 2024.

Quadro 2: Elementos Para a Análise do Uso e Ocupação do Solo

Classes de Uso do Solo	AMOSTRA PLANETSCOPE	PADRÃO	DESCRIÇÃO
CORTE RASO		Textura: lisa Formato: irregular/regular Cor: marrom claro	Remoção completa da cobertura florestal em um curto intervalo de tempo, sendo substituída por outras coberturas e usos, por exemplo, pastagem, agrícola ou urbano (INPE, 2021).
EXTRAÇÃO MINERAL		Textura: rugosa Formato: irregular Cor: amarelo claro	Áreas de remoção completa da vegetação local, com presença de piscinas artificiais.
VEGETAÇÃO ARBÓREA		Textura: rugosa Formato: regular/irregular Cor: verde claro/verde escuro	Estrato arbóreo pouco alterado ou inalterado, composto por vegetação natural.
VEGETAÇÃO SECUNDÁRIA		Textura: lisa ou rugosa Formato: regular/irregular Cor: verde claro	Áreas com vegetação de pequeno porte, gramíneas e vegetação arbustiva. Inclui regiões em estágios iniciais de regeneração.

Fonte: autora, 2024.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. Amazônia Legal e Territórios Indígenas

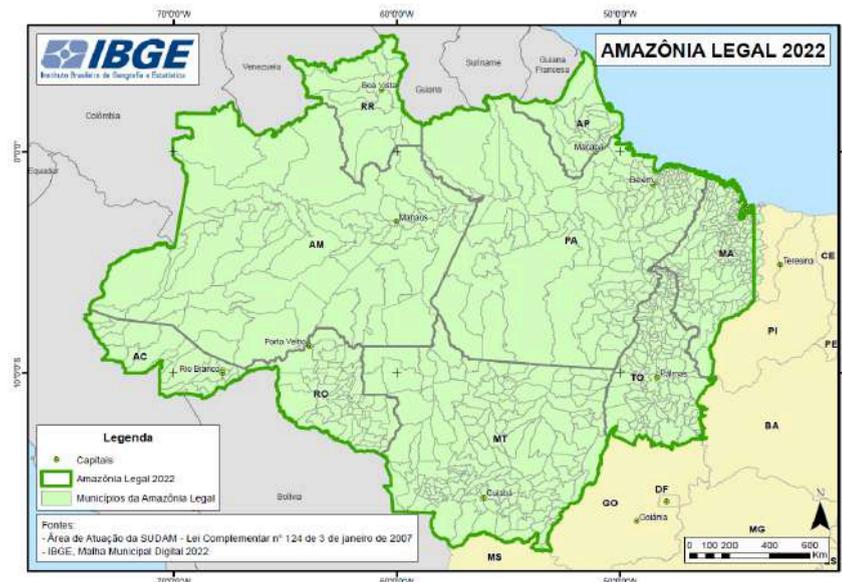
No Brasil, existem dois principais territórios geográficos destacáveis: o bioma Amazônia e a Amazônia Legal. O bioma Amazônia, com uma extensão de 4,2

milhões de quilômetros quadrados, é definido como um conjunto de ecorregiões com fauna, flora e processos ecológicos similares. Ele é composto por florestas tropicais úmidas, uma vasta rede hidrográfica e uma enorme biodiversidade, representando 48% do território nacional (AMAZONIA2030, 2021).

Por sua vez, a Amazônia Legal (figura 1) abrange aproximadamente 5 milhões de quilômetros quadrados e inclui não só toda a área do bioma Amazônia, mas também partes do bioma Cerrado e Pantanal. Essa região engloba todos os estados da Região Norte (Acre, Amazonas, Amapá, Pará, Rondônia, Roraima e Tocantins), além de Mato Grosso e parte do Maranhão, representando 59% do território nacional (AMAZONIA2030, 2021).

Outro conceito relevante é o da Pan-Amazônia, um território que transcende as fronteiras brasileiras e abrange outros oito países. A Pan-Amazônia possui uma área estimada em 7,8 milhões de quilômetros quadrados, dos quais o Brasil detém 64%. Em seguida, vêm Peru (10%), Bolívia (6%), Colômbia (6%), Venezuela (6%) e o restante (8%), distribuído entre Equador, Guiana, Guiana Francesa e Suriname. A população nessa região é estimada em 38 milhões de habitantes (AMAZONIA2030, 2021).

Figura 1: Estados e Municípios que compõem a Amazônia Legal no Brasil.



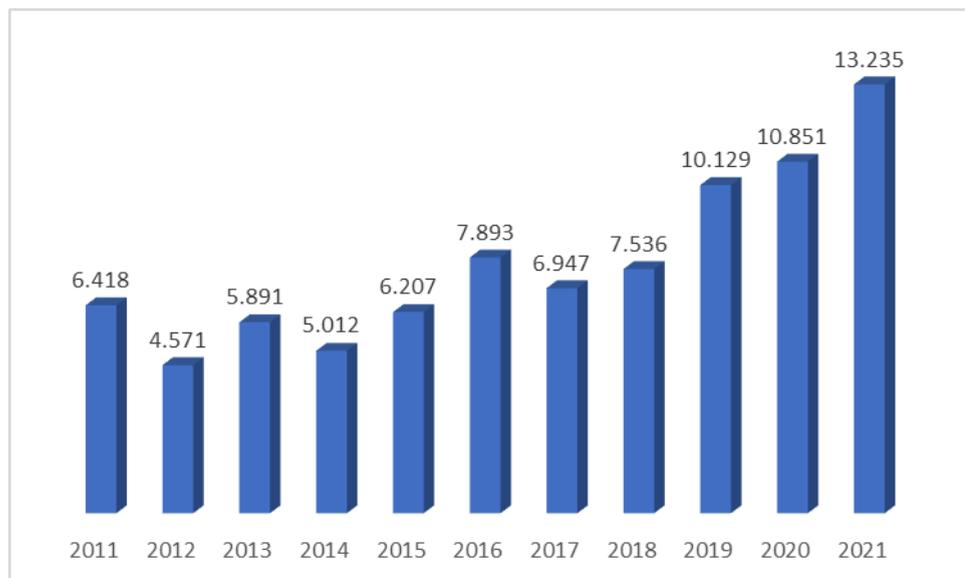
Fonte: IBGE, 2022.

A Amazônia Legal conta com 45% do seu território composto por Áreas Protegidas, distribuídas em Unidades de Conservação (UC) de Uso Sustentável (aproximadamente 11%), Proteção Integral (8%), Terras Indígenas (TI) (23%), Áreas

de Proteção Ambiental (APA) (3%) e Terras Quilombolas (TQ) (0,2%). Além disso, as áreas com Cadastro Ambiental Rural (26%), os assentamentos rurais (8%), as áreas militares (1%) e outras áreas (20%) completam o território da região (AMAZONIA2030, 2021).

A incidência de desflorestamento em floresta primária na Amazônia Legal apresentou um aumento expressivo a partir de 2018, alcançando 7.536 quilômetros quadrados, com um pico de 13.235 quilômetros quadrados em 2021 (gráfico 1) (INPE, 2022a). Ademais, o sistema PrevisIA do Imazon, responsável por avaliar o risco de desmatamento futuro na região, antecipou que 15.391 quilômetros quadrados de florestas na Amazônia Legal estariam em risco de desmatamento em 2022 (PrevisIA, 2022).

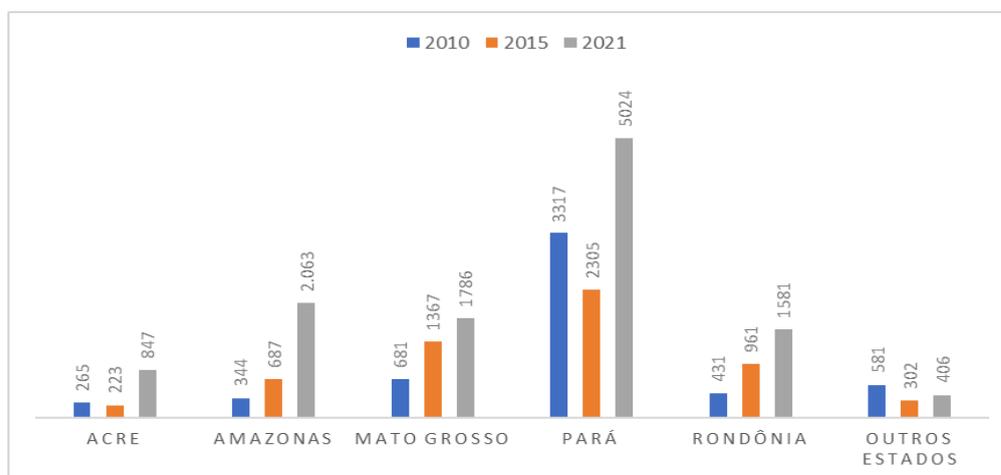
Gráfico 1: Taxa de desmatamento na Amazônia Legal, 2011 a 2021 (Em km²/Ano)



Fonte: Dados do Prodes – INPE, 2021.

No ano de 2021, o estado do Pará registrou a maior degradação de florestas nativas na Amazônia Legal, com uma perda de 5.024 quilômetros quadrados de florestas (gráfico 2). No total acumulado, o Pará já havia desmatado uma área de 284.299 quilômetros quadrados até 2021, o que representa 25% (tabela 1) de sua cobertura florestal original (AMAZONIA2030, 2021).

Gráfico 2: Taxa de desmatamento por estado da Amazônia Legal, 2010- 2021
(Por estado - km²)



Fonte: Adaptado - Dados do Prodes – INPE, 2021.

Tabela 1: Evolução do desmatamento nos estados da Amazônia Legal até 2021

ESTADO	DESMATAMENTO ANUAL (km ²)			TOTAL ATÉ 2021	
	ATÉ 2010	2011-2015	2016-2021	ÁREA (km ²)	RELAÇÃO À COBERTURA FLORESTAL ORIGINAL (EM%)
ACRE	20.106	1.379	3.332	24.817	15
AMAPÁ	2.964	172	160	3.296	4
AMAZONAS	34.104	2.820	8.468	45.392	3
MARANHÃO	107.094	1.534	1.712	110.340	77
MATO GROSSO	206.517	5.692	10.284	222.493	43
PARÁ	250.667	11.135	22.497	284.299	25
RONDÔNIA	84.680	4.284	8.146	97.110	46
RORAIMA	9.463	810	1.802	12.075	8
TOCANTINS	30.145	273	190	30.608	76
AMAZÔNIA LEGAL	745.740	28.099	56.591	830.430	21

Fonte: Adaptado - Dados do Prodes – INPE, 2021.

Até o ano de 2021, 42% da extensão territorial da Amazônia Legal era constituída por Áreas de Preservação, que se dividiam em Unidades de Conservação (UCs), Terras dos Povos Originários (TPOs) e Terras de Comunidades Quilombolas (TCQs). Propriedades privadas ocupavam 21% da área, assentamentos rurais ocupavam aproximadamente 8%, e áreas militares representavam 1% do território regional. Outros tipos de terras, que incluíam florestas sob domínio público e áreas de domínio público sem destinação específica, totalizavam 25% da região (tabela 2). Quanto à destinação fundiária, cerca de 71% da Amazônia Legal já possuía alguma forma de destinação, enquanto os outros 29%

não tinham informações registradas sobre a destinação fundiária (BRITO et al, 2021a).

Tabela 2: Situação territorial na Amazônia Legal, 2019

CLASSE FUNDIÁRIA		ÁREA (km ²)	ÁREA (em %)
UC*	Uso Sustentável	530.511,7	10,6
	Proteção Integral	394.922,2	7,9
	APA	186.792,3	3,7
Terras Indígenas		1.151.920,5	23
Terras Quilombolas		9.692,1	0,2
Assentamentos Rurais		392.196	7,8
Imóvel Privado		1.053.247	21
Área Militar		26.693,6	0,5
Outros		1.269.093	25,3
TOTAL		5.015.068,4	100

Fonte: adaptado de Brito et al. (2021) com base nos dados de ISA e IBGE.

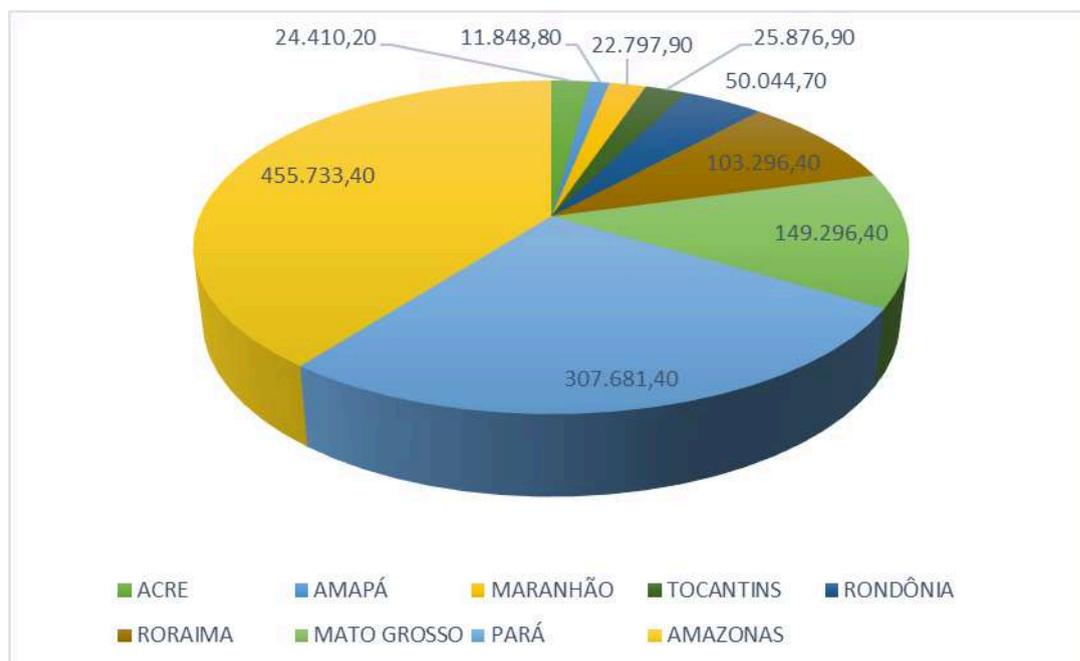
*Unidades de Conservação

As UCs são divididas em dois grupos: de Sustentabilidade e de Proteção Integral (Brasil 2000). As Zonas Resguardadas (tabela 3) abarcam UCs e Tis, tendo essas regiões 42% do território da Amazônia Legal, dos quais 23% são Tis e 22% são UCs. Em termos de extensão, as TIs predominam nos estados do Amazonas (455.733,4 km²) e Pará (307.681,4 km²) (gráfico 3).

Tabela 3: Áreas protegidas e categoria por estados da Amazônia Legal, 2020

ESTADO	PROTEÇÃO INTEGRAL (km ²)				USO SUSTENTÁVEL (km ²)				UC* TOTAL	TI ** (km ²)	ÁREAS PROTEGIDAS TOTAL ***	
	ESEC	REBIO	PARNA E PES	RVS E MONAT	FLONA, FLOTA	RESEX, FLOREX, ARIEX	RDS	APA			km ²	%
ACRE	845,2	-	14.955,50	-	9.898,90	27.001,30	-	348,5	53.049,3	24.410,2	77.111,00	47
AMAPÁ	1.176,9	4.002	42.080,30	-	27.855,10	5.026,30	8.578,80	395,2	89.114,6	11.849	100.720	71
AMAZONAS	17.645,8	15.234,40	96.281	-	101.335,60	46.984,30	100.677,70	18.842	397.000,9	455.733,40	833.893,30	53
MARANHÃO	1,2	2.931,60	10.576,20	-	-	1.510,60	-	29.408,10	44.427,7	22.797,90	38.441,60	15
MATO GROSSO	2.768,6	45,3	15.576,20	799,2	1,7	1.605,50	-	10.499,30	31.459,8	149.375,00	170.336,50	19
PARÁ	45,3	19.959,20	29.910,00	112,30	117.405,30	44.540,90	1.849	98.137,90	388.986,2	307.681,40	607.360,30	49
RONDÔNIA	3.716,2	5.830,50	13.239	-	7.492,50	20.237,90	569,5	1.193,10	52.55,2	50.044,70	101.179,60	43
RORAIMA	4.684,5	-	5.757,30	-	4.313,30	3.972,50	-	8.027,50	26.755,2	103.296,40	122.024,10	54
TOCANTINS	6.316,0	-	3.890,00	326	-	90,7	-	22.614,60	33.238,3	25.876,90	36.500,50	13
AMAZÔNIA LEGAL	114.226	48.003	232.430,70	1.237,50	268.302,40	150.970,00	111.675	189.466,20	1.116.311	1.151.065,60	2.087.565,90	42

Fonte: Adaptado de Brito et al, 2021.

Gráfico 3: Terras Indígenas Por Estado na Amazônia Legal (km²)

Fonte: Adaptado do Prodes – INPE, 2021.

Os direitos dos povos indígenas à terra foram oficialmente reconhecidos apenas quatro séculos após o início da colonização do Brasil, tanto pelo estado português quanto pelo estado brasileiro, apesar de sua presença nessas terras remontar a cerca de dez mil anos antes da chegada dos europeus (ALENCAR, 2015). A primeira menção aos direitos territoriais dos povos indígenas surgiu na Constituição de 1934, que reconhecia a posse da terra por aqueles povos indígenas que a ocupavam de forma permanente, porém, proibia a sua venda, uma disposição mantida nas constituições de 1937 e 1946 (SILVA & PUEREZA, 2019).

A Constituição de 1967 trouxe um pequeno avanço nos direitos indígenas, reconhecendo o direito exclusivo de usufruto das riquezas naturais encontradas nas terras por eles ocupadas e invalidando qualquer tentativa de domínio, posse ou ocupação por terceiros das terras indígenas, sem direito a ação ou indenização contra a União e a FUNAI (ALENCAR, 2015).

Somente na Constituição de 1988, a Carta Magna, dedicou um capítulo específico e oito artigos adicionais em diferentes capítulos para tratar dos direitos indígenas, estabelecendo no "Capítulo VIII – Dos Índios", a definição de Terras Indígenas (TIs) como áreas do território nacional tradicionalmente ocupadas por povos indígenas, de propriedade da União e reconhecidas como tal de forma permanente, entre outras disposições.

Com a promulgação da Constituição da República Federativa do Brasil em 1988, as Terras Indígenas (TIs) foram reconhecidas. O artigo 231 da Constituição afirma: "São reconhecidos aos índios sua organização social, costumes, línguas, crenças e tradições, e os direitos originários sobre as terras que tradicionalmente ocupam, competindo à União demarcá-las, proteger e fazer respeitar todos os seus bens" (BRASIL, 1988, p. 126).

No mesmo artigo, em seu primeiro parágrafo, as TIs são caracterizadas como: "[...] terras tradicionalmente ocupadas pelos índios as por eles habitadas em caráter permanente, as utilizadas para suas atividades produtivas, as imprescindíveis à preservação dos recursos ambientais necessários ao seu bem-estar e as necessárias à sua reprodução física e cultural, segundo seus usos, costumes e tradições" (BRASIL, 1988, p. 126).

Ao reconhecer os povos indígenas como detentores de estruturas sociais, crenças, tradições e idiomas a serem preservados (BRASIL, 1988), a Constituição de 1988 abandonou definitivamente a perspectiva assimilacionista, característica do antigo Estatuto do Índio, Lei nº 6001/1973, que regulamentou as interações entre o Estado brasileiro e a sociedade indígena. Esse Estatuto seguiu um princípio previsto no Código Civil brasileiro de 1916, que considerava os indígenas como "relativamente incapazes" e determinava que eles deveriam ser colocados sob tutela de um órgão estatal indigenista (primeiramente o Serviço de Proteção ao Índio - SPI, de 1910 a 1967, e atualmente a Fundação Nacional do Índio - Funai) até que alcançassem a "integração à comunhão nacional", ou seja, à sociedade brasileira (BRASIL, 1973).

Ao quebrar com o paradigma da tutela, a Constituição de 1988 também introduziu uma inovação ao reconhecer que os povos indígenas, suas comunidades e organizações, assim como qualquer pessoa física ou jurídica no Brasil, têm legitimidade para pleitear em juízo em defesa de seus direitos e interesses (BRASIL, 1988). Esse princípio está estabelecido no Artigo 232 da Constituição Federal de 1988:

"[...] Os indígenas, suas comunidades e organizações são partes legítimas para ingressar em juízo em defesa de seus direitos e interesses, intervindo o Ministério Público em todos os atos do processo"

As disposições relacionadas ao direito indígena estabelecidas na Constituição orientaram e continuam a orientar a elaboração de numerosos laudos antropológicos

produzidos no contexto dos processos de demarcação de terras indígenas no Brasil. Das vastas terras brasileiras, que totalizam uma extensão territorial de 851.196.500 hectares, correspondendo a 8.511.965 km², as Terras Indígenas (TIs) compreendem 791 áreas, ocupando um total de 118.144.054 hectares (1.181.441 km²), sendo 61 áreas declaradas, 47 identificadas, 535 áreas homologadas e reservadas e 148 em identificação incluindo 6 terras interditadas para grupos em isolamento voluntário (ISA a, 2024).

Dessa forma, cerca de 13,9% das terras do país são destinadas aos povos indígenas e a maioria das TIs está concentrada na Amazônia Legal, abrangendo 430 áreas e ocupando 115.803.611 hectares, o que representa 23% do território amazônico e 98,25% da extensão total de todas as TIs do Brasil. O restante, 1,75%, está distribuído pelas regiões Nordeste, Sudeste, Sul, e nos estados de Mato Grosso do Sul e Goiás (ISA a, 2024).

Terras Indígenas e Extração Mineral

Conforme estabelecido pela Constituição Federal Brasileira de 1998, as Terras Indígenas (TIs) são espaços demarcados com o intuito de assegurar os direitos dos povos indígenas relativos à posse da terra, preservação física, reprodução, identidade cultural, subsistência e organização social (SILVA et al, 2023), desempenhando um papel crucial na preservação do patrimônio etnocultural (RORATO et al, 2022).

Dentre as áreas demarcadas legalmente para a preservação do povo indígena, destacam-se a Terra Indígena Apyterewa, destinando 54,5% de sua extensão à mineração; Baú, com 92,4%; Kayapó, com 33,4%; Munduruku, com 31,4%; Sawré Muybu (Pimental), com 56,8%; e Yanomami, com 34,4% (RORATO et al, 2022). Ainda segundo Rorato et al, 2022, os pedidos para atividades mineradoras incidem sobre cerca de 15% da abrangência integral das terras indígenas designadas para salvaguardar grupos isolados na região da Amazônia Legal Brasileira, um valor proporcional ao impacto observado em relação ao total das terras indígenas, sendo evidenciado em terras de dimensões intermediárias, como Xikrin do Rio Catete ou Baú, onde os interesses minerários abrangem aproximadamente 80% da extensão total.

2.2. Sensoriamento Remoto e Mapeamento Ambiental das Áreas Suscetíveis a Desmatamento

De acordo com Meneses e Almeida (2012), o sensoriamento remoto pode ser entendido como o conjunto de técnicas utilizadas para obter informações e imagens dos elementos da superfície terrestre sem que haja um contato físico direto entre o sensor e o objeto em questão. Dessa maneira, essa concepção estabelece os seguintes princípios: i) Não deve haver matéria presente no espaço entre o objeto e o sensor; ii) As informações do objeto podem ser transmitidas através do espaço vazio; iii) A comunicação entre o objeto e o sensor é realizada por meio da radiação eletromagnética.

A obtenção das propriedades dos objetos é realizada por meio de sensores orbitais, cada um com características únicas, como: a resolução na dimensão espacial, que estabelece a precisão na observação de um objeto na superfície; a resolução temporal, determinada pelo intervalo de tempo entre as revisões de um sensor específico em um ponto específico da superfície; a resolução espectral, que se refere ao número de bandas (intervalos do espectro eletromagnético) capturadas pelo sensor; e a resolução radiométrica, que permite a distribuição de pixels em diferentes tons de cinza (MORAES, 2015).

Quanto à interação da radiação eletromagnética com o alvo terrestre, ela se divide em três componentes: a refletida, a absorvida e a transmitida. Cerca de 50% da energia que atinge a planta é absorvida, enquanto os outros 50% são refletidos ou transmitidos; somente a refletância é considerada no processo de sensoriamento remoto. A resposta espectral da refletância da vegetação se refere à habilidade da planta em refletir a radiação eletromagnética em diferentes comprimentos de onda do espectro (MOREIRA, 2005).

Dessa forma, recentemente, surgiram novas abordagens baseadas em dados de sensores em órbita, que combinam múltiplos espectros e informações temporais de alta e média resolução espacial. Essas ferramentas têm sido cruciais na estimativa de parâmetros como cobertura vegetal, degradação florestal e expansão urbana (NAIKOO et al., 2020). O sensoriamento remoto, em conjunto com a tecnologia GIS (Sistema de Informações Geográficas), oferece uma plataforma robusta para analisar as mudanças na paisagem em escala global (SILVA & PACHECO, 2020).

2.2.1. PlanetScope

Criada em 2010 por uma equipe de cientistas anteriormente ligados à NASA, a Planet tem como propósito principal adquirir imagens do planeta diariamente e tornar a mudança global clara e acessível, sendo muito útil em áreas como Defesa e Inteligência, Gerenciamento de Emergência, Energia e Infraestrutura, Silvicultura, Mapeamento, Agricultura, Governo Civil, Seguro, Finanças e Inteligência de Negócios (PLANET LABS b, 2023).

Os produtos provenientes dos satélites PlanetScope derivam de três conjuntos de equipamentos, identificados como PS2, PS2.SD e PSB.SD. Após o lançamento bem-sucedido de 88 satélites Dove em fevereiro de 2017 e de mais 48 em julho do mesmo ano, a Planet alcançou a Missão 1 (PLANET LABS c, 2023).

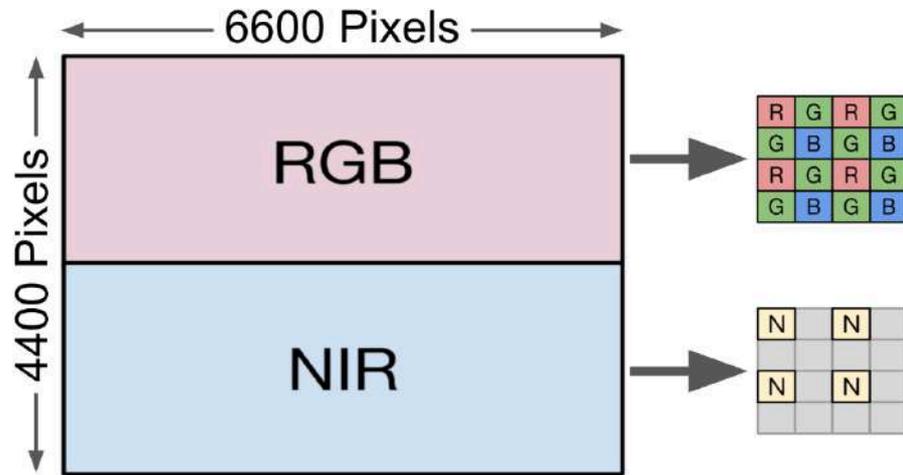
As imagens são capturadas como uma sequência ininterrupta de quadros únicos, conhecidos como “cenas”. Essas cenas são resultantes de diversas gerações de satélites PlanetScope. A geração mais antiga desses satélites capturava um único quadro RGB (vermelho, verde, azul) ou um quadro dividido, com uma metade sendo RGB e a outra NIR (infravermelho próximo), dependendo das capacidades do satélite em questão. Por outro lado, a nova geração de satélites PlanetScope (PS2.SD e PSB.SD) adquire imagens com quadros multistripe, nos quais as bandas estão divididas entre RGBNIR (PS2.SD) ou RGBNIR, verde I, amarelo e azul costeiro (PSB.SD) (PLANET LABS d, 2024).

A Planet oferece duas linhas de produtos para imagens PlanetScope: o produto Basic Scene e o produto Ortho Scene. O produto Basic Scene representa a radiância no topo da atmosfera (TOA) ajustada e um produto corrigido no nível do sensor. Esse produto foi elaborado para usuários com habilidades avançadas em processamento de imagens e correção geométrica, não sendo ortorretificado ou corrigido para distorções do terreno. Por outro lado, as cenas Ortho são imagens de quadros únicos capturadas por um satélite PlanetScope, mas com aplicação de processamento pós-captura adicional (PLANET LABS d, 2024).

Esse feito notável permitiu à Planet capturar imagens da superfície terrestre em uma escala global, cobrindo aproximadamente 200 milhões de quilômetros quadrados diariamente, em quatro diferentes faixas espectrais: azul, verde, vermelho e infravermelho próximo (NIR). Em agosto de 2021, a Planet realizou a atualização de todos os satélites Dove originais para a próxima geração de Doves. A

empresa mantém uma frequência de observação quase diária e adicionou quatro novas bandas espectrais: verde I, borda vermelha, amarela e azul costeira (PLANET LABS c, 2023).

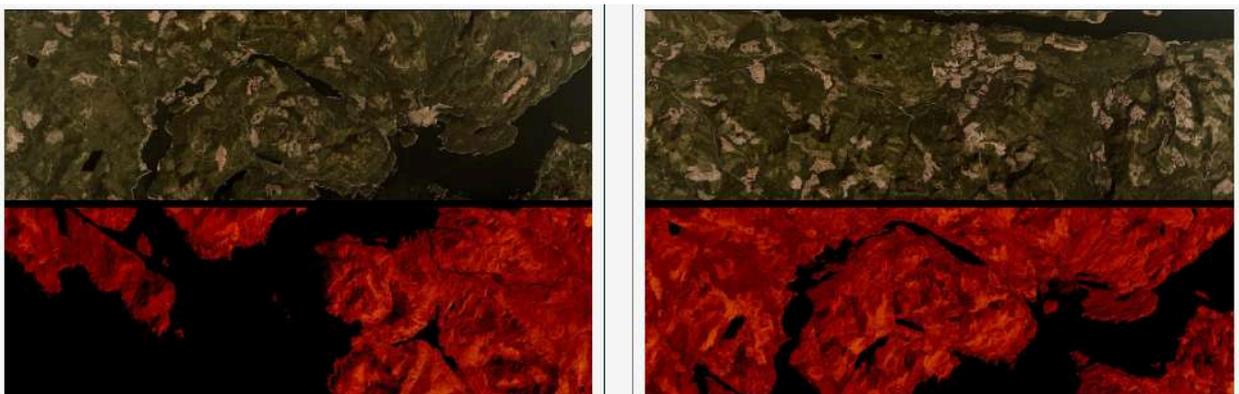
Figura 2: Representação da Imagem do Instrumento PS2



Fonte: Planet Labs, 2024.

Dessa maneira, cada quadro capturado pelo instrumento PS2 compreende uma metade superior que representa uma imagem RGB e uma metade inferior que corresponde a uma imagem NIR (como ilustrado abaixo). A metade RGB de cada quadro é então mesclada com a metade NIR do quadro adjacente, resultando na geração da imagem final de 4 bandas, como mostrado na figura 3 (Planet Labs c, 2024).

Figura 3: Imagens do Instrumento PS2



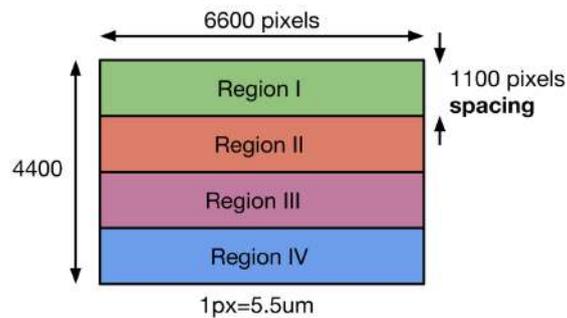
Fonte: Planet Labs, 2024.

2.2.1.1. O Instrumento PS2.SD

O sistema PS2.SD é formado pelo mesmo telescópio denominado “PS2” e pelo mesmo detector de quadros 2D utilizado no sistema PS2 (figura 4). No entanto,

os filtros de padrão Bayer e os filtros de banda passante presentes nos satélites PS2 foram substituídos por um filtro de bloco de açougueiro de alta eficiência. Esse filtro PS2.SD é composto por quatro filtros de banda passante individuais que segregam a luz em cada um dos canais azul, verde, vermelho e NIR, sendo a seleção dos filtros de banda passante para o sistema PS2.SD cuidadosamente alinhada e é interoperável com os filtros utilizados no Sentinel-2 (PLANET LABS c, 2024).

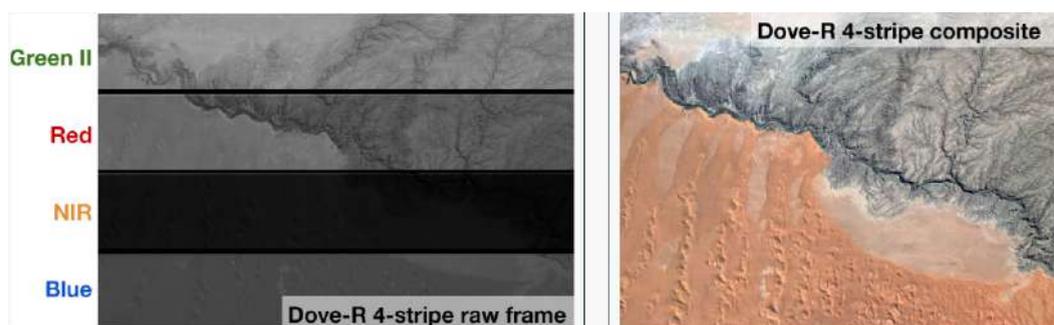
Figura 4: Representação da Imagem do Instrumento PS2.SD



Fonte: Planet Labs, 2024.

Cada quadro capturado pelo sistema PS2.SD é composto por quatro faixas, conforme ilustrado na figura 5. Para produzir a imagem final de quatro bandas, é realizada a sobreposição de diversos quadros consecutivos em cada lado de um quadro específico (PLANET LABS c, 2024).

Figura 5: Imagens do Instrumento PS2.SD



Fonte: Planet Labs, 2024.

2.2.2.2. O Instrumento PSB.SD

O instrumento mais recente, o PSB.SD, abriga o telescópio de última geração "PSBlue", equipado com um sensor ampliado de 47 megapixels e uma capacidade

de filtragem equivalente à do PS2.SD, cobrindo as faixas espectrais Vermelha, Verde, Azul e NIR (PLANET LABS c, 2023).

As funcionalidades aprimoradas do PSB.SD ampliam sua capacidade ao adicionar quatro novas faixas além das já presentes no PS2.SD (Vermelha, Verde, Azul e NIR). Essas novas faixas incluem Red Edge, Green I, Yellow e Coastal Blue, como demonstrado no quadro 3. Destaca-se que a faixa Red Edge é compatível com a banda 5 do Sentinel-2, conforme descrito na tabela abaixo nesta seção, que detalha a faixa de absorção de cada faixa espectral (PLANET LABS c, 2023).

A carga útil do PSB.SD conta com um sensor maior e atualizado, resultando em uma ampliação significativa do enquadramento das cenas capturadas, tanto em largura quanto em altura, quando comparada às cenas capturadas pelos dispositivos PS2.SD e Dove Classic. Cada cena agora é composta por oito faixas, criando uma imagem final de 8 bandas com múltiplas cenas consecutivas empilhadas em cada lado de uma cena específica (PLANET LABS c, 2023).

Quadro 3: Ordem de Banda e Frequência dos Sensores.

Ordem de Banda e Frequência do Sensor			
	Frequência de imagens do pedido retornado dos sensores PlanetScope		
Bandas encomendadas	Imagens do PS2	Imagens do PS2.SD	Imagens do PSB.SD
3-bandas			
Banda 1 = Red (Vermelho)	Red: 590 - 670 nm	Red: 650 - 682 nm	Red: 650 - 680 nm
Banda 2 = Green (Verde)	Green: 500 - 590 nm	Green: 547 - 585 nm	Green: 547 - 585 nm
Banda 3 = Blue (Azul)	Blue: 455 - 515 nm	Blue: 464 - 517 nm	Blue: 465 - 515 nm
4-bandas			
Banda 1 = Blue (Azul)	Blue: 455 - 515 nm	Blue: 464 - 517 nm	Blue: 465 - 515 nm
Banda 2 = Green (Verde)	Green: 500 - 590 nm	Green: 547 - 585 nm	Green: 547 - 585 nm
Banda 3 = Red (Vermelho)	Red: 590 - 670 nm	Red: 650 - 682 nm	Red: 650 - 680 nm
Banda 4 = Near-infrared (Infravermelho Próximo)	NIR: 780 - 860 nm	NIR: 846 - 888 nm	NIR: 845 - 885 nm
8-bandas			
Banda 1 = Coastal Blue(Azul Costeiro)	n/a	n/a	Coastal Blue 431 - 452 nm
Banda 2 = Blue (Azul)			Blue: 465 - 515 nm
Banda 3 = Green I (Verde I)			Green I: 513 - 549 nm
Banda 4 = Green (Verde)			Green: 547 - 583 nm
Banda 5 = Yellow (Amarelo)			Yellow: 600 - 620 nm
Banda 6 = Red (Vermelho) *			Red: 650 - 680 nm
Banda 7 = Red Edge (Borda Vermelha)			Red Edge: 697 - 713 nm
Banda 8 = Near-infrared (Infravermelho Próximo)			NIR: 845 - 885 nm

Fonte: Adaptado de Planet Labs c, 2024. *borda vermelha refere-se à região de rápida mudança na refletância da vegetação na faixa do infravermelho próximo do espectro eletromagnético

2.3. Classificação de Imagens

2.3.1. Classificação Supervisionada kNN

A técnica dos k-vizinhos mais próximos (kNN) é um método de aprendizado de máquina supervisionado simples, capaz de abordar tanto problemas de regressão quanto de classificação (MORAITIS, TSIPI & VOUYIOUKAS, 2020). É um algoritmo clássico de aprendizado supervisionado usado principalmente para tarefas de categorização. Este método conta com um parâmetro chamado k, que indica a quantidade de 'vizinhos mais próximos' (UDIN et al, 2022).

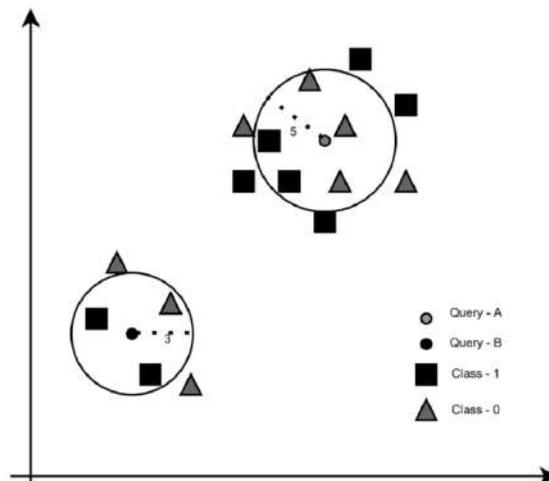
O princípio central envolve usar medidas de proximidade para encontrar as k amostras de treinamento mais próximas da amostra que está sendo analisada (figura 6). Com base nisso, podem ser realizadas previsões usando os resultados desses k vizinhos. Em problemas de regressão, a estimativa final é calculada pela média dos k vizinhos mais próximos (MORAITIS, TSIPI & VOUYIOUKAS, 2020), sendo esses dados selecionados de acordo com as distâncias mais curtas até o ponto de interesse. Depois de identificar os k pontos mais próximos, o algoritmo faz uma votação para determinar a classe mais comum entre eles. A classe com mais votos é considerada a classificação final da análise (UDIN et al., 2022).



Fonte: Pacheco et al, 2021.

Se k for 3, por exemplo, para a Consulta B (figura 7), o sistema busca os 3 vizinhos mais próximos e observa que 2 são da classe 1 e 1 é da classe 0. Posteriormente, aplica a regra de votação para determinar a classe predominante, classificando-a como 1. No mesmo sentido, se k for 5 para a Consulta A e houver mais vizinhos da Classe 0, a classificação resultante será 0 (UDIN et al, 2022).

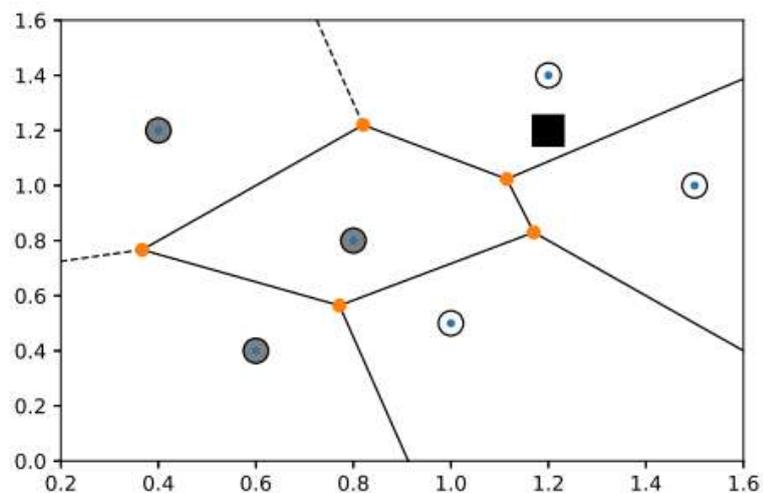
Figura 7: Exemplo do método kNN



Fonte: Udin et al, 2022

Sendo a fronteira de divisão determinada pelo parâmetro k , a fronteira de escolha resulta na formação do que é denominado células de Voronoi (figura 8), uma técnica particular de subdivisão de um espaço métrico, que considera as distâncias entre objetos ou subconjuntos no espaço. Isso faz com que dados semelhantes se agrupem na mesma área dentro do espaço de dispersão dos dados. Com isso, calcula-se a distância entre dois pontos usando uma métrica de distância, sendo a mais comumente utilizada a distância euclidiana mostrada na equação 2 (UDIN et al, 2022).

Figura 8: Células de Voroni



Fonte: Udin et al, 2022.

Ao medir a separação entre dois pontos, as medidas típicas incluem a distância Euclidiana, Manhattan e Minkowski, com a Euclidiana sendo a mais popular. Abaixo, explicamos essa medição. Suponha que $X = (x_1, x_2, \dots, x_n)$ e $Y = (y_1, y_2, \dots, y_n)$ sejam dois pontos, onde X é menor que Y . A distância Euclidiana entre X e Y é representada pela equação 1 (UDIN, 2022):

$$d(x, y)_e = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2} \quad \text{Eq. 1}$$

Caso haja uma dimensão da variável com relevância distinta das demais, é possível introduzir um peso relativo (w_i). Com isso, a distância Euclidiana ponderada pode ser expressa conforme a equação 2 (UDIN, 2022).

$$d(x, y)_m = \sqrt{w_1(x_1 - y_1)^2 + w_2(x_2 - y_2)^2 + \dots + w_n(x_n - y_n)^2} \quad \text{Eq. 2}$$

Sabendo disso, é possível afirmar que existem várias técnicas para calcular essa distância. As mais conhecidas são a euclidiana (equação 3), Manhattan (equação 4) e Chebyshev (equação 5), sendo a distância euclidiana é a aplicação mais comum entre essas técnicas (VU, DIHN & TO, 2019).

$$D_{Euclidean}(x, y) = \left(\sum_{i=1}^n (x_i - y_i)^2 \right)^{1/2} \quad \text{Eq. 3}$$

A distância de Manhattan, também conhecida como distância de quarteirão, é uma distância altamente popular. A distância de Manhattan é fornecida por:

$$D_{Manhattan}(x, y) = \sum_{i=1}^n |x_i - y_i| \quad \text{Eq. 4}$$

Entre dois vetores, a distância de Chebyshev, métrica mínima, ou norma do infinito, é o máximo de suas magnitudes absolutas ao longo da dimensão vetorial. A distância de Chebyshev (MORAITIS, 2020) é definido por:

$$D_{Chebyshev}(x, y) = \max_i |x_i - y_i| \quad \text{Eq. 5}$$

Em que $x, y =$ vetor.

O algoritmo kNN opera sob a suposição de que objetos similares estão próximos uns dos outros. A estratégia conhecida como kNN funciona ao calcular as distâncias entre um pixel e todos os pontos nos dados, e em seguida, seleciona os k vizinhos mais próximos, calculando a média dos mais frequentes. A escolha adequada do número de vizinhos (k) pode resultar no melhor ajuste para problemas de regressão, sendo possível alcançar isso ao experimentar diferentes valores de k e selecionar aquele que proporciona resultados ótimos (MORAITIS, TSIPI & VOUIOUKAS, 2020).

Em outras palavras, o número k no kNN é crucial para garantir um desempenho ideal. Se o valor de k for muito baixo, o modelo torna-se mais complexo, aumentando assim o risco de overfitting, que consiste em um modelo que se ajusta muito bem aos dados de treinamento específicos, perdendo a capacidade de generalização para novos dados não vistos, especialmente quando o vizinho mais próximo exibe comportamento semelhante a ruído. Por outro lado, valores altos de k simplificam a estrutura do modelo, mas podem afetar a precisão das previsões entre amostras vizinhas (MORAITIS, TSIPI & VOUIOUKAS, 2020).

2.3.2. Matriz de Confusão

A tabela de confusão, também chamada de matriz de confusão (CONGALTON, 1983; STEHMAN & FOODY, 2019), é uma ferramenta de disposição quadrada que quantifica a semelhança entre os dados de referência (geralmente organizados em colunas, provenientes de fotos ou vídeos aéreos, medições de solo, etc.) e os dados de classificação (geralmente organizados em linhas, gerados a partir de mapas ou dados de sensoriamento remoto) (CONGALTON, 1991). A representação da matriz de confusão está demonstrada no quadro 2.

Considerando que existem n amostras distribuídas entre k^2k^2 células, em que cada amostra é atribuída a uma das k classes no mapa, distribuídas de forma independente entre as mesmas k classes no conjunto de dados de referência. Portanto, corresponde ao número de amostras distribuídas na classe i ($i = 1, 2, \dots, k$) no conjunto de dados de classificação e classe j ($j = 1, 2, \dots, k$) no conjunto de dados de referência. Já n_{i+} é a soma do número de amostras designadas como classe i no

mapa e n_{j+} é a soma do número de amostras da classe j nos dados de referência, conforme apresentado nas equações 6 e 7 (SOUZA, 2020).

$$n_{i+} = \sum_{j=1}^k n_{ij} \quad \text{Eq. 6}$$

$$n_{+j} = \sum_{i=1}^k n_{ij} \quad \text{Eq. 7}$$

A equação 6 indica a soma total de cada linha nos dados de classificação, enquanto a equação 7 denota a soma total de cada coluna nos dados de referência. A diagonal principal da matriz de confusão reflete a concordância entre os dados de classificação e os dados de referência, sendo representada por n_{ij} , onde $i = j$ ($i = 1, 2, \dots, k$) (quadro 4) (CONGALTON, 2009). Assim, a classificação correta é refletida pelas amostras na diagonal principal da matriz de confusão, enquanto a classificação incorreta é indicada pelas amostras fora da diagonal principal (COUTO, 2003; STEHMAN, 2006).

Quadro 4: Matriz de Confusão

		Dados de Referência (j =			Total das Linhas n_{i+}
		colunas)			
Dados de Referência (i = linhas)		n_{11}	n_{12}	n_{1k}	n_{1+}
		n_{21}	n_{22}	n_{2k}	n_{2+}
		n_{31}	n_{32}	n_{kk}	n_{k+}
Total das Linhas n_{+j}		n_{+1}	n_{+2}	n_{+k}	n

Fonte: Adaptado de Congalton, 2009.

Denotando p_{ij} como a proporção de amostras correspondente à célula i, j -ésima (n_{ij}), a equação 8 expressa a proporção de amostras que cada célula possui de uma combinação específica de classes de cobertura de terra classificada e referenciada (Salk et al., 2018). Quando $i = j$, encontra-se a proporção da diagonal principal da matriz (equação 9). Então, as proporções marginais das linhas p_{i+} (equação 10) e

colunas p_{+j} (equação 11) podem ser definidas como concordância ao acaso (SOUZA, 2020).

$$p_{ij} = \frac{n_{ij}}{n} \quad \text{Eq. 8}$$

$$p_{ii} = \frac{n_{ii}}{n} \quad \text{Eq. 9}$$

$$p_{i+} = \sum_{j=1}^k p_{ij} = \frac{n_{i+}}{n} \quad \text{Eq. 10}$$

$$p_{+j} = \sum_{i=1}^k p_{ij} = \frac{n_{+j}}{n} \quad \text{Eq. 11}$$

A matriz de confusão é uma ferramenta valiosa para análises estatísticas, especialmente no contexto do Sensoriamento Remoto. Ela nos permite avaliar de forma clara e precisa a concordância entre os dados classificados e os dados de referência, possibilitando uma compreensão mais profunda da acurácia dos modelos utilizados. Dentro desse contexto, são utilizados diversos métodos de análise de acurácia, cada um com suas particularidades e aplicabilidades. Destacam-se a acurácia total, o Kappa de Cohen, o índice de Tau, o Pi de Scott, o Kappa ponderado e o índice Ground Truth, entre outros (SOUZA, 2020).

Ao serem analisadas as frequências de uso desses métodos em publicações científicas, percebe-se que a acurácia total, com 62,7% das publicações, e o Kappa de Cohen, com 29,5% das publicações de artigos científicos, são os mais amplamente empregados, representando a maioria dos estudos. Isso se deve, em parte, à sua simplicidade de cálculo e interpretação, tornando-os acessíveis para diversos tipos de análises (SOUZA, 2020).

No entanto, é importante mencionar que o Kappa ponderado, apresentando 1,07% de publicações, não é tão adotado devido à sua complexidade na atribuição de pesos às diferentes classes. Em contrapartida, o índice de Tau, que possui 1,13% de publicações, e o Pi de Scott, com 0,7%, também ganham destaque por oferecerem uma abordagem diferenciada na análise de concordância, complementando as análises tradicionais de acurácia (SOUZA, 2020).

Um ponto interessante é a utilização do índice Pabak, que é mais recente e ainda pouco difundido, mas apresenta potencial para aprimorar a avaliação da acurácia em relação ao uso e cobertura do solo, sendo uma área de estudo em constante evolução e aprimoramento (SOUZA, 2020).

2.3.3. Categorias de Acurácia

2.3.3.1. Acurácia Total

A precisão total ou precisão global proposta por Story e Congalton (1986) visa avaliar a concordância geral entre os dados de categorização e os de referência, calculando a proporção da diagonal principal em relação ao número total de amostras, p_o , como expresso na equação 12.

$$p_o = \frac{\sum_{i=1}^k n_{ii}}{n} \quad \text{Eq. 12}$$

A porcentagem de concordância, também conhecida como p_o por autores como Story, Congalton (1986), Ma e Redmond (1995), e como proporção observada por Koukolas, Blackburn (2001), Congalton (2009), é representada pela soma das amostras categorizadas corretamente, conforme expresso na equação 13.

$$p_o = \sum_{i=1}^k p_{ii} \quad \text{Eq. 13}$$

2.3.3.2. Kappa Cohen

A técnica de análise Kappa, introduzida por Cohen (1960), é uma abordagem multivariada discreta empregada na avaliação de precisão (Bishop et al., 1975). Ela quantifica a concordância entre as classificações, excluindo a concordância por acaso (COHEN, 1960). O resultado obtido pela análise Kappa é a estatística KHAT (K), que mensura o grau de concordância entre as classificações e as referências. Ao considerar duas matrizes, essa estatística permite identificar diferenças entre as matrizes de dois avaliadores, em datas distintas, entre outras situações (CONGALTON, 2009, p.107).

Para calcular o estimador K, é preciso determinar a proporção de concordância observada atualmente, representada por p_o (equação 14), e a proporção de concordância por acaso, representada por p_c (equação 15), que é o

produto das proporções marginais das linhas e colunas das classificações e das referências. A p_c também é conhecida como proporção esperada (SOUZA, 2020).

$$p_c = \sum_{i=1, j=1}^k p_{i+j} \quad \text{Eq. 14}$$

Dentro de um modelo de amostragem multinomial, a estimativa de máxima verossimilhança para K é expressa por (SOUZA, 2020):

$$\hat{K} = \frac{p_o - p_c}{1 - p_c} \quad \text{Eq. 15}$$

No entanto, é importante destacar que o numerador dessa equação representa a discrepância entre os dados observados e os dados esperados (os dados de classificação), tornando essa estatística comparável à análise da família Qui-quadrado (X^2) (SOUZA, 2020).

Os resultados de K variam de -1 a +1, onde -1 indica ausência de concordância, 0 indica concordância equivalente entre os dados, e +1 indica concordância perfeita. Landis e Koch (1977) categorizaram o nível de concordância K em três faixas: valores acima de 0,80 indicam alta concordância, entre 0,40 e 0,80 indicam concordância moderada, e abaixo de 0,40 indicam baixa concordância.

2.3.3.3. Pi de Scott

O índice Pi de Scott (equação 16), criado por Scott em 1955, ajusta a concordância prevista com base no número de grupos e em quão frequentemente esses grupos são usados. A equação dele é parecida com a do Kappa, mas muda ao calcular a concordância esperada usando as proporções de cada grupo na amostra total de elementos do conjunto (SOUZA, 2020).

$$\pi = \frac{p_o - p_s}{1 - p_s} \quad \text{Eq. 16}$$

A concordância prevista é influenciada pela quantidade de grupos e pela frequência de uso de cada um durante um teste específico (SCOTT, 1955). Se assumirmos que as proporções de concordância são uniformes entre as categorizações e que conhecemos as unidades em cada grupo em toda a população (SOUZA, 2020), o valor de p_s é dado por (equação 17):

$$p_s = \sum_{i=1}^k \left(\frac{p_{i+} + p_{+i}}{2} \right)^2 \quad \text{Eq. 17}$$

Esse índice pode variar de 0 a 1, não importa a quantidade de grupos, o que facilita a comparação com a precisão total. Quanto mais próximo de 1, maior é a concordância entre os classificadores. A concordância prevista mínima, ou incerteza máxima, ocorre quando todos os grupos têm a mesma frequência de uso, e aumenta conforme ocorre qualquer desvio da distribuição uniforme de frequências entre os grupos (SCOTT, 1955).

2.3.3.4. Índice tau

O índice Tau foi concebido por Klecka (1980) e introduzido no contexto do sensoriamento remoto por Ma e Redmond (1995). Similar ao Kappa, busca avaliar o grau de concordância presente na matriz de confusão. Couto (2003) argumenta que o Tau quantifica a melhora na precisão das classificações considerando o ajuste aleatório das amostras para as respectivas classes.

Ma e Redmond (1995) destacam que a diferença principal entre os índices Kappa e Tau reside nas abordagens probabilísticas. Enquanto o Kappa se baseia na probabilidade a posteriori, o Tau utiliza a probabilidade a priori. Isso significa que o Kappa depende da matriz de confusão, enquanto o Tau pode ser calculado antes mesmo da elaboração dessa matriz.

De acordo com Klecka (1980), o coeficiente Tau pode ser determinado utilizando a seguinte equação:

$$T = \frac{p_o - p_r}{1 - p_r} \quad \text{Eq. 18}$$

Se $p_r = 1/k$, então para probabilidades a priori de associação iguais entre os grupos:

$$T_e = \bar{\tau} = \frac{p_o - (1/k)}{1 - (1/k)} \quad \text{Eq. 19}$$

T_e , então, representa o coeficiente Tau em situações em que as classificações são feitas com base em probabilidades iguais de pertencer a uma classe específica.

Ma e Redmond (1995) afirmam que T_e aproxima da acurácia total p_o à medida que o número de classes aumenta.

2.3.3.5. Pabak

O método Pabak (Prevalência - ajustado - ajustado Kappa) foi desenvolvido por Byrt, Bishop e Carlin (1993) e corrige o índice de Kappa para considerar as diferenças entre a proporção total de erros e acertos nas avaliações, bem como para o viés entre os mapas de referência e classificação. Isso resulta em um índice mais preciso na avaliação da precisão temática (SOUZA, 2020). A equação para calcular o Pabak é:

$$PABAK = \frac{2 \left(\frac{\sum_{i=1}^k n_{ii}}{n} \right) - p_e}{1 - p_e} \quad \text{Eq. 20}$$

Onde $p_e = 0,50$, obtido através das médias das diagonais (Byrt, Bishop e Carlin, 1993). Substituindo esse valor na equação (14), obtemos a nova equação:

$$PABAK = \frac{2 \left(\frac{\sum_{i=1}^k n_{ii}}{n} \right) - 0,5}{1 - 0,5} = 2p_o - 1 \quad \text{Eq. 21}$$

Segundo os autores Byrt, Bishop e Carlin (1993), esse índice "é um método natural de ajuste para viés e prevalência, resultando em um índice linearmente relacionado com a concordância observada,

2.4. Volume de Biomassa e de Degradação

A degradação da cobertura florestal natural em escala global é consequência primordialmente relacionada ao desmatamento com propósitos madeireiros, à intensificação de atividades agrícolas que resultam na degradação do solo, aos incêndios florestais e a eventos naturais impactantes (ARRAES et al., 2012). No cenário atual do Brasil, observa-se que a maior parte da diminuição das florestas, especialmente na região amazônica, está associada à expansão das fronteiras agropecuárias, à abertura de novas estradas, à exploração madeireira e mineral e à construção de infraestruturas como hidrelétricas. Dentre esses fatores, destaca-se a pecuária como um dos principais catalisadores do desmatamento (COHN et al., 2014).

2.5. Sistema de Informação Geográfica

O espaço territorial representa uma vasta área de estudo quando organizado dentro de um Sistema de Informações Geoespaciais (SIG); uma ampla gama de dados e informações é coletada tanto remotamente, por meio de satélites, GPS, drones e computadores, quanto diretamente, por meio de trabalhos de campo. Estes dados podem ser processados, analisados e interpretados de maneira precisa, o que pode ser alcançado de modo altamente eficiente utilizando softwares especializados em SIG (BARBOSA, 2023).

Para a correta utilização desses equipamentos e programas, é crucial que o usuário do sistema possua um conhecimento apropriado, conforme ilustrado na figura 9. Isso implica compreender desde a natureza de cada camada de informação (como tipos de solo, relevo, rochas, uso do solo, etc.), até a parte técnica do software (como a construção de bancos de dados e a utilização de análises estatísticas, por exemplo) (BARBOSA, 2023).

Figura 9: Exemplo dos termos que compõem o SIG



Fonte: Adaptado de Barbora, 2023.

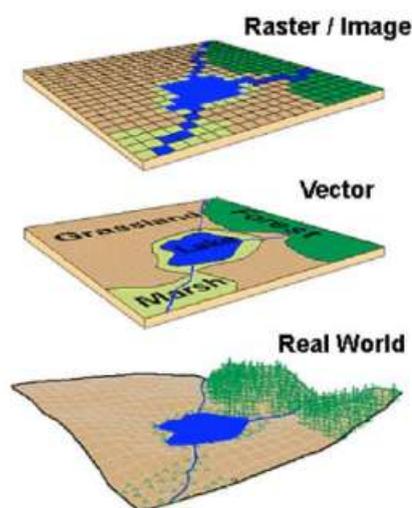
Mesmo do ponto de vista do usuário, o SIG se revela como um instrumento poderoso, preciso e eficaz para as atividades de planejamento urbano e regional, incluindo a gestão dos recursos hídricos (USMANI, 2020), devido à sua capacidade de integrar uma ampla variedade de informações e bancos de dados cartográficos (PINHEIRO et al., 2009).

Algumas das aplicações dos SIG abrangem a combinação e interpretação de mapas, simulação de cenários e modelagem, apoio à tomada de decisões sobre o uso do solo, delimitação territorial, monitoramento ambiental e gerenciamento de recursos hídricos. Um dos softwares de SIG mais renomados é o QGIS, conhecido por sua licença de Código Aberto sob a Licença Pública Geral (GNU) (SCHMITT & MOREIRA, 2015).

Assim como em todo processo de aprendizado, existem diferentes abordagens, desde as mais avançadas até as mais simples. No caso do SIG, isso se reflete na distinção entre a produção do SIG e a sua utilização. Na última, pode-se empregar o sistema apenas para consultas e operações básicas, enquanto a produção envolve o desenvolvimento de materiais, criação de mapas, elaboração de relatórios, entre outras atividades (BARBOSA, 2023).

No âmbito do SIG, o território pode ser representado por dois formatos principais: vetorial e raster (figura 10). Os elementos dos mapas vetoriais são de três tipos: pontos, linhas e polígonos, os quais podem ser editados de forma independente. Este formato também permite a associação de atributos organizados em tabelas aos elementos, ou seja, a criação de bancos de dados. Essas tabelas possibilitam a manipulação de características numéricas e qualitativas de várias maneiras, como a realização de seleções, divisão em classes e elaboração de gráficos (BARBOSA, 2023).

Figura 10: Vetores e Rasters Representando o Mundo Real Através do SIG



Fonte: Saab, 2003.

Por outro lado, as imagens raster são compostas por pixels (sendo a imagem uma matriz de pixels). A classificação desses pixels permite mapear características específicas do terreno, como o seu uso e ocupação, por exemplo. A utilização de instrumentos digitais, exemplificados pelas imagens provenientes de satélites, possibilita a aquisição de dados terrestres que constituem a base de análises concernentes às transformações na utilização do solo ao longo do tempo, viabilizando a concepção de estratégias para abordar questões de ordem socioeconômica e ambiental (PAULA, ZAMBRANO & PAULA, 2018). Os Sistemas de Informação Geográfica (SIG) disponibilizam diversas funcionalidades para a produção de dados capazes de auxiliar na detecção de determinadas alterações na configuração da paisagem.

A integração com informações suplementares pode conduzir à geração de insights valiosos em um contexto específico (ZAEHRINGER et al., 2018), a exemplo das pesquisas acerca das características dos solos em diferentes escalas espaciais e temporais abrangendo níveis globais e regionais. Portanto, a aplicação dos SIG reveste-se de grande relevância em estudos relacionados às transformações paisagísticas, permitindo a compreensão de que as variações na cobertura e nos usos do solo desempenham um papel crucial na modificação do ambiente global, com repercussões nos serviços ecossistêmicos e na diversidade biológica (MENDOZA-PONCE et al., 2018).

3 OBJETIVOS

3.1. Objetivo Geral

Identificar áreas suscetíveis à degradação ambiental no Território Indígena Apyterewa, Pará, Brasil, por meio do mapeamento de uso e ocupação do solo, utilizando o Índice de Vegetação Ajustado ao Solo (SAVI) e a técnica de classificação kNN, derivados de imagens PlanetScope

3.2 Objetivos Específicos

- I. Analisar o processo de uso e ocupação do solo no Território Indígena Apyterewa por meio do SAVI e KNN;
- II. Identificar e mapear áreas suscetíveis a degradação ambiental;

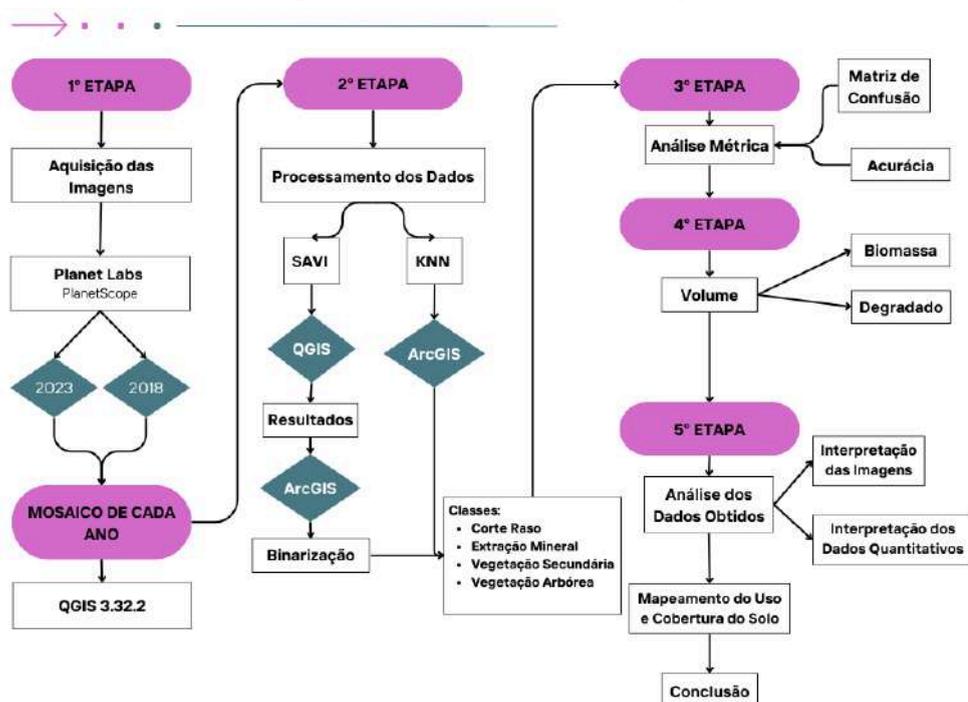
- III. Quantificar o volume por área de biomassa degradada, derivada das análises por KNN e SAVI;
- IV. Investigar as potencialidades do classificador KNN e do índice SAVI em identificar mudanças no cenário da paisagem por meio de imagens PlanetScope.

4 METODOLOGIA

O estudo foi conduzido em cinco etapas sequenciais e interdependentes. A primeira etapa consistiu no pré-processamento das imagens, utilizando registros de 2018 e 2023 da plataforma Planet Labs. Na segunda etapa, foi realizado o processamento dos dados para transformar as imagens em informações úteis, utilizando o Índice de Vegetação SAVI e o algoritmo kNN para classificação.

Na terceira fase, as metodologias empregadas foram avaliadas e comparadas. Na quarta etapa, calcularam-se os volumes de biomassa e biomassa degradada para identificar padrões de degradação. Por fim, a quinta etapa envolveu a análise e interpretação dos dados, resultando em um mapeamento detalhado do uso e cobertura do solo, proporcionando uma compreensão das dinâmicas ambientais ao longo do tempo.

Fluxograma 1: Etapas Metodológicas



Fonte: autora, 2024.

4.1. Caracterização da Área de Estudo

Este estudo concentra-se na análise da Terra Indígena (TI) Apyterewa no localizado do município de São Félix do Xingu, no estado do Pará. A homologação oficial dessa TI foi efetuada por meio do decreto s/n, promulgado em 19 de abril de 2007 (BRASIL, 2007), ficando atualmente sob a gestão compartilhada da Fundação Nacional do Índio (FUNAI) e da Secretaria Especial de Saúde Indígena (SESAI). Com uma vasta extensão territorial de 777.435,48 hectares, situada em São Félix do Xingu, estado do Pará, essa TI é habitada pelo povo Parakanã, que integra a família linguística Tupi-Guarani, utilizando a língua Akwawa para se comunicar.

As coordenadas geográficas da região abrangem 52°41'09,60"W e 05°07'30,30"S, 51°23'38,40"W e 05°17'45,60"S (ISA, 2023). No entanto, devido à vastidão da TI, optou-se por restringir a área de estudo a uma porção menor dentro da TI em análise, com coordenadas de 51°58'01,20"W e 05°37'01,20"S, 51°47'45,60"W e 5°37'01,20"S, 51°47'45,60"W e 5°47'16,80"S, 51°58'01,20"W e 5°47'16,80"S resultando em uma área reduzida para 36044,32 hectares (figura 11).

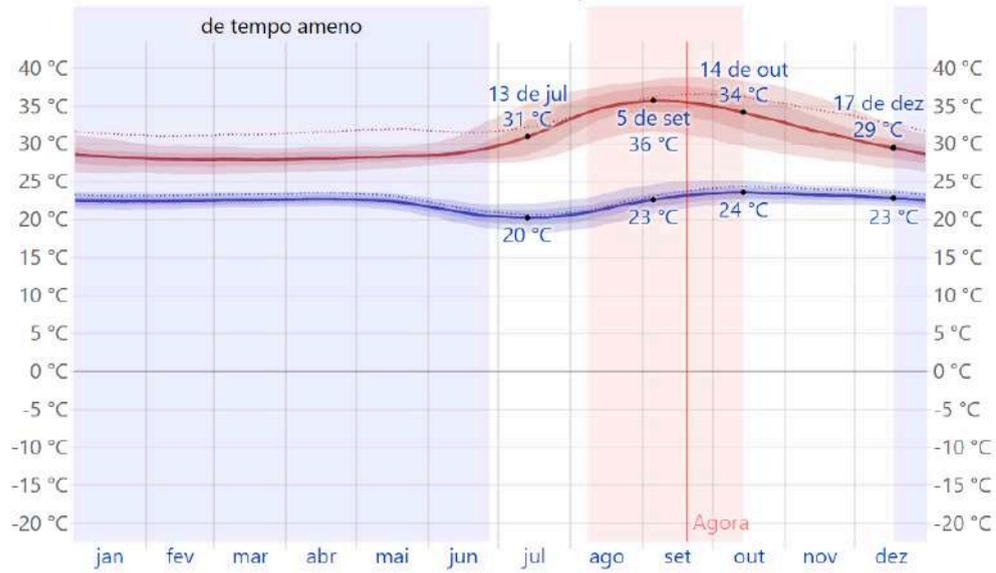
De acordo com informações espaciais fornecidas pelo IBGE (2018a), a área em análise apresenta uma composição fitofisionômica característica da vegetação da Amazônia Legal, compreendendo 62,49% de Floresta Ombrófila Densa Submontana Dossel e 37,51% de Floresta Ombrófila Aberta Submontana com presença de palmeiras e cipós. Destaca-se que toda a região está integralmente inserida na bacia hidrográfica do rio Xingu (ISA, 2023).

Em consonância com a tipificação de Hoffman (2017), a topografia exhibe dois padrões predominantes: suavemente ondulado e ondulado, com altitudes variando entre 200 e 230 metros. De acordo com a tabela 4, a temporada de calor dura cerca de 2,2 meses, do dia 8 de agosto até 14 de outubro, com temperaturas máximas diárias que ultrapassam os 34 °C. O período mais quente no local ocorre em setembro, quando as temperaturas atingem, em média, 36 °C durante o dia e 23 °C à noite (Weather Spark, 2024).

Já a fase mais fresca do ano se estende por aproximadamente 6,3 meses, de 17 de dezembro até 26 de junho, com temperaturas diárias que ficam abaixo dos 29 °C. Junho é o mês mais frio, com médias de 21 °C nas mínimas e 29 °C nas máximas (Weather Spark, 2024). O padrão climático identificado conforme a classificação de Köppen e Geiger é do tipo Aw (Climate-Data, 2019). Além disso, segundo dados espaciais fornecidos pelo IBGE (2018b), o mapeamento de solos na

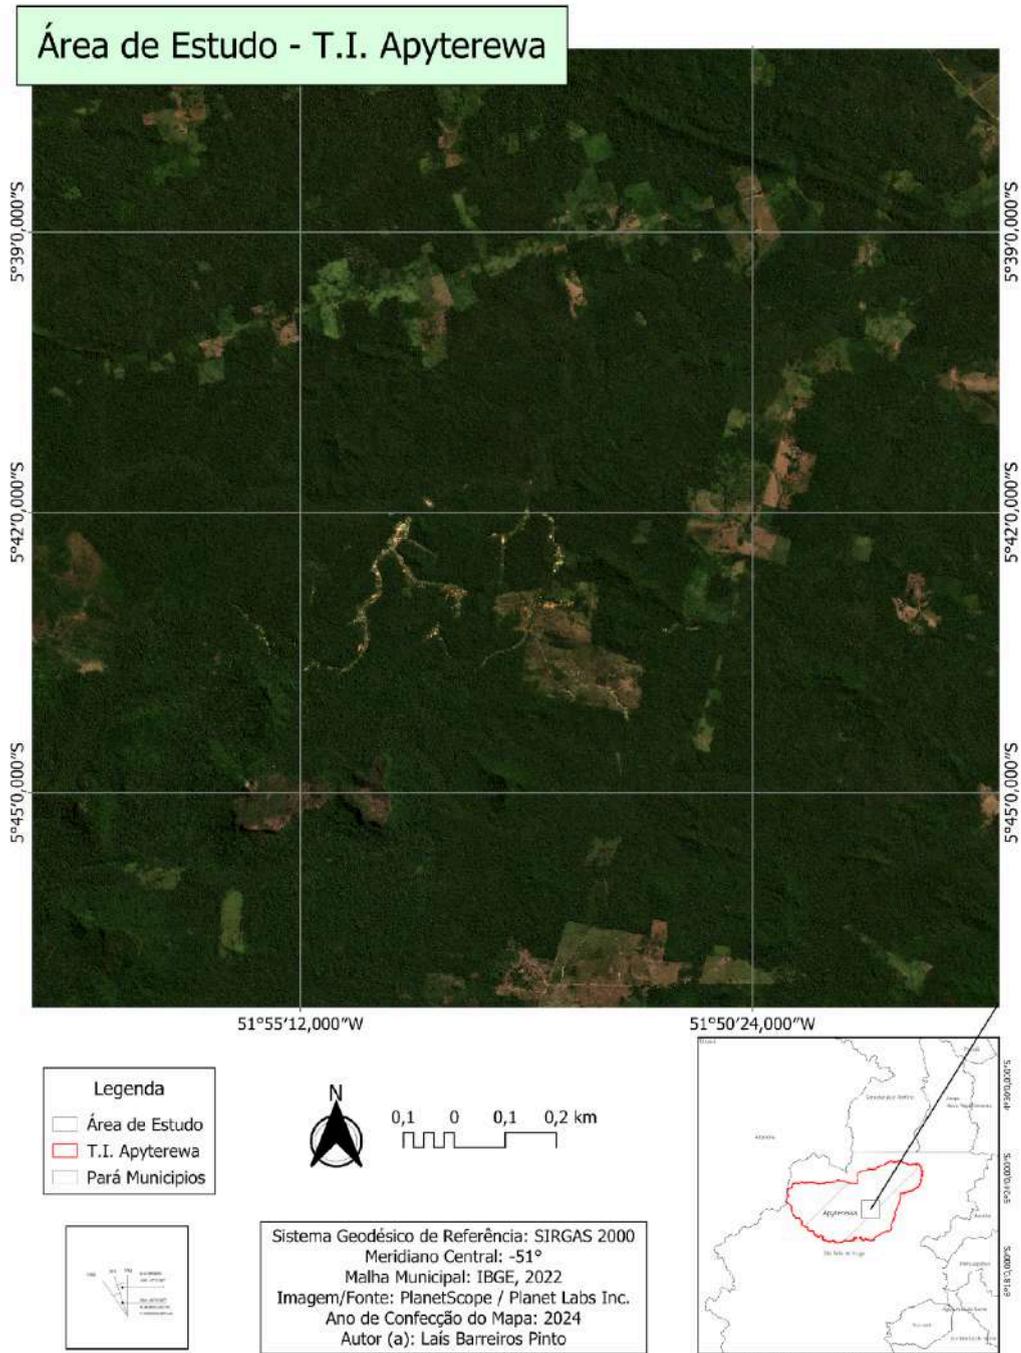
Amazônia Legal categoriza o tipo de solo da região como Argissolo Vermelho Amarelo Distrófico.

Tabela 4: Temperaturas máximas e mínimas médias



Fonte: Weather Spark, 2024.

. **Figura 11:** Mapa de localização da Terra Indígena Apyterewa



Fonte: autora, 2024.

A Terra Indígena Apyterewa, no sul do Pará, é historicamente ocupada pelos Apyterewa-Parakanã e foi oficialmente demarcada em 2007 (BRASIL, 2007). Com uma população de 1383 indígenas (ISA b, 2024), a área de 773.000 hectares sofre com invasões e degradação ambiental, sendo palco de um prolongado conflito fundiário (BÜLL, 2022). Entre agosto de 2020 e julho de 2021, a T.I. Apyterewa foi a

mais desmatada do Brasil e a terceira mais impactada por queimadas ilegais (INPE, 2021; ISA b, 2024).

Os Parakanã são um povo tradicional que vive entre os rios Pacajá e Tocantins, falando uma língua tupi-guarani. No final do século XIX, uma disputa levou à divisão do grupo em Parakanã Orientais e Ocidentais, cada um com modos de vida distintos. Os Orientais, mais sedentários, centralizaram-se em suas aldeias, enquanto os Ocidentais adotaram um estilo de vida mais nômade e beligerante (ISA b, 2024).

Atualmente, o grupo está dividido em dois blocos populacionais. Os Parakanã Orientais habitam a Terra Indígena Parakanã, regularizada em 1980, e representam dois terços da população de 600 pessoas distribuídas em cinco aldeias (ISA b, 2024). Os Ocidentais residem na Terra Indígena Apyterewa, que, embora inicialmente demarcada com 981.000 hectares, teve sua área reduzida para 773.000 hectares (ISA b, 2024).

A divisão entre os Parakanã-Apyterewa e os Parakanã Orientais reflete-se em diferentes padrões de organização sociocultural. Enquanto os Orientais mantêm aldeias coesas, os Ocidentais, nômades, se dividem em pequenos grupos dedicados à caça. A caça, além de subsistência, está ligada à vida espiritual, especialmente ao xamanismo, onde os sonhos, estimulados pelo consumo de carne de caça, têm um papel central (BÜLL, 2022; Fausto, 2014).

4.2. Aquisição de Dados

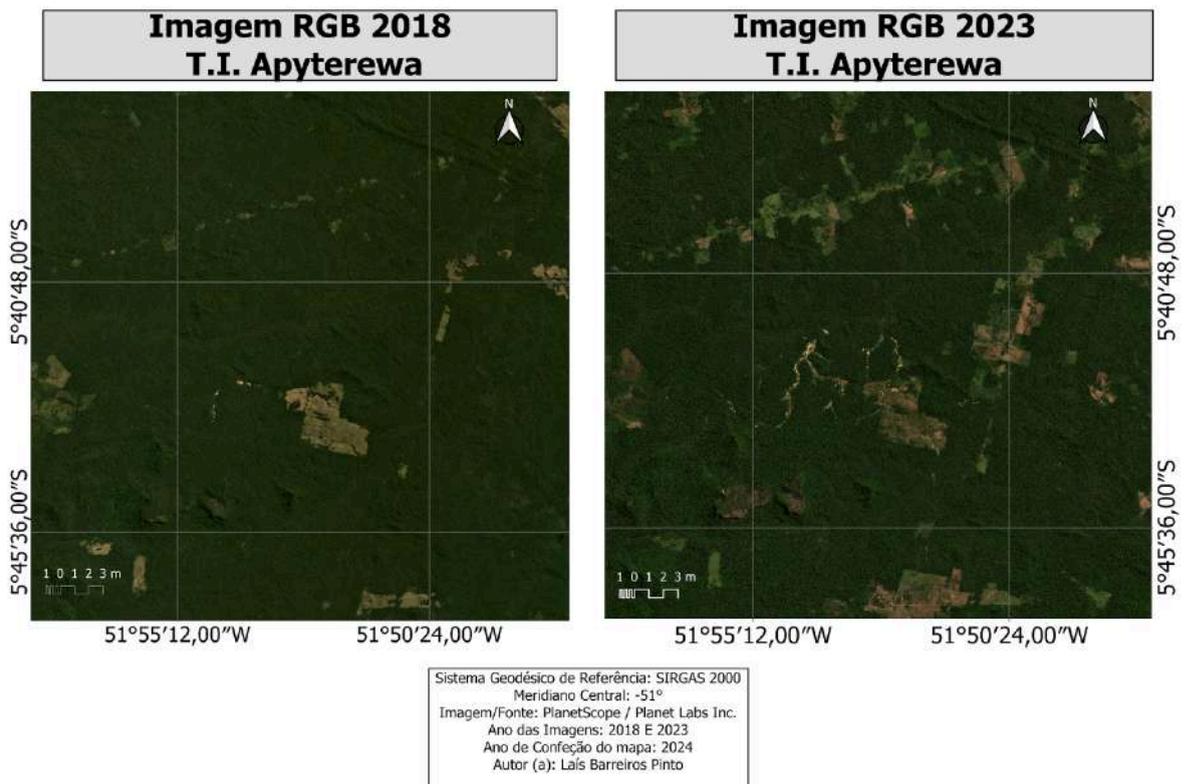
A aquisição das imagens referentes aos anos de 2018 e 2023 (tabela 5) foi conduzida por meio do portal <https://www.planet.com/account/#/dashboard>, responsável pela disseminação educativa das imagens captadas por satélite. Utilizando a ferramenta *Basemaps* (PLANET LABS et al., 2024), foram adquiridas cinquenta e cinco imagens segmentadas que englobavam completamente a área de estudo para o ano de 2018, abrangendo o terceiro trimestre composto pelos meses de julho, agosto e setembro, capturadas pelo sensor Dove Clássico (PS2). Para o ano de 2023, foram selecionadas também cinquenta e quatro imagens segmentadas que abrangiam toda a área de estudo por meio do *Basemaps*, referentes ao terceiro trimestre, compreendendo os meses de julho, agosto e setembro, do referido ano, capturadas pelo sensor Super Dove (PSB.SD).

Tabela 5: Especificações das Imagens de 2018 e 2023 neste estudo

Satélite	Sensor	Período	Quantidade de Imagens
PlanetScope	Dove Classic (PS2)	Terceiro Trimestre	55
PlanetScope	Super Dove (PSB.SD)	Quarto Trimestre	55

Fonte: autora, 2024.

Em seguida, um shapefile foi criado com as seguintes coordenadas: E = 392852,847 e N = 9379023,789, E = 411898,091 e N = 9379052,609, E = 411924,522 e N = 9360136,314, E = 392884,181 e N = 9360106,756. Cada mosaico foi então recortado e foi gerada a área de estudo (figura 12), possibilitando uma visualização mais detalhada e uma análise mais precisa das informações contidas nas imagens. Esses procedimentos foram essenciais para o desenvolvimento de estudos e análises geoespaciais na área de interesse.

Figura 12: Área de Estudo T.I. Apyterewa

Fonte: autora, 2024.

Além disso, as imagens foram adquiridas através do mapa base da Planet, que consiste em uma estrutura de informação geográfica que serve como base para adicionar outras camadas de dados. Ele proporciona contexto para as camadas que

se sobrepõem, como, por exemplo, a adição de dados cadastrais de agências postais sobre um mapa físico de um território, facilitando a localização de recursos. Elementos estáveis como rios, limites e rodovias também podem ser incorporados a essa camada subjacente (PLANET LABS, 2024).

O Mapa Base Global é utilizado em mapeamentos e simulações visuais, sendo gerado automaticamente anualmente e cobrindo todo o globo em bandas RGB. Ele é adequado para o monitoramento e análise de mudanças ao longo do tempo, podendo ser ajustado de acordo com necessidades específicas, como a escolha de imagens de origem e frequência de atualizações (PLANET LABS, 2024).

Os mapas base de reflectância de superfície da Planet são produtos de mosaicos temporais otimizados para consistência radiométrica, reduzindo efeitos de nuvens e outros fenômenos atmosféricos. Eles são ideais para aplicações em mapeamento de florestas, vegetação e cobertura do solo, facilitando a compreensão das mudanças ao longo do tempo (PLANET LABS, 2024).

Esses mapas de reflectância de superfície utilizam um algoritmo proprietário que harmoniza imagens com o Landsat, criando mosaicos de alta qualidade. Podem ser adquiridos em áreas de interesse com frequências de atualização variáveis, de acordo com a necessidade, como trimestral ou semanal (PLANET LABS, 2024).

Ademais, o Mapa Base Global da Planet cobre áreas entre 74° Norte e 60° Sul, minimizando distorções nos polos. As imagens são selecionadas com base em sua qualidade e distribuídas em quadrantes de 4.096 x 4.096 pixels, sendo visualizadas através da ferramenta online Basemaps Viewer (PLANET LABS, 2024).

4.3. Processamento

4.3.1. SAVI

O sensoriamento remoto traz benefícios para a agricultura, como o monitoramento da vegetação e a estimativa de parâmetros biológicos, utilizando Índices de Vegetação (IVs) para avaliar características como biomassa e produtividade (FORMAGGIO & SANCHES, 2017). Esses índices são gerados a partir de combinações espectrais e ajudam a identificar áreas de maior refletância da vegetação (GANDHI et al., 2015). Embora eficazes, os IVs enfrentam limitações causadas por interferências atmosféricas, que podem comprometer a precisão das medidas (HUETE, 1988).

Para monitorar o uso do solo, são necessárias análises temporais que capturam o desenvolvimento das culturas ao longo do tempo (HOLBEN, 1986). O sensoriamento remoto também permite monitorar o solo em diversas escalas e reduz custos com a disponibilização gratuita de imagens para pesquisa (JOHANN et al., 2016; BECKER et al., 2017).

O Soil Adjusted Vegetation Index (SAVI), se apresenta como uma adaptação do Índice de Vegetação da Diferença Normalizada (NDVI) ao buscar superar suas limitações, Jensen (2009) destacou a necessidade de um índice que melhorasse os valores do NDVI sem a necessidade de validações ou medições em campo. A melhoria do índice foi alcançada por meio da introdução de uma constante denominada "L", a qual foi projetada para minimizar o efeito do brilho do solo nos cálculos do índice (equação 22), sendo a variabilidade dessa constante condicionada à densidade do dossel presente na área de estudo, variando de varia de 1 a 0,25 (HUETE, 1988).

$$SAVI = \frac{(1 + L)x(NIR - R)}{(NIR + R + L)} \quad \text{Eq. 22}$$

Para o presente estudo, dada a alta densidade da vegetação observada no bioma Amazônia, especialmente na Terra Indígenas analisada, foi adotada a constante "L" com o valor de 0,25. Essa escolha foi realizada visando uma melhor adaptação do Índice de Vegetação Ajustado ao Solo (SAVI) às condições particulares desse ambiente. Para o cálculo do SAVI, utilizou-se o software QGIS na versão 3.32.2, que permitiu a manipulação das bandas espectrais dos sensores das imagens capturadas nos anos de 2018 e 2023, conforme especificado na tabela 6:

Tabela 6: Dados dos sensores do satélite PlanetScope

Sensor	Red (nm)	NIR (nm)	Ano
Super Dove (PSB.SD)	650-680	845-885	2023
Classic Dove (PS2)	590-670	780-860	2018

Fonte: autora, 2024.

Subsequentemente, após o cálculo do SAVI no software QGIS versão 3.32.2 para os anos de 2018 e 2023, a classificação das imagens foi feita através do

método Natural Breaks (Jenks). Após esta etapa, os rasters foram convertidos em polígonos utilizando a ferramenta *Raster to Polygon* no software ArcGIS PRO. Dessa maneira, além de permitir a análise das áreas para diferentes anos por meio do SAVI, a conversão das imagens-índice, proporcionadas pelo cálculo do índice, em polígonos viabilizou o cálculo das áreas para cada classe selecionada nas duas datas escolhidas para a análise desta pesquisa.

4.3.2. kNN

A partir das informações espectrais das áreas com características semelhantes, uma vez que um determinado alvo dificilmente é caracterizado por uma única assinatura espectral, é elaborado um mapa de "pixels" classificados, representados por símbolos gráficos ou cores. Esse processo de classificação digital consiste em converter um extenso conjunto de níveis de cinza em cada banda espectral em um número reduzido de classes em uma única imagem (ABREU e COUTINHO, 2014).

A definição das classes de cobertura da terra foi realizada através da interpretação visual da imagem e, após esse procedimento, foram identificadas e definidas quatro classes de cobertura da terra na área de estudo, a saber: corte raso, extração mineral, vegetação secundária e vegetação arbórea. Para a realização da classificação supervisionada, foi utilizado o algoritmo kNN, que é uma técnica estatística amplamente reconhecida e utilizada para a classificação de imagens com base na distância euclidiana.

Após a classificação pelo algoritmo kNN, as imagens de 2018 e 2023 foram convertidas em vetores utilizando a ferramenta *Raster to Polygon*, de maneira similar às imagens do SAVI. Essa conversão permitiu o cálculo das áreas, em hectares, para cada classe de uso do solo em ambos os anos analisados.

4.3.3. Validação dos Dados

Para a verificação da confiabilidade dos resultados obtidos na classificação das imagens deste estudo, utilizou-se o Kappa Cohen. Esse coeficiente, representado pela equação 16, é uma medida estatística que avalia a concordância entre as classes atribuídas pela classificação e as classes reais presentes na imagem.

Os resultados do coeficiente kappa (K) (tabela 7) variam de -1 a +1, sendo que -1 indica ausência total de concordância, 0 indica concordância equivalente entre os dados observados e os dados esperados ao acaso, e +1 indica concordância perfeita entre a classificação e a realidade. Landis e Koch (1977) estabeleceram uma categorização para os valores de K , onde valores acima de 0,80 indicam alta concordância entre a classificação e os dados reais, valores entre 0,40 e 0,80 indicam concordância moderada, e valores abaixo de 0,40 indicam baixa concordância, sugerindo a necessidade de revisão ou ajustes na classificação realizada e as classes reais presentes na imagem.

Tabela 7: Classes e desempenho do Índice Kappa

Classes do Índice	Desempenho
< 0	Péssimo
0 - 0,2	Ruim
0,21 - 0,4	Razoável
0,41 - 0,6	Bom
0,61 - 0,8	Muito Bom
0,81- 1,0	Excelente

Fonte: Adaptada de Landis e Koch (1977)

Para que o K possa ser calculado, é necessário compreender como calcular cada parâmetro encontrado na equação 16 (LANDIS & KOCH, 1977), como encontrado abaixo. Para calcular a proporção de concordância p_o , descrita na equação 16, basta somar a diagonal da matriz de confusão e dividir pelo total de pixels, como exemplificado da tabela 8.

Tabela 8: Matriz de erros (ou matriz de confusão) da classificação

Classes	Água	Área Urbana	Área Úmida	Mangue	Solo Exposto	Vegetação Arbustiva	Total	Acurácia Usuário	Kappa
Água	97,42	0,00	0,34	40,36	0,17	0,00	69,49	98,90	0
Área Urbana	0,00	98,10	6,20	0,00	0,02	1,77	5,15	92,93	0
Área Úmida	0,60	0,66	65,29	1,93	0,38	0,10	1,99	73,23	0
Mangue	1,88	0,00	22,76	57,60	0,66	2,09	3,21	32,97	0
Solo Exposto	0,10	0,01	0,03	0,12	97,39	1,28	7,85	97,03	0
Vegetação Arbustiva	0,00	1,23	5,38	0,00	1,38	94,77	12,31	97,66	0
Total	100,00	100,00	100,00	100,00	100,00	100,00	100,00	0	0
Acurácia Produtor	97,42	98,10	65,29	57,60	97,39	94,77	0	95,67	0
Kappa	0	0	0	0	0	0	0	0	0,9106

Fonte: Machado, 2020.

- I) Probabilidade de uma classe é o total estimado dividido pelo total real para cada classe
- II) Cálculo da Probabilidade real = total real / total estimado para cada classe
- III) Multiplicação da probabilidade estimada e real para cada classe
- IV) Proporção esperada (p_c) = é a multiplicação do resultado de todas as probabilidades estimadas e reais de cada classe.
- V) Por fim, o cálculo do K pode ser realizado (equação 16).

Como resultado do processamento, a matriz de erros mostra o resultado do Kappa e este resultado deve ser compatível com o resultado encontrado na equação 16. A acurácia, nesse contexto, surge como uma medida de precisão que revela a confiabilidade de um pixel de referência ser corretamente classificado, considerando os erros de omissão e comissão presentes na classificação.

A designada "acurácia do usuário" ou confiabilidade, por sua vez, indica a probabilidade de um pixel classificado em um mapa ou imagem realmente representar a categoria correspondente no terreno. Essa métrica é expressa pela razão entre o número de elementos corretamente classificados em uma determinada classe e o total de elementos dessa mesma classe (equação 23) (STORY e CONGALTON, 1986; CONGALTON, 1991; CONGALTON & GREEN 1999).

$$au = \frac{x_{ii}}{x_{i+}} \quad \text{Eq. 23}$$

Em que au representa a acurácia do usuário, X_{ii} é o número de elementos classificados corretamente e X_{i+} é o total de elementos classificados para uma classe i . Por outro lado, a medida de precisão denominada "acurácia do produtor" indica a proporção de pixels corretamente classificados em uma categoria em relação ao total de pixels dessa categoria, conforme estabelecido pelos dados de referência (equação 24). Essa métrica reflete a probabilidade de um pixel de referência ser classificado de forma precisa, sendo efetivamente uma medida de erro de omissão (STORY e CONGALTON, 1986; CONGALTON, 1991; CONGALTON & GREEN 1999).

$$ap = \frac{x_{ii}}{x_{+i}} \quad \text{Eq. 24}$$

Em que ap representa a acurácia do usuário, X_{ii} é o número de elementos classificados corretamente e X_{i+} é o total de elementos classificados para uma classe i .

4.4. Volume de Biomassa e Volume Degradado

4.4.1. Cálculo do Volume

Para determinar o volume de biomassa, foi necessário calcular o Índice de Biomassa de Vegetação Lenhosa (IBVL), que pode ser estimado de maneira relativa, partindo da premissa de que, em condições de preservação ideal, a vegetação deve exibir um porte arbóreo superior a 4,5 metros de altura e um alto grau de cobertura do solo pela vegetação, que deve ser extremamente densa (superior a 80%). Nessa circunstância, o volume da biomassa atinge seu valor máximo, representado por 1, em contraste com uma área desprovida de cobertura vegetal, cujo valor é 0 (CHAVES et al., 2008) (tabela 9).

Tabela 9: Índice de porte da biomassa para as diferentes classes

Classe de Vegetação		Índice de Porte (Ip)
Arbórea	> 4,5 m	1,00
Subarbórea	3,0 a 4,5 m	0,75
Arbustiva	1,5 a 3,0 m	0,50
Subarbustiva	< 1,5 m	0,25
Sem Vegetação		0

Fonte: Chaves et al, 2008.

Ao atribuir valores numéricos relativos às categorias de vegetação com base no porte, conforme delineado no Índice de Porte (Ip) na Tabela 10, e no nível de cobertura do solo pela vegetação, conforme apresentado no Índice de Recobrimento (Ir) na tabela 10, tornou-se possível calcular o Índice de Biomassa de Vegetação Lenhosa (IBVL) por meio da multiplicação desses parâmetros vegetais (CHAVES et al., 2008).

Tabela 10: Índices de recobrimento da biomassa para as diferentes sub- classes de vegetação

Subclasse de Vegetação	Índice de Recobrimento (Ir)
Muito densa > 80%	1,0
Densa 60 a 80%	0,8
Aberta 40 a 60%	0,6
Rala 20 a 40%	0,4
Muito rala < 20%	0,2
Sem Vegetação	0

Fonte: Chaves et al, 2008

Para categorias de vegetação homogênea em termos de porte, o valor do Índice de Biomassa de Vegetação Lenhosa (IBVL) foi obtido pela multiplicação dos valores atribuídos às características das plantas em relação ao porte (Índice de Porte, Ip) e ao grau de cobertura do solo (Índice de Recobrimento, Ir), conforme representado por (CHAVES et al., 2008) (equação 25).

$$IBVL = Ip \times Ir \quad \text{Eq. 25}$$

No entanto, quando uma classe apresenta múltiplos portes de biomassa distintos, conforme apontado por Chaves (2008), é necessário atribuir pesos específicos: 3 para o primeiro componente da classe, 2 para o segundo e 1 para o terceiro, sendo utilizada uma média ponderada. Neste caso, como foram apenas duas classes atribuídas à vegetação rasteira, foram atribuídos os pesos três e dois, respectivamente, como na equação 26. Para este estudo foram utilizados os pesos 3 e 2.

$$IBVL = [(Ip_1 \times 3) + (Ip_2 \times 2) + (Ip_3 \times 1) / 6] \times Ir \quad \text{Eq. 26}$$

Para cada bioma correspondente a uma área fisiográfica específica sob análise, é essencial estabelecer um valor de referência para a biomassa em seu estado de máxima preservação. Isso é crucial para estimar com precisão o volume de biomassa em outras áreas de estudo. O método para tal estimativa envolveu a multiplicação do volume padrão de referência pela extensão da área em questão, além do Índice de Biomassa de Vegetação Lenhosa (IBVL) derivado da descrição da vegetação, conforme destacado por CHAVES et al. (2008) (equação 27).

$$\bar{VBVL} = V_{\text{máx.}} \times \text{Área} \times \text{IBVL} \quad \text{Eq. 27}$$

Para o bioma Amazônico, o volume de referência ($V_{\text{máx}}$) é definido como 247 m^3 por hectare, conforme indicado na tabela 11 pela FAO (2014). A mensuração da área, realizada em hectares, é calculada para cada categoria (corte raso, extração mineral, vegetação arbórea e vegetação subarbusciva), com base nos resultados obtidos pelo índice SAVI e pelo algoritmo kNN. Nesse cálculo, as categorias de corte raso e extração mineral são consideradas conjuntamente, representando áreas desprovidas de vegetação (solo exposto).

Tabela 11: Valores de volume, biomassa e carbono por hectare, FCEB, R e TC deduzidos a partir do FRA2015

Bioma	Volume ($\text{m}^3 \text{ha}^{-1}$)	Biomassa (t ha^{-1})	Carbono (t ha^{-1})	FCEB (t t^{-1})	R (t t^{-1})	TC (t t^{-1})
Amazônia	247	303	152	1,22	0,19	0,5
Caatinga	63	63	30	1	0,27	0,47
Cerrado	66	83	39	1,25	0,59	0,48
Mata Atlântica	97	129	61	1,33	0,22	0,74
Pampa	74	80	38	1,07	0,48	0,48
Geral	191	233	116	1,22	0,22	0,5

Fonte: Adaptado de FAO, 2014. * Valor desconsiderado neste estudo, sendo substituído por 0,47 (default do IPCC). FCEB: fator de conversão e expansão de biomassa. R: razão de raízes. TC: teor de carbono.

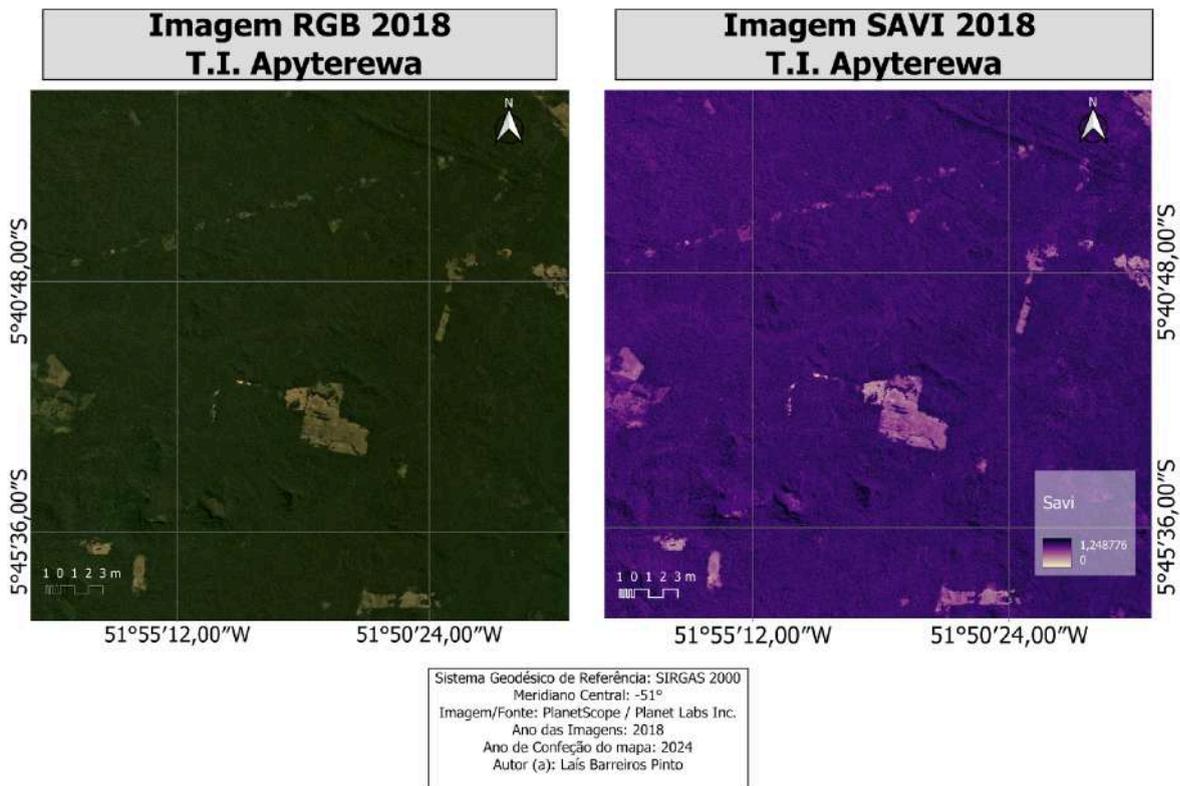
Para a determinação do volume de degradação (equação 27), foi suficiente utilizar o volume de referência ($V_{\text{máx}}$), obtido pelo FAO (2014) (tabela 11), e o IBVL resultante para cada classe analisada, conforme delineado por Francisco et al. (2014).

5. RESULTADOS E DISCUSSÕES

5.1. Análise do SAVI

A análise dos dados do produto SAVI para o ano de 2018 (figura 13), localizado em uma área que inclui parte da Terra Indígena Apyterewa, revela quatro classes preestabelecidas e analisadas: extração mineral, corte raso, vegetação arbórea e vegetação rasteira

Figura 13: Mapas das Imagens RGB e SAVI para o ano de 2018



Fonte: autora, 2024.

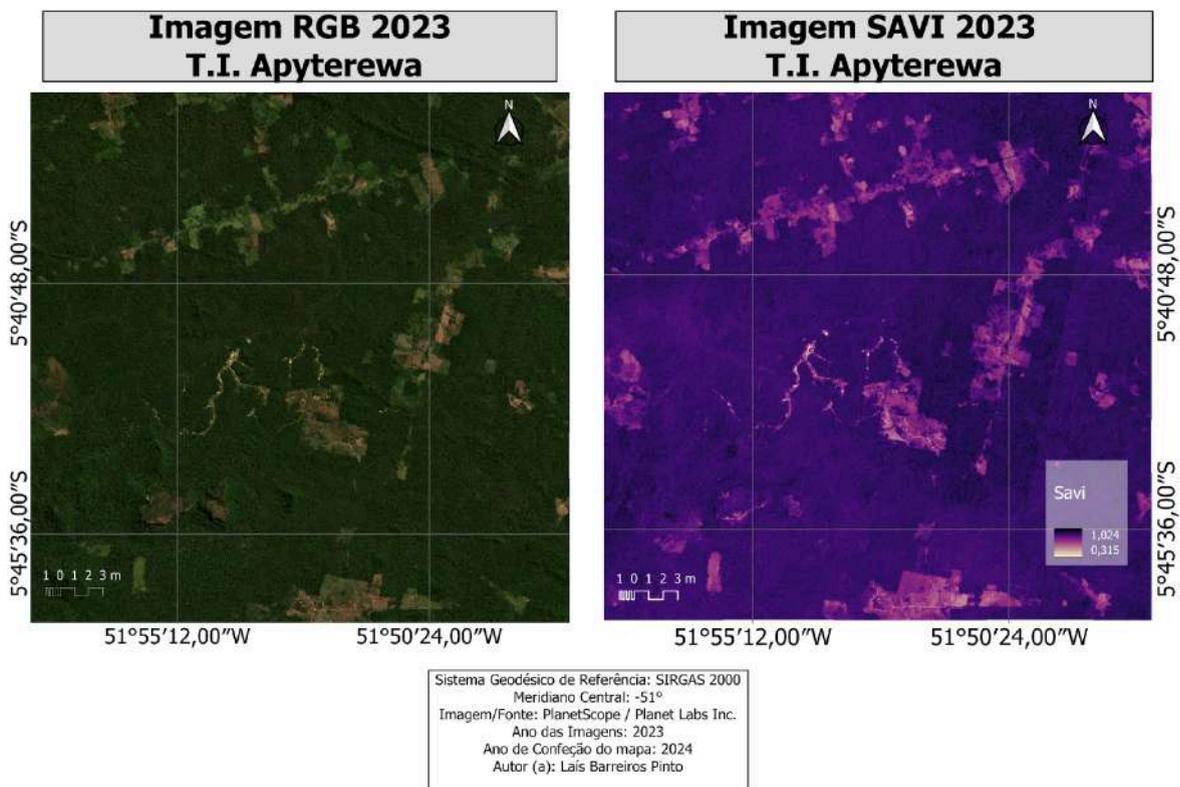
Assim, conforme observado na tabela 12, a classe predominante nesta área é a vegetação arbórea, que corresponde a 89,81% da área, com 32.371,17 hectares e um índice variando entre 1,088 e 1,25. Em seguida, a vegetação rasteira cobre 10,05% da área, com 3.621,40 hectares e um índice entre 1,024 e 1,087. O corte raso ocupa 0,13% da área, com 46,19 hectares e um índice entre 0,892 e 1,023. Por fim, a extração mineral cobre 0,02% da área, com 5,52 hectares e um índice entre 0,283 e 0,891.

Tabela 12 - Áreas do ano de 2018 adquirido a partir do SAVI

CLASSES	Área 2018 (Ha)	Área 2018 (%)
EXTRAÇÃO MINERAL	5,56	0,02%
CORTE RASO	46,19	0,13%
VEGETAÇÃO RASTEIRA	3621,40	10,05%
VEGETAÇÃO ARBÓREA	32371,17	89,81%

Fonte: autora, 2024.

Para o ano de 2023, a análise dos dados do produto SAVI (figura 14), assim como em 2018, a área de estudo manteve-se com 36.044,32 hectares, abrangendo as quatro classes preestabelecidas e analisadas.

Figura 14: Mapas das Imagens RGB e SAVI para o ano de 2023

Fonte: autora, 2024.

A vegetação arbórea se destaca como a classe dominante, assim como no ano de 2018, de acordo com a tabela 13, abrangendo 79,91% da área, equivalente a 20.8626,99 hectares, com um índice variando entre 0,933 e 1,024. Em segundo lugar, a vegetação rasteira cobre uma porção significativa, abarcando 18,10% da área, correspondendo a 6.522,45 hectares, com um índice oscilando entre 0,856 e 0,932. A ocupação de corte raso é notavelmente menor, englobando apenas 2,39%

da área, totalizando 859,68 hectares, com um índice variando entre 0,735 e 0,855. Por último, a extração mineral apresenta uma proporção mínima, cobrindo apenas 0,10% da área, equivalente a 35,20 hectares, com um índice entre 0,021 e 0,734.

Tabela 13: Áreas do ano de 2023 adquirido a partir do SAVI

CLASSES	Área 2023 (Ha)	Área 2023 (%)
EXTRAÇÃO MINERAL	35,20	0,10%
CORTE RASO	859,68	2,39%
VEGETAÇÃO RASTEIRA	6522,45	18,10%
VEGETAÇÃO ARBÓREA	28626,99	79,42%

Fonte: autora, 2024.

5.2. Análise do kNN

A análise da imagem obtida da área de estudo para o ano de 2018, representada na figura 20, revelou valores significativamente distintos daqueles fornecidos pelo índice SAVI. A área total em estudo compreendia 36.044,32 hectares, e a classificação supervisionada da imagem permitiu uma discriminação detalhada do uso do solo e da cobertura vegetal.

Em 2018, a atividade de Extração Mineral foi identificada em uma área de apenas 1,10 hectares, o que corresponde a 0,003% da área total. Este valor sugere uma atividade de mineração muito limitada na região, possivelmente indicando que a extração de recursos minerais não era uma prática intensiva ou que as operações estavam em fases muito iniciais ou de declínio.

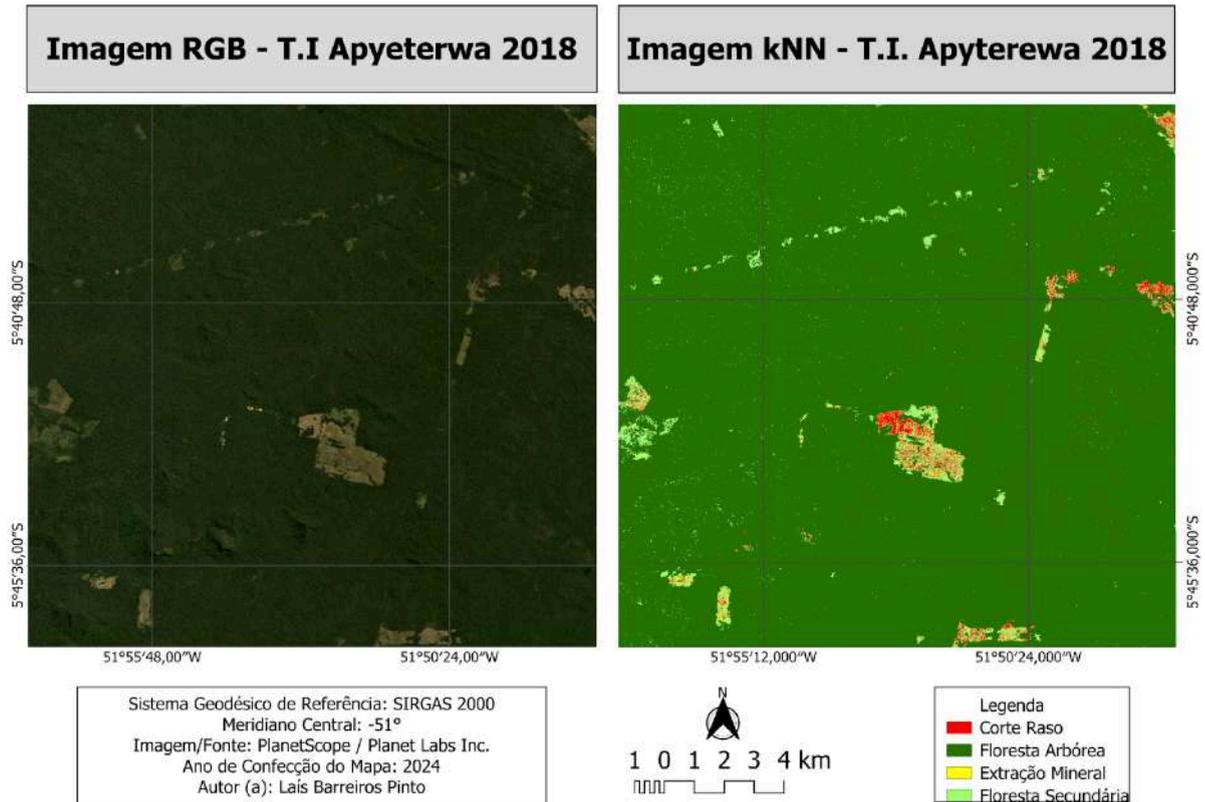
A área de corte raso, destinada à remoção completa da vegetação, abrangeu 71,95 hectares, representando 0,2% da área total. Este percentual, embora pequeno, ainda indica que práticas de desmatamento ocorrem na região, o que pode estar relacionado a atividades agrícolas ou outras formas de uso intensivo da terra.

A vegetação rasteira, que inclui gramíneas e outras plantas de baixo porte, ocupou uma área de 1.109,84 hectares, correspondendo a 3,08% da área total. A vegetação arbórea dominou o território, com 34.861,44 hectares, representando 96,72% da área total. Este dado destaca a predominância de florestas ou áreas densamente arborizadas na região de estudo, sugerindo uma cobertura vegetal robusta (tabela 14).

Tabela 14: Área do ano de 2018 adquirido a partir do kNN

CLASSES	Área 2018 (Ha)	Área 2018 (%)
EXTRAÇÃO MINERAL	1,10	0,003%
CORTE RASO	71,95	0,20%
VEGETAÇÃO RASTEIRA	1109,84	3,08%
VEGETAÇÃO ARBÓREA	34861,44	96,72%

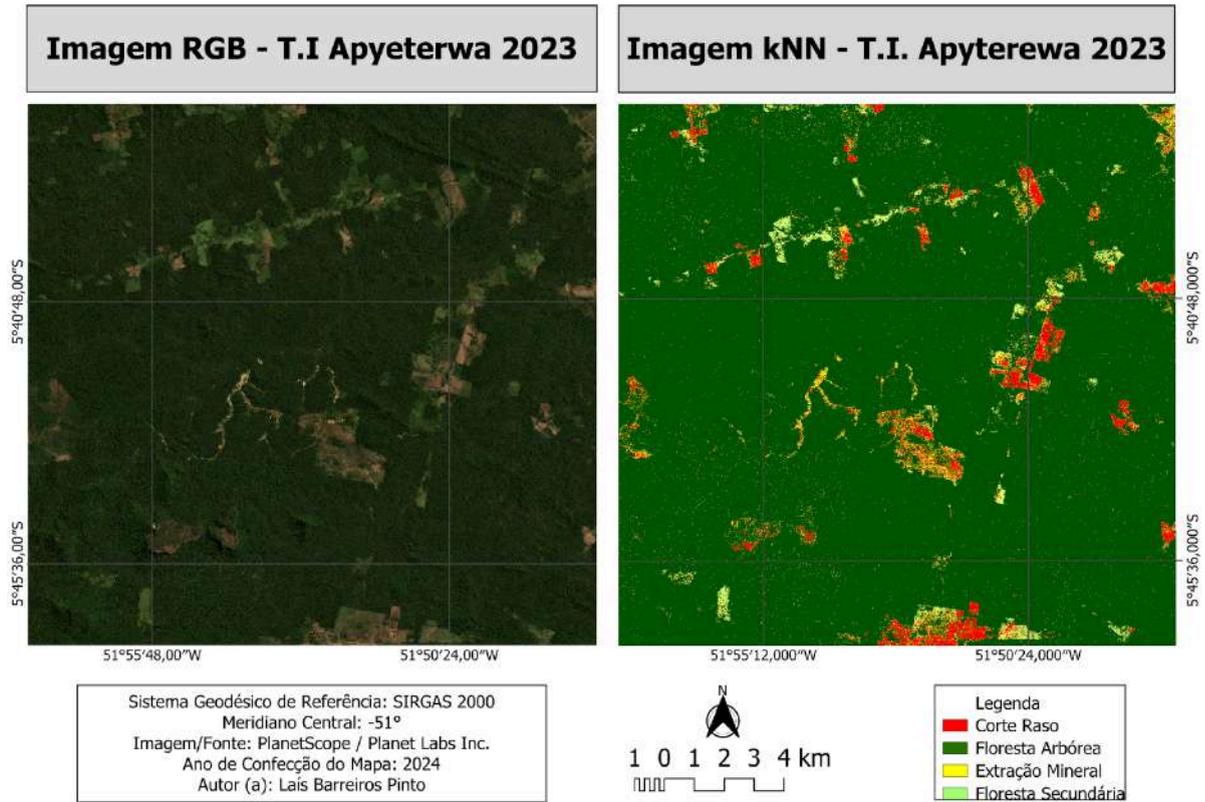
Fonte: autora, 2024.

Figura 15: Imagem kNN para o ano de 2018

Fonte: autora, 2024.

A análise do kNN para o ano de 2023 (figura 16), da mesma forma que para o ano de 2018, evidenciou valores diferentes dos obtidos através do SAVI. Apesar do polígono da área de estudo ter sido de 36.044,32 hectares, a soma dos valores dos hectares atribuídos a cada classe resultou em 35.996,44 hectares, indicando uma perda de 47,87 hectares em relação à área original, tendo em vista a retirada das nuvens e sombras da imagem.

Figura 16: Mapa com as imagens RGB e kNN para o ano de 2023



Fonte: autora, 2024.

Em termos específicos de uso do solo, notável é o fato de que a extração mineral foi identificada em uma área relativamente pequena, correspondendo a meros 0,08% da extensão total, totalizando 27,37 hectares. Por outro lado, o corte raso foi consideravelmente mais abrangente, cobrindo uma parcela de 4,51% da área total, abrangendo 1623,26 hectares, o que pode sugerir um aumento significativo das atividades de desmatamento. A cobertura vegetal arbórea se destacou como a predominante, abarcando impressionantes 93,36% da área total, que equivalem a 33.605,17 hectares, indicando uma presença significativa de florestas ou regiões densamente arborizadas. Já a vegetação rasteira ocupou uma fatia menor, representando 2,06% da área total, com 740,65 hectares (tabela 15).

Tabela 15: Área do ano de 2023 adquirido a partir do kNN

CLASSES	Área 2023 (Ha)	Área 2023 (%)
CORTE RASO	1623,26	4,51%
EXTRAÇÃO MINERAL	27,37	0,08%
VEGETAÇÃO ARBÓREA	33605,17	93,36%
VEGETAÇÃO RASTEIRA	740,65	2,06%

Fonte: autora, 2024.

5.2.1. Validação dos Dados

Os resultados da classificação do uso e cobertura para o ano de 2018 são apresentados na tabela 16, que inclui as matrizes de erro das classificações supervisionadas obtidas através do método kNN aplicado às imagens RGB do satélite PlanetScope. A matriz de erro de classificação detalha a distribuição percentual de pixels classificados corretamente e incorretamente. Utilizando essa matriz, foi automaticamente calculado o coeficiente Kappa, medida que quantifica o grau de concordância entre a classificação realizada na imagem e os valores reais observados, proporcionando uma avaliação da consistência do modelo (LANDIS e KOCH, 1977) (tabela 17), que avaliou a precisão do mapeamento realizado.

Tabela 16: Matriz de confusão para o ano de 2018

Classes	Corte Raso	Extração Mineral	Vegetação Arbórea	Vegetação Rasteira	TOTAL (REAL)	Acurácia do Usuário	KAPPA
Corte Raso	7	1	0	2	10	0,7	
Extração Mineral	3	7	0	0	10	0,7	
Vegetação Arbórea	0	0	115	1	116	0,991379	
Vegetação Rasteira	0	0	0	10	10	1	
TOTAL (ESTIMADO)	10	8	115	13	146	0	
Acurácia do Produtor	0,7	0,875	1	0,769231	0	0,952055	
KAPPA							0,866684

Fonte: autora, 2024.

Tabela 17: Classes e desempenho do Índice Kappa

Classes do Índice	Desempenho
< 0	Péssimo
0 - 0,2	Ruim
0,21 - 0,4	Razoável
0,41 - 0,6	Bom
0,61 - 0,8	Muito Bom
0,81- 1,0	Excelente

Fonte: Adptada de Landis e Koch (1977)

A análise do treinamento do algoritmo de classificação para o ano de 2018 revelou um Índice de Kappa de 0,866684, considerado excelente de acordo com a tabela de Landis e Koch (1977). A avaliação de acurácia é crucial para determinar a qualidade do mapeamento realizado, fornecendo taxas de acerto geral, além das taxas de acerto e erro para cada classe definida. A acurácia do produtor indica a proporção de pixels de cada classe corretamente atribuídos pelo classificador, enquanto a acurácia do usuário refere-se às estimativas das frações de pixels

corretamente classificados no mapeamento (PONTIUS e MILLONES, 2011; MAPBIOMAS, 2019).

Dada a natureza automática do coeficiente Kappa derivado do processamento, é vantajoso proceder com uma abordagem manual para fins de validação e confirmação. Nesse contexto, optou-se por empregar o coeficiente Kappa de Cohen (equação 15) para este propósito de cálculo. A proporção de concordância observada, representada por p_o , é calculada pela soma dos elementos diagonais da matriz de confusão, correspondentes aos valores de cada classe, dividida pelo total real.

Para a classe de corte raso, foram observados 7 pixels corretamente classificados, para extração mineral, também 7 pixels corretos, para vegetação arbórea, 115 pixels corretos, e para vegetação rasteira, 10 pixels corretos. Ao dividir esse total pelo número total de pixels estimados, que é de 146 pixels, foi obtido uma proporção de concordância observada de 0,95205479, o que indica que 95,20% dos pares de classificação estão em concordância.

Para calcular a proporção de concordância por acaso (p_c), inicialmente calculou-se a probabilidade do estimado para cada classe e a probabilidade real. A probabilidade do estimado corresponde à divisão do total estimado de cada classe pelo total geral de elementos, 146 pixels. Por sua vez, a probabilidade real é calculada dividindo o total real de elementos de cada classe pelo total geral de elemento, 146 pixels (quadro 5)

Quadro 5: Valores do Total Estimado, Total Real, Probabilidade do Estimado e Real1

	TOTAL ESTIMADO	TOTAL REAL	PROBABILIDADE DO ESTIMADO	PROBABILIDADE REAL
Corte Raso	10	10	0,068	0,068
Extração Mineral	8	10	0,055	0,068
Vegetação Arbórea	115	116	0,788	0,795
Vegetação Arbórea	13	10	0,089	0,068

Fonte: autora, 2024.

Na segunda etapa do cálculo da proporção de concordância por acaso (p_c), as probabilidades do estimado e do real de cada elemento foram multiplicadas. Na terceira etapa, a soma dos resultados de cada multiplicação foi realizada, conforme evidenciado no quadro 6.

Quadro 6: Multiplicação das probabilidades para cada classe

	PROBABILIDADE DO ESTIMADO	PROBABILIDADE REAL	MULTIPLICAÇÃO
Corte Raso	0,068	0,068	0,005
Extração Mineral	0,055	0,068	0,004
Vegetação Arbórea	0,788	0,795	0,626
Vegetação Arbórea	0,089	0,068	0,006

Fonte: autora, 2024.

Na quarta e última etapa do cálculo da proporção de concordância por acaso (p_c), ocorreu a soma das multiplicações realizadas para cada classe. Assim, obteve-se um valor de 0,640364046, equivalente a 64,03% para o p_c . Com os parâmetros p_o e p_c , que correspondem a 95,20% e 64,03%, respectivamente, calculou-se o coeficiente Kappa de Cohen utilizando a equação 15. O resultado obtido foi de 86,67%, o qual está em total concordância com o valor do Kappa gerado pelo processo de classificação 5

Os resultados da classificação do uso da terra para o ano de 2023 estão detalhados na tabela 18, que contém a matriz de erro (ou de confusão) da classificação supervisionada obtida através da aplicação do método kNN nas imagens RGB provenientes do satélite PlanetScope.

Tabela 18: Matriz de confusão para o ano de 2023

Classes	Corte Raso	Extração Mineral	Vegetação Arbórea	Vegetação Rasteira	TOTAL (REAL)	Acurácia do Usuário	KAPPA
Corte Raso	10	1	0	0	10	1	
Extração Mineral	0	5	0	0	5	2	
Vegetação Arbórea	0	0	109	3	112	0,973214	
Vegetação Rasteira	0	0	1	9	10	0,9	
TOTAL (ESTIMADO)	10	5	110	12	137	0	
Acurácia do Produto	1	1	0,990909	0,75	0	0,970803	
KAPPA							0,91167

Fonte: autora, 2024.

A precisão é uma métrica fundamental para avaliar a qualidade do mapeamento realizado, conforme discutido por PONTIUS e MILLONES em 2011 e MAPBIOMAS em 2019. A análise do treinamento do algoritmo de classificação para o ano de 2023 revelou um Índice Kappa de 0,91167, indicando um desempenho excelente, conforme estabelecido na tabela de Landis e Koch em 1977 (tabela 17).

Assim, como realizado para o ano de 2018, se torna vantajoso proceder com uma abordagem manual para fins de validação e confirmação, utilizando, também para este ano, o Kappa Cohen (equação 15). O cálculo da proporção de concordância observada, representada por p_o e o cálculo da proporção de

concordância por acaso (p_c) foram calculados para que pudesse ser obtido o Kappa Cohen.

Para a classe de corte raso, foram observados 7 pixels corretamente classificados, para extração mineral, também 5 pixels corretos, para vegetação arbórea, 109 pixels corretos, e para vegetação rasteira, 09 pixels corretos. Ao dividir esse total pelo número total de pixels estimados, que é de 137 pixels, foi obtida uma proporção de concordância observada de 0,9708029197, o que indica que 95,20% dos pares de classificação estão em concordância.

Para calcular a proporção de concordância por acaso (p_c), inicialmente calculou-se a probabilidade do estimado para cada classe e a probabilidade real. A probabilidade do estimado corresponde à divisão do total estimado de cada classe pelo total geral de elementos, 146 pixels. Por sua vez, a probabilidade real é calculada dividindo o total real de elementos de cada classe pelo total geral de elemento, 146 pixels (quadro 7).

Quadro 7: Valores do Total Estimado, Total Real, Probabilidade do Estimado e Real2

	TOTAL ESTIMADO	TOTAL REAL	PROBABILIDADE DO ESTIMADO	PROBABILIDADE REAL
Corte Raso	10	10	0,073	0,073
Extração Mineral	5	5	0,036	0,036
Vegetação Arbórea	110	112	0,803	0,818
Vegetação Arbórea	12	10	0,088	0,073

Fonte: autora, 2024.

Na segunda etapa do cálculo da proporção de concordância por acaso (p_c), as probabilidades do estimado e do real de cada elemento foram multiplicadas. Na terceira etapa, a soma dos resultados de cada multiplicação foi realizada, conforme evidenciado no quadro 8.

Quadro 8: Multiplicação das probabilidades para cada classe

	PROBABILIDADE DO ESTIMADO	PROBABILIDADE REAL	MULTIPLICAÇÃO
Corte Raso	0,073	0,073	0,005
Extração Mineral	0,036	0,036	0,001
Vegetação Arbórea	0,803	0,818	0,656
Vegetação Arbórea	0,088	0,073	0,006

Fonte: autora, 2024.

Na quarta e última etapa do cálculo da proporção de concordância por acaso (p_c), ocorreu a soma das multiplicações realizadas para cada classe. Assim,

obteve-se um valor de 0,669454952, equivalente a 66,94% para o p_c . Com os parâmetros p_o e p_c , que correspondem a 95,20% e 66,94%, respectivamente, calculou-se o coeficiente Kappa de Cohen utilizando a equação 15. O resultado obtido foi de 91,17%, corroborando com o valor do Kappa gerado pelo processo de classificação.

O sensoriamento remoto é, portanto, um recurso amplamente empregado para a identificação e análise da vegetação, pois permite avaliar extensas regiões sem a necessidade de obtenção de dados diretamente no local (SILVA et al, 2021). Assim como para Sonter et al (2014) e Yang et al (2018), que relataram a aplicação de imagens de satélite para mensurar as alterações no uso da terra em regiões de mineração e para detectar variações na vegetação, descrevendo a dinâmica da cobertura vegetal, bem como a extensão e o padrão de recuperação, é possível observar que os dados apresentados nesta pesquisa revelam um notável incremento na degradação ambiental ao longo de um período de 5 anos na área de estudo desta pesquisa através do uso de imagens orbitais.

De acordo com o gráfico 4, o uso do método SAVI destaca um aumento expressivo na prática do Corte Raso, também referido como solo exposto resultante de desmatamento, que em 2018 ocupava uma extensão de 46,49 hectares, evoluindo para 859,68 hectares em 2023, representando um acréscimo substancial de 813,49 hectares e um aumento percentual de 1761,10%. No que concerne à atividade de Extração Mineral, que detinha uma área de 5,56 hectares em 2018 e atingiu 35,20 hectares em 2023, verificou-se um acréscimo de 29,64 hectares, o que se traduz em um aumento percentual de 533,63% em relação à área de estudo, demonstrado no gráfico 4. Dessa forma, fica evidente que as operações de mineração provocam significativos impactos ambientais, resultando em considerável degradação ecológica, levando ao desmatamento e à subsequente perda de biodiversidade, gerando sérias consequências para o ecossistema amazônico (SILVA et al, 2021).

Similarmente, a expansão da Vegetação Rasteira foi observada, passando de 3621,40 hectares em 2018 para 6522,45 hectares em 2023, resultando em um incremento de 2901,05 hectares e um aumento percentual de 80,11%, de tal forma que pode indicar que ao longo do período de cinco anos, ocorreram cortes mais frequentes que desencadearam o início do processo de regeneração da vegetação nativa. Essas análises permitem inferir que o avanço do desmatamento, evidenciado

pelo aumento de três classes como Extração Mineral, Corte Raso e Vegetação Rasteira, ocorreu de maneira acentuada. Como resultado direto desse fenômeno, a vegetação arbórea, sofreu uma redução de 11,57%, em módulo no gráfico 5, visto que em 2018 ocupava uma área de 32371,17 hectares e em 2023 reduziu-se para 28626,99 hectares, refletindo uma diminuição absoluta de 3744,18 hectares.

Gráfico 4: Dados Obtidos das Análises do SAVI entre 2023 e 2018.



Fonte: autora, 2024.

Assim como os dados gerados pelo SAVI, os dados para o kNN evidenciam um considerável aumento na degradação ambiental ao longo de cinco anos na área de estudo do presente estudo. De acordo com o gráfico 5, é notável um aumento expressivo na prática do Corte Raso, denominado como a exposição do solo resultante de atividades de desmatamento, que em 2018 abarcava uma área de 71,95 hectares, expandindo-se para 1623,26 hectares em 2023, o que representa um aditamento substancial de 1551,31 hectares e um aumento percentual de 2156,19%.

Em relação à atividade de Extração Mineral, que ocupava 1,10 hectare em 2018 e cresceu para 27,37 hectares em 2023, identifica-se um incremento de 26,27 hectares, traduzindo-se em um incremento percentual de 2390,24% em relação à área de estudo, conforme demonstrado no gráfico 5. Similarmente, observou-se uma diminuição na área de Vegetação Rasteira, evidenciada no gráfico 5, reduzindo de

1109,84 hectares em 2018 para 740,65 hectares em 2023, resultando em uma diminuição de 369,18 hectares e um decréscimo percentual de 33,26%. Além disso, houve um decréscimo na vegetação arbórea, que apresentava 34.861,44 hectares em 2018 e 33.605,17 hectares em 2023, resultando em uma diminuição de 1256,27 hectares e um decréscimo percentual de apenas 3,60%.

Essas análises permitem inferir que o avanço do desmatamento, representado pelo incremento de duas classes, Extração Mineral e Corte Raso, ocorreu de maneira marcante. Como consequência do aumento do desmatamento, houve um decréscimo na vegetação arbórea, assim como na vegetação rasteira, indicando novos cortes em áreas anteriormente ocupadas por vegetação rasteira.

Ademais, ao examinar a matriz de confusão para a classificação realizada no ano de 2023, notou-se uma confusão entre as quatro classes analisadas: Corte Raso e Extração Mineral; Vegetação Rasteira e Vegetação Arbórea. Observou-se que a classe Extração Mineral foi confundida com a classe Corte Raso, possivelmente devido à similaridade na resposta espectral entre o solo exposto naquela época e certos materiais característicos da área de extração mineral.

Além disso, verificou-se uma confusão entre as classes de Vegetação Rasteira e Vegetação Arbórea, provavelmente devido à presença de vegetação semelhante situada entre a vegetação densa e aquela que apresenta uma resposta espectral similar à encontrada na vegetação rasteira.

Gráfico 5: Dados Obtidos das Análises do kNN entre 2023 e 2018.



Fonte: autora, 2024

A análise da dinâmica de uso e ocupação do solo na Terra Indígena Apyterewa, utilizando os métodos SAVI e kNN, revela uma semelhança com as observações do PRODES (INPE, 2021). De acordo com o PRODES (2021), entre 2018 e 2021, houve um aumento de 75,62% nas atividades antrópicas na Amazônia Legal. Especificamente para a área de estudo, durante o período analisado, registrou-se um crescimento impressionante de 2159,59% nas atividades antrópicas pelo método kNN e 1617,64% pelo índice espectral SAVI. Em termos de perda de vegetação natural, o método kNN indicou uma redução de 3,60%, enquanto o SAVI mostrou uma diminuição de 11,57% na vegetação arbórea.

Embora o método kNN tenha alcançado uma acurácia de usuário e produtor de 97,08% para o ano de 2023 e 95,20% para 2018, evidenciando um desempenho excelente conforme a tabela 17, ao comparar as imagens geradas pelo kNN e SAVI com as imagens RGB correspondentes de cada ano, percebe-se que o índice SAVI ofereceu maior confiabilidade. Zhang (2021) atribui isso ao fato de o kNN ser vulnerável ao overfitting, além de ressaltar que, apesar do sucesso estatístico do kNN, ainda existem muitos desafios na sua aplicação, como a determinação do valor de K, a escolha do vizinho mais próximo, a busca eficiente dos vizinhos e as regras de classificação.

5.3. Volume de Biomassa e de Degradação

Conforme Mourão (2021), a utilização da tecnologia lidar permitiu a determinação da altura máxima e mediana geral da vegetação localizada ao norte do município São Félix do Xingu, onde pode ser encontrada a Terra Indígena Apyterewa. Para estimar tais métricas, foi elaborado um Modelo Digital de Elevação (MDE) com base em um total de 4383 árvores mapeadas. O estudo realçou que a altura máxima da vegetação nessa área é de 60,43 metros, enquanto a altura mediana é de 35,60 metros. Dessa forma, entende-se que a altura da mediana geral pode ser utilizada no cálculo do índice de porte de biomassa para este estudo (tabela 9) para estimar o índice de biomassa de vegetação lenhosa (IBVL), através da equação 25.

5.3.1. SAVI

Para o ano de 2018, a vegetação arbórea na Terra Indígena Apyterewa, considerando a altura mediana de 35,60 metros, possui um índice de porte da biomassa (I_p) de 1,00, dado que a classe de vegetação arbórea é definida por alturas superiores a 4,5 metros. A vegetação rasteira, que corresponde à vegetação secundária no início da regeneração após um corte raso, tem um I_p de 0,25, sendo caracterizada por alturas inferiores a 1,5 metros. Em geral, vegetações rasteiras apresentam alturas menores que 50 centímetros. As classes de Extração Mineral e Corte Raso, por não possuírem vegetação, têm um I_p de 0 (tabela 9).

Após analisar os índices de porte da biomassa (I_p), procedeu-se à avaliação dos índices de recobrimento da biomassa (I_r), o SAVI, a vegetação arbórea demonstrou um recobrimento de 89,81% da área de estudo, classificando-se como muito densa, e, portanto, apresentando um I_r de 1,0 conforme a tabela (tabela 10). Em contrapartida, a vegetação rasteira teve um recobrimento de 10,05%, refletindo um I_r de 0,2, sendo considerada como muito rala. Para as classes de extração mineral e corte raso, que não possuem vegetação, atribuiu-se um I_r de zero.

A partir dessas informações, foi possível calcular o Índice de Biomassa de Vegetação Lenhosa (IBLV), utilizando a equação 25. O volume de biomassa, portanto, calculado pela equação 27, baseia-se na área calculada para cada classe, o volume máximo de preservação em m^3 por hectare, atribuído pelo FAO2014, e o IBVL. Para o volume degradado, basta multiplicar o volume degradado e o IBVL (tabela 19).

Tabela 19: IBVL, volume de biomassa e volume de degradação para o ano de 2018

Classes	IBVL	Volume de Biomassa (m^3)	Volume de Degradação ($m^3 \times ha^{-1}$)
Vegetação Arbórea	1	7995,68	247
Vegetação Rasteira	0,05	44,76	12,35
Extração Mineral	0	0	0
Corte Raso	0	0	0

Fonte: autora, 2024.

Assim como para o ano de 2018, a análise do Índice de Porte da Biomassa (I_p) na vegetação arbórea da Terra Indígena Apyterewa para o ano de 2023, considerando a mediana de altura de 35,60 metros, revela um I_p de 1,00. Isso se deve à definição da classe arbórea, que compreende alturas superiores a 4,5 metros (tabela 9). Para as classes de extração mineral e corte raso, por não possuírem vegetação, o I_p é zero. Já a vegetação rasteira, ao ser examinada em seus índices

por pixels, mostrou uma variedade de índices associados à classe de corte raso, indicando uma vegetação rasteira em estágio inicial, característica da classe subarbusciva, com alturas inferiores a 1,5 metros.

No entanto, a vegetação rasteira apresentou dois portes de biomassa distintos. Conforme apontado por Chaves et al (2008), o cálculo utilizado do IBVL foi através da equação 25. Entretanto, em determinadas áreas classificadas como vegetação rasteira, foram identificados pixels com índices menores que os da vegetação arbórea e maiores que os de corte raso, sugerindo uma vegetação rasteira em estágio mais avançado, podendo ser classificada como arbustiva por Chaves et al (2008). Após a análise dos índices de porte de biomassa (I_p), deu-se continuidade à avaliação do recobrimento da biomassa (I_r) nas quatro classes. Percebeu-se que a vegetação arbórea cobriu 79,42% da área de estudo, indicando uma subclasse de vegetação densa e resultando em um I_r de 0,8 conforme a tabela de referência (tabela 10).

Em contrapartida, a vegetação rasteira apresentou uma cobertura de apenas 10,05%, gerando um I_r de 0,2 e sendo caracterizada como muito rala. Quanto às classes de extração mineral e corte raso, que não apresentavam cobertura vegetal, atribuiu-se um I_r de zero. Dessa forma, assim como para o ano de 2018, foram calculados os volumes de biomassa e de degradação (tabela 20).

Tabela 20: IBLV, volume de biomassa e volume de degradação para a ano de 2023 - SAVI

Classes	IBVL	Volume de Biomassa (m ³)	Volume de Degradação (m ³ x ha ⁻¹)
Vegetação Arbórea	0,8	6396,54	197,6
Vegetação Rasteira	0,08	71,62	19,76
Extração Mineral	0	0	0
Corte Raso	0	0	0

Fonte: autora, 2024.

5.3.2. kNN

Para a técnica kNN do ano 2018, os índices de porte da biomassa (I_p) para as classes de vegetação arbórea, vegetação rasteira, extração mineral e corte raso permanecem inalterados, sendo 1,00, 0,25, 0 e 0, respectivamente. Para o índice de recobrimento da biomassa (I_r), foram atribuídos os valores de 0,2 para as classes de corte raso, extração mineral e vegetação rasteira, considerando que seus

percentuais em relação à área total foram de 0,2%, 0,003% e 3,08%, respectivamente.

Entretanto, para a vegetação arbórea, que apresentou um percentual de 96,72% da área total, manteve-se o Ir de 1,0, classificando-a como uma subclasse muito densa. Com base nesses valores de índices de porte e recobrimento de biomassa, foi possível calcular o volume de biomassa e de degradação presente na área de estudo, conforme demonstrado na tabela 21.

Tabela 21: Dados e estimativa da degradação da vegetação

Classes	IBVL	Volume de Biomassa (m ³)	Volume de Degradação (m ³ x ha ⁻¹)
Vegetação Arbórea	1	8610,78	247
Vegetação Rasteira	0,05	13,71	12,35
Extração Mineral	0	0	0
Corte Raso	0	0	0

Fonte: autora, 2024.

Para o ano de 2023, o Índice de Porte da Biomassa (Ip) foi definido com valor zero para as classes de corte raso e extração mineral, devido à ausência de vegetação. No entanto, para as classes de vegetação arbórea e vegetação rasteira, os valores atribuídos foram 1,00 e 0,25, respectivamente. Isso ocorre porque, na área de estudo, a vegetação arbórea é composta por árvores com mais de 30 metros de altura, enquanto a vegetação rasteira possui um Ip de 0,25, caracterizada por alturas menores que 1,5 metros.

Para o Índice de Recobrimento da Biomassa (Ir), os valores atribuídos foram de 0,2 para as classes de corte raso, extração mineral e vegetação rasteira, considerando que suas porcentagens em relação à área total foram de 4,51%, 0,08% e 2,06%, respectivamente, classificadas como vegetação muito rala, conforme a tabela 10.

Já para a vegetação arbórea, que ocupa 93,36% da área total, o Ir foi mantido em 1,0, categorizando-a como uma subclasse muito densa. Com base nesses índices de porte e recobrimento de biomassa, foi possível calcular o volume de biomassa e de degradação na área de estudo, conforme mostrado na tabela 22.

Tabela 22: IBLV, volume de biomassa e volume de degradação para a ano de 2023 - kNN

Classes	IBVL	Volume de Biomassa (m ³)	Volume de Degradação (m ³ x ha ⁻¹)
Vegetação Arbórea	1	8300,48	247
Vegetação Rasteira	0,05	9,15	12,35
Extração Mineral	0	0	0
Corte Raso	0	0	0

Fonte: autora, 2024.

Nas regiões continentais, a vegetação é o tipo de cobertura terrestre mais predominante e comum, refletindo interações significativas tanto com fatores abióticos naturais quanto com atividades humanas. Dessa forma, a vegetação serve como um indicador da qualidade e preservação ambiental. A resposta espectral da vegetação nas imagens de sensores remotos está principalmente ligada ao tipo, qualidade e quantidade de biomassa vegetal, que variam espacialmente e temporalmente, dependendo da disponibilidade de fatores essenciais para o desenvolvimento das plantas, como luz, calor, nutrientes e água (JENSEN, 2009). Dessa maneira, diversos sistemas de classificação e legendas adotados por projetos de monitoramento e gestão ambiental utilizam parâmetros ecofisiológicos para classificar a vegetação, separando as classes de vegetação com base em diferentes ambientes, porte e densidade de cobertura (CHAVES et al, 2008).

o volume de biomassa para o ano de 2018 é significativamente maior para a vegetação arbórea, registrando $8.610,78 \text{ m}^3 \times 10^{-3}$ por hectare com o método kNN e $7.995,68 \times 10^{-3} \text{ m}^3$ por hectare com o SAVI, refletindo um incremento de 7,69% na área inicialmente proposta pelo SAVI. A vegetação rasteira, que apresentou $44,76 \text{ m}^3$ por hectare com o SAVI, sofreu uma redução considerável ao ser avaliada pelo método kNN, apresentando um volume de biomassa de $13,71 \text{ m}^3$ por hectare, correspondendo a uma diminuição de 69,37% da área total proposta inicialmente pelo SAVI.

Além disso, a vegetação arbórea, tanto no SAVI quanto no kNN, representou uma área onde a vegetação possui mais de 30 metros de altura, sendo classificada como "Arbóreo" com um I_p de 1,00 e como uma subclasse de vegetação "Muito Densa", com 89,81% e 96,72% de cobertura para o SAVI e kNN, respectivamente, e um I_r de 1,0. Conseqüentemente, o volume de degradação permaneceu constante para ambas as técnicas, com 247 m^3 por hectare. Para a vegetação rasteira, com 3,08% e 10,05% de cobertura de vegetação para o kNN e SAVI, respectivamente, sendo a classificação uma área subarbustiva, com um I_p de 0,25 e uma subclasse "Muito Rala", com um I_r de apenas 0,2. com um IBVL de 0,05, o volume de degradação também permaneceu constante para ambas as técnicas, com um volume de degradação de $12,35 \text{ m}^3$ por hectare.

Assemelhando-se ao proposto por Chaves et al (2008) para o bioma da Caatinga, este método de classificação é simples, rápido e prático, o que o torna de fácil aplicação. Sendo apenas descritivo, é de baixo custo, mas sua precisão

depende da experiência e habilidade de quem o utiliza. A conversão dos padrões de vegetação descritos por essa classificação em índices de biomassa da vegetação lenhosa (IBVL) permite também utilizar esses dados em equações e modelos que descrevem processos hidrológicos, erosivos, sedimentológicos, agroclimáticos e de impactos ambientais. Utilizado como referência descritiva dos padrões de vegetação, o IBVL, quando correlacionado com índices de reflectância, pode auxiliar na interpretação automática de imagens de satélite, contribuindo para a agilização de trabalhos de mapeamento de inventários florísticos e florestais.

6. CONCLUSÃO

A identificação de áreas suscetíveis a degradação ambiental por desmatamento por meio de imagens PlanetScope, no Território Indígena Apyterewa, entre os anos de 2018 a 2023, foi objetivo deste estudo, em que são elencadas as principais conclusões: em ambas as técnicas foi possível observar o aumento significativo de corte raso, bem como o aumento da extração mineral. Além disso, ficou perceptível o melhor desempenho do SAVI em comparação com o kNN para a análise de áreas com mata densa, do mesmo modo que também foi notório a redução do volume de biomassa da classe vegetação arbórea.

O kNN, por exemplo, revelou-se um método excessivamente suscetível ao overfitting, mostrando-se inadequado para o monitoramento de florestas densas. Em contrapartida, o SAVI, por ser um índice espectral sensível tanto à vegetação quanto ao solo, demonstrou maior eficácia na vigilância de áreas florestais densas.

O desmatamento está ocorrendo em um momento crítico, em que a floresta amazônica corre o risco iminente de atravessar um ponto de inflexão climático do qual talvez não consiga se recuperar. Nesse contexto, a Amazônia brasileira encontra-se pouco envolvida em projetos que promovam o desenvolvimento sustentável e a preservação florestal. Até o presente, as iniciativas de conservação têm se disseminado predominantemente por meio de políticas impostas de cima para baixo, em vez de intervenções e incentivos locais positivos na região amazônica brasileira. Explorar estratégias que gerem benefícios econômicos para os pecuaristas a partir da manutenção das florestas pode mitigar o desmatamento tanto dentro quanto fora da T.I. Apyterewa e em outras áreas protegidas da Amazônia. Tal estratégia pode ser crucial para incentivar práticas pecuárias sustentáveis, aumentar a produtividade, evitar a desflorestação, reduzir os passivos ambientais em um setor tradicionalmente de baixo desempenho e promover a justiça social e econômica para as populações rurais e indígenas.

Esses achados revelam uma situação crítica nas "áreas protegidas" da Amazônia brasileira. Para reverter esse cenário destrutivo, é vital desenvolver estratégias de preservação florestal que reflitam os significativos valores ecossistêmicos globais e regionais, incluindo o sequestro de carbono, a proteção da saúde humana contra aerossóis nocivos e outros potenciais econômicos a longo prazo. As estratégias devem contemplar o apoio a economias e práticas pecuárias e

agrícolas equitativas e sustentáveis, com o intuito de reduzir os passivos ambientais nesses setores tradicionalmente de baixo desempenho. Tais estratégias são essenciais não apenas para evitar a desflorestação, mas também para mitigar os impactos ambientais e ecológicos resultantes da perda florestal. Uma resposta mais robusta incluiria a abordagem da ameaça de perda florestal e o feedback da degradação, promovendo o recrescimento florestal em reservas degradadas.

REFERÊNCIAS

- ABDI, A. M. **Land cover and land use classification performance of machine learning algorithms in a boreal landscape using Sentinel-2 data**. *GIScience & Remote Sensing*: Taylor & Francis Online, 2019. v. 87. ISSN 1548-1603. <https://doi.org/10.1080/15481603.2019.1650447>
- ABREU, K. M. P.; COUTINHO, L. M. **Sensoriamento remoto aplicado ao estudo da vegetação com ênfase em índice de vegetação e métricas da paisagem**. *Vértices*. Campos dos Goytacazes, Rio de Janeiro, v. 16, n. 1, p. 173-198, 2014. <https://doi.org/10.18227/2177-4307.acta.v12i29.4001>
- AMAZONIA2030. Disponível em: <https://amazonia2030.org.br/fatos-da-amazonia-2021/#:~:text=A%20popula%C3%A7%C3%A3o%20est%C3%A1%20estimada%20em,5%2C6%20habitantes%20por%20km%C2%B2> . <Acesso em: 12 maio 2024>.
- ADIRI, Z; LHISSOU, R.; HARTI, A. E.; JELLOULLI, A.; CHAKOURI, M. **Recent advances in the use of public domain satellite imagery for mineral exploration: A review of Landsat-8 and Sentinel-2 applications**. *Ore Geology Reviews*: Elsevier, 2020. 103-332 p. v. 117. ISSN 0169-1368. <https://doi.org/10.1016/j.oregeorev.2020.103332>
- ALENCAR, Adriana Vital Silva. **Evolução histórica dos direitos indígenas**. 2015. Disponível em: <<https://jus.com.br/artigos/35348/evolucao-historica-dos-direitos-indigenas>>. Acesso em: 12 maio 2024.
- ALLEN, R. G., TASUMI, M.; TREZZA, R. **SEBAL (Surface Energy Balance Algorithms for Land**. *Advanced Training and Users Manual – Idaho Implementation, version 1.0*, 97 p., 2002. Disponível em: <https://posmet.ufv.br/wp-content/uploads/2017/04/MET-479-Waters-et-al-SEBAL.pdf> . Acesso em: 29 maio 2024.
- ARRAES, R.A; MARIANO, F.Z.; SIMONASSI, A.G. **Causas do Desmatamento no Brasil e seu Ordenamento no Contexto Mundial**. *Revista de Economia e Sociologia Rural*, v.50, n.1, p.119-140, 2012.
- ARRECHEA-CASTILLO, D. A; SOLANO-CORREA, Y. T; MUÑOZ-ORDÓÑEZ, J.f; PENCUE-FIERRO, E. L; FIGUEROA-CASAS, A. **Multiclass Land Use and Land Cover Classification of Andean Sub-Basins in Colombia with Sentinel-2 and Deep Learning**. *Remote Sensing*: MDPI, 2023. v. 15. ISSN 2072-4292. <https://doi.org/10.3390/rs15102521>
- ASSIS, L. F. F. G; FERREIRA, K. R; VINHAS, L ; MAURANO, L; ALMEIDA, C; CARVALHO, A; RODRIGUES, J ; MACIEL, A; CAMARGO, C. **TerraBrasilis: A Spatial Data Analytics Infrastructure for Large-Scale Thematic Mapping**. 11. ed. *ISPRS International Journal of Geo-Information*: MDPI, 2019. v. 8. ISSN 2220-9964. <https://doi.org/10.3390/ijgi8110513>

ASNER, G. P; TUPAYACHI, R. **Accelerated losses of protected forests from gold mining in the Peruvian Amazon**. 9. ed. Environmental Research: LETTER, 2017. v. 12. ISSN 1748-9326. <https://doi.org/10.1088/1748-9326/aa7dab>

BARBOSA, G. L. **TRANSFERÊNCIA DE CONHECIMENTO NO USO DE SISTEMAS DE INFORMAÇÕES GEOGRÁFICAS (SIG) APLICADO À GESTÃO DE ÁGUAS SUBTERRÂNEAS EM BACIAS HIDROGRÁFICA**. Dissertação (Mestrado em Gestão e Regulação de Recursos Hídricos) - Universidade Estadual Paulista Júlio de Mesquita Filho. UNESP Campus Ilha Solteira, São Paulo, 2022-2023.

BAKKER, L. B; GASPARINETTI, P.; QUEIROZ, J. M; VASCONCELLOS, A. C. S. **Economic Impacts on Human Health Resulting from the Use of Mercury in the Illegal Gold Mining in the Brazilian Amazon: A Methodological Assessment**. 5. ed. International Journal of Environmental Research and Public Health: MDPI, 2022. v. 18. ISSN 1660-4601. <https://doi.org/10.3390/ijerph182211869>

BECKER, W. R.; JOHANN, J. A.; RICHETTI, J.; SILVA, L. C. A. **Data mining techniques for separation of summer crop based on satellite images**. Engenharia Agrícola, Jaboticabal – SP, v. 37, n. 4, p. 750–759, 2017

Brasil. Lei nº 9.985/2000, que institui o Sistema Nacional de Unidades de Conservação. **Casa Civil da Presidência da República**, 2000. Disponível em: http://www.planalto.gov.br/ccivil_03/LEIS/L9985.htm <Acesso em: 13 maio 2024>.

BRASIL. Decreto-lei s/nº, de 19 de abril de 2007. Homologa a demarcação administrativa da Terra Indígena Apyterewa, localizada no Município de São Félix do Xingu, no Estado do Pará. **Diário Oficial da União**: seção 1, Brasília, DF, n. 76, p. 09, 20 abr. 2007.

BRASIL. Constituição (1988), **Capítulo VIII – DOS INDÍOS, Art. 231**. Disponível em: http://www.planalto.gov.br/ccivil_03/constituicao/constituicao.htm . Acesso em: 11 de maio 2024.

BRASIL. Constituição (1988), **Capítulo VIII – DOS INDÍOS, Art. 232**. Disponível em: http://www.planalto.gov.br/ccivil_03/constituicao/constituicao.htm . Acesso em: 11 de maio 2024.

BRASIL. Lei nº 6.001, de 19 de dezembro de 1973. **Dispõe sobre o Estatuto do Índio**. Diário Oficial da União: seção 1, Brasília, DF, v. 7, p. 13.177, 21 dez. 1973. PL 2.328/1970. Disponível em: http://www.planalto.gov.br/ccivil_03/leis/l6001.htm. Acesso em 11 maio 2024.

BRITO, B.; ALEMIDA, J.; GOMES, P.; SALOMÃO, R. **Dez fatos essenciais sobre regularização fundiária na Amazônia**. Belém: Imazon, 2021a. Disponível em: <https://imazon.org.br/publicacoes/dez-fatos-essenciais-regularizacao-fundiaria-Amazônia/> . <Acesso em: 13 maio 2024 >.

BUENO MACHADO, Carolyne e NEVES, Alana. **Delimitação de Áreas de Preservação Permanente das sub-bacias do Reservatório Jaguari-Jacareí, Sistema Cantareira (SP) - classificação e identificação de conflito na cobertura**

da terra (2013). Conferência: XVIII Simpósio Brasileiro de Sensoriamento Remoto – SBSR. 2017.

BÜLL, P. L. G. **BANALIZAÇÃO DA ILEGALIDADE: O DIREITO INDÍGENA ATUAL SOB A ÓTICA DA TERRA INDÍGENA APYTEREWA, RIO XINGU**. Monografia (Bacharelado em Direito) - Faculdade Nacional de Direito, Universidade Federal do Rio de Janeiro. Rio de Janeiro, p. 15. 2022.

Byrt, T., Bishop, J., & Carlin, J. B. (1993). **Bias, prevalence, and kappa**. *Journal of Clinical Epidemiology*, 46 (5), 423-429.

CALVIMONTES, J; MASSARO, L; ARAUJO, C. H. X; MORAES, R. R; MELLO, J; FERREIRA, L. C; THEIJE, M. **Small-scale gold mining and the COVID-19 pandemic: Conflict and cooperation in the Brazilian Amazon**. 4. ed. *The Extractive Industries and Society*: Elsevier, 2019. 1347-1350 p. v. 7. ISSN 2214-790X. <https://doi.org/10.1016/j.exis.2020.08.013>

CHAVES, I. B; LOPES, V. L; FFOLLIOT, P. F. FFOLLIOTT; PAES-SILVA, A. P. **UMA CLASSIFICAÇÃO MORFO-ESTRUTURAL PARA DESCRIÇÃO E AVALIAÇÃO DA BIOMASSA DA VEGETAÇÃO DA CAATINGA**. 2. ed. *REVISTA CAATINGA*: Universidade Federal Rural do Semi-Árido Brasil, 2008. 04-213 p. v. 21. ISSN 0100-316.

Cohen, J.A. (1960). **A coefficient of agreement for nominal scales**. *Educational and Psychological Measurement*, 20, 213–220.

CONGALTON, R. C; MEAD, R. A. **A Quantitative Method to Test for Consistency and Correctness in Photointerpretation**. 1. ed. *Photogrammetric Engineering and Remote Sensing: School of Forestry and Wildlife Resources*, 1983. 69-74 p. v. 49. Disponível em: https://www.asprs.org/wp-content/uploads/pers/1983journal/jan/1983_jan_69-74.pdf

CONGALTON, R. C. **A review of assessing the accuracy of classifications of remotely sensed data**. 1. ed. *Remote Sensing of Environment*: Elsevier, 1991. 35-46 p. v. 37. ISSN 0034-4257. [https://doi.org/10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B)

CONGALTON, R. G.; GREEN, K. **Assessing the Accuracy of Remotely Sensed Data: principles and practices**. New York, Lewis Publishers. 137 p. 1999.

CONGALTON, Russell G.; GREEN, Kass. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. 2. ed. Boca Raton: Crc Press, 2009. 183 p.

COUTO, Paula. **Assessing the accuracy of spatial simulation models. Ecological Modelling**, [s.l.], v.167, n. 1-2, p.181-198, set. 2003. Elsevier BV. [http://dx.doi.org/10.1016/s0304-3800\(03\)00176-5](http://dx.doi.org/10.1016/s0304-3800(03)00176-5).

CHAVES, M. E. D.; PICOLI, M. C. A.; SANCHES, I. D.. **Recent Applications of Landsat 8/OLI and Sentinel-2/MSI for Land Use and Land Cover Mapping: A Systematic Review**. *Remote Sensing: MDPI*, 2020. v. 12. ISSN 2072-4292. <https://doi.org/10.3390/rs12183062>

CLIMATE-DATA. **Dados climáticos para cidades mundiais**. 2019. Disponível em: <https://pt.climate-data.org/>. Acesso em: 13 fev. 2024.

COHN, A.S.; MOSNIER, A.; HAVLÍK, P.; OBERSTEINER, M. **Cattle ranching intensification in Brazil can reduce global greenhouse gas emissions by sparing land from deforestation**. 20. ed. SOCIAL SCIENCES: PNAS, 2014. 7236-7241 p. v. 111. <https://doi.org/10.1073/pnas.1307163111>

DHAU, I.; ADAM, E.; AYISI, K. K.; MUTANGA, O. Detection and mapping of maize streak virus using RapidEye satellite imagery. **Geocarto International**, v. 34, n. 8, p. 856-866, 2019. <https://doi.org/10.1080/10106049.2018.1450448>

DINIZ, C. G.; SOUZA, A. A. A.; SANTOS, D. C.; DIAS, M. C.; ADAMI, M.; MAURANO, L. E. P.; VALERIANO, D. M.; NARVAES, I. S.; GOMES, A. R.; MAIA, J. S.; MORAES, D. R. V.; LUZ, N. C. **DETER-B: The New Amazon Near Real-Time Deforestation Detection System**. Journal of Selected Topics in Applied Earth Observations and Remote Sensing: IEEE, 2015. 850-853 p. v. 8. ISSN 3619-3628. <https://doi.org/10.1109/JSTARS.2015.2437075>

DOS SANTOS, H.G.; JACOMINE, P. K. T.; ANJOS, L. H. C. dos; OLIVEIRA, V. Á. de; LUMBRERAS, J. F.; COELHO, M. R.; ALMEIDA, J. A. de; ARAÚJO FILHO, J. C. de; OLIVEIRA, J. B. de; CUNHA, T. J. F. **Sistema Brasileiro de Classificação de Solos**. 5. ed. Brasília, DF: Revista e Ampliada. Brasília, DF: Embrapa, 2018. 356 p. v. 1. ISSN 978-85-7035-800-4. Disponível em: <https://www.agroapi.cnptia.embrapa.br/portal/assets/docs/SiBCS-2018-ISBN-9788570358004.pdf>. Acesso em: 13 fev. 2024.

DUCHEMIN, B.; HADRIA, R.; ERRAKI, S.; BOULET, G.; MAISONGRANDE, P.; CHEHBOUNI, A.; ESCADAFAL, R.; EZZAHAR, J.; HOEDJES, J.C.B.; KHARROU, M.H.; KHABBA, S.; MOUGENOT, B.; OLIOSSO, A.; RODRIGUEZ, J.C.; SIMONNEAUX, V. **Monitoring wheat phenology and irrigation in Central Morocco: On the use of relationships between evapotranspiration, crops coefficients, leaf area index and remotely-sensed vegetation indices**. Agricultural Water Management: Elsevier, v. 79, p.1-27, 2006. <https://doi.org/10.1016/j.agwat.2005.02.013>

EPIPHANIO, J. C. N.; GLERIANI, J. M.; FORMAGGIO, A. R.; RUDORFF, B. F. T. **Índices de vegetação no sensoriamento remoto da cultura do feijão**. Pesquisa Agropecuária Brasileira, Brasília – DF, v. 31, n. 6, p. 445-454, jun. 1996.
ESPEJO, J. C.; MESSINGER, M.; D, F. R.; ASCORRA, C.; FERNANDEZ, L. E.; SILMAN, M. **Deforestation and Forest Degradation Due to Gold Mining in the Peruvian Amazon: A 34-Year Perspective**. Remote Sensing: PrePrints, 2018. v. 10. <https://doi.org/10.20944/preprints201811.0113.v1>

FACELI, K.; LORENA, A. C.; GAMA, J.; ALMEIDA, T. A.; CARVALHO, A. C. P. (2021) **Inteligência artificial: uma abordagem de aprendizado de máquina**. Rio de Janeiro: LTC. Disponível em: <https://repositorio.usp.br/directbitstream/ff933d41-4c3d-4b57-80c2-b4f1c805b1dc/3128493.pdf>. Acesso em: 23 mar. 2024.

FAO – **Food and Agriculture Organization of the United Nations**. FRA2015 Brazil, Country Report. Rome: FAO, 2014. Disponível em: <http://www.fao.org/3/a-az172e.pdf> . <Acesso em: 08 maio 2024>.

FAUSTO, Carlos. **Inimigos Fiéis: História, Guerra e Xamanismo na Amazônia**. 1. ed. Edusp: Editora da Universidade de São Paulo, 2014. ISBN 10: 8531405742.
FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento remoto em agricultura**. São José dos Campos - SP: Oficina de Textos, 2017.

FRANCISCO, P. R. M Keviane Pereira Aragã; RIBEIRO, G. N; NETO, J. M. M; ARAGÃ, K. P. **Avaliação da Degradação da Caatinga do Município de Sumé-PB Estimado pelo Volume de Biomassa da Vegetação Lenhosa**. 01. ed. Revista Brasileira de Geografia Física: UFPE, 2014. 117-129 p. v. 07. ISSN 1984-2295.

GAY, J. S; SANCHEZ, L. E. **The outbreak of illegal gold mining in the Brazilian Amazon boosts deforestation**. 28. ed. Regional Environmental Change: SPRINGER, 2021. v. 21. ISSN 1436-378X. <https://doi.org/10.1007/s10113-021-01761-7>

GAY, J. S; SONTER, L. J; SANCHEZ, L. E. **Exploring potential impacts of mining on forest loss and fragmentation within a biodiverse region of Brazil's northeastern Amazon**. Resources Policy: Elsevier, 2020. v. 67. ISSN 0301-4207. <https://doi.org/10.1016/j.resourpol.2020.101662>

GEIST H.J.& LAMBIN E.F. 2002. **Proximate Causes and Underlying Driving Forces of Tropical Deforestation**. BioScience 52:143-150.

GRECCO, E. D; SILVEIRA, L. F. V; LIMA, V. L. S; PEZZOPANE, J. E. M. **Estimativa do índice de área foliar e determinação do coeficiente de extinção luminosa da abóbora Cucurbita moschata var. japonesa**: Estimation of leaf area index and determination of light extinction coefficient of pumpkin Cucurbita moschata var. japanese. 01. ed. Idesia: SCIELO, 2011. 37-41 p. v. 29. ISSN 0718-3429. <http://dx.doi.org/10.4067/S0718-34292011000100006>

GANDHI, G. M.; PARTHIBAN, S.; THUMMALU, N.; CHRISTY, A. Ndvi: **Vegetation change detection using remote sensing and gis**. A case study of vellore district. Procedia Computer Science, v. 57, p. 1199–1210, 2015

GUIMARÃES, M.J.M., FILHO, M.A.C., PEIXOTO, C.P., JUNIOR, F.A.G., OLIVEIRA, V. V. M. **Estimation of leaf area index of banana orchards using the method LAI-LUX**. Water Resources and Irrigation, v.2, n.2, p.71-76, 2013. Disponível em: <https://core.ac.uk/download/pdf/270268139.pdf> . Acesso em: 10 jun 2024.

HADDAWAY, N. R; COOKE, S. J; LESSER, P; MACURA, B; NILSSON, A. E; TAYLOR, J. J; RATIO, K. **Evidence of the impacts of metal mining and the effectiveness of mining mitigation measures on social–ecological systems in Arctic and boreal regions: a systematic map protocol**. 8. ed. BMC: Environmental Evidence, 2019. v. 8. ISSN 2047-2382. <https://doi.org/10.1186/s13750-019-0152-8>

HUANG, D.; TANG, Y.; QIN, R. An evaluation of PlanetScope images for 3D reconstruction and change detection – experimental validations with case studies. **GIScience & remote sensing**, v. 59, n. 1, p. 744–761, 2022. <https://doi.org/10.1080/15481603.2022.2060595>

HANSEN, M. C.; POTAPOV, P. V. ; MOORE, R.; HANCHER, M.; TURUBANOVA, S. A.; TYUKAVINA, A.; THAU, D. ; STEHMAN, S. V. ; GOETZ, S. J. ; LOVELAND, T. R. ; KOMMAREDDY, A.; EGOROV, A. ; CHINI, L.; JUSTICE, C. O.; TOWNSHEND, J. R. G.. **Rapid Recent Deforestation Incursion in a Vulnerable Indigenous Land in the Brazilian Amazon and Fire-Driven Emissions of Fine Particulate Aerosol Pollutants**. *Local: SCIENCE*, 2013. 850-853 p. v. 342. ISSN 6160. <https://doi.org/10.1126/science.1244693>

HOFFMAN, E. L. **Enos e a distribuição pluviométrica no sudoeste da Amazônia oriental paraense. Orientador Rivanildo Dallacort**. Dissertação (Mestrado em Biodiversidade e Agroecossistemas Amazônicos) e Faculdade de Ciências Biológicas e Agrárias da Universidade do Estado de Mato Grosso – UNEMAT, 2017, 89p. Disponível em: <http://portal.unemat.br/media/files/EMERSON%20LUIS%20HOFFMANN.pdf>. Acesso em: 11 maio 2024.

HUETE, A. R. **A soil-adjusted vegetation index (SAVI)**. 3. ed. Remote Sensing of Environment: Elsevier, 1988. 295-309 p. v. 25. ISSN 0034-4257. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X).

IBGE. População residente do Censo Demográfico IBGE 2010. Unpublished, 2010. <https://censo2010.ibge.gov.br> . < Acesso em: 12 maio 2024 >.

IBGE. População residente estimada: Estimativas de População – EstimaPop. Unpublished, 2022a. <https://sidra.ibge.gov.br/pesquisa/estimapop> . < Acesso em: 12 maio 2024 >.

IBGE. **Mapeamento de recursos naturais do Brasil**. 2018a. Vegetação 1:250.000. Disponível em: https://geoftp.ibge.gov.br/informacoes_ambientais/vegetacao/vetores/escala_250_mil/ . Acesso em: 13 fev. 2024.

IBGE d. **Mapeamento de recursos naturais do Brasil**. 2018b. Pedologia 1:250.000. Disponível em: https://geoftp.ibge.gov.br/informacoes_ambientais/pedologia/vetores/escala_250_mil/ . Acesso em: 13 fev. 2024.

Instituto Nacional de Pesquisas Espaciais (INPE). **Estimativa de desmatamento por corte raso na Amazônia Legal para 2021 é de 13.235 km²**. Disponível em: <https://www.gov.br/inpe/pt-br/assuntos/ultimas-noticias/divulgacao-de-dados-prodes.pdf> , 2021.

Inpe. Avisos de desmatamento Deter. Unpublished, 2022b. Disponível em: <http://terrabrasilis.dpi.inpe.br/> . <Acesso em 13 maio 2024 >.

ISA a, INSTITUTO SOCIOAMBIENTAL. **Terras Indígenas no Brasil**. Terra Indígena Kayapó. Disponível em: < <https://terrasindigenas.org.br/pt-br/terras-indigenas/3585>>. Acesso em: 13 dez. 2023

ISA, INSTITUTO SOCIOAMBIENTAL b. **Terras Indígenas no Brasil**. Disponível em < <https://pib.socioambiental.org/pt/Povo:Parakan%C3%A3#:~:text=Os%20Parakan%C3%A3%20teriam%20sido%20avistados,Estrada%20de%20Ferro%20do%20Tocantins>>. Acesso em: 11 maio 2024.

ISA, INSTITUTO SOCIOAMBIENTAL. **Terras Indígenas no Brasil**. Disponível em< <https://terrasindigenas.org.br/> >. Acesso em: 11 maio 2024.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Tradução: EPIPHANIO, J. C. N. São José dos Campos: Parêntese, 2009. 598 p. Tradução de Remote sensing of the environment: na Earth resource perspective.

JOHANN, J. A.; BECKER, W. R.; URIBE-OPAZO, M. A.; MERCANTE, E. **Uso de imagens do sensor orbital modis na estimação de datas do ciclo de desenvolvimento da cultura da soja para o estado do Paraná – Brasil**. Engenharia Agrícola, Jaboticabal – SP, v. 36, n. 1, p. 126–142, fev. 2016.

JONCKHEERE, I., FLECK, S., NACKAERTS, K., MUY, B., COPPIN, P., WEISS, M. BARET, F., **Review of methods for in situ leaf area index determination Part I. Theories, sensors and hemispherical photography**. Agricultural and Forest Meteorology, v. 121, 19–35, p.2004.

JUNIOR, J. A. S.; PACHECO, A. P. **Classificador Support Vector Machines para o mapeamento da cobertura do solo usando imagens CBERS-4/MUX e Landsat-8/OLI**. 03. ed. Revista Brasileira de Geografia Física: UFPE, 2023. 1304-1319 p. v. 16. ISSN 1984-2295.

KAIMOWITZ D. & ANGELSEN A. 1998. **Economic models of tropical deforestation: a review**. CIFOR - Center for International Forestry Research, Indonesia, 153p.

LARCHER, W. **Ecofisiologia vegetal**. São Carlos, SP. Rima, 2000, p. 531, 2020.

LAONAMSAI, J; LAONAMSAI, P; SAPRATHET, T; KIMMANY, B; GANCHANASURAGIT, T; CHOMCHAWCHAN, P; TOMUN, N. **Utilizing NDWI, MNDWI, SAVI, WRI, and AWEI for Estimating Erosion and Deposition in Ping River in Thailand**. 3. ed. Hydrology: MDPI, 2023. p. v. 10. ISSN 2306-5338. <https://doi.org/10.3390/hydrology10030070>

LILAY, M. Y. ; TAYE, G. D.. **Semantic segmentation model for land cover classification from satellite images in Gambella National Park, Ethiopia**. SN Applied Sciences: Springer, 2023. v. 5. ISSN 2523-3971. <https://doi.org/10.1007/s42452-023-05280-4>

LANDIS, J. R; KOCH, G. G. The measurement of observer agreement for categorical data. *Biometrics*, 33(1): 159-174. 1977.

LOYAZA, N; RIGOLINI, J. The Local Impact of Mining on Poverty and Inequality: Evidence from the Commodity Boom in Peru. *World Development: Elsevier*, 2016. 219-234 p. v. 84. ISSN 0305-750X. <https://doi.org/10.1016/j.worlddev.2016.03.005>

KEENAN, R.J. et al. **Dynamics of global forest area: Results from the FAO Global Forest Resources Assessment 2015**. *Forest Ecology and Management*, v.352, n.7, p.9-20, 2015.

KESHTKAR, H.; VOIGT, W.; ALIZADEH, E.. **Land-cover classification and analysis of change using machine-learning classifiers and multi-temporal remote sensing imagery**. *Arabian Journal of Geosciences: Springer*, 2017. v. 10. ISSN 1866-7538. <https://doi.org/10.1007/s12517-017-2899-y>

KLECKA, W. R. *Discriminant Analysis (Quantitative Applications in the Social Sciences, 19.)*. Newbury: SAGE Publication, Inc., 71 p., 1980.

MARTINS, W. B. R; DE MATOS RODRIGUES, J. I. M; PEREIRA DE OLIVEIRA, V. P; DOS SANTOS BARROS, W. S. Mining in the Amazon: Importance, impacts, and challenges to restore degraded ecosystems. Are we on the right way?. *Ecological Engineering: Elsevier*, 2022. v. 174. ISSN 0925-8574. <https://doi.org/10.1016/j.ecoleng.2021.106468>

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**. 3. ed. *Revista Equador: UFPI*, 2020. 209 - 232 p. v. 9. Disponível em: <http://www.ojs.ufpi.br/index.php/equador>

MATAVELI, G ; CHAVES, M ; GUERRERO, J ; ESCOBAR-SILVA, E. V; CONCEIÇÃO, K; OLIVEIRA, G. **Mining Is a Growing Threat within Indigenous Lands of the Brazilian Amazon**. *Remote Sensing: mdpi*, 2022. 40-92 p. v. 14. ISSN 2072-4292. <https://doi.org/10.3390/rs14164092>

MENESES, A. B. De. **Estorvos civilizatórios: Civilizing hindrances**. *Instituto de Estudos Brasileiros: Scielo*, 2022. v. 82. ISSN 0020-3874. <https://doi.org/10.11606/issn.2316-901X.v1i82p290-296>

MORAES, E. C. **Fundamentos de sensoriamento remoto. Apostila**. Instituto Nacional de Pesquisas Espaciais (INPE/MCTI). 2015. Disponível em: <http://www.dsr.inpe.br/vcsr/files/capitulo_1.pdf>. Acesso em: 10 maio 2024.

MORAITIS, N; TSIPI, L; VOUYIOUKAS, D. **Machine Learning-Based Methods for Path Loss Prediction in Urban Environment for LTE Networks**. *Local: IEEE*, 2020. 1-6 p. ISBN 978-1-7281-9722-7. <https://doi.org/10.1109/WiMob50308.2020.9253369>

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. Viçosa – MG: Livraria UFV, 2005.

NAIKOO, M. W., RIHAN, M., ISHTIAQUE, M., & SHAHFAHAD. (2020). **Analyses of land use land cover (LULC) change and built-up expansion in the suburb of a metropolitan city: Spatio temporal analysis of Delhi NCR using landsat datasets**. *Journal of Urban Management*, 9(01). <https://doi.org/10.1016/j.jum.2020.05.004>

MA, Z; REDMOND, R. L. **Tau Goefficients for Accuracy Assessment of Classificationf Remote Sensing Data**. 4. ed. *Remote Sensing Brief: PHOTOGRAMMETRIC ENGINEERING AND REMOTE SENSING*, 1995. 435-439 p. v. 61. Disponível em: https://www.asprs.org/wp-content/uploads/pers/1995journal/apr/1995_apr_435-439.pdf

MAPBIOMAS. **Análise de Acurácia**. <Disponível em: <https://brasil.mapbiomas.org/analise-de-acuracia/#:~:text=Acur%C3%A1cias%20do%20produtor%3A%20S%C3%A3o%20as,pixel%20da%20classe%20j%20corretamente> >. Acesso em: 22 maio 2024.

MACHADO, C. C. C. et al. **Estimativa do Índice de Área Foliar no Parque Nacional do Catimbau (PE - Brasil) e sua comparação com medições de campo usando o LAI-2200**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16. (SBSR). 2013, Foz do Iguaçu. Anais... São José dos Campos: INPE, 2013. p. 2850-2857. DVD, Internet. ISBN 978-85-17-00066-9 (Internet), 978-85-17-00065-2 (DVD). Disponível em: <http://marte2.sid.inpe.br/rep/dpi.inpe.br/marte2/2013/05.28.23.47.10> >. Acesso em: 10 jun 2024.

MENESES, P. R; ALMEIDA, T. **Introdução ao processamento de imagens de Sensoriamento remoto**. UnB, CNPq, Brasília, 266p, 2012. Disponível em: <http://www.cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8> >. Acesso em: 12 maio 2024.

MENESES, H. D. N. D. M; COSTA. H. N. M.; BASTA, P. C.; MORAIS, C. G.; PEREIRA, R. J. B.; SOUZA S .M. S.; **Mercury Contamination: A Growing Threat to Riverine and Urban Communities in the Brazilian Amazon**. *International Journal of Environmental Research and Public Health*: MDPI, 2022. v. 19. ISSN 1660-4601. <https://doi.org/10.3390/ijerph19052816>

MORAITIS, N.; TSIPI, L.; VOUYIOUKAS, D. **Flood Detection and Susceptibility Mapping Using Sentinel-1 Remote Sensing Data and a Machine Learning Approach: Hybrid Intelligence of Bagging Ensemble Based on K-Nearest Neighbor Classifier**. *IEEE explore*, 2020. v. 6. ISSN 2160-4894. <https://doi.org/10.1109/WiMob50308.2020.9253369>

PACHECO, A. P; JUNIOR, J. A. S; RUIZ-ARMENTEROS, A. M; HENRIQUES, R. F. **Assessment of k-Nearest Neighbor and Random Forest Classifiers for Mapping Forest Fire Areas in Central Portugal Using Landsat-8, Sentinel-2, and**

Terra Imagery. 7. ed. Remote sensing: Mdpi, 2021. 13-45 p. v. 13. ISSN 2072-4292. <https://doi.org/10.3390/rs13071345>

PAIVA, Y.G., **Estimativa do Índice de Área Foliar por métodos óticos e Sensoriamento Remoto para calibrar modelo Ecofisiológico em plantios de Eucalipto em áreas de relevo ondulado**. 74f. Mestrado em Meteorologia Agrícola. Universidade Federal de Viçosa, MG, 2009

PINHEIRO et al., Geoprocessamento aplicado à gestão dos recursos hídricos na bacia hidrográfica do Rio Macaé-RJ. SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. Anais [...]. Natal: INPE, 2009, p. 4247-4254.

PAULA, P. A., ZAMBRANO, L., & PAULA, P. **Análisis Multitemporal de los cambios de la vegetación, en la Reserva de Producción de Fauna Chimborazo como consecuencia del cambio climático**. Enfoque UTE, v. 9, n. 2, p. 125–137, 2018. doi: <https://doi.org/10.29019/enfoqueute.v9n2.252>

PLANET LABS a. **Planet Imagery Product Specifications**. February 2024, Available online <https://www.planet.com/products/> (2024) (Acesso em 09 de fev de 2024).

PLANET LABS b. **Introduction to Planet's Mission and History**. Disponível em: <<https://university.planet.com/introduction-to-planet/1814576/scorm/3qbb4shgwi380>> . Acesso em: 08 maio 2024.

PLANET LABS c. **Understanding PlanetScope Instruments**. Disponível em: <<https://developers.planet.com/docs/apis/data/sensors/>>. Acesso em: 06 mar. 2024.

PLANET LABS d. **Items & Assets**. Disponível em: <<https://developers.planet.com/docs/apis/data/items-assets/>> . Acesso em: 08 maio 2024.

PLANET LABS e. **Basemaps Overview** . Disponível em: <<https://developers.planet.com/docs/basemaps/>> . Acesso em: 08 maio 2024

PONTIUS, J.R; MILLIONES, M. Death to kappa: birth of quantify disagreement and allocation disagreement for accuracy assessment. International Journal of Remote Sensing, 2011.

PrevisIA. Belém: Imazon, 2022. Disponível em: <https://previsia.org>. <Acesso em: 13 maio 2024>.

RORATO, A. C; ESCADA, M. I; CAMARA, G.; PICOLI, M. C. A; VERSTEGEN, J. A. **Environmental vulnerability assessment of Brazilian Amazon Indigenous Lands**. Environmental Science & Policy: Elsevier, 2022. 19-36 p. v. 129. ISSN 1462-9011. <https://doi.org/10.1016/j.envsci.2021.12.005>

SAAB, David. **Conceptualizing Space: mapping schemas as meaningful representations**. 2003. Thesis (Master of Arts in Intercultural Relations) – Lesley University, Cambridge, 2003. DOI: 10.13140/2.1.3030.1767.

SANCHEZ-CUERVO, A. M; LIMA, L. S; DALLMEIER, F; GARATE, P; BRAVO, A; VANTHOMME, H. **Twenty years of land cover change in the southeastern Peruvian Amazon: implications for biodiversity conservation**. 8. ed. Regional Environmental Change: Springer, 2019. v. 20. ISSN 1436-378X. <https://doi.org/10.1007/s10113-020-01603-y>

In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2009. *Anais* [...]. Natal: INPE Brasil, 25-30, p. 3003-3009. < Disponível em: https://d1wqtxts1xzle7.cloudfront.net/32714726/3003-3009-libre.pdf?1391201807=&response-content-disposition=inline%3B+filename%3DAnalise_da_Cobertura_Vegeta_l_Atraves_dos.pdf&Expires=1716338939&Signature=eLAKbVv4tsTUh5x~gVm24LcsZ9Ls6eK~5yB7wwaPORpWvIOVoDPtP-W~nVkp2b0tsIB3SvtU0lhQ0YWUKq0cgaX0d537yIp3h07qi7kFGJpOxQIKGaRzmZtWTFiQQzcmpVyAE~ZtRD5W8gtSR9ufAl1C4o7AjtzirgQceAL9VoWAJWceSIYIdvRQtO991aACXD7iU7OqeJ50sLXQ2yPgjaZWcX04tVfDmO0pmKgccc9hMPqsnwolzAp8K~7cOoHhcQtpBRkkMpLk6SwN-zBUcholy6qcXaj0Z8bYisUAxkW4TYv7fpmXAlxND6paLrEp2oHrLdwhzxl77kjl55ybuQ__&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA > Acesso em: 21 maio 2024.

SAPRATHET, T ; LOSIRI, C ; SITTHI, A . **Onitoring of Morphological Change in Lam Phachi River Using Geo-informatics System**. Applied Geography and Geoinformatics for Sustainable Development: Springer, 2022. p. ISSN 978-3-031-16217-6. https://doi.org/10.1007/978-3-031-16217-6_4

SILVA, G; PUEREZ, M. G. B. **A DEMARCAÇÃO DE TERRAS INDÍGENAS NA AMAZÔNIA LEGAL**. 22. ed. Nupem: Campo Mourão, 2019. 43-53 p. v. 11. ISSN 2176-7912.

SERVIÇO FLORESTAL BRASILEIRO (SFB). O que é o Inventário Florestal Nacional. Brasília, 2017. Disponível em: <http://www.florestal.gov.br/inventario-florestal-nacional> . (Acesso em 06 de maio de 2024).

SILVA, C. F. A; ANDRADE, M. O; SANTOS, A. M; MELO, S. N. **Road network and deforestation of indigenous lands in the Brazilian Amazon**. Transportation Research Part D: Transport and Environment: Elsevier, 2023.v. 119. ISSN 1361-9209. <https://doi.org/10.1016/j.trd.2023.103735>

SILVA-JUNIOR, C. H L; SILVA, F. B; ARISI, B. M ; MATAVELI, G ; PESSOA, A. C. M ; CARVALHO, N. S; REIS, J. B. C ; JUNIOR, A. R. S ; MOTTA, N. A.c.s ; SILVA, P. V. M; RIBEIRO, F. D ; SIQUEIRA-GAY, J; ALENCAR, A ; SAATCHI, S ; ARAGÃO, L. E.o.c ; ANDERSON, L.o; MELO, M.. **Brazilian Amazon indigenous territories under deforestation pressure**. Scientific Reports: Nature, 2021. 58-51 p. v. 13. ISSN 2045-2322. <https://doi.org/10.1038/s41598-023-32746-7>

SCHMITT, A; MOREIRA, C. R. **Manejo e gestão de bacia hidrográfica utilizando o software gratuito Quantum-GIS**. Cultivando o Saber: FAG, 2015. 125 – 137 p. ISSN 2175-2214. Disponível em: https://www.fag.edu.br/upload/revista/cultivando_o_saber/566ec59f31e47.pdf

SCOTT, W.A. (1955) **Reliability of content analysis: the case of nominal scale coding**. Public Opin Q 19: 321–325.

SOUZA, Josiane Aparecida Cardoso de Souza. ACURÁCIA DAS MÉTRICAS DE VALIDAÇÃO DA CLASSIFICAÇÃO DE IMAGENS. 2019-2020. Dissertação (Mestrado em Engenharia de Produção) - Departamento de Engenharia de Produção, Universidade Federal de Minas Gerais, Minas Gerais, 2002-2003.

SILVA, J. L. S; ARAÚJO, R. A.; ESTEVES, V. P. P; LOEBMANN, D. G. S. W; VICENTE, L. E; PASCHOAL, J. P.; MORGADO, C. R. V. **Analysis of vegetation recovery in areas impacted by bauxite mining in the Amazon Forest.** Clean Technologies and Environmental Policy: Springer, 2021. 1617–1640 p. v. 23. ISSN 1618-9558. <https://doi.org/10.1007/s10098-021-02052-9>

SONTER, L. J.; MORAN, C. J.; BARRETT, D. J.; SOARES-FILHO, B. S.. **Processes of land use change in mining regions.** Journal of Cleaner Production: Elsevier, 2014. 494-501 p. v. 84. ISSN 0959-6526. <https://doi.org/10.1016/j.jclepro.2014.03.084>

STEHMAN, S. V.; FOODY, G. M. Key issues in rigorous accuracy assessment of land cover products. Remote Sensing Of Environment, [s.l.], v. 231, p.1-23, set. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2019.05.018> .

STORY, M; CONGALTON, R. G. **Accuracy Assessment: A User's Perspective.** 3. ed. Remote Sensing Brief: PHOTOGRAMMETRIC ENGINEERING AND REMOTE SENSING,, 1986. 397-399 p. v. 52. Disponível em: https://www.asprs.org/wp-content/uploads/pers/1986journal/mar/1986_mar_397-399.pdf

TOLESSA, T; DECHASSA, C; SIMANE, B; ALAMEREW, B; KIDANE, M. **Land use/land cover dynamics in response to various driving forces in Didessa sub-basin, Ethiopia.** GeoJournal: Springer, 2020. 747–760 p. v. 85. ISSN 1572-9893. <https://doi.org/10.1007/s10708-019-09990-4>

UDIN, S.; HAQUE, I.; LU, H.; MONI, M. A.; GIDE, E.. **Comparative performance analysis of K-nearest neighbour (KNN) algorithm and its different variants for disease prediction.** Scientific Reports: Nature, 2022. v. 12. ISSN 2045-2322.

USMANI, Raja Sher Afgun et al. **Geographic information system and big spatial data: a review and challenges.** International Journal of Enterprise Information Systems - IJEIS, Hershey, v. 16, n. 4, p. 101-145, 2020.

VU, T. Q.; DIHN, V. L.; TO, T. T., 2022. **Propagation Path Loss Models at 28 GHz Using K-Nearest Neighbor Algorithm.** Journal of Communication and Computer: David Explore, 2019. 1-8 p. v. 17. <https://doi.org/10.17265/1548-7709/2022.01.001>

YANG, Y; ERSKINE, P.D.; LENCHER, A.M.; MULLIGAN, D; ZHANG, S; WANG, Z. **Detecting the dynamics of vegetation disturbance and recovery in surface mining area via Landsat imagery and LandTrendr algorithm.** Journal of Cleaner Production: Elsevier, 2018. 353-362 p. v. 178. ISSN 0959-6526. <https://doi.org/10.1016/j.jclepro.2018.01.050>

WEATHER SPARK. **Clima e condições meteorológicas médias em São Félix do Xingu no ano todo.** <Disponível em: <https://pt.weatherspark.com/y/29780/Clima-caracter%C3%ADstico-em-S%C3%A3o-F%C3%A9lix-do-Xingu-Par%C3%A1-Brasil-durante-o-ano>>. Acesso em: 19 set 2024.

WORLANYO, A. S; JIANGFENG, L. **Evaluating the environmental and economic impact of mining for post-mined land restoration and land-use: A review.** Journal of Environmental Management: Elsevier, 2021. v. 279. ISSN 0301-4797. <https://doi.org/10.1016/j.jenvman.2020.111623>

ZHANG, S.. **Challenges in KNN Classification.** 10. ed. Transactions on Knowledge and Data Engineering: IEEE, 2021. 4663-4675 p. v. 34. ISSN 1558-2191. <https://doi.org/10.1109/TKDE.2021.3049250>

ZHAO, D.; HUANG, L.; LI, J.; QI, J. **A comparative analysis of broadband and narrowband derived vegetation indices in predicting LAI and CCD of a cotton canopy.** Journal of Photogrammetry and Remote Sensing: Elsevier. v.62, p.25-33, 2007. <https://doi.org/10.1016/j.isprsjprs.2007.01.003>

ZHENG, G; MOSKAL, L. M. **Retrieving Leaf Area Index (LAI) Using Remote Sensing: Theories, Methods and Sensors.** 4. ed. Sensors: Mdpi, 2009. 2719-2745 p. v. 9. ISSN 1424-8220. <https://doi.org/10.3390/s90402719>