



USO DO GOOGLE EARTH ENGINE PARA DETEÇÃO DE POTENCIAIS DESMATAMENTOS ? LÁBREA/AM

KIMBERLLY FERREIRA PINTO

novembro de 2023



USO DO GOOGLE EARTH ENGINE PARA DETEÇÃO DE POTENCIAIS DESMATAMENTOS LÁBREA/AM

KIMBERLLY FERREIRA PINTO

Outubro de 2023

**USO DO *GOOGLE EARTH ENGINE* PARA DETEÇÃO DE POTENCIAIS
DESMATAÇÕES – LÁBREA/AM**

KIMBERLLY FERREIRA PINTO

Dissertação submetida para satisfação parcial dos requisitos do grau de

MESTRE EM ENGENHARIA CIVIL – GESTÃO DA CONSTRUÇÃO

Orientador: Eng. Maria do Rosário Santos Oliveira (ISEP)

Co-Orientador: Prof. Dr. Sergio Vicente Denser Pamboukian (Universidade Presbiteriana Mackenzie)

OUTUBRO DE 2023

Eu, Kimberlly Ferreira Pinto, estudante nº 1210360, do Mestrado em Engenharia Civil do Instituto Superior de Engenharia do Porto, declaro que não fiz plágio nem auto-plágio, pelo que o trabalho intitulado “Uso do *Google Earth Engine* para deteção de potenciais desmatações – Lábrea/AM” é original e da minha autoria, não tendo sido usado previamente para qualquer outro fim. Mais declaro que todas as fontes usadas estão citadas, no texto e na bibliografia final, segundo as regras de referenciação adotadas na instituição.

Porto e ISEP, 2023/10/22

Kimberlly F. Pinto

ÍNDICE GERAL

Índice Geral	v
Resumo	vii
Abstract	ix
Agradecimentos	xi
Índice de Texto	xiii
Índice de Figuras	xv
Índice de Tabelas.....	xvii
Abreviaturas.....	xix
Capítulo 1 Introdução	20
Capítulo 2 Revisão Bibliográfica	39
Capítulo 3 Metodologia	45
Capítulo 4 Resultados e Discussões	54
Capítulo 5 Considerações Finais	62
Referências Bibliográficas	65
Apêndice A	73
Apêndice B	75

RESUMO

O geoprocessamento é uma ferramenta essencial na Engenharia Civil, desempenhando um papel crucial na coleta, análise e interpretação de dados geoespaciais para o planejamento e execução de projetos. O uso dessa ferramenta também pode contribuir para estudos de desmatamento. O ano de 2022 teve um aumento significativo de 22,3% no número de alertas de desmatamento no Brasil em comparação com o ano anterior, resultando na identificação, validação e refinados de um total de 76.193 alertas. Este aumento alarmante destaca a urgência de um monitoramento ambiental eficaz e proactivo para promover ações concretas no controle da desmatamento, preservando os recursos naturais preciosos do país. Nesse contexto, o presente trabalho almeja demonstrar o potencial do *Google Earth Engine* como uma ferramenta fundamental para a coleta e análise de dados relacionados a desmatamento. Foi desenvolvido um *script*, por meio da plataforma do *Google Earth Engine*, com o intuito de extrair imagens provenientes do satélite Landsat 8 e realizar a classificação supervisionada de áreas suscetíveis a desmatamento na cidade de Lábrea, situada no estado do Amazonas. Os resultados derivados da classificação supervisionada foram submetidos a uma análise e comparados com os dados provenientes da plataforma Mapbiomas Alertas. Essa abordagem permitiu constatar que o *Google Earth Engine*, empregando em grande parte algoritmos de Inteligência Artificial, oferece resultados confiáveis, mesmo mostrando diferenças em sua comparação com o Mapbiomas Alertas.

Palavras-chave: *Google Earth Engine*; Desmatamento; Classificação Supervisionada

ABSTRACT

Geoprocessing is an essential tool in Civil Engineering, playing a crucial role in the collection, analysis and interpretation of geospatial data for project planning and execution. The use of this tool can also contribute to deforestation studies. The year 2022 had a significant 22.3% increase in the number of deforestation alerts in Brazil compared to the previous year, resulting in the identification, validation, and refined of a total of 76,193 alerts. This alarming increase highlights the urgency of effective and proactive environmental monitoring to promote concrete actions to control deforestation, preserving the country's precious natural resources. In this context, this work aims to demonstrate the potential of Google Earth Engine as a fundamental tool for collecting and analyzing data related to deforestation. A script was developed, using the Google Earth Engine platform, with the aim of extracting images from the Landsat 8 satellite and carrying out the supervised classification of areas susceptible to deforestation in the city of Lábrea, located in the state of Amazonas. The results derived from the supervised classification were subjected to an analysis and compared with data from the Mapbiomas Alertas platform. This approach allowed to verify that Google Earth Engine, largely employing Artificial Intelligence algorithms, offers reliable results, even showing differences in its comparison with Mapbiomas Alertas.

Keywords: Google Earth Engine; Deforestation; Supervised Classification

AGRADECIMENTOS

Em primeiro lugar, desejo expressar minha mais profunda gratidão a Deus por me conceder esta oportunidade singular e por me capacitar a cada passo do caminho. Agradeço à minha mãe, Elizabete Pinto, que sempre me ensinou a perseverar, que dedicou-se com todos os seus recursos para me auxiliar nessa jornada e que é um exemplo diário em minha vida. A minha irmã, Kemelly Dantas, merece meu sincero agradecimento pelo apoio e compreensão, mesmo estando distante. Ao meu pai, Aldemir Pinto (*In memoriam*), que desempenhou um papel fundamental na minha formação e crescimento, ajudando-me a chegar até o ponto em que me encontro hoje, quero expressar minha eterna gratidão por ser a minha força, mesmo estando fisicamente ausente.

Não posso deixar de agradecer à Universidade Presbiteriana Mackenzie e ao Instituto Superior de Engenharia do Porto por me proporcionarem a oportunidade de explorar meus estudos por meio da Dupla Titulação. Aos meus orientadores, Engenheira Rosário Oliveira e Professor Sérgio Pamboukian, devo um agradecimento especial por sua inestimável ajuda na elaboração deste documento.

Agradeço ao Théo Reis, que esteve ao meu lado desde o início desse sonho, e ao Rodrigo Tamura, Regina Lima, Manuella Silva, Guilherme Kepler e Luiza Assunção, cujas contribuições diretas e indiretas foram fundamentais nessa trajetória.

Gostaria de expressar minha gratidão ao Gabriel Dantas, que, mesmo de forma indireta, ofereceu forte apoio ao longo de todo o percurso dos estudos e na elaboração deste trabalho.

Por fim, quero agradecer a Giovanna Faria e a todos os meus amigos, que compreenderam a necessidade do meu isolamento ao longo de meses e continuaram a oferecer seu apoio inabalável.

Minhas palavras de agradecimento não podem capturar completamente a profundidade da minha gratidão, mas meu muito obrigada a todos por estarem presentes e por tornarem essa jornada uma verdadeira dádiva.

ÍNDICE DE TEXTO

Capítulo 1	Introdução	20
1.1	Contextualização do geoprocessamento	20
1.2	Considerações Iniciais	21
1.3	Objetivo	23
1.4	Referencial Teórico	23
1.4.1	SENSORIZAÇÃO REMOTA, SATÉLITES E BANDAS	23
1.4.2	COMPOSIÇÃO DE BANDAS E CLASSIFICAÇÃO SUPERVISIONADA	26
1.4.3	ALGORITMOS DE CLASSIFICAÇÃO SUPERVISIONADA	29
1.4.4	GOOGLE EARTH ENGINE (GEE)	35
Capítulo 2	Revisão Bibliográfica	39
2.1	Ferramentas para detecção de desmatamento	39
2.2	Aplicação da classificação supervisionada para detecção de desmatamento	41
Capítulo 3	Metodologia	45
3.1	Município do estudo de caso	45
3.2	Desenvolvimento no <i>google earth engine code editor</i>	46
3.3	Obtenção dos dados para comparação no Mapbiomas	52
Capítulo 4	Resultados e Discussões	54
Capítulo 5	Considerações Finais	62
5.1	Conclusões	62
5.2	Desenvolvimentos futuros	63

ÍNDICE DE FIGURAS

Figura 1.1 - Mapa dos alertas de desmatamento no Brasil em 2022.....	22
Figura 1.2 - Mapa da Amazônia Legal	22
Figura 1.3 - Coleta de dados por meio do Sensorização Remota orbital	24
Figura 1.4 - Representação do espectro eletromagnético	24
Figura 1.5 - Energia refletida por objetos na superfície terrestre (assinatura espectral)	26
Figura 1.6 - Combinação de bandas	27
Figura 1.7 - Comparação da Classificação Supervisionada com o Google Satellite.....	29
Figura 1.8 - Divisão do nó raiz	30
Figura 1.9 - Classificação CART	31
Figura 1.10 - Fases de treinamento e classificação do classificador Random Forest	32
Figura 1.11 - Modelo de conjunto de árvore	33
Figura 1.12 - Comparação entre os classificadores RF (A), GT (B) e CART (C)	34
Figura 1.13 - Google Earth Engine Explorer	36
Figura 1.14 - Página do GEE com indicação das janelas e interfaces descritos acima	38
Figura 1.15 - Google Earth Engine Timelapse.....	38
Figura 2.1 - Exemplo de levantamentos feitos pela plataforma Mapbiomas	40
Figura 2.2 - Exemplo de levantamentos feitos pela plataforma Mapbiomas Alerta.....	41
Figura 2.3 - Composição colorida RGB das bandas 6, 5 e 4 do satélite Landsat-8	43

ÍNDICE DE FIGURAS

Figura 2.4 - Fluxograma das etapas metodológicas	43
Figura 3.1 - Imagem do .kml no Google Earth, com a cidade de Lábrea circulada em preto.....	46
Figura 3.2 - Catálogo de dados do Landsat 8, disponibilizado pela plataforma do GEE.....	47
Figura 3.3 - Filtro para a seleção das imagens do Landsat 8, julho/2022.....	47
Figura 3.4 - Pins para classificação supervisionada, julho/2022	48
Figura 3.5 - Comando para mesclar as classes selecionadas.....	49
Figura 3.6 - Treinamento para localização das amostras/pins	49
Figura 3.7 - Treinamento para identificação das assinaturas espectrais	49
Figura 3.8 - Execução da classificação supervisionada para todas as imagens selecionadas.....	50
Figura 3.9 - Cálculo de pixel por classe e transformação para hectares	50
Figura 3.10 - Exportação das imagens classificadas para o <i>Google Drive</i>	51
Figura 3.11 - Filtro para a seleção das imagens do Landsat 8, junho/2022.	51
Figura 3.12 - Pins para classificação supervisionada, junho/2022.	52
Figura 3.13 - Página principal da plataforma do Mapbiomas Alertas	53
Figura 3.14 - Quantidade de áreas desmatadas em Lábrea/AM ao longo do ano de 2022	53
Figura 4.1 - Demonstração da aplicação do “CLOUD_COVER_5%”	54
Figura 4.2 - Imagens, das coordenadas de Lábrea/AM, do Satélite Landsat 8 para julho de 2022.....	55
Figura 4.3 - Classificação supervisionada aplicada no GEE, julho/2022	56
Figura 4.4 - Demonstração das áreas com significativa presença de nuvens, julho/2022	56
Figura 4.5 - Comparação das áreas de solo exposto e desmatadas da classificação supervisionada	57
Figura 4.6 - Classificação supervisionada aplicada no GEE, junho/2022	59
Figura 4.7 - Demonstração das áreas com significativa presença de nuvens, junho/2022.....	59

ÍNDICE DE TABELAS

Tabela 1.1 - Especificações das bandas espectrais dos sensores OLI e TIRS do Landsat-8 25

Tabela 4.1 - Áreas e percentagens das classes da classificação supervisionada feita pelo GEE, julho 58

Tabela 4.2 - Áreas e percentagens das classes da classificação supervisionada feita pelo GEE de junho. 60

ABREVIATURAS

API - *Application Programming Interface*

CAR – Cadastro Ambiental Rural

DETER - Detecção do Desmatamento em Tempo quase Real

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária

GEE – *Google Earth Engine*

GLAD - *Global Analysis and Discovery*

IBGE - Instituto Brasileiro de Geografia e Estatística

INPE – Instituto Nacional de Pesquisas Espaciais

MODIS - *Moderate-Resolution Imaging Spectroradiometer*

NIR - *Near InfraRed* (Infravermelho próximo)

OLI - *Operational Land Imager*

PRODES - Projeto de Monitoramento do Desmatamento na Amazônia Brasileira por Satélites

QGIS – *Quantum Geographic Information System*

REM - Radiação eletromagnética

SAD - Sistema de alerta mensal

SIAD - Sistema Integrado de Alerta de Desmatamento

SIG ou GIS - Sistema de Informação Geográfica (*Geographic Information System*)

SIGEF – Sistema de Gestão Fundiária

SIPAMSar - Sistema Integrado de Alerta de Desmatamento (SIAD), Sistema Integrado de Alerta de Desmatamento

SIRAD-X - Sistema por Indicação por Radar de Desmatamento

TIRS - *Thermal Infrared Sensor*

Capítulo 1

INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO DO GEOPROCESSAMENTO

O geoprocessamento é uma ferramenta essencial na Engenharia Civil, desempenhando um papel crucial na coleta, análise e interpretação de dados geoespaciais para o planejamento e execução de projetos. Essa disciplina, que combina informações geográficas com tecnologia da informação, tem se tornado cada vez mais indispensável na busca por soluções eficientes e sustentáveis para os desafios enfrentados pelos profissionais da área (CISER,2023).

A capacidade de visualizar dados geográficos de forma integrada proporciona aos engenheiros civis uma compreensão mais abrangente e detalhada do ambiente em que estão trabalhando. O uso de sistemas de informação geográfica (SIG) permite a análise espacial, auxiliando na identificação de padrões e na tomada de decisões informadas. Isso é particularmente relevante em projetos de infraestrutura, onde a localização e a topografia desempenham um papel crucial (CISER, 2023; LIMA, 2022).

O planejamento urbano é uma área em que o geoprocessamento se destaca. Ao considerar fatores como zoneamento, acessibilidade e distribuição populacional, os engenheiros civis podem desenvolver projetos que promovam o crescimento sustentável das cidades. A análise espacial também é valiosa na identificação de áreas de risco, como regiões propensas a deslizamentos de terra, enchentes ou outros desastres naturais. Essa informação é vital para o desenvolvimento de estratégias de prevenção e mitigação de riscos (FARINA, 2006; FERREIRA, 2011).

Na gestão de recursos hídricos, o geoprocessamento desempenha um papel crucial na avaliação e monitoramento de bacias hidrográficas. A capacidade de mapear a distribuição da água, analisar a qualidade e prever mudanças sazonais permite um gerenciamento mais eficaz dos recursos hídricos. Isso é fundamental em um contexto de mudanças climáticas, em que a escassez de água e eventos climáticos extremos se tornam mais frequentes (NÚCLEO DE HIDROMETRIA, 2023; AMARAL, 2017).

Além disso, o geoprocessamento é uma ferramenta valiosa na construção e manutenção de rodovias, ferrovias e outras infraestruturas de transporte. A análise de dados geoespaciais facilita o projeto de rotas eficientes, considerando fatores como topografia, tráfego e impacto ambiental. A manutenção preditiva,

baseada em dados geográficos, também contribui para prolongar a vida útil das infraestruturas, reduzindo custos e minimizando interrupções (GRANDEZZI *et al.*, 2016).

1.2 CONSIDERAÇÕES INICIAIS

Analisando os meios de utilização de ferramentas de geoprocessamento, este trabalho tem o intuito de utilizar desta ferramenta para um estudo de caso de desmatamento. A desmatamento é associada geralmente à supressão parcial ou completa da vegetação florestal nativa de uma determinada região. A Mata Atlântica, Mata Araucária, Caatinga, o Cerrado, o Pantanal e a Floresta Amazônica são os seis tipos de vegetação existentes no Brasil, (podendo ter outras divisões e denominações) e a desmatamento destas florestas é algo que acontece desde a colonização implementada pelos portugueses (PENA, 2022).

Cerca de 60% da área da Floresta Amazônica se encontra no Brasil, distribuída nos estados do Amazonas, Acre, Amapá, Rondônia, Pará e Roraima, tendo neste espaço 38% de florestas densas, 36% de florestas não densas, 14% de vegetação aberta e 12% da área ocupada por vegetação secundária e atividades agrícolas. Atualmente a Floresta Amazônica é a que vem sofrendo mais com o crescimento da desmatamento, tendo como um dos principais motivos a expansão das fronteiras agrícolas do país (LEITE, 2022). Como indicado na Figura 1.1, a “Amazônia e Cerrado juntos representaram 90,1% da área desmatada do país. Quando somada à Caatinga, os três biomas responderam por 96,9% das perdas” (MAPBIOMAS, 2023, pg. 12).

Dentro do bioma da Floresta Amazônica, está a Amazônia Legal instituída pelo governo brasileiro em 1953, que corresponde a cerca de 59% do território brasileiro com uma área de 5.015.067,86 km². A Amazônia Legal engloba, além dos estados da área da Floresta Amazônica, mais três estados brasileiros, o Mato Grosso, Tocantins e parte do território do Maranhão, como mostrado na Figura 1.2 (Desafios do desenvolvimento, 2008; INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE), 2021).

A desmatamento é algo que vem crescendo ao longo dos anos e em 2022 foram identificados, validados e refinados 76.193 alertas de desmatamento no Brasil, totalizando 2.057.251 ha, tendo um aumento de 22,3% relativo ao ano de 2021. Sendo a agropecuária o principal vetor de desmatamento, respondendo por 95,7% de todas as alertas validadas, os estados brasileiros que tiveram o maior número de áreas desmatadas em 2022 encontram-se na Amazônia Legal, com 456.702 ha no Pará e 274.184 ha no Amazonas (MAPBIOMAS, 2023). Se a desmatamento continuar no ritmo de crescimento que está atualmente, corre-se o risco de 40% da Amazônia Legal estar desflorestada até 2050 (SANTOS, 2021).




Figura 1.1 - Mapa dos alertas de desmatamento no Brasil em 2022 (MAPBIOMAS, 2023).

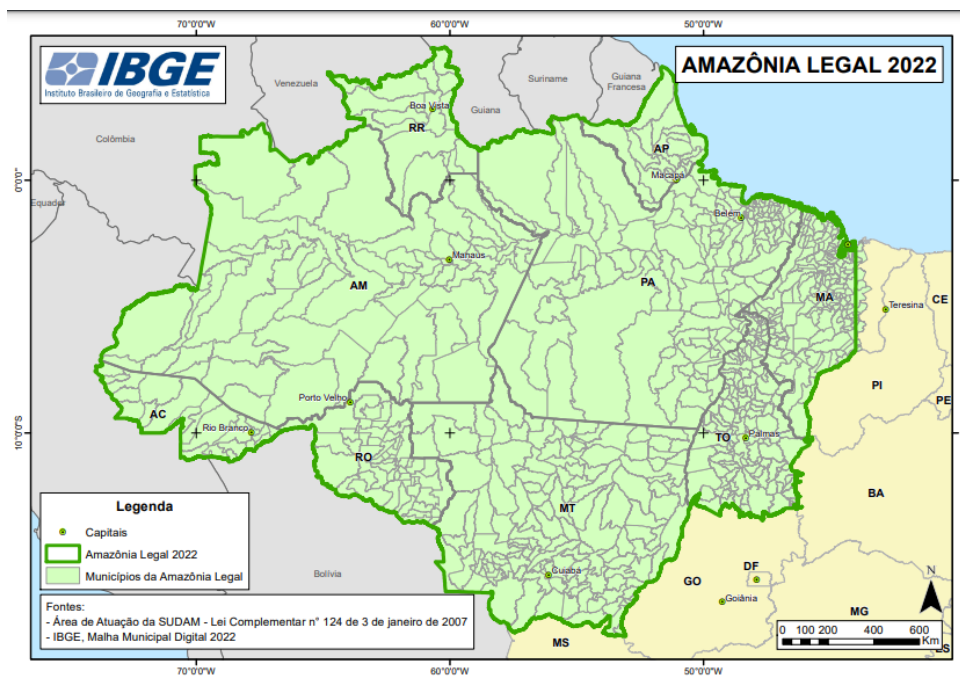


Figura 1.2 - Mapa da Amazônia Legal (INPE, 2023).

Segundo o MapBiomas (2022), o monitoramento é peça central para que sejam tomadas ações para o controle da desmatamento e o Brasil possui pelo menos 11 sistemas que geram dados para o monitoramento da desmatamento (MAPBIOMAS, 2022). DETER, PRODES, Sistema que Utiliza Satélites Landsat (GLAD), JJ-Fast, MapBiomas Alerta, Sistema de alerta mensal (SAD), Sistema Integrado de Alerta de Desmatamento (SIAD), Sistema Integrado de Alerta de Desmatamento (SIPAMSar), Sistema por Indicação por Radar de Desmatamento (SIRAD-X) e PrevisIA, são alguns desses sistemas de monitoramento de desmatamento existentes no Brasil (BOURSCHEIT, 2022).

Em 1996, a Medida Provisória 1.511 do Código Florestal foi editada, ampliando as restrições das áreas da reserva legal (áreas com vegetação dentro das propriedades que não podem ser desmatadas) para 80% em florestas e reduzindo para 35% no Cerrado dentro da Amazônia Legal. Porém em 2021 apenas 1,34% dos alertas obtidos, ou seja, 936 alertas, atenderam as regras de legalidade da Reserva Legal, gerando assim um nível de ilegalidade de desmatamento no país de cerca de 98% (LEI, 2017; MAPBIOMAS, 2022).

1.3 OBJETIVO

Em prol de contribuir no processo de monitoramento de desmatamentos, este trabalho tem como objetivo um estudo de caso da desmatamento na cidade de Lábrea no Amazonas, com o uso do *Google Earth Engine* para fazer o levantamento de dados.

Neste estudo de caso será feita a verificação, através da classificação supervisionada, dos potenciais locais com desmatamento na cidade em estudo, para o mês de julho de 2022. E será feita a comparação com os dados de desmatamento disponibilizados na plataforma e no relatório do Mapbiomas.

1.4 REFERENCIAL TEÓRICO

Nesta seção serão explicados termos e conceitos necessários para o melhor entendimento da proposta de estudo descrita neste trabalho.

1.4.1 SENSORIZAÇÃO REMOTA, SATÉLITES E BANDAS

De acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE) (2022), Vale *et al.* (2018) e Jensen (2009), a sensorização remota é uma tecnologia para aquisição de informações de alguma propriedade de um objeto, fenômeno ou área, sem ter contato físico com o que está sendo analisado. Sendo assim uma ferramenta importante para o conhecimento da superfície terrestre e para medir e monitorar atividades humanas na Terra.

As informações são obtidas através de radiação eletromagnética (REM), geradas por fontes passivas ou ativas, que em junção com sensores acoplados em aeronaves ou satélites coletam e registam a reflexão gerada pelo objeto em estudo (Figura 1.3). Esses sensores permitem que sejam obtidas informações sobre diferentes aspectos da superfície terrestre, como a cobertura vegetal, a topografia e a umidade do solo (VENTURIERI, 2007; RUDORFF, 2022; PESSOA *et al.*, 2019; STEFFEN, 2022).




Figura 1.3 - Coleta de dados por meio da Sensorização Remota orbital (Florenzano, 2011).

A frequência contínua dessa radiação é representada pelo espectro magnético, que são bandas com diferentes comprimentos de onda que abrangem espectros visíveis e invisíveis ao olho humano (ver Figura 1.4). O comprimento visível é dividido em três faixas, sendo elas azul, verde e vermelha. Entre outras bandas também notáveis, mas fora do comprimento visível, estão as bandas de infravermelho, ultravioleta e raios X. permitindo que sejam obtidas informações sobre diferentes aspectos da superfície terrestre, como a cobertura vegetal, a topografia e a umidade do solo. (VENTURIERI, 2007; RUDORFF, 2022; PESSOA *et al.*, 2019; STEFFEN, 2022).




Figura 1.4 - Representação do espectro eletromagnético (Venturieri, 2007).

A sensorização remota é amplamente utilizado em diversas áreas, como agricultura, geologia, cartografia, meteorologia e planejamento urbano. Na agricultura, por exemplo, ele é utilizado para monitorar o crescimento das plantas, identificar áreas com deficiência de nutrientes e detetar pragas e doenças. Na geologia, ele é utilizado para mapear a superfície terrestre, identificar áreas com potencial mineral e estudar a dinâmica das placas tectônicas. Na cartografia, ele é utilizado para produzir mapas precisos e atualizados. Na meteorologia, ele é utilizado para prever o tempo e monitorar eventos climáticos extremos. E no planejamento urbano, ele é utilizado para monitorar o crescimento das cidades, identificar áreas com risco de deslizamentos de terra e planejar o uso do solo.

Entre as tecnologias que podem ser utilizadas para a sensorização remota, estão os sensores acoplados aos satélites artificiais que se encontram em órbita hoje em dia. Essa tecnologia apresenta uma vantagem ao fazer a sensorização remota, pois com ela é possível atuar no espectro visível, podendo assim trabalhar com imagens coloridas (RUDORFF 2022; PESSOA *et al.*, 2019).

O Landsat-8 é um modelo de satélite artificial que possui dois sensores, o *Operational Land Imager* (OLI) e o *Thermal Infrared Sensor* (TIRS) e onze bandas espectrais (Tabela 1.1). As bandas 4, 3 e 2 são as bandas *Red, Green, Blue* (RGB), que juntas fazem a combinação das cores verdadeiras (KOGUT, 2022). Este satélite faz o mapeamento de uma região a cada 16 dias, sendo esse seu tempo de revisita (EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA, 2022).

Tabela 1.1 - Especificações das bandas espectrais dos sensores OLI e TIRS do Landsat-8 (Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) – adaptado, 2022).

Sensor	Bandas Espectrais	Resolução Espectral	Resolução Espacial
OLI (Operational Land Imager)	(B1) COSTAL	0.433 - 0.453 μm	30 m
	(B2) AZUL	0.450 - 0.515 μm	
	(B3) VERDE	0.525 - 0.600 μm	
	(B4) VERMELHO	0.630 - 0.680 μm	
	(B5) INFRAVERMELHO PRÓXIMO	0.845 - 0.885 μm	
	(B6) INFRA. MÉDIO	1.560 - 1.660 μm	
	(B7) INFRA. MÉDIO	2.100 - 2.300 μm	
	(B8) PANCROMÁTICO	0.500 - 0.680 μm	15 m
	(B9) Cirrus	1.360 - 1.390 μm	30m
TIRS (Thermal Infrared Sensor)	(B10) LWIR - 1	10.30 - 11.30 μm	100m
	(B11) LWIR - 2	11.50 - 12.50 μm	

1.4.2 COMPOSIÇÃO DE BANDAS E CLASSIFICAÇÃO SUPERVISIONADA

“Os materiais superficiais naturais como a vegetação, a água e o solo descoberto, refletem diferentes proporções de energia nas porções do espectro eletromagnético do azul, do verde, do vermelho e do infravermelho próximo” (JENSEN, 2009, pg. 134) e com a quantidade de reflexão em cada um desses materiais em diferentes comprimentos de ondas, é possível esboçar assinaturas espectrais (JENSEN, 2009).

Para a vegetação, a absorção de energia no espectro vermelho é de 91% por conta de seu processo de fotossíntese, por este motivo há pouca energia refletida no comprimento do espectro vermelho. Porém a faixa espectral do infravermelho próximo (NIR) tem um comportamento oposto, pois a estrutura celular das folhas reflete muita energia neste comprimento de onda, tendo uma reflexão de aproximadamente 28% da energia no comprimento de onda em vegetação saudável (ver Figura 1.5) (JENSEN, 2009; RUDORFF, 2022).




Figura 1.5 - Energia refletida por objetos na superfície terrestre (assinatura espectral) (Florenzano, 2011).

É possível selecionar bandas com características específicas para criar uma imagem mais fácil de analisar, de acordo com as necessidades de cada estudo. Essa seleção é denominada combinação de bandas e permite que o espectro não visível ao olho humano seja representado nas cores RGB, como visto na Figura 1.5. A combinação pode ser feita de várias maneiras como, por exemplo, em locais com alguma existência de vegetação é possível ter uma visualização mais nítida de florestas/vegetação se utilizar da combinação das bandas de cor azul, com a banda 2, a cor verde com a banda 3 e a cor vermelha do infravermelho próximo (NIR, do inglês *Near InfraRed*) com a banda 5. O uso da banda NIR permite uma visualização mais nítida da vegetação, pois a reflexão das plantas no intervalo do infravermelho próximo é alta (KOGUT, 2022; RUDORFF, 2022; EUROPEAN SPACE AGENCY, 2023). Por este motivo, na Figura 1.6 é possível visualizar os locais com vegetação na coloração vermelha.




Figura 1.6 - Combinação de bandas (Kogut, 2022).

“A classificação de imagens digitais consiste em identificar nas mesmas, os diferentes alvos, fenômenos ou feições que apresentam padrões espectrais similares e atribuí-los a uma determinada classe ou tema” (VENTURIERI, 2007, pg.78).

Existem dois tipos para a abordagem de classificação multiespectral. A classificação supervisionada e a classificação não-supervisionada, sendo a classificação supervisionada um procedimento bastante utilizado para fazer análises quantitativas de imagens obtidas por sensorização remota, representando tipos específicos de cobertura terrestre (CRÓSTA, 2002; SANTOS *et al.*, 2021).

A classificação supervisionada é uma técnica de processamento de imagens que permite a identificação de objetos em uma imagem com base em um conjunto de amostras previamente rotuladas. Essas amostras são usadas para treinar um algoritmo de aprendizado de máquina que, posteriormente, é capaz de classificar novos objetos em uma imagem (FILHO, 2005; GOMES, 2007).

Existem diversos métodos de classificação supervisionada, cada um com suas próprias características e aplicações. Entre os métodos de classificação supervisionada mais utilizados, pode-se citar árvores de decisão, método que utiliza uma estrutura de árvore para representar as decisões que levam à classificação dos objetos, como o método *Classification and Regression Trees* (CART) que utiliza de uma estrutura de árvore, o *Random Forest* (RF) que utiliza um conjunto de árvores de decisão para realizar a classificação e o *Gradient Tree Boost* (GTB) que é um método que utiliza um conjunto de árvores de decisão, mas ao contrário do RF, ele utiliza uma abordagem de *boosting* para melhorar a precisão da classificação (item 1.4.3) (REBOUÇAS, 2009; CECHIM, 2023).

Outro tipo de método é o da regressão logística, método que utiliza uma função logística para modelar a relação entre as variáveis independentes e a variável dependente, o método de máquinas de vetores de suporte, que utiliza um hiperplano para separar as classes de objetos, redes neurais, método que utiliza

uma rede de neurônios artificiais para modelar a relação entre as variáveis independentes e a variável dependente e k-vizinhos mais próximos, método que classifica um objeto com base nas classes dos “k” objetos mais próximos a ele. Cada método, independente da técnica utilizada, procura encontrar o melhor relacionamento possível entre as variáveis atributo/independentes (X) e a variável alvo/dependente (Y) (REBOUÇAS, 2009 ; REMIGIO, 2020).

A classificação supervisionada é amplamente utilizada em áreas como a cartografia, a agricultura, a ecologia, a geologia e a engenharia civil. Na cartografia, por exemplo, a classificação supervisionada é usada para a criação de mapas temáticos, que representam a distribuição espacial de diferentes tipos de cobertura do solo, como florestas, pastagens e áreas urbanas. Na agricultura, a classificação supervisionada é usada para a identificação de culturas e para o monitoramento do crescimento das plantas. Na ecologia, a classificação supervisionada é usada para a identificação de habitats e para o monitoramento de espécies animais. Na geologia, a classificação supervisionada é usada para a identificação de diferentes tipos de rochas e minerais (FILHO, 2005; MAYA, 2015).

Na engenharia civil, por sua vez, a classificação supervisionada é usada para a análise de imagens de satélite e aerofotogramétricas, permitindo a identificação de áreas de risco, como encostas instáveis, e a delimitação de áreas de preservação ambiental. A classificação supervisionada também é utilizada para a identificação de áreas urbanas e rurais, para o planejamento urbano e para a gestão de recursos hídricos (AERO ENGENHARIA, 2023).

A classificação supervisionada é um processo que envolve várias etapas. A primeira etapa é a seleção de amostras de treinamento, que são áreas da imagem que representam as diferentes classes de objetos que se deseja identificar.

Segundo Crósta (2002), para efetuar a classificação supervisionada deve-se ter um prévio conhecimento da área que está sendo analisada para que esta possa ser utilizada como padrão de comparação para formação de classes.

Essa formação de classes, é o agrupamento de *pixels* com reflectância espectral parecida, que por sua vez é a proporção entre o fluxo de radiação eletromagnética incidente numa superfície (SANTOS *et al.*, 2010). Alguns exemplos de classes são: solo exposto, vegetação, pastagem, água e área urbana (CENTENO, 2022).

A segunda etapa é a extração de características dessas amostras, que são usadas para treinar o algoritmo de aprendizado de máquina. A terceira etapa é a classificação propriamente dita, que envolve a aplicação do algoritmo treinado para identificar os objetos na imagem.

Portanto, para realizar a classificação supervisionada é necessário selecionar amostras que sejam representativas de cada classe e determinar as assinaturas espectrais de cada uma delas. Em seguida o

processamento da imagem é feito associando à cada *pixel* da imagem analisada a assinatura espectral que mais se assemelha a ele, gerando assim um resultado confiável (ver Figura 1.7) (OLIVEIRA *et al.*, 2014).

A classificação supervisionada é uma técnica poderosa que permite a identificação de objetos em imagens de forma rápida e precisa. No entanto, a qualidade da classificação depende da qualidade das amostras de treinamento e das características extraídas dessas amostras. Além disso, a classificação supervisionada é uma técnica que requer um alto grau de conhecimento especializado e experiência para ser aplicada corretamente (FILHO, 2005; MAYA, 2015).




Figura 1.7 - Comparação da Classificação Supervisionada com o Google Satellite (PINTO, 2023).

1.4.3 ALGORITMOS DE CLASSIFICAÇÃO SUPERVISIONADA

"Árvores de classificação são usadas quando para cada observação da amostra de aprendizagem sabemos a classe com antecedência" (TIMOFEEV, 2004, pg. 10). O algoritmo de *Classification and Regression Trees* (CART) é um método de aprendizado de máquina utilizado em problemas de classificação e regressão. O algoritmo CART é uma árvore de classificação que lida facilmente com dados que vem com algum tipo de ruído, ele isola os valores discrepantes em um nó diferente para não atingir os resultados. Especificamente, este algoritmo se destaca na classificação supervisionada, onde o objetivo é categorizar elementos em classes distintas com base em variáveis de entrada (TIMOFEEV, 2004).

O funcionamento do CART é bastante intuitivo e baseia-se na construção de uma árvore de decisão. Inicialmente, a árvore começa com um nó raiz que contém todo o conjunto de dados de treinamento. Em

seguida, o algoritmo procura a melhor forma de dividir esse conjunto em subgrupos mais homogêneos (Figura 1.8) (KUMAR, 2009).

A busca pela divisão ideal é realizada de maneira recursiva, considerando as variáveis disponíveis e selecionando aquela que melhor separa os dados em classes mais puras, ou seja, maximiza a homogeneidade dentro de cada subgrupo. Isso é feito por meio de critérios como Gini, entropia ou erro de classificação, onde o objetivo é minimizar a impureza dos grupos resultantes após a divisão (TIMOFEEV, 2004; KUMAR, 2009).

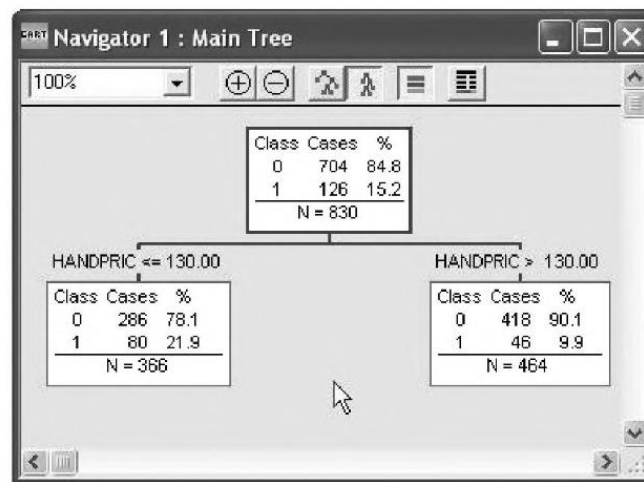


Figura 1.8 - Divisão do nó raiz (KUMAR, 2009).

À medida que a árvore cresce, ela se ramifica em nós que representam decisões baseadas nos valores das variáveis. Este processo continua até que certos critérios de parada sejam atingidos, como profundidade máxima da árvore ou número mínimo de observações em um nó.

Uma vez construída a árvore, ela pode ser utilizada para classificar novos dados, seguindo os caminhos estabelecidos pelos nós da árvore, onde cada nó representa uma condição sobre as variáveis de entrada. Os dados percorrem esses nós até alcançarem as folhas da árvore, que correspondem às classes de destino.

O CART é flexível e capaz de lidar com diferentes tipos de variáveis (categóricas e numéricas), sendo robusto em relação a dados ruidosos. Sua interpretabilidade é uma de suas vantagens, já que as decisões são representadas visualmente em uma estrutura hierárquica de árvore. No entanto, a construção da árvore pode levar a um ajuste excessivo aos dados de treinamento, o que pode ser mitigado por meio de técnicas como a poda da árvore (TIMOFEEV, 2004).

Uma das desvantagens do CART é que a havendo modificações nas amostras de aprendizagem, por mais insignificantes que sejam, podem causar mudanças radicais na árvore de decisão, fazendo com que a complexidade da árvore aumente ou desapareça e fazendo com que haja mudanças na divisão de variáveis e valores, como demonstrado por Cechim (2023) em seus resultados onde foi observado que houve confusões entre algumas classes selecionadas (Figura 1.9) (TIMOFEEV, 2004).

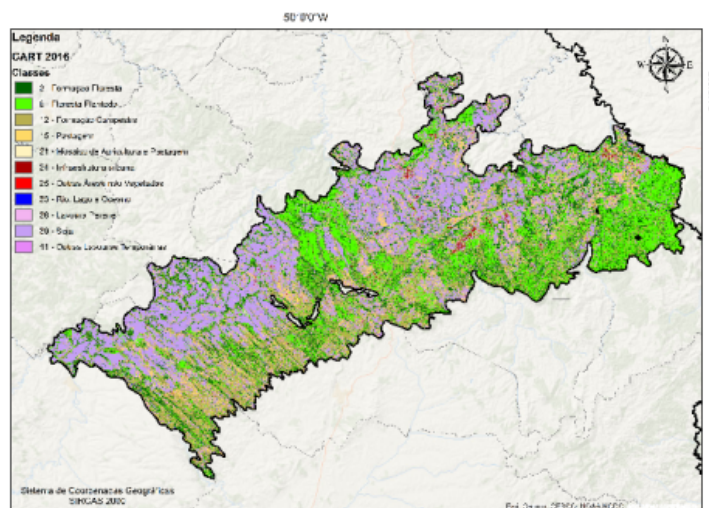


Figura 1.9 - Classificação CART (CECHIM, 2023).

O algoritmo *Random Forest* (RF) é uma poderosa técnica de aprendizado de máquina utilizada usualmente utilizado para estudos de associação genética. É adequado para aplicações genéticas, uma vez que é computacionalmente eficiente e modela bem os mecanismos causais genéticos. Ele opera por meio da construção de múltiplas árvores de decisão e a combinação de seus resultados para obter uma predição mais precisa e robusta (GOLDSTEIN *et al.*, 2011).

O funcionamento do *Random Forest* inicia com a criação de um conjunto de árvores de decisão, cada uma treinada com uma amostra aleatória do conjunto de dados de treinamento, e utilizando uma técnica conhecida como "*bootstrap*" para criar essas amostras. Essa abordagem de amostragem aleatória, chamada de *bagging* (*bootstrap aggregating*), aumenta a diversidade entre as árvores, reduzindo a tendência ao sobre ajuste (Figura 1.10) (BELGIU *et al.*, 2016).

Cada árvore no *Random Forest* é construída de forma similar ao algoritmo CART, porém, em cada nó da árvore, a divisão é realizada considerando apenas um subconjunto aleatório das variáveis disponíveis. Esse processo de seleção aleatória de variáveis em cada divisão é uma característica fundamental do *Random Forest*, garantindo que cada árvore seja treinada com diferentes conjuntos de atributos (Figura 1.10) (BELGIU *et al.*, 2016).

Quando se trata de fazer previsões com novos dados, o *Random Forest* combina as previsões de todas as árvores individuais para chegar a uma predição final. No caso de classificação, por exemplo, cada árvore

"vota" na classe a que a observação pertence, e a classe mais frequente entre todas as árvores é escolhida como a predição final.

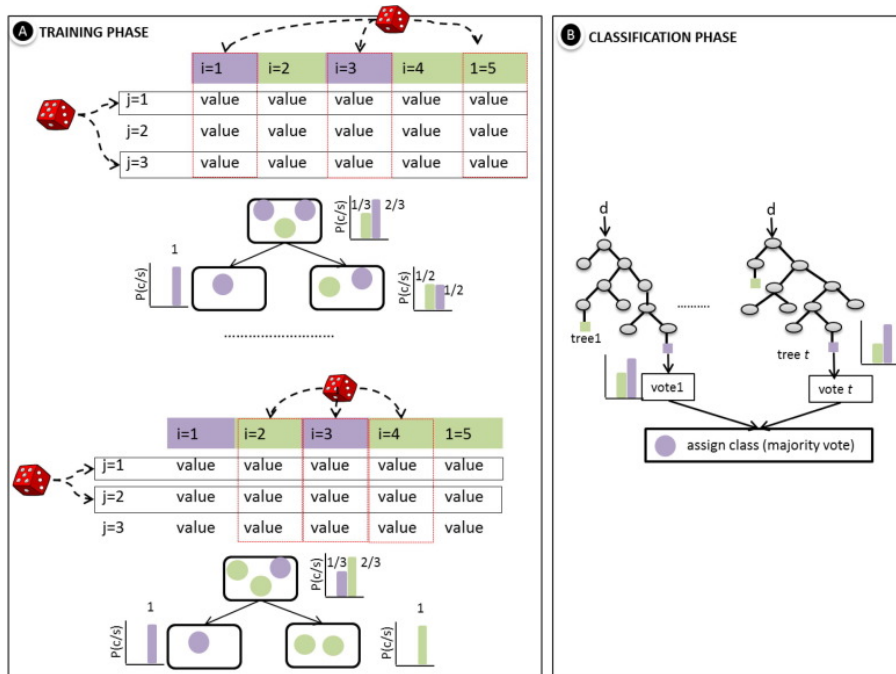


Figura 1.10 - Fases de treinamento e classificação do classificador Random Forest: i = amostras, j = variáveis, p = probabilidade, c = classe, s = dados, t = número de árvores, d = novos dados a serem classificados e valor = os diferentes valores que a variável j pode ter (BELGIU *et al.*, 2016).

A força do *Random Forest* reside na sua capacidade de reduzir a variância e o sobre ajuste, enquanto mantém um bom desempenho preditivo. Ao criar múltiplas árvores independentes e combiná-las, o algoritmo tende a produzir modelos mais estáveis e robustos, menos sensíveis a pequenas variações nos dados de treinamento.

Além disso, o *Random Forest* permite a avaliação da importância relativa de cada variável na predição, o que auxilia na interpretabilidade do modelo. Sua versatilidade, eficácia e capacidade de lidar com uma grande quantidade de dados fazem do *Random Forest* uma escolha popular e poderosa em problemas de classificação supervisionada (BELGIU *et al.*, 2016).

Por sua vez, o algoritmo *Gradient Tree Boosting* (GTB) é uma técnica avançada de aprendizado de máquina com sucesso em muitas aplicações para problemas de classificação e regressão em diferentes campos, exceto em projetos estruturais. Ele opera através da construção sequencial de árvores de decisão, onde cada nova árvore é treinada para corrigir os erros residuais das árvores anteriores, resultando em um modelo altamente preciso (TRUONG *et al.*, 2020).

O funcionamento do GTB começa com a criação de uma árvore de decisão inicial, que faz uma previsão inicial com base nos dados de entrada. Em seguida, o algoritmo calcula os erros residuais entre as previsões iniciais e os valores reais do conjunto de treinamento. A árvore seguinte é então construída para corrigir esses erros residuais, focando nos casos onde o modelo inicial errou mais (Figura 1.11) (TRUONG *et al.*, 2020).




Figura 1.11 - Modelo de conjunto de árvore (TRUONG *et al.*, 2020).

Cada nova árvore é treinada de forma iterativa, adicionando-a ao conjunto existente e ajustando os pesos das previsões anteriores para se concentrar nas áreas onde o modelo está menos preciso. Isso é feito através da aplicação de um gradiente descendente, onde o algoritmo busca minimizar uma função de perda.

O *Gradient Tree Boosting* utiliza a técnica de *boosting* para melhorar a precisão do modelo, onde cada nova árvore tenta corrigir as deficiências das anteriores, resultando em uma combinação robusta de várias árvores de decisão mais simples (NAGANNA *et al.*, 2020).

Uma das vantagens do GTB é sua capacidade de lidar com dados de diferentes tipos (categóricos e numéricos) sem a necessidade de pré-processamento extensivo. Além disso, o algoritmo é robusto em relação ao sobre ajuste, graças ao seu processo de construção sequencial que foca em corrigir os erros anteriores. Entretanto, o *Gradient Tree Boosting* pode ser mais sensível a *outliers* e ruídos nos dados em comparação com outros métodos. Além disso, pode ser mais computacionalmente exigente devido ao seu processo iterativo. No geral, o *Gradient Tree Boosting* é reconhecido por sua eficácia em produzir modelos de alta precisão, sendo uma escolha poderosa para problemas de classificação e regressão em que a precisão é crucial (NAGANNA *et al.*, 2020).

Cechim (2023) ao comparar esses três algoritmos verificou que o CART apresentou uma confusão espectral em algumas classes escolhidas, enquanto o RF e o GTB apresentaram semelhança em seus resultados (Figura 1.12). E em seu estudo o RF apresentou o melhor dos três resultados.




Figura 1.12 - Comparação entre os classificadores RF (A), GT (B) e CART (C) (CECHIM, 2023).

O *Support Vector Machine* (SVM) é um poderoso algoritmo de aprendizado de máquina utilizado para várias aplicações que vão desde identificação de partículas e categorização de texto até detonação de motor, detecção, bioinformática, marketing de banco de dados e em problemas de classificação supervisionada. Sua abordagem é baseada na ideia de encontrar um hiperplano ótimo que separe os dados em diferentes classes, maximizando a margem entre essas classes (SHIHONG *et al.*, 2003; OSISANWO *et al.*, 2017).

O funcionamento do SVM começa com a representação dos dados em um espaço multidimensional, onde cada observação é mapeada como um ponto nesse espaço, e o objetivo é encontrar o melhor hiperplano que separe esses pontos em suas respectivas classes. Esse hiperplano é selecionado de forma a maximizar a distância entre os pontos mais próximos de cada classe, chamados de vetores de suporte (SHIHONG *et al.*, 2003).

No caso de um problema de classificação com duas classes, o hiperplano ótimo é uma linha que separa os pontos em dois grupos distintos no espaço multidimensional. Para problemas com mais de duas classes, o SVM utiliza estratégias como o *One-vs-All*, onde várias linhas são traçadas para separar cada classe das demais (SHIHONG *et al.*, 2003).

Uma característica fundamental do SVM é a utilização de funções de *kernel*, que permitem mapear os dados para espaços de dimensões mais elevadas. Isso permite lidar com dados que não são linearmente

separáveis no espaço original, transformando-os em um espaço onde a separação linear é possível (SHIHONG *et al.*, 2003).

Durante o treinamento, o SVM busca otimizar a margem entre os pontos das diferentes classes, enquanto minimiza a ocorrência de erros de classificação. Isso é feito através de técnicas de otimização matemática, como a maximização da margem e a minimização do erro (MOUNTRAKIS *et al.*, 2010).

Uma das vantagens do SVM é sua eficácia na classificação de conjuntos de dados complexos, mesmo quando os dados não são linearmente separáveis. Além disso, sua capacidade de lidar com alta dimensionalidade e sua resistência ao sobre ajuste o tornam uma escolha popular em muitos cenários.

No entanto, o desempenho do SVM pode ser afetado negativamente por conjuntos de dados muito grandes, pois o tempo de treinamento pode ser computacionalmente exigente. Além disso, a escolha adequada do tipo de *kernel* e de parâmetros é crucial para o bom desempenho do algoritmo (SHIHONG *et al.*, 2003).

1.4.4 GOOGLE EARTH ENGINE (GEE)

O *Google Earth Engine* é uma ferramenta computacional do *Google*, lançada em 2010, que emergiu como uma ferramenta transformadora no campo do geoprocessamento, oferecendo uma plataforma abrangente e acessível para pesquisadores e profissionais que buscam compreender e abordar desafios complexos em estudos geoespaciais. Contém um vasto catálogo de dados geoespaciais com vários *petabytes* de informações permitindo que os usuários explorem e realizem análises em escala global.

Nesses catálogos, encontra-se uma ampla variedade de conjuntos de dados geoespaciais de acesso público, abrangendo observações de sistemas de imagens aéreas e de satélite em diferentes faixas espectrais, variáveis ambientais e climáticas, informações sobre a cobertura da terra, dados topográficos e conjuntos de dados socioeconômicos. Isso não apenas simplifica a coleta de dados, mas também amplia o alcance dos estudos, permitindo *insights* em regiões remotas ou de difícil acesso.

O GEE é disponibilizado gratuitamente para fins não lucrativos a fim de oferecer para estudantes, cientistas e desenvolvedores dados de sensorização remota para entender e abordar questões relacionadas ao meio ambiente, recursos naturais, mudanças climáticas, entre outros. As ferramentas de geoprocessamento integradas no GEE adicionam uma camada de sofisticação às análises. Desde a filtragem espacial até a classificação de imagens e cálculos de índices espectrais, as possibilidades são vastas. Essa capacidade de realizar análises avançadas diretamente na plataforma economiza tempo e recursos, eliminando a necessidade de transferir grandes volumes de dados para processamento local (GOOGLE EARTH ENGINE, 2023; GORELICK, 2023; GORELICK, 2017).

CAPÍTULO 1

Com o uso dessa ferramenta, pode-se adquirir as imagens dos satélites Landsat -4, -5, -6, -7 e -8, MODIS e Sentinel -1, -2, -3 e -5P e pode-se aplicar algoritmos a essas imagens, filtrar e reduzir coleções, mapear um algoritmo dentro de uma coleção e fazer cálculos. O *Google Earth Engine* também fornece *Application Programming Interface* (API) que segundo UFPel (2020) são utilizados rotinas e padrões de programação para acesso a aplicativos de software ou plataformas baseadas na Web (GORELICK, 2023; GORELICK, 2017).

A plataforma permite a criação de séries temporais de dados, possibilitando a observação de padrões e tendências ao longo de períodos específicos. Assim como, também oferece uma variedade de algoritmos de classificação supervisionada, incluindo Classification and Regression Trees (CART) que foi utilizado neste trabalho, *Random Forest* (RF), *NaiveBayes* e SVM (GOOGLE EARTH ENGINE, 2023).

O GEE é composto por três plataformas, a primeira é o *Google Earth Engine Explorer* (ver Figura 1.13), plataforma de visualização de dados que permite aos usuários acessar todos os conjuntos de dados disponíveis no catálogo de dados do GEE. Ele é composto por um *Workspace* e pelo próprio catálogo de dados, onde é possível fazer pesquisas das informações necessárias para um estudo e importá-las para o *Workspace* a fim de gerenciar, visualizar os dados selecionados, fazer análises de mudanças temporais, adicionar camadas para agregar ao estudo e aplicar composições de cores, como o RGB (AMANI *et al.*, 2020; GOOGLE EARTH SOLIDÁRIO, 2023).

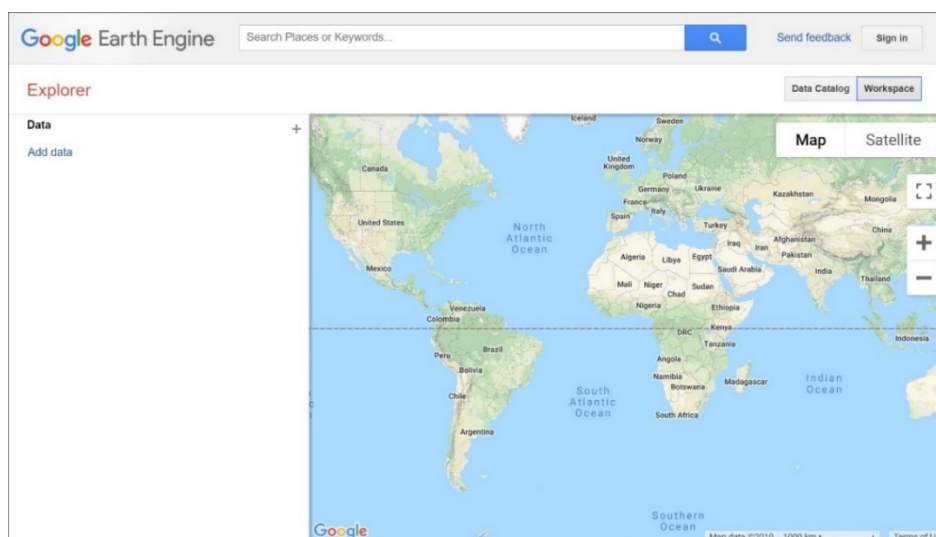


Figura 1.13 - Google Earth Engine Explorer (GOOGLE EARTH SOLIDÁRIO, 2023).

A segunda plataforma é o *Google Earth Engine Code Editor*, uma ferramenta que, em contraste com o GEE Explorer, é designada para processar uma quantidade substancialmente maior de informações, fazendo uso da linguagem de programação *JavaScript* como seu principal meio de operação, podendo ser acessada

pela página da Web (<https://code.earthengine.google.com>). Como ilustrado na Figura 1.14, esta plataforma apresenta uma divisão em diferentes componentes, cada um com funções específicas:

1. *Code editor*: Uma janela de programação que possibilita a criação de *scripts* personalizados para realizar operações específicas.
2. *Abas Script, Docs e Assets*: Esta seção oferece acesso a *scripts* preexistentes, contém informações essenciais sobre os comandos e funções disponíveis e permite o armazenamento de arquivos criados diretamente no servidor do *Google Earth Engine*, respetivamente.
3. *Abas Inspector, Console e Tasks*: A aba *Inspector* fornece informações detalhadas sobre as camadas do mapa, enquanto a *Console* exhibe resultados e informações produzidas durante a execução do código, com o uso da função "*print()*". A aba *Tasks* é dedicada à gestão e monitoramento das atividades a serem executadas, como, por exemplo, a exportação de imagens geradas.
4. *Visualização do mapa*: Essa janela apresenta uma visualização cartográfica que adota a projeção WGS-84 (EPSG: 3857) para representar os dados geográficos processados.
5. *Layers*: Nesta área, encontram-se opções para a manipulação e personalização da representação de cada camada adicionada ao mapa. Isso permite uma flexibilidade significativa na exibição dos dados.
6. *Botões para criação de Geometrias*: Esses botões facilitam a criação de formas geométricas que podem ser posteriormente utilizadas como entradas (*inputs*) nos *scripts* elaborados.

Essa plataforma, dada a sua capacidade de processamento avançada e a flexibilidade proporcionada pelas linguagens de programação *JavaScript* e *Python*, torna-se uma ferramenta particularmente poderosa e versátil para análises geoespaciais de grande escala, viabilizando a manipulação de volumes significativos de dados e a realização de operações geográficas complexas com precisão e eficiência (AMANI *et al.*, 2020; UFPel, 2020).

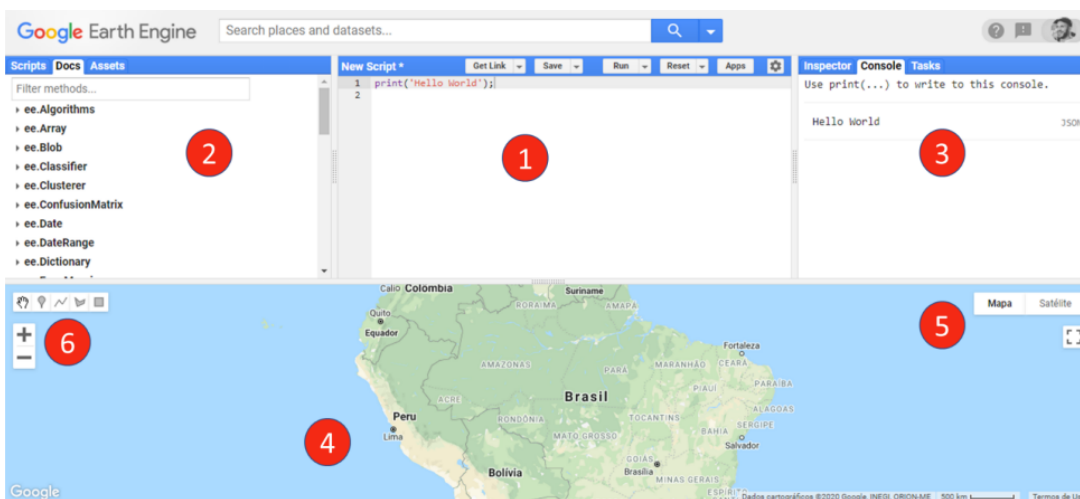


Figura 1.14 - Página do GEE com indicação das janelas e interfaces descritos acima (UFPel, 2020).

Por fim, tem-se à plataforma conhecida como *Google Earth Engine Timelapse* (ver Figura 1.15), uma fascinante ferramenta que, com base em dados acumulados ao longo das últimas quatro décadas, possibilita a criação de vídeos em *timelapse*. Esta abordagem única oferece uma maneira impressionante de visualizar e monitorar a evolução de regiões em nosso planeta, fornecendo um instrumento de inestimável valor para a pesquisa e a compreensão de processos geoespaciais em larga escala (AMANI *et al.*, 2020).

Além disso, um aspecto particularmente relevante do GEE *Timelapse* é a sua capacidade de traduzir dados complexos em representações visuais acessíveis ao público em geral. Essa ferramenta torna possível comunicar de forma eficaz e impactante as mudanças ambientais e suas implicações para públicos que não possuem formação científica especializada. Ao transformar dados em vídeos em *timelapse* cativantes, o GEE *Timelapse* desempenha um papel vital na conscientização pública sobre questões cruciais, como a desmatamento da Amazônia e as mudanças climáticas (AMANI *et al.*, 2020).

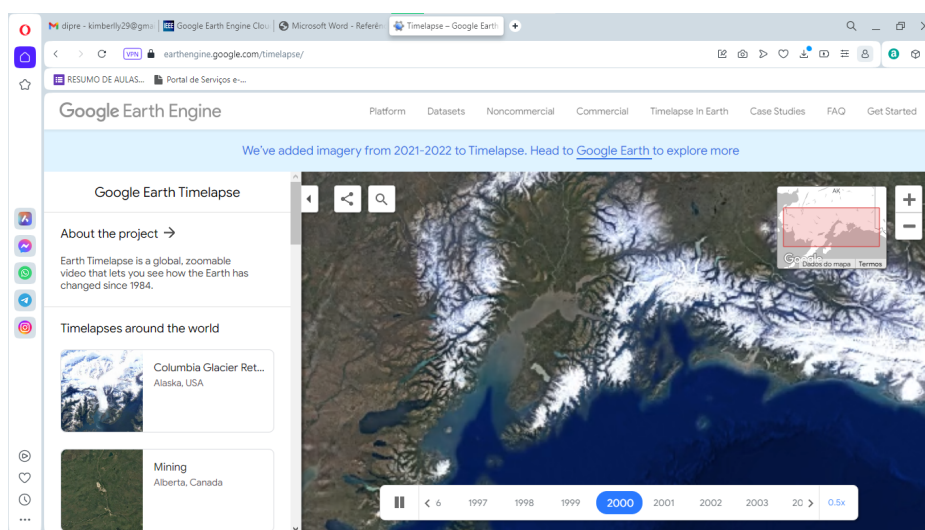


Figura 1.15 - Google Earth Engine Timelapse (Elaboração própria, 2023).

Capítulo 2

REVISÃO BIBLIOGRÁFICA

2.1 FERRAMENTAS PARA DETECÇÃO DE DESMATAÇÃO

O Instituto Nacional de Pesquisas Espaciais (INPE) é responsável pelo Sistema de Detecção da Desmatação em Tempo quase Real (DETER), criado em 2004, e pelo Projeto de Monitoramento da Desmatação na Amazônia Brasileira por Satélites (PRODES), criado em 1988, que detetam alterações na cobertura florestal por meio de satélites, na Amazônia Legal. O DETER é responsável pelo suporte na fiscalização e controle, emitindo os alertas, e o PRODES estima as taxas anuais de desmatação da floresta primária (“corte raso”) na Amazônia Legal, ou seja, áreas que estão tendo a primeira desmatação, sem regeneração da vegetação (ALMEIDA, 2022; INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS, 2022).

Até 2002 o sistema utilizado pelo PRODES era analógico, onde a avaliação era feita através de imagens impressas (INPE E OBT, 2022). Sartorio *et al.* (2019) chegaram à conclusão de que uma metodologia de detecção retroativa de desmatação a partir dos dados do PRODES analógico, dificultava a aferição dos resultados, pois a análise do processo de identificação de desmatação era feita puramente por interpretação visual. Em relação à essa limitação da metodologia utilizada no PRODES, pode-se encontrar tecnologias atuais para implementar o monitoramento de desmatações ao longo do tempo. Sartorio *et al.* (2019) comprovam, também, que o uso da metodologia de mesclar as informações de taxa de desmatação global com as imagens obtidas pelo satélite (no período em que há uma lacuna de informações sobre a desmatação), pode servir como uma ferramenta para estudos secundários da evolução da desmatação.

Para parte do solucionamento da limitação das ferramentas empregadas ao longo dos anos, foi criado o Projeto de Mapeamento Anual da Cobertura e Uso do Solo do Brasil – MapBiomias. O MapBiomias é uma iniciativa colaborativa que visa mapear e monitorar o uso da terra no Brasil. O projeto é composto por uma rede de ONGs, universidades e *startups* de tecnologia que trabalham juntas para fornecer informações precisas e atualizadas sobre a cobertura da terra no país. O MapBiomias usa imagens de satélite para mapear a cobertura da terra em todo o território brasileiro, incluindo florestas, pastagens,

plantações, áreas urbanas e muito mais. O projeto começou em 2015 e desde então tem produzido mapas anuais de cobertura da terra no Brasil, como visto na Figura 2.1 (RODRIGUES, 2018).

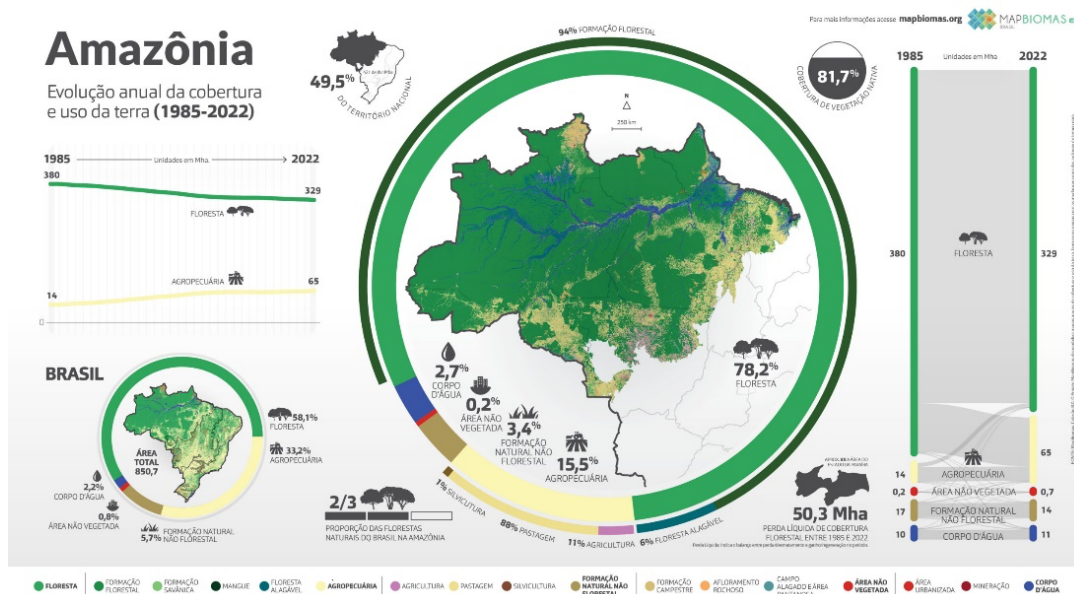


Figura 2.1 - Exemplo de levantamentos feitos pela plataforma Mapbiomas (MAPBIOMAS, 2023).

Dentro do Mapbiomas, existe o MapBiomas Alerta que é um sistema de validação e refinamento de alertas de desmatamento com imagens de alta resolução. Ele é uma plataforma de acesso aberto e gratuito que reúne todos os alertas disponíveis para o território nacional e cruzamentos com outros dados relevantes, como autorizações de supressão de vegetação, embargos etc. O sistema permite entender a dinâmica da desmatamento no Brasil desde 2019 com a seleção do período desejado e em diferentes limites geográficos (ex. biomas, estados, municípios), recortes fundiários (ex. CAR, Unidades de Conservação e Terras Indígenas) e situação administrativa (ex. autorizações e embargos) com mapas, gráficos e estatísticas para subsidiar ações que garantam o desenvolvimento sustentável do território brasileiro. A informação gerada para o monitoramento desta plataforma é obtida por pelo menos 8 sistemas de detecção, dentre eles o PRODES e o DETER. Nesta plataforma, para cada alerta que passa por um processo de validação e refinamento, um relatório é gerado, incluindo imagens que documentam o estado da área antes e depois do evento de desmatamento (ver Figura 2.2).

Além disso, são identificadas possíveis sobreposições e correspondências com as áreas registradas no Cadastro Ambiental Rural (CAR), no Sistema de Gestão Fundiária (SIGEF), entre outros. Adicionalmente, o histórico recente da área em análise é rastreado nos mapas anuais de cobertura e uso da terra no Brasil, conforme fornecidos pelo projeto, permitindo uma compreensão abrangente e detalhada das mudanças

que ocorreram no local, auxiliando em esforços de monitoramento e preservação ambiental (MAPBIOMAS, 2023).

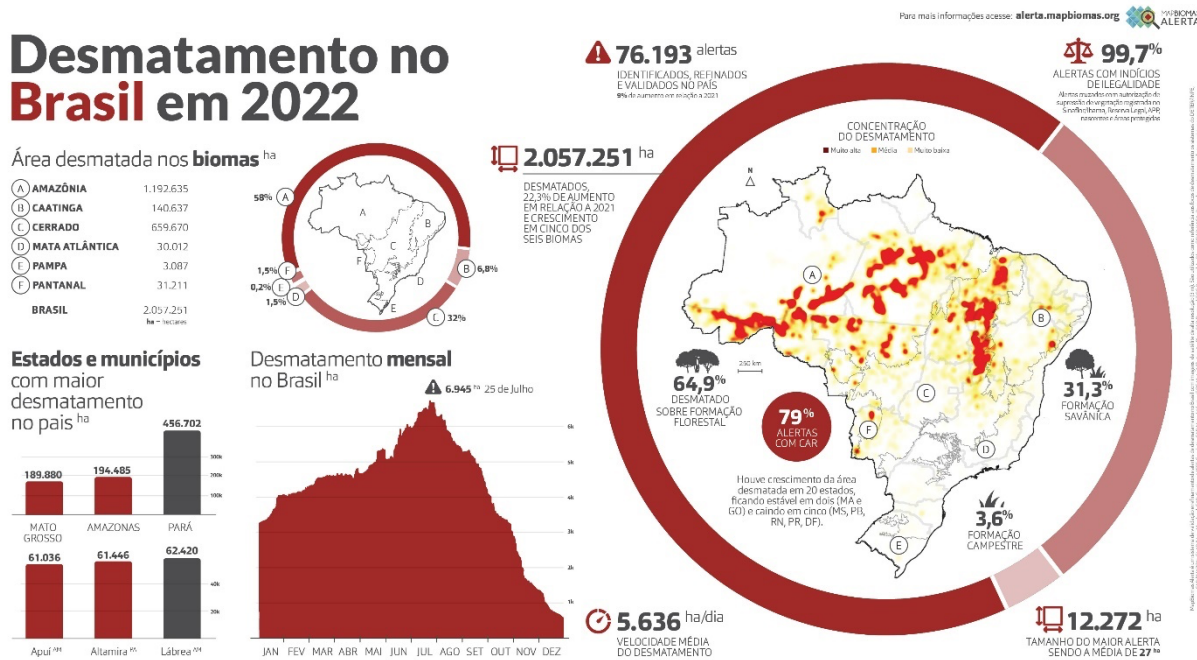


Figura 2.2 -Exemplo de levantamentos feitos pela plataforma Mappiombras Alerta (MAPBIOMAS, 2023).

2.2 APLICAÇÃO DA CLASSIFICAÇÃO SUPERVISIONADA PARA DETEÇÃO DE DESMATAÇÃO

O estudo na Terra indígena da cidade de São Félix do Xingu, no Pará, traz uma metodologia onde foi feito o uso das imagens dos satélites Landsat-5 e Landsat-8 em um período de 18 anos e foram feitas as identificações dos objetos e classificações por interpretação visual (ALVES, 2018). Os resultados encontrados por Alves (2018) ajudaram na análise para verificação do aumento ou redução da desmatção em cada ano em estudo para a cidade analisada, podendo verificar com esses dados o avanço que a agropecuária teve na região.

Uma outra ferramenta para aplicação da classificação supervisionada é o QGIS, um software livre e de código aberto que oferece uma ampla gama de ferramentas para análise de dados geoespaciais. O QGIS oferece várias opções para a realização de classificação supervisionada, incluindo o *Semi-Automatic Classification Plugin* (SCP) e o *Orfeo Toolbox*. O SCP é um *plugin* do QGIS utilizado para a classificação semiautomática de imagens de sensorização remota permitindo a rápida criação de áreas de treinamento ou regiões de interesse (ROI – *Region Of Interest*) que são armazenadas em um *shapefile*. Calcula automaticamente as assinaturas espectrais das áreas de treinamento, possibilitando sua visualização por meio de gráficos. Além disso, oferece ferramentas para *download* e manipulação de imagens Landsat e

Sentinel, integrando vários algoritmos de classificação para análises mais precisas (PAMBOUKIAN, 2023; ARAÚJO, 2015).

O *Orfeo Toolbox* é um conjunto de ferramentas de processamento de imagens de código aberto que pode ser usado em conjunto com o QGIS para realizar classificação supervisionada. O *Orfeo Toolbox* oferece vários algoritmos de classificação, incluindo o *Random Forest*, o SVM e o KNN. Além disso, o *Orfeo Toolbox* oferece ferramentas para a criação de Áreas de Treinamento e para a extração de características de imagens de satélite.

Por sua vez Verçosa *et al.* (2021) utilizaram de informações e imagens de satélites fornecidas pelo MapBiomas, juntamente com fotos aéreas retiradas de um levantamento aerofotogramétrico para obtenção de dados de correlação da desmatagem na área de estudo. Com esses dados foi criado um mosaico que foi georreferenciado, recortado e vetorizado no Sistema de Informação Geográfica (SIG) QGIS. Com o processamento dos dados obtidos foi possível verificar em quais anos a quantidade desmatada foi maior, como também pode-se verificar as áreas que foram reflorestadas e os impactos que o crescimento desses desmatamentos trouxeram para a região ao redor do Rio Largo (rio do município estudado). Obtendo-se a conclusão de que o uso de ferramentas de geoprocessamento juntamente com a sensorização remota, ajudam na análise de impactos ambientais (VERÇOSA *et al.*, 2021).

Pinto (2023) também utilizou do SIG QGIS para a execução da classificação supervisionada em uma região da cidade de Altamira, no Pará. Foi utilizado a plataforma USGS para fazer o download das imagens do satélite Landsat 8 e através do *Semi-Automatic Classification Plugin* (SCP), foi possível selecionar as amostras das classes escolhidas, sendo essas classes: água, urbano, solo exposto, vegetação, nuvem e sombra de nuvem. Esse *plugin* possibilitou a extração das áreas e percentagens e uso de classes para detecção de nuvens contribuiu para obtenção de resultados mais assertivos quanto as áreas das respectivas classes (ver Figura 1.7 b). Porém, como concluído por Pinto (2023), essa ferramenta não é uma ferramenta ágil.

Outra aplicação para a detecção de desmatamentos é através do uso da ferramenta do *Google Earth Engine*, com isso, em um estudo feito por Rodrigues (2018) na cidade de Barreiras/BA, localizada no Cerrado brasileiro, foi feita uma análise potencial de detecção de desmatamento utilizando imagens do satélite Sentinel-1A e Landsat 8. As imagens do Sentinel-1A foram obtidas pela plataforma do GEE, para fazer a verificação dos polígonos de desmatamento presentes na região. Já as imagens do Landsat-8 foram utilizadas para fazer uma análise visual das áreas com desmatamento. Foi possível observar que utilizando os dois satélites e meios para identificação de desmatamento encontra-se semelhanças dos polígonos apresentados, podendo haver pequenas divergências quanto ao período de tempo entre cada imagem obtida (ver Figura 2.3).




Figura 2.3 - Composição colorida RGB das bandas 6, 5 e 4 do satélite Landsat-8 de 02 de outubro de 2016 e 21 de outubro de 2017 (antes e depois da desmatção) no município de Barreiras em (a) e (d) e as imagens correspondentes do satélite Sentinel1A obtidas em 03 de outubro de 2016 e 10 de novembro de 2017 na polarização VV em (b) e (e) e na polarização VH, em (c) e (f) (RODRIGUES, 2018).

Vale (2019) empreendeu um estudo abrangente no estado do Pará, uma região que, atualmente, destaca-se por abrigar o maior número de alertas de desmatamento, abarcando uma vasta extensão territorial, conforme relatado no MAPBIOMAS (2023). Conforme evidenciado na Figura 2.4, a pesquisa baseou-se na análise de imagens provenientes dos satélites Landsat 5 e 8, abrangendo o período que se estende de 1988 a 2018. A aquisição e processamento dessas imagens foram conduzidos por meio da utilização de um *script* elaborado especificamente para o ambiente do *Google Earth Engine*.

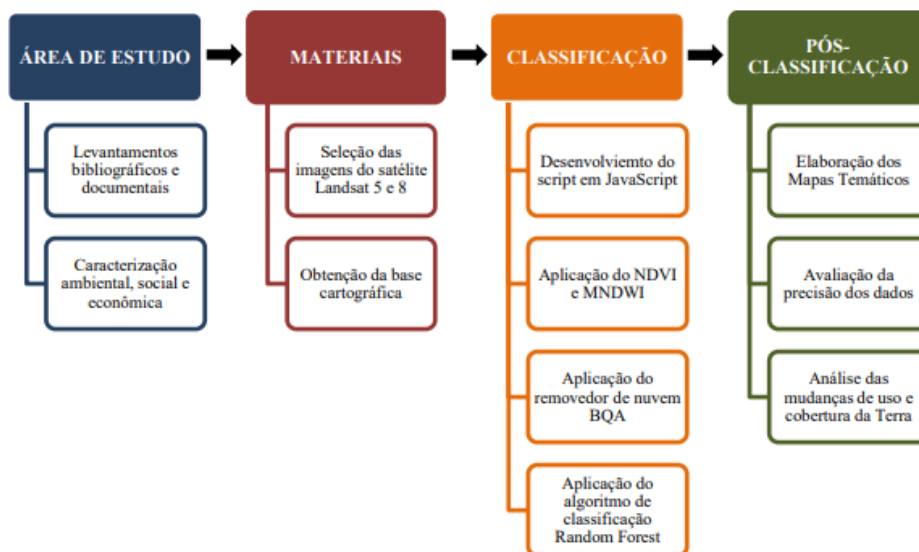


Figura 2.4 - Fluxograma das etapas metodológicas (VALE, 2019).

CAPÍTULO 2

Com o referido *script* foi possível aplicar fórmulas para cálculo de índices espectrais, que utilizam da reflectância das diversas bandas utilizadas em cada fórmula. Através desse procedimento, foi possível avaliar se os locais investigados exibiam características como a presença de água, vegetação, nuvens ou solos expostos. Além disso, foi feita uma classificação da cobertura e uso da terra. Esta classificação abarcou classes como agricultura, floresta, hidrografia, pastagem, vegetação secundária, entre outros.

Os resultados obtidos no decurso do período de tempo examinado revelaram que a categoria de pastagem se destacava de maneira notória no que tange a desmatção, com uma extensão desmatada aproximada de 68.000 km². Vale (2019) destacou, de forma notável, a contribuição da plataforma do *Google Earth Engine* no que tange à agilidade do processo de classificação e monitoramento. Como afirma o autor, "[...] essa plataforma vem ser uma importante ferramenta no monitoramento e controle da desmatção ilegal por permitir aquisição de dados de forma rápida e segura" (pg. 58).

Capítulo 3

METODOLOGIA

3.1 MUNICÍPIO DO ESTUDO DE CASO

O município de Lábrea, localizado no Sudeste do Amazonas, está entre os 50 municípios com maiores áreas desmatadas de 2019 a 2022, onde em 2022, com uma área desmatada de 62.419,5 ha, Lábrea foi o município brasileiro com a maior área desmatada detetada, tendo uma velocidade diária de desmatamento de 171 ha/dia (MAPBIOMAS, 2023).

Para a abordagem e análise pormenorizada deste município, foi empreendido um meticuloso esforço no desenvolvimento de um código personalizado no *Google Earth Engine Code Editor* (ver Apêndice B), a fim de extrair as imagens capturadas pelo satélite Landsat 8, durante o mês de menor ocorrência de cobertura de nuvens permitindo uma análise mais confiável, com menor interferência atmosférica garantindo a obtenção de informações visuais claras e ininterruptas, essenciais para uma interpretação precisa do território em estudo.

Para o início do código, foi preciso a obtenção das coordenadas do município. Através do *site* do governo do estado do Amazonas (estado em que a cidade de Lábrea se situa), foi possível fazer o *download* do arquivo com as coordenadas em extensão *.kml* de todos os municípios do estado e foi importado para o *Google Earth* (Figura 3.1), onde foi possível selecionar apenas a cidade em estudo, adquirindo assim as coordenadas com latitude, longitude e altitude.

Para a Inteligência Artificial do GEE localizar a área exata em que a cidade de Lábrea se encontra, é preciso ter as informações de latitude e longitude, portanto foi feito um *script* a parte (ver Apêndice A), em linguagem *python*, para separar a altitude e apenas deixar as coordenadas necessárias para aplicação no *Google Earth Engine*. Neste *script* também foi preciso dividir pela metade a quantidade de coordenadas do município, para otimizar o processamento do *script* do GEE, como será descrito melhor no capítulo 4.

Após a obtenção das coordenadas e a localização das imagens do satélite (descrição no item 3.2) abrangendo imagens entre os dias 01 a 26 de julho de 2022, foi feito o procedimento de um método de classificação supervisionada a essas imagens.

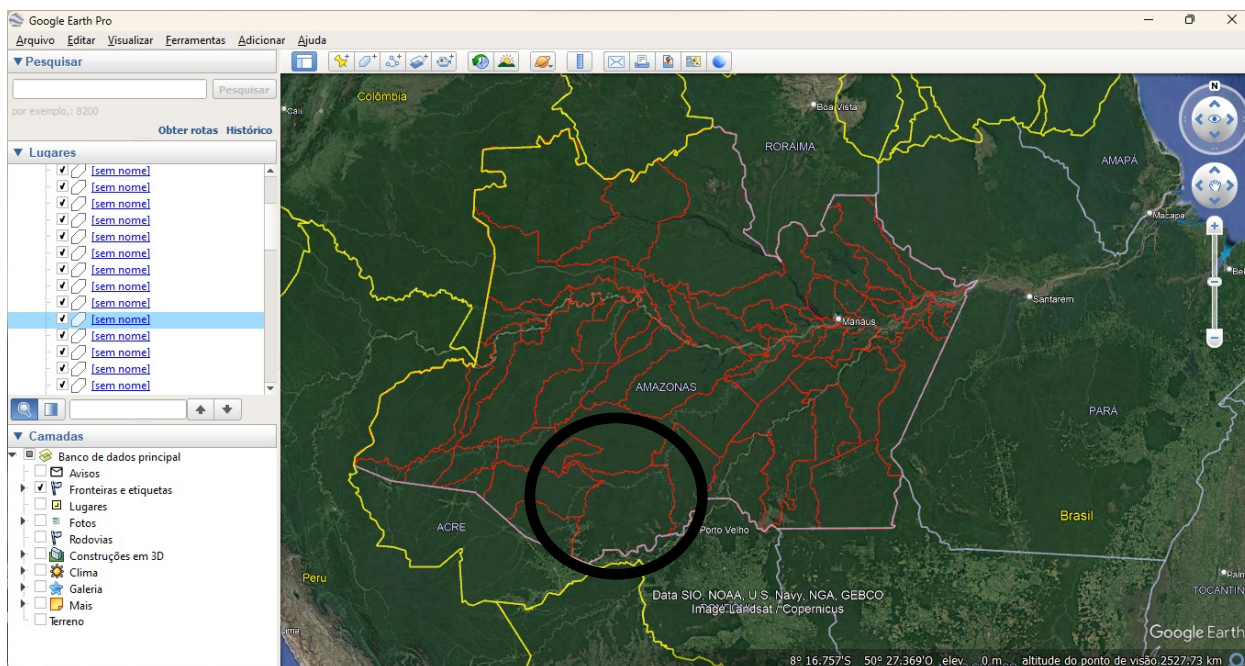


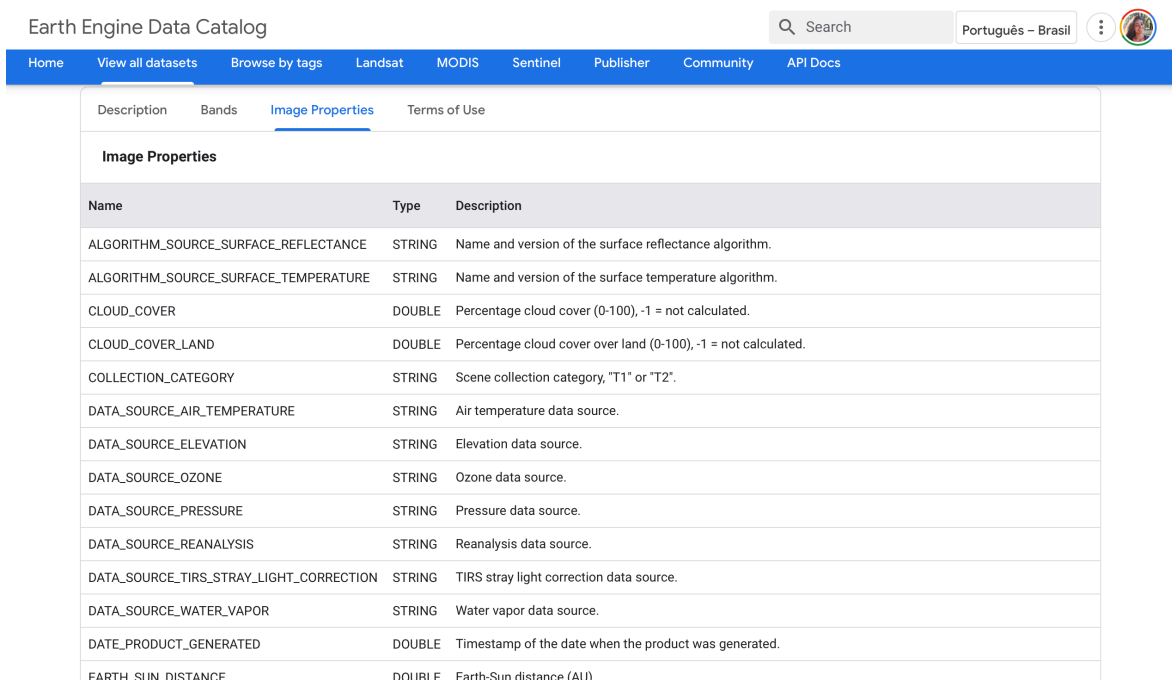
Figura 3.1 - Imagem do .kml no Google Earth, com a cidade de Lábrea circulado em preto (Elaboração própria, 2023).

Essa abordagem metodológica, embasada na análise supervisionada, permitiu a identificação e categorização de diversos *pixels* com colorações diferenciadas presentes no município de Lábrea. Esta etapa crítica do processo proporciona uma riqueza de informações acerca do uso da terra, cobertura vegetal e outros aspectos relevantes, fornecendo assim *insights* valiosos para a compreensão do contexto ambiental e geográfico da região.

3.2 DESENVOLVIMENTO NO GOOGLE EARTH ENGINE CODE EDITOR

No catálogo de dados, disponibilizados na plataforma GEE, teve-se a oportunidade de acessar as informações detalhadas concernentes ao satélite utilizado, nomeadamente o Landsat 8. Essas informações incluem a descrição pormenorizada da coleção de imagens disponíveis, as diversas bandas espectrais que podem ser utilizadas e as instruções precisas sobre como incorporá-las de forma adequada ao código de programação (ver Figura 3.2). Além disso, são fornecidas informações acerca das propriedades que podem ser aplicadas às imagens, tais como a propriedade "CLOUD_COVER", que

oferece orientações sobre como aplicá-la para obter imagens com níveis de cobertura de nuvens ajustados às preferências do utilizador.



Name	Type	Description
ALGORITHM_SOURCE_SURFACE_REFLECTANCE	STRING	Name and version of the surface reflectance algorithm.
ALGORITHM_SOURCE_SURFACE_TEMPERATURE	STRING	Name and version of the surface temperature algorithm.
CLOUD_COVER	DOUBLE	Percentage cloud cover (0-100), -1 = not calculated.
CLOUD_COVER_LAND	DOUBLE	Percentage cloud cover over land (0-100), -1 = not calculated.
COLLECTION_CATEGORY	STRING	Scene collection category, "T1" or "T2".
DATA_SOURCE_AIR_TEMPERATURE	STRING	Air temperature data source.
DATA_SOURCE_ELEVATION	STRING	Elevation data source.
DATA_SOURCE_OZONE	STRING	Ozone data source.
DATA_SOURCE_PRESSURE	STRING	Pressure data source.
DATA_SOURCE_REANALYSIS	STRING	Reanalysis data source.
DATA_SOURCE_TIRS_STRAY_LIGHT_CORRECTION	STRING	TIRS stray light correction data source.
DATA_SOURCE_WATER_VAPOR	STRING	Water vapor data source.
DATE_PRODUCT_GENERATED	DOUBLE	Timestamp of the date when the product was generated.
EARTH_SUN_DISTANCE	DOUBLE	Earth-Sun distance (AU).

Figura 3.2 - Catálogo de dados do Landsat 8, disponibilizado pela plataforma do GEE (Elaboração própria através da plataforma do GEE, 2023).

Delimitou-se, então, uma área de interesse com base nas coordenadas geográficas, obtidas no site do governo do Amazonas, correspondentes ao município de Lábrea (demonstradas no item anterior). Com base nessas informações, extraídas do catálogo de dados do GEE, foi possível dar início ao processo de desenvolvimento, que envolveu a “chamada” da coleção de imagens do satélite Landsat 8 *Level 2, Collection 2, Tier 1*, a qual possui correção de reflectância atmosférica. Essa coleção de imagens foi solicitada especificamente no período temporal do mês de julho de 2022, com fins de demonstração, por ser um período com baixa presença de nuvens na região (ver Figura 3.3). Em seguida, houve à aplicação de um filtro para identificar a presença de nuvens nas imagens, sendo possível configurar o limite de cobertura de nuvens desejado com base na propriedade "CLOUD_COVER". Com a execução do código, a Inteligência Artificial seleciona somente as imagens do satélite que se enquadram dentro do critério de até 10% de cobertura de nuvens.

```
// Filtrar a coleção da imagem dentro do polígono e data especificados
var imagens = ee.ImageCollection('LANDSAT/LC08/C02/T1_L2')
  .filterBounds(areaDeInteresse)
  .filterDate('2022-07-01', '2022-07-31')
  .filterMetadata('CLOUD_COVER', 'less_than', 10);
Map.addLayer(imagens, {bands: ['SR_B5', 'SR_B6', 'SR_B7'], max: 65455 }, 'image');
```

Figura 3.3 - Filtro para a seleção das imagens do Landsat 8, julho/2022 (Elaboração própria, 2023).

Após a etapa de seleção das imagens, foi feita uma identificação visual de diferentes regiões, onde para cada região foram empregues, manualmente, *pins* para cada classe (identificado com um *layer* no GEE). Com isso, foram adicionados *layers* representando as principais classes de interesse, nomeadamente: água, áreas urbanas, vegetação e solos expostos. É relevante salientar que, em cada análise que emprega a classificação supervisionada, os tipos de classes podem variar conforme a região na qual o estudo está sendo conduzido. As classes selecionadas para esta pesquisa correspondem às áreas existentes no município de Lábrea.

No decorrer da análise detalhada da área em questão, foi empenhada a distribuição estratégica, como demonstrado na Figura 3.4, de 33 marcadores ou elementos que indicavam a presença de áreas urbanas (em amarelo), 47 marcadores referentes a corpos d'água (em azul), 39 marcadores relacionados à vegetação (em verde) e, por fim, 78 marcadores representativos de solos expostos (em rosa), sendo que para cada classe foram selecionadas variações de cores dentro da mesma classe, gerando assim assinaturas espectrais mais confiáveis. Vale ressaltar que esses elementos, cuidadosamente selecionados, não apenas representam de maneira exemplar as classes em foco, mas também desempenham o crucial papel de servir como pontos de referência fundamentais para a subsequente detecção e análise de todas as feições que pertencem a essas respectivas classes, presentes na vasta área de do município de Lábrea.




Figura 3.4 - Pins para classificação supervisionada, julho/2022 (Elaboração própria, 2023).

Já com a localização das classes feitas, foi possível criar uma linha de código para indicar que é preciso mesclar as classes para poder obter uma imagem homogênea com cada classe separada de acordo com a seleção dos *pins* indicados anteriormente (ver Figura 3.5).

```
// Mesclar as coleções de features (classes) como antes
var classes = areaurbana.merge(agua).merge(soloexposto).merge(vegetacao);
```

Figura 3.5 - Comando para mesclar as classes selecionadas (Elaboração própria, 2023).

Posteriormente, procedeu-se à implementação de um “treinamento” no código, visando capacitar a inteligência artificial a discernir com precisão a localização das amostras disponibilizadas (ver Figura 3.6), seguindo-se do treinamento destinado a permitir a identificação das assinaturas espectrais que guardam semelhança com as amostras coletadas (ver Figura 3.7).

```
// Criar dados de treinamento usando map
var bands = ['SR_B2', 'SR_B3', 'SR_B4', 'SR_B5', 'SR_B6', 'SR_B7'];

var training = imagens.map(function (imagem) {
  var amostras = imagem.select(bands).sampleRegions({
    collection: classes,
    properties: ['landcover'],
    scale: 30
  });
  return amostras;
}).flatten();
```

Figura 3.6 - Treinamento para localização das amostras/pins (Elaboração própria, 2023).

```
// Treinar o classificador
var classifier = ee.Classifier.smileCart().train({
  features: training,
  classProperty: 'landcover',
  inputProperties: bands
});
```

Figura 3.7 - Treinamento para identificação das assinaturas espectrais (Elaboração própria, 2023).

Com a conclusão destas etapas de treinamento, o programa adquiriu a capacidade de efetuar a classificação da imagem, isto é, recebeu a imagem a ser analisada e, munido do conhecimento obtido a partir das amostras, foi capaz de apontar os pontos que correspondem a corpos de água, áreas urbanas, regiões de vegetação e áreas de solo exposto. Com isso foi aplicado o código da Figura 3.8, para efetuar a classificação supervisionada em todas as imagens que rodeiam a cidade de Lábrea, para estabelecer os padrões de visualização da imagem, como escala e cores de cada classe e para transformar todas as imagens, obtidas através da classificação, em apenas uma única imagem.

Após a execução do processo visual da classificação supervisionada, foi aplicado uma contagem de *pixels* para transformação em área. Como visto na Tabela 1.1, um *pixel* equivale a 30 metros, portanto na

aplicação feita no código foi informado o tamanho do *pixel* e foi feito o pedido para retorno da quantidade existente de *pixel* em cada classe para transformação posterior em metros quadrados e em seguida em hectares (ver Figura 3.9).

Com todas as etapas acima citadas tendo sido concluídas, foi possível exportar a seleção das imagens classificadas (ver Figura 3.10) em caso de aplicação em outros softwares, como por exemplos softwares GIS.

```
// Exibir a classificação das imagens
print(classificadas);

// Exibir a coleção de imagens classificadas
Map.centerObject(areaDeInteresse, 11);
Map.addLayer(classificadas, {min: 0, max: 3, palette:
['yellow', 'blue', 'red', 'green']}, 'classification');
Map.addLayer(classes);

// Mosaico das imagens classificadas em uma única imagem
var mosaicClassified = classificadas.mosaic();
```

Figura 3.8 - Execução da classificação supervisionada para todas as imagens selecionadas (Elaboração própria, 2023).

```
// Defina as cores das classes
var classColors = [0, 1, 2, 3];

// Loop através de cada cor e calcular a área
classColors.forEach(function(cor) {
  var areaImagem = mosaicClassified.eq(cor);
  var areaPixels = areaImagem.reduceRegion({
    reducer: ee.Reducer.sum(),
    geometry: areaDeInteresse,
    scale: 30,
    maxPixels: 10e12
  });

  var areaM2 = ee.Number(areaPixels.get
('classification')).multiply(ee.Number(30*30));
  var areaHectare = areaM2.divide(1e4);
  print('Área de ' + cor + ': ', areaHectare);
});
```

Figura 3.9 - Cálculo de pixel por classe e transformação para hectares (Elaboração própria, 2023).

```

// Exportar a imagem mosaico das classificações para o Google Drive
var exportConfig = {
  image: mosaicClassified,
  description: 'classe_labrea_AM', // Nome do arquivo de saída
  folder: 'GEE_EXPORT', // Nome da pasta no Google Drive
  scale: 10, // Resolução espacial em metros
  region: imagens.geometry().getInfo(),
  crs: 'EPSG:4326', // Sistema de coordenadas de saída (WGS84)
  maxPixels: 10e12
};

Export.image.toDrive(exportConfig);

```

Figura 3.10 - Exportação das imagens classificadas para o *Google Drive* (Elaboração própria, 2023).

Para todas as etapas de elaboração desse código, foram feitas “impressões” dos dados para visualização quantitativa de cada processo feito, desde a extração da quantidade de imagens adquiridas ao filtrar as imagens do satélite na Figura 3.3, até as áreas obtidas através da contagem dos *pixels*, efetuados através do código da Figura 3.9. Todas essas informações ficam armazenadas na aba do *Console* (ver Figura 1.8) para eventuais consultas.

Com o intuito de aprimorar a precisão na comparação dos resultados obtidos, foram rigorosamente seguidas as mesmas etapas metodológicas anteriormente delineadas para a obtenção dos dados referentes ao mês de junho de 2022, na localidade de Lábrea, Amazonas. Em virtude da notória ocorrência de cobertura de nuvens durante o mencionado período, adotou-se um critério de filtragem, estabelecendo-se um limiar de 75% de presença de nuvens para a realização desse processo seletivo (Figura 3.11).

```

// Filtrar a coleção da imagem dentro do polígono e data especificados
var imagens = ee.ImageCollection('LANDSAT/LC08/C02/T1_L2')
  .filterBounds(areaDeInteresse)
  .filterDate('2022-06-01', '2022-06-30')
  .filterMetadata('CLOUD_COVER', 'less_than', 75);
Map.addLayer(imagens, {bands: ['SR_B5', 'SR_B6', 'SR_B7'], max: 65455 }, 'image');

```

Figura 3.11 - Filtro para a seleção das imagens do Landsat 8, junho/2022 (Elaboração própria, 2023).

Os marcadores, em sua grande maioria, foram mantidos preservando sua localização original. Entretanto, devido à constatação da presença de cobertura de nuvens em determinadas áreas onde os *pins* foram inicialmente posicionados, fez-se necessário realizar ajustes pontuais, deslocando alguns marcadores para áreas onde não se verificasse tal interferência. Esse procedimento se fez essencial a fim de assegurar a integridade e a precisão dos dados geográficos, evitando quaisquer distorções que pudessem comprometer a análise, garantindo, assim, uma representação mais fidedigna e coerente com a realidade

das regiões demarcadas pelos marcadores (Figura 3.12). Quanto ao treinamento do processo classificatório, à própria execução da classificação e à subsequente mensuração da área, manteve-se inalterados os parâmetros fundamentais do *script* utilizado




Figura 3.12 - Pins para classificação supervisionada, junho/2022 (Elaboração própria, 2023).

3.3 OBTENÇÃO DOS DADOS PARA COMPARAÇÃO NO MAPBIOMAS

Na plataforma Mapbiomas Alertas, todos os dados relativos aos alertas de desmatamento em território brasileiro são meticulosamente registrados e documentados. Como ilustrado no canto esquerdo da Figura 3.13, essa plataforma oferece uma gama de funcionalidades que possibilitam a filtragem das detecções de desmatamento com base em critérios diversos, como cidades, biomas, áreas de proteção, períodos temporais e uma série de outros parâmetros. Adicionalmente, é possível acessar informações estatísticas detalhadas acerca da desmatamento nas áreas ou regiões selecionadas (canto direito da Figura 3.13).

Graças a essa robusta funcionalidade, foi possível realizar uma filtragem precisa dos dados relativos aos alertas de desmatamento concernentes à cidade de Lábrea, referentes ao mês de julho de 2022. Adicionalmente, essa abordagem possibilitou a obtenção de uma visão panorâmica abrangente da quantidade de área desmatada ao longo do ano de 2022, conforme apresentado na Figura 3.14. Neste gráfico, os meses, de janeiro a dezembro, encontram-se representados ao longo do eixo horizontal, enquanto a área total desmatada é meticulosamente retratada no eixo vertical. Essas informações se revelam cruciais para a compreensão e análise do panorama da desmatamento na região e representam um

recurso valioso para a tomada de decisões e a condução de estudos subsequentes, pois destas informações fornecidas foram extraídas as informações de áreas desmatadas para comparação com os resultados obtidos na plataforma do GEE.

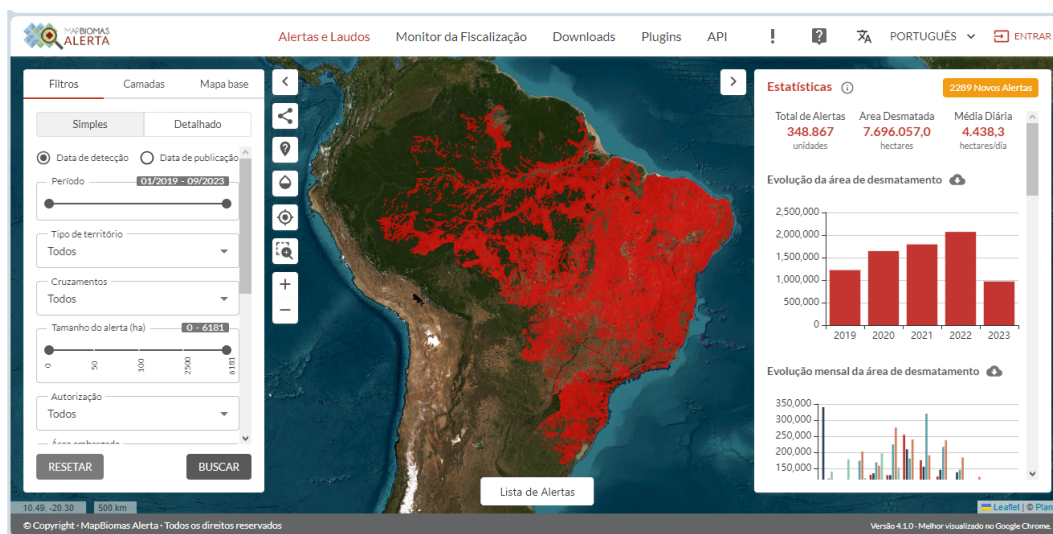


Figura 3.13 - Página principal da plataforma do Mapbiomas Alertas¹ (Elaboração própria, 2023).




Figura 3.14 - Quantidade de áreas desmatadas em Lábrea/AM ao longo do ano de 2022 (Elaboração própria, 2023).

¹ [https://plataforma.alerta.mapbiomas.org/mapa?monthRange\[0\]=2019-01&monthRange\[1\]=2023-09&sources\[0\]=All&territoryType=all&authorization=all&embargoed=all&locationType=alert_code&activeBaseMap=7](https://plataforma.alerta.mapbiomas.org/mapa?monthRange[0]=2019-01&monthRange[1]=2023-09&sources[0]=All&territoryType=all&authorization=all&embargoed=all&locationType=alert_code&activeBaseMap=7)




Figura 4.2 - Imagens, das coordenadas de Lábrea/AM, do Satélite Landsat 8 para julho de 2022 (RGB)
(Elaboração própria, 2023).

Com a seleção de imagens realizada por meio do processo previamente delineado, inicialmente foram adquiridas 385 imagens que abrangiam o polígono geográfico correspondente à cidade de Lábrea. Após a aplicação de critérios de filtro às imagens da coleção e a conclusão das etapas de treinamento, o *Google Earth Engine* selecionou apenas 13 imagens, quantidade a partir da qual o processo de classificação prosseguiu.

Na Figura 4.3, são apresentados os resultados visuais obtidos por meio da execução do código desenvolvido no *Google Earth Engine* para a aplicação da classificação supervisionada. Os resultados gerados pela análise das imagens processadas por técnicas de Inteligência Artificial indicam que as áreas com presença de vegetação são representadas em verde, as áreas de água em azul, a área urbana em amarelo e as áreas de solo exposto em vermelho. Devido ao fato de que a cobertura de nuvens utilizada não foi de 0%, foi possível observar que, em alguns pontos, as nuvens foram incorretamente classificadas como área urbana, água ou solo exposto, conforme ilustrado na Figura 4.4. Em virtude desse acontecimento, as áreas correspondentes a essas classes experimentaram distorções na representação da realidade das imagens analisadas, resultando em um aumento significativo, considerando uma avaliação visual do tamanho das áreas afetadas pelas nuvens, no resultado do processo de classificação.

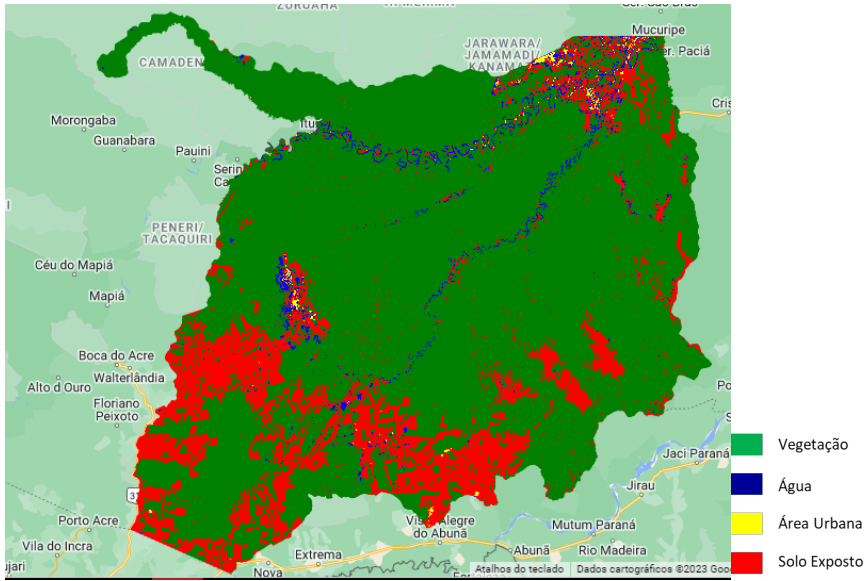
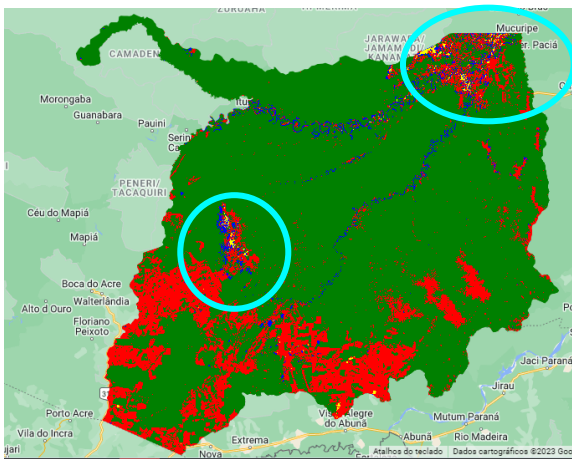


Figura 4.3 - Classificação supervisionada aplicada no GEE, julho/2022 (Elaboração própria, 2023).



a) Cobertura de nuvens na classificação

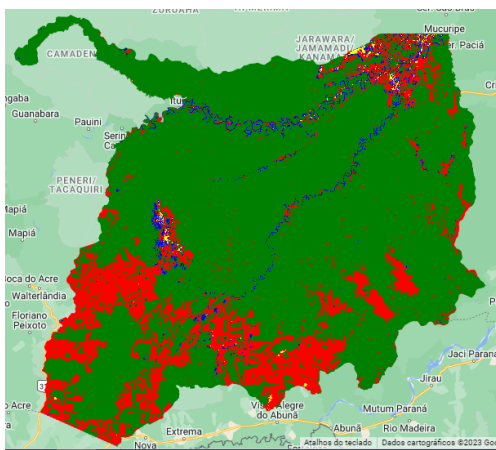


b) Cobertura de nuvens na imagem de satélite

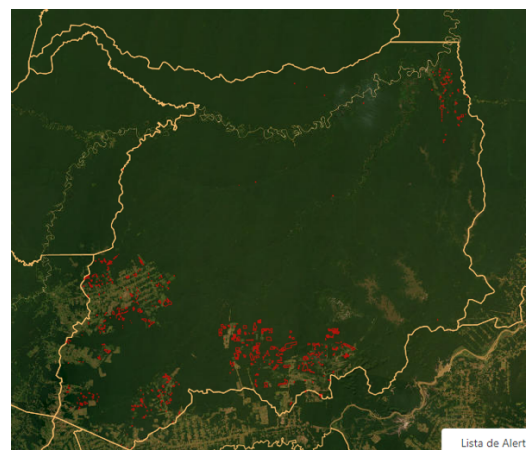
Figura 4.4 - Demonstração das áreas com significativa presença de nuvens, julho/2022 (Elaboração própria, 2023).

Ao cotejar os resultados visuais obtidos por meio da aplicação da classificação supervisionada no *Google Earth Engine* com os resultados disponíveis na plataforma do MapBiomias, observa-se uma diferença notável no que tange à extensão das áreas de solo exposto em relação às áreas de alertas de desmatamento monitoradas pelo MapBiomias. A Figura 4.5 (b) exhibe, de forma destacada em vermelho, as áreas que apresentaram alertas de desmatamento no mês de julho de 2022, enquanto a Figura 4.5 (c) ilustra as áreas que foram identificadas com alertas de desmatamento desde janeiro de 2019 até julho de 2022. Em ambas as imagens, é perceptível que a quantidade de áreas desmatadas, conforme identificadas pelos alertas do MapBiomias, não engloba integralmente todas as áreas que ostentam solos expostos.

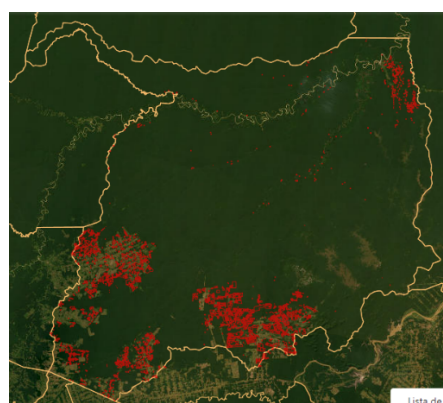
Por outro lado, as áreas de solos expostos, obtidas por meio do processo de classificação supervisionada detalhado no capítulo anterior, são representações abrangentes das áreas de solo desprotegido, abrangendo não apenas aquelas que foram expostas no mês de julho, mas também as que se encontravam nesse estado em períodos anteriores (conforme evidenciado na Figura 4.5 (a)). A distinção é clara e denota que a classificação supervisionada, utilizando as técnicas e metodologias discutidas previamente, oferece uma visão mais completa e abrangente das áreas de solo exposto, contribuindo para uma análise mais detalhada da evolução de desmatamento e da exposição do solo ao longo do tempo. Essa observação destaca a capacidade da classificação supervisionada em captar áreas de solo exposto que não necessariamente coincidem com as áreas monitoradas como alertas de desmatamento, acrescentando valor e precisão às análises ambientais e de uso da terra.



a) Imagem gerada no GEE – Classificação



b) Mapbiomas-Alertas de desmatamento, jul./22



c) Mapbiomas - Alertas de desmatamento, em Lábrea de janeiro de 2019 a julho de 2022

Figura 4.5 - Comparação das áreas de solo exposto e desmatadas da classificação supervisionada e do Mapbiomas (Elaboração própria, 2023).

Feita a classificação supervisionada no GEE e observado seu resultado visual, também foi possível quantificar cada uma das classes escolhidas e selecionadas (ver Tabela 4.1) e com os valores obtidos no Mapbiomas das áreas de desmatamentos com alerta, foi possível ver a diferença das áreas relatadas pela plataforma com os resultados obtidos através da classificação. De acordo com o Mapbiomas, a área desmatada em julho de 2022 em Lábrea foi de aproximadamente 5.255 hectares enquanto a área total das alertas feitas desde o início de janeiro de 2019 até o mês de julho de 2022 é de aproximadamente 175.095 hectares (MAPBIOMAS, 2023).

Tabela 4.1 - Áreas e percentagens das classes da classificação supervisionada feita pelo GEE, julho/2022 (Elaboração própria 2023).

Classes	Áreas (ha)	Percentagens (%)
Área Urbana	31.165,11	0,4
Água	248.916,47	3,6
Vegetação	5.330.431,34	76,8
Solo Exposto	1.333.764,79	19,2

Em comparação com os dados do Mapbiomas, a classificação supervisionada feita pela plataforma do *Google Earth Engine* supera em quase 254 vezes a área desmatada em julho de 2022. Essa comparação feita do período acumulado do GEE até julho de 2022 com a área desmatada efetiva detectada pelo Mapbiomas é uma comparação com parâmetros distintos, dado que as áreas de solo exposto obtidos na classificação supervisionada do *Google Earth Engine* no mês de julho, do ano em estudo, são um acúmulo de todo solo exposto sem uma data de início, pois as imagens de satélites captam a realidade do local não podendo concluir o período em que se abrangem as imagens obtidas.

Por este motivo foram obtidos os dados de classificação supervisionada do mês anterior (junho de 2022), onde na Figura 4.6 é possível verificar os resultados visuais obtidos da classificação supervisionada. Como para este mês não foi possível utilizar um filtro de nuvens inferior a 75%, a presença de nuvens nesta classificação é maior do que a vista no mês de julho. Por isso, a presença de nuvens foi classificada com solo exposto, em sua maioria, água e área urbana (Figura 4.7).

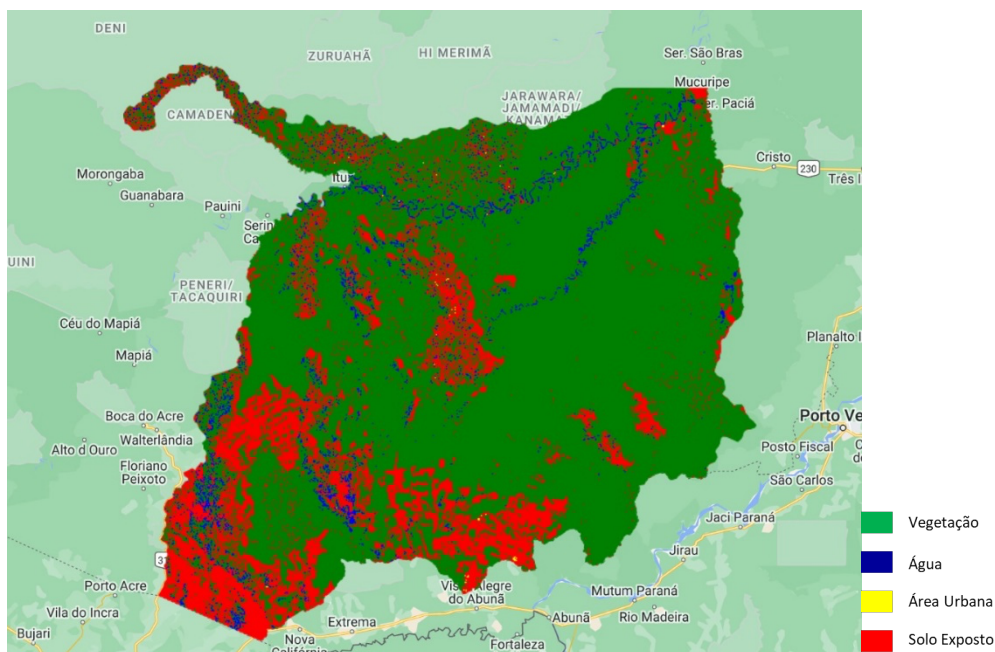
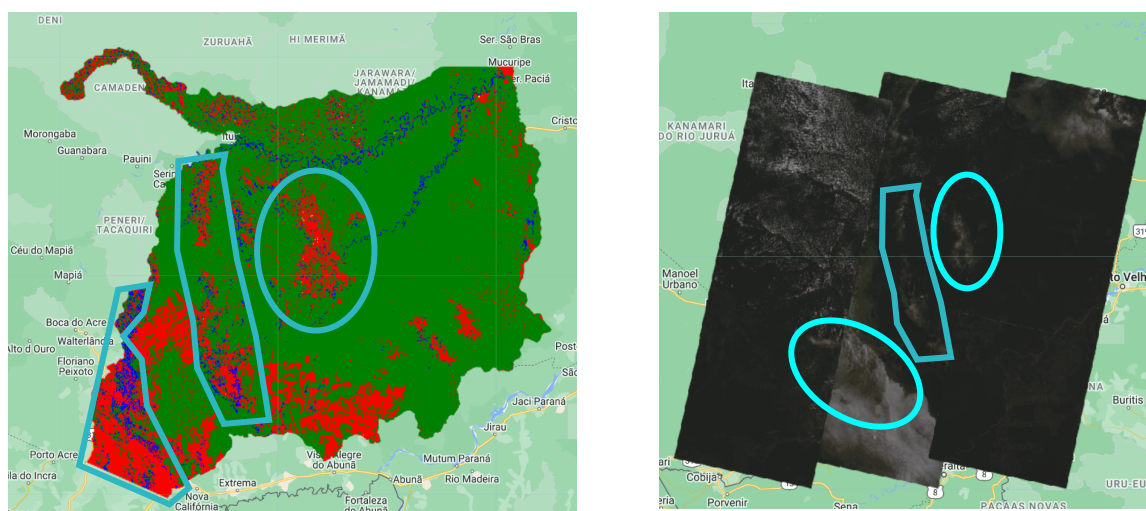


Figura 4.6 - Classificação supervisionada aplicada no GEE, junho/2022 (Elaboração própria, 2023).



a) Cobertura de nuvens na classificação

b) Cobertura de nuvens na imagem de satélite

Figura 4.7 - Demonstração das áreas com significativa presença de nuvens, junho/2022 (Elaboração própria, 2023).

e com esses resultados subtrair a área de solos expostos do mês de julho para obter a área efetiva desmatada em julho, de acordo com os dados obtidos no *Google Earth Engine*. Na Tabela 4.2 é possível observar os resultados das classes selecionadas de junho de 2022.

Tabela 4.2 - Áreas e percentagens das classes da classificação supervisionada feita pelo GEE de junho/2022 (Elaboração própria 2023).

Classes	Áreas (ha)	Percentagens (%)
Área Urbana	5.910,36	0,08
Água	188.136,62	2,71
Vegetação	5.445.177,63	78,42
Solo Exposto	1.304.629,34	18,79

Ao subtrair a área de solo exposto do de julho de 2022 (área de 1.333.764,79 ha) da área de solo exposto de junho de 2022 (área de 1.304.629,34 ha), foi obtido uma área de 29.135,45 ha. Essa diferença obtida é a área efetiva dos solos expostos durante o período do mês de julho de 2022 em Lábrea.

Em comparação com os dados do Mapbiomas, em relação ao mês de julho de 2022 a classificação supervisionada feita pela plataforma do *Google Earth Engine* supera em aproximadamente 554% a área de 5.255 ha de julho de 2022 do Mapbiomas. Mesmo havendo ainda uma diferença considerável, é possível notar que ao selecionar uma janela temporal mais exata com o objeto em comparação o resultado é filtrado de uma melhor forma. Essa diferença dos resultados obtidos tanto na comparação dos resultados acumulados do GEE, quanto dos resultados dos dois meses retirados da plataforma e subtraídos, pode-se dar por vários fatores.

Um dos fatores que pode ter influenciado nas áreas em geral da classificação supervisionada foi a diminuição das coordenadas da cidade. Quando foram utilizadas as coordenadas em sua totalidade, o *script* do GEE não conseguiu ser efetuado pelo tamanho de informações trazidas pelas coordenadas. Por este motivo, foram selecionadas apenas a metade das coordenadas de Lábrea, o que não foi uma quantidade grande o suficiente para não executar o código e nem tão pequena para não se ter o contorno da cidade. Porém, essa diminuição das coordenadas acarretou em acréscimo na área da cidade, levando em conta que, de acordo com IBGE (2023) a área da cidade de Lábrea é de 6.826.268 hectares e a área total obtida na classificação é de aproximadamente 6.944.278 hectares.

A escolha do algoritmo utilizado para efetuar a classificação supervisionada através do *Google Earth Engine* pode também ter causado a falta de precisão em alguns dos resultados obtidos (ver item 1.4.3 para melhores clarificações).

A presença de nuvens em alguns locais das imagens obtidas também influenciou na diferença das áreas com solo exposto, visto que na parte central e superior da cidade tem a existência de nuvens que foram detetadas pela Inteligência Artificial como sendo local de solos expostos (como demonstrado na Figura 4.4). Para a melhoria desses resultados poderia ter sido criada uma classe de nuvens e detetar qual a área de ocupação de nuvem nas imagens e extrair esse valor das outras classes.

A desproporção, entre os resultados obtidos com os demonstrados pela plataforma, também pode ser justificada pela presença de áreas de cultivo na região. Muitas áreas aparecem como desmatadas por conta da agricultura. Dependendo da época do ano, por conta do ciclo de cultura de cada cultivo, essas áreas podem ser vistas como vegetação ou como desmatação.

Outra explicação para a diferença dos resultados em áreas menores desmatadas é que “os sistemas de monitoramento da desmatação apresentam áreas mínimas de detecção. Por exemplo, os alertas menores do que 6,25 hectares não são detetados na Amazônia [...]” (MAPBIOMAS, 2022, pg. 30). Portanto, as áreas que muitas vezes são desmatadas por pessoas que tendo o conhecimento desta brecha no monitoramento, aproveitam-se para aos poucos irem desmatando pequenas clareiras e com isso muitas destas áreas menores obtidas pela classificação supervisionada não estão contempladas nos resultados da plataforma do Mapbiomas.

Capítulo 5

CONSIDERAÇÕES FINAIS

5.1 CONCLUSÕES

Com o crescimento incessante dos índices de desmatamento no território brasileiro, com destaque para a região Amazônica, o presente estudo teve como premissa a exploração da utilização da plataforma *Google Earth Engine* para a realização de uma classificação supervisionada na cidade de Lábrea, situada no estado do Amazonas. O objetivo primordial era a detecção de áreas desmatadas e a subsequente demonstração da credibilidade dos dados obtidos por meio dessa plataforma.

Este trabalho revelou que, munido de um conhecimento prévio elementar em programação, foi possível agilizar o desenvolvimento de um *script* destinado à filtragem de imagens provenientes do satélite Landsat 8, seleção de amostras das classes escolhidas e selecionadas, treinamento do sistema de Inteligência Artificial para a execução da classificação supervisionada e a posterior obtenção das áreas correspondentes a cada uma dessas classes.

Com o êxito na elaboração do *script* e a obtenção das imagens classificadas, foi conduzida uma análise sobre a presença de áreas com solo exposto, em contrapartida aos dados disponíveis na plataforma do Mapbiomas, que abrangem a mesma região geográfica. A comparação entre essas duas fontes de informação revelou uma notável disparidade na quantidade de áreas com solo exposto, sugerindo que nem todo o solo identificado na classificação supervisionada pode ser caracterizado como desmatamento ilegal, conforme monitorado pelo Mapbiomas. Destaca-se também a carência de uma classe que represente as nuvens, uma vez que a presença destas interferiu significativamente nos resultados das classes selecionadas.

Conclui-se, ademais, que no processo de classificação supervisionada, a qualidade das amostras coletadas para gerar os resultados depende em grande medida da experiência e sensibilidade do operador da plataforma ou software utilizado. Portanto, quando o operador não possui um conhecimento aprofundado da área em estudo, os resultados obtidos podem carecer de confiabilidade. No entanto, o auxílio de ferramentas ágeis e sistemas de Inteligência Artificial contribuem substancialmente para elevar

a confiabilidade dos resultados, uma vez que o processo não se baseia inteiramente na intervenção manual.

5.2 DESENVOLVIMENTOS FUTUROS

Deixando margem para trabalhos a serem desenvolvidos em um horizonte futuro, vislumbra-se a valiosa possibilidade de incorporar análises temporais como ferramenta para entender a evolução da desmatamento ao longo dos anos. Esse enfoque permitiria traçar um panorama histórico e discernir as tendências que moldaram o crescimento alarmante da desmatamento, que tanto afeta o país.

Ademais, é pertinente considerar a exploração da relação entre a expansão de áreas de cultivo na cidade objeto de estudo e a incidência de alertas de desmatamento. A hipótese proposta é que a ampliação das áreas destinadas à agricultura possa estar diretamente correlacionada com o aumento dos números de alertas de desmatamento na localidade em questão. Essa conjectura, no entanto, requer uma investigação mais aprofundada e poderia ser eficazmente explorada por meio de um estudo realizado ao longo de um período de dois anos, com uma análise dos ciclos de cultivo que se sucedem ao longo de 24 meses.

Deixando, igualmente, uma janela aberta para investigações posteriores, existe a possibilidade de empregar diferentes métodos de detecção de desmatamento com o uso da plataforma *Google Earth Engine*. Um desses métodos seria a utilização de índices espectrais que avaliam a saúde da vegetação, proporcionando uma abordagem distinta e complementar à classificação supervisionada. O intuito seria confrontar as informações obtidas por meio dessas diferentes abordagens e, assim, aferir a veracidade e a confiabilidade dos dados obtidos. Isso abriria novas perspectivas para um entendimento mais abrangente da desmatamento e contribuiria para o aprimoramento das técnicas de monitoramento ambiental.

REFERÊNCIAS BIBLIOGRÁFICAS

AERO ENGENHARIA – Quais são os 7 benefícios da classificação supervisionada [Em linha]. [Consult. 12 Nov. 2023]. Disponível na WWW: <https://aeroengenharia.com/glossario/quais-sao-os-7-beneficios-da-classificacao-supervisionada/>

ALMEIDA, Claudio *et al.* - Metodologia utilizada nos sistemas PRODES e DETER. Portal INPE. 08.25.11.46-NTC. São José dos Campos. 2ª edição (atualizada), 2022. [Consult. 20 Out. 2022]. Disponível na WWW: <<http://mtc-m21d.sid.inpe.br/col/sid.inpe.br/mtc-m21d/2022/08.25.11.46/doc/publicacao.pdf>>

ALVES, Pedro Henrique - Dinâmica da desmatção na terra indígena apyterewa mediante a aplicação de técnicas de sensorização remota. Altamira: [S.n.], 2018 Trabalho de Conclusão de Curso. Disponível na WWW: <<https://bdm.ufpa.br:8443/jspui/handle/prefix/1210>>

AMANI, Meisam *et al.* - Google Earth Engine Cloud Computing Platform for Remote Sensing Big Data Applications: A Comprehensive Review. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing [Em linha]. Volume 13. (Set. 2020),P. 5326-5350. [Consult. 10 Set. 2023]. Disponível na WWW: ISSN 2151-1535

AMARAL, Francisco - Uso de técnicas de geoprocessamento na otimização do traçado e na melhoria operacional de sistemas adutores de abastecimento de água [Texto policopiado]. Recife: [s.n.], 2017. Tese de doutorado.

ARAÚJO, Mônica – Classificação supervisionada de imagens orbitais [Em linha]. 2015. [Consult. 15 nov. 2023]. Disponível na WWW: < <https://clickgeo.com.br/qgis-classificacao-supervisionada-imagens-de-satelite-com-semi-automatic-classification-plugin/>>

BELGIU, Mariana; DRĂGUTJ, Lucian - Random forest in remote sensing: A review of applications and future directions. ISPRS Journal of Photogrammetry and Remote Sensing. ISSN: 0924-2716 (11 Jan. 2016) 24-31.

BOURSCHEIT, Aldem. Conheça 10 sistemas de monitoramento por satélite da Amazônia [Em linha]. [Consult. 31 Out. 2022]. Disponível na <WWW:<https://infoamazonia.org/webstories/conheca-10-sistemas-que-monitoram-o-desmatção-da-amazonia/>>

REFERÊNCIAS BIBLIOGRÁFICAS

CECHIM, Clóvis *et al.*- Classificação Supervisionadas de Imagens Sentinel 2 com Machine Learning no Google Earth Engine. Anais do XX Simpósio Brasileiro de Sensorização Remota [Em linha]. Vol. 20 (2023), p. 79-82. [Consult. 13 Nov. 2023]. Disponível na: ISBN: 978-65-89159-04-9

CENTENO, Jorge - Sensorização Remota: Classificação de imagens [Em linha]. [Consult. 23 Nov. 2022]. Disponível na WWW: <https://docs.ufpr.br/~centeno/m_sr1/pdf/aula10.pdf>

CISER - Entenda a importância do geoprocessamento para a construção civil [Em linha]. [Consult. 13 Nov. 2023]. Disponível na WWW: < <https://blog.ciser.com.br/construcao-civil/geoprocessamento-e-sua-importancia-na-construcao-civil/>>

CRÓSTA, Alvaro - Processamento digital de imagens de sensorização remota. 4 ed. Campinas: Instituto de Geociências/UNICAMP, 2002. 151 p. ISBN 85-85369-02-7

Desafios do desenvolvimento. Nº 44 (Jun. 2008) – Brasília: Segmento RM Editores, 2008. ISSN 1806-9363

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA) - Landsat: *Land Remote Sensing Satellite* [Em linha]. [Consult. 06 Nov. 2022]. Disponível na WWW: <<https://www.embrapa.br/satelites-de-monitoramento/missoes/landsat>>

EUROPEAN SPACE AGENCY (ESA) - Assinaturas espectrais [Em linha]. [Consult. 29 Maio. 2023] Disponível na WWW: https://www.esa.int/SPECIALS/Eduspace_PT/SEM7W765P1G_0.html#:~:text=Diferentes%20tipos%20de%20superf%C3%ADcie%2C%20como,denominada%20assinatura%20espectral%20da%20superf%C3%ADcie. Acesso em: 29 maio 2023

FARINA, Flávia – Abordagem sobre as técnicas de geoprocessamento aplicadas ao planejamento e gestão urbana. Cadernos EBAPE BR. Canoas. Vol4, nº 4 (2006), p. 1-13.

FERREIRA, Fernanda ; MOURA, Ana ; QUEIROZ, Gabriela - Geoprocessamento no planejamento urbano. XIII CONFIBSIG - Conferencia Iberoamericana de Sistemas de Información Geográfica [Em linha]. (2011) p. 15-30. [Consult. 13 Nov. 2023]. Disponível na WWW: < <https://www.geoproea.com.br/publicacoes/2011/geoprocessamento-no-planejamento-urbano>>

FILHO, Aguinaldo – Uso de altimetria e Imagens de satélite na diferenciação de tipos florestais [Texto policopiado]. Recife: [s.n.], 2005. Dissertação Pós-Graduação. Disponível na WWW: < [Uso de altimetria e imagens de satélite na diferenciação de tipos florestais \(1library.org\)](#)>

FLORENZANO, Teresa - Iniciação em sensorização remota. 3ª Ed. São Paulo: Oficina de Textos, 2011. 128 p. ISBN 978-857975-016-8

GOLDSTEIN, Benjamin ; POLLEY, Eric ; BRIGGS, Farren - Random Forests for Genetic Association Studies. Statistical Applications in Genetics and Molecular Biology. ISSN: 1544-6115 (7 Dez. 2011).

GOMES, Otávio - Novas Possibilidades na Caracterização de Minérios [Texto policopiado]. Rio de Janeiro: [s.n.], 2007. Tese de doutorado. Disponível na WWW: < https://www2.dbd.puc-rio.br/pergamum/tesesabertas/0312496_07_pretextual.pdf>

GOOGLE EARTH ENGINE – Classificação Supervisionada [Em linha]. [Consult. 13 de Nov. 2023]. Disponível na WWW: < <https://developers.google.com/earth-engine/guides/classification>>

GOOGLE EARTH SOLIDÁRIO - Introdução ao Google Earth Engine [Em linha]. [Consult. 10 Set. 2023]. Disponível na WWW: < <https://www.google.com/earth/outreach/learn/introduction-to-google-earth-engine/>>

GORELICK, Noel – *Google Earth Engine* [Em linha]. [Consult. 24 Set. 2023]. Disponível na WWW: < https://projects.listic.univ-smb.fr/seminaires/EarthEngine_LISTIC.21062016.pdf>

GORELICK, Noel - Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment* [Em linha]. Volume 202. N° 3 (Dez. 2017), P. 18-27. [Consult. 10 Set. 2023]. Disponível na WWW: ISSN 0034-4257

GRANDEZZI, Mariana *et al.* - Aplicação do geoprocessamento na análise da Infraestrutura de transporte existente para o acesso aos portos brasileiros. XLIV CONGRESSO BRASILEIRO DE EDUCAÇÃO EM ENGENHARIA [Em linha]. (2016). [Consult. 13 Nov. 2023]. Disponível na WWW: < https://www.mackenzie.br/fileadmin/OLD/62/ARQUIVOS/PUBLIC/user_upload/_imported/fileadmin/LA_BGEO/Trabalhos/Cobenge2016/APLICACAO_DO_GEOPROCESSAMENTO_NA_ANALISE_DA_INFRAESTRUTURA_DE_TRANSPORTE_EXISTENTE_PARA_O_ACESSO_AOS_PORTOS_BRASILEIROS.pdf>

TIMOFEEV, Roman- Classification and Regression Tree (CART) Theory and Applications. Berlin: CASE, 2004. Tese mestrado. Disponível na WWW: <[https://d1wqtxts1xzle7.cloudfront.net/38106508/timofeev-libre.pdf?1436189003=&response-content-](https://d1wqtxts1xzle7.cloudfront.net/38106508/timofeev-libre.pdf?1436189003=&response-content-disposition=inline%3B+filename%3DClassification_and_Regression_Trees_CART.pdf&Expires=1700190560&Signature=Ah5g9CMV2rhrnLkLlVrkMLgkIv~YMza0p4I6fN~-MLJQgzJ5Ebn1e3xGOMAwgwuDB-ZNwGvH48br0mp1RquMla-qj-bxTV1hx0d~qp8qeHp~PxpAZVKMycWf4Y02zv5tqOpuO~hvZFW9MkJZaEyDiHa4ivZkAB3B-RcOURvkYTzoN0A-CDkGzONHSU92~KviBDtImrxEXHklao49cmrVWD1wZMUnCVt3xng5vbHzE6T4VZBRHzQXXFzrE93b5L1Kf1R4egEHiqOTY4Lvdnul8PU~oQoPaKew6Uwir7v4-JUyKIS2-oyW1EmfthSegBlf34YGtjq4jBZu~sb6eOgBQ__&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA)

[disposition=inline%3B+filename%3DClassification_and_Regression_Trees_CART.pdf&Expires=1700190560&Signature=Ah5g9CMV2rhrnLkLlVrkMLgkIv~YMza0p4I6fN~-MLJQgzJ5Ebn1e3xGOMAwgwuDB-](https://d1wqtxts1xzle7.cloudfront.net/38106508/timofeev-libre.pdf?1436189003=&response-content-disposition=inline%3B+filename%3DClassification_and_Regression_Trees_CART.pdf&Expires=1700190560&Signature=Ah5g9CMV2rhrnLkLlVrkMLgkIv~YMza0p4I6fN~-MLJQgzJ5Ebn1e3xGOMAwgwuDB-ZNwGvH48br0mp1RquMla-qj-bxTV1hx0d~qp8qeHp~PxpAZVKMycWf4Y02zv5tqOpuO~hvZFW9MkJZaEyDiHa4ivZkAB3B-RcOURvkYTzoN0A-CDkGzONHSU92~KviBDtImrxEXHklao49cmrVWD1wZMUnCVt3xng5vbHzE6T4VZBRHzQXXFzrE93b5L1Kf1R4egEHiqOTY4Lvdnul8PU~oQoPaKew6Uwir7v4-JUyKIS2-oyW1EmfthSegBlf34YGtjq4jBZu~sb6eOgBQ__&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA)

[ZNwGvH48br0mp1RquMla-qj-](https://d1wqtxts1xzle7.cloudfront.net/38106508/timofeev-libre.pdf?1436189003=&response-content-disposition=inline%3B+filename%3DClassification_and_Regression_Trees_CART.pdf&Expires=1700190560&Signature=Ah5g9CMV2rhrnLkLlVrkMLgkIv~YMza0p4I6fN~-MLJQgzJ5Ebn1e3xGOMAwgwuDB-ZNwGvH48br0mp1RquMla-qj-bxTV1hx0d~qp8qeHp~PxpAZVKMycWf4Y02zv5tqOpuO~hvZFW9MkJZaEyDiHa4ivZkAB3B-RcOURvkYTzoN0A-CDkGzONHSU92~KviBDtImrxEXHklao49cmrVWD1wZMUnCVt3xng5vbHzE6T4VZBRHzQXXFzrE93b5L1Kf1R4egEHiqOTY4Lvdnul8PU~oQoPaKew6Uwir7v4-JUyKIS2-oyW1EmfthSegBlf34YGtjq4jBZu~sb6eOgBQ__&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA)

[bxTV1hx0d~qp8qeHp~PxpAZVKMycWf4Y02zv5tqOpuO~hvZFW9MkJZaEyDiHa4ivZkAB3B-](https://d1wqtxts1xzle7.cloudfront.net/38106508/timofeev-libre.pdf?1436189003=&response-content-disposition=inline%3B+filename%3DClassification_and_Regression_Trees_CART.pdf&Expires=1700190560&Signature=Ah5g9CMV2rhrnLkLlVrkMLgkIv~YMza0p4I6fN~-MLJQgzJ5Ebn1e3xGOMAwgwuDB-ZNwGvH48br0mp1RquMla-qj-bxTV1hx0d~qp8qeHp~PxpAZVKMycWf4Y02zv5tqOpuO~hvZFW9MkJZaEyDiHa4ivZkAB3B-RcOURvkYTzoN0A-CDkGzONHSU92~KviBDtImrxEXHklao49cmrVWD1wZMUnCVt3xng5vbHzE6T4VZBRHzQXXFzrE93b5L1Kf1R4egEHiqOTY4Lvdnul8PU~oQoPaKew6Uwir7v4-JUyKIS2-oyW1EmfthSegBlf34YGtjq4jBZu~sb6eOgBQ__&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA)

[RcOURvkYTzoN0A-](https://d1wqtxts1xzle7.cloudfront.net/38106508/timofeev-libre.pdf?1436189003=&response-content-disposition=inline%3B+filename%3DClassification_and_Regression_Trees_CART.pdf&Expires=1700190560&Signature=Ah5g9CMV2rhrnLkLlVrkMLgkIv~YMza0p4I6fN~-MLJQgzJ5Ebn1e3xGOMAwgwuDB-ZNwGvH48br0mp1RquMla-qj-bxTV1hx0d~qp8qeHp~PxpAZVKMycWf4Y02zv5tqOpuO~hvZFW9MkJZaEyDiHa4ivZkAB3B-RcOURvkYTzoN0A-CDkGzONHSU92~KviBDtImrxEXHklao49cmrVWD1wZMUnCVt3xng5vbHzE6T4VZBRHzQXXFzrE93b5L1Kf1R4egEHiqOTY4Lvdnul8PU~oQoPaKew6Uwir7v4-JUyKIS2-oyW1EmfthSegBlf34YGtjq4jBZu~sb6eOgBQ__&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA)

[CDkGzONHSU92~KviBDtImrxEXHklao49cmrVWD1wZMUnCVt3xng5vbHzE6T4VZBRHzQXXFzrE93b5L1Kf1](https://d1wqtxts1xzle7.cloudfront.net/38106508/timofeev-libre.pdf?1436189003=&response-content-disposition=inline%3B+filename%3DClassification_and_Regression_Trees_CART.pdf&Expires=1700190560&Signature=Ah5g9CMV2rhrnLkLlVrkMLgkIv~YMza0p4I6fN~-MLJQgzJ5Ebn1e3xGOMAwgwuDB-ZNwGvH48br0mp1RquMla-qj-bxTV1hx0d~qp8qeHp~PxpAZVKMycWf4Y02zv5tqOpuO~hvZFW9MkJZaEyDiHa4ivZkAB3B-RcOURvkYTzoN0A-CDkGzONHSU92~KviBDtImrxEXHklao49cmrVWD1wZMUnCVt3xng5vbHzE6T4VZBRHzQXXFzrE93b5L1Kf1R4egEHiqOTY4Lvdnul8PU~oQoPaKew6Uwir7v4-JUyKIS2-oyW1EmfthSegBlf34YGtjq4jBZu~sb6eOgBQ__&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA)

[R4egEHiqOTY4Lvdnul8PU~oQoPaKew6Uwir7v4-JUyKIS2-](https://d1wqtxts1xzle7.cloudfront.net/38106508/timofeev-libre.pdf?1436189003=&response-content-disposition=inline%3B+filename%3DClassification_and_Regression_Trees_CART.pdf&Expires=1700190560&Signature=Ah5g9CMV2rhrnLkLlVrkMLgkIv~YMza0p4I6fN~-MLJQgzJ5Ebn1e3xGOMAwgwuDB-ZNwGvH48br0mp1RquMla-qj-bxTV1hx0d~qp8qeHp~PxpAZVKMycWf4Y02zv5tqOpuO~hvZFW9MkJZaEyDiHa4ivZkAB3B-RcOURvkYTzoN0A-CDkGzONHSU92~KviBDtImrxEXHklao49cmrVWD1wZMUnCVt3xng5vbHzE6T4VZBRHzQXXFzrE93b5L1Kf1R4egEHiqOTY4Lvdnul8PU~oQoPaKew6Uwir7v4-JUyKIS2-oyW1EmfthSegBlf34YGtjq4jBZu~sb6eOgBQ__&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA)

[oyW1EmfthSegBlf34YGtjq4jBZu~sb6eOgBQ__&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA](https://d1wqtxts1xzle7.cloudfront.net/38106508/timofeev-libre.pdf?1436189003=&response-content-disposition=inline%3B+filename%3DClassification_and_Regression_Trees_CART.pdf&Expires=1700190560&Signature=Ah5g9CMV2rhrnLkLlVrkMLgkIv~YMza0p4I6fN~-MLJQgzJ5Ebn1e3xGOMAwgwuDB-ZNwGvH48br0mp1RquMla-qj-bxTV1hx0d~qp8qeHp~PxpAZVKMycWf4Y02zv5tqOpuO~hvZFW9MkJZaEyDiHa4ivZkAB3B-RcOURvkYTzoN0A-CDkGzONHSU92~KviBDtImrxEXHklao49cmrVWD1wZMUnCVt3xng5vbHzE6T4VZBRHzQXXFzrE93b5L1Kf1R4egEHiqOTY4Lvdnul8PU~oQoPaKew6Uwir7v4-JUyKIS2-oyW1EmfthSegBlf34YGtjq4jBZu~sb6eOgBQ__&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA)

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE) (2021) - Amazônia Legal: O que é [Em linha]. [Consult. 06 Nov. 2022^a]. Disponível na WWW: <<https://www.ibge.gov.br/geociencias/cartas-e-mapas/mapas-regionais/15819-amazonia-legal.html?=&t=o-que-e>>

REFERÊNCIAS BIBLIOGRÁFICAS

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE) - Sensorização Remota [Em linha]. [Consult. 06 Nov.2022^b]. Disponível na WWW: <<https://atlascolar.ibge.gov.br/conceitos-gerais/o-que-e-cartografia/sensorizacao-remota.html>>

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE) – Território Brasil/Amazonas/Lábrea [Em linha]. [Consult. 16 Out. 2023]. Disponível na WWW: <<https://cidades.ibge.gov.br/brasil/am/labrea/panorama>>

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE) – DETER [Em linha]. [Consult. 20 Out. 2022]. Disponível na WWW: <<http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/deter/deter>>

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE) – Amazônia Legal 2022 [Em linha]. [Consult. 20 Out. 2023]. Disponível na WWW: <https://geoftp.ibge.gov.br/organizacao_do_territorio/estrutura_territorial/amazonia_legal/2022/Mapa_da_Amazonia_Legal_2022_sem_sedes.pdf>

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS E COORDENAÇÃO GERAL DE OBSERVAÇÃO DA TERRA (INPE E OBT) - Monitoramento de Floresta Amazônica por Satélite [Em linha]. [Consult. 20 Out. 2022]. Disponível na WWW: <http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes/pdfs/apresentacao_prodes-1.pdf>

JENSEN, John - Sensorização Remota Do Ambiente: Uma Perspectiva em Recursos Terrestres. 2ªEd. São José dos Campos: Parêntese, 2009. 598 p. ISBN: 978-85-60507-06-1

KOGUT, Petro - Bandas De Landsat 8: Combinações De Imagens De Satélite [Em linha]. [Consult. 08 Nov. 2022]. Disponível na WWW:< <https://eos.com/pt/blog/bandas-de-landsat-8/>>

KUMAR, Xindong – The top ten algorithms in data mining [Em linha]. 1ª ed., Florida: A chapman&hall book, 2009.[Consult. 16 nov.2023]. Disponível na WWW: < [https://books.google.com.br/books?hl=pt-BR&lr=&id=_kcEnc9kYAC&oi=fnd&pg=PA179&dq=Classification+and+Regression+Trees+\(CART\)&ots=eU0avgRMck&sig=SBAS5UurJLDrMg5rjPqIG2_UUQco#v=onepage&q=Classification%20and%20Regression%20Trees%20\(CART\)&f=false](https://books.google.com.br/books?hl=pt-BR&lr=&id=_kcEnc9kYAC&oi=fnd&pg=PA179&dq=Classification+and+Regression+Trees+(CART)&ots=eU0avgRMck&sig=SBAS5UurJLDrMg5rjPqIG2_UUQco#v=onepage&q=Classification%20and%20Regression%20Trees%20(CART)&f=false)>. ISBN 978-1-4200-8964-6

LEI nº 12.651. Cartilha Código Florestal. (17/03/16) 1-20.

LEITE, Maria Beatriz Ayello - Floresta Amazônica-Localização [Em linha]. [Consult. 06 Nov. 2022]. Disponível na WWW: <https://ambientes.ambientebrasil.com.br/amazonia/floresta_amazonica/floresta_amazonica_-_localizacao.html>

LIMA, Bruno – O papel dos sistemas de informação geográfica (SIG) na construção de cidades inteligentes [Em linha]. 2022. [Consult. 13 de Nov. 2023]. Disponível em WWW: < <https://blogdaengenharia.com/engenharia/o-papel-dos-sistemas-de-informacao-geografica-sig-na-construcao-de-cidades-inteligentes/>>

MAPBIOMAS - Relatório Anual de Desmatamento 2021. São Paulo, Brasil: MapBiomass, 2022. 126 p.

MAPBIOMAS - Relatório Anual de Desmatamento 2022. São Paulo, Brasil: MapBiomass, 2023. 125 p.

MAYA, Anthony – Influência da sazonalidade climática no levantamento do uso e cobertura do solo, com uso de geotecnologias, em uma bacia hidrográfica do semiárido [Texto policopiado]. Fortaleza [s.n.], 2015. Dissertação de mestrado. Disponível na WWW: < <https://1library.org/document/y6e7n35z-influencia-sazonalidade-climatica-levantamento-cobertura-bacia-hidrografica-semiarido.html>>

MOUNTRAKIS, Giorgos ; IM, Jungho ; OGOLE, Caesar – Support vector machine in remote sensing: A review. ISPRS Journal of Photogrammetry and Remote Sensing. ISSN: 0924-2716 (01 Nov. 2010) 247-259.

NAGANNA, Sujay *et al.* - On the evaluation of the gradient tree boosting model for groundwater level forecasting. Knowledge-Based Engineering and Sciences. ISSN: 2788-7839 (31 Dez. 2020) 48–57.

NÚCLEO DE HIDROMETRIA - Geoprocessamento aplicado aos recursos hídricos [Em linha]. [Consult. 13 Nov. 2023]. Disponível na WWW: < <http://nh.eesc.usp.br/geoprocessamento-aplicado-aos-recursos-hidricos/>>

OLIVEIRA, Guilherme *et al.* - Classificação supervisionada como ferramenta para avaliação da dinâmica do uso e cobertura do solo. Enciclopedia Biosfera [Em linha]. Vol. 10 n° 18 (2014). [Consult. 29 Maio. 2023]. Disponível na WWW: <https://www.conhecer.org.br/enciclop/2014a/AGRARIAS/Classificacao%20supervisionada.pdf>

OSISANWO, F. *et al.* - Supervised Machine Learning Algorithms: Classification and Comparison. International Journal of Computer Trends and Technology (IJCTT). ISSN: 2231-2803 (2017) 128-138.

PAMBOUKIAN, Sergio – Classificação supervisionada [Em linha]. [Consult. 15 Nov. 2023]. Disponível na WWW: < https://moodle.isep.ipp.pt/pluginfile.php/288542/mod_resource/content/4/Guia_Referencias_Bibliograficas.pdf>

PENA, Rodolfo - Desmatamento no Brasil [Em linha]. [Consult. 06 Nov. 2022]. Disponível na WWW: <<https://escolakids.uol.com.br/geografia/desmatamento-no-brasil.htm>>

PESSOA, M. *et al.* - Detecção de áreas de clareiras na Floresta Amazônica através de monitoramento via satélite usando técnicas de aprendizagem de máquina. Anais do XLVI Seminário Integrado de Software e Hardware [Em linha]. Vol. 46 (2019), p. 125-136. [Consult. 01 Nov. 2022]. Disponível na: ISSN 2595-6205

REFERÊNCIAS BIBLIOGRÁFICAS

PINTO, Kimberlly - Uso de geotecnologias para detecção de desmatações [Texto policopiado]. São Paulo: [s.n.], 2023. Trabalho de conclusão de curso.

REBOUÇAS, Sílvia ; SOUSA, Lisete ; PIRES, Ana - Metodologias de classificação supervisionada para análise de dados de *microarrays* [Em linha]. Lisboa: 2009. [Consult. 13 de Nov. 2023]. Disponível na WWW: < <http://ceaul.org/wp-content/uploads/2018/10/ReboucasSousaPires-2009.pdf>>

REMIGIO, Matheus – Modelos de classificação [Em linha]. 2020. [Consult. 13 de Nov. 2023]. Disponível em WWW: < <https://medium.com/@msremigio/modelos-de-classifica%C3%A7%C3%A3o-8cea27df4a3>>

RODRIGUES, Thaise - Detecção de desmatações no oeste da bahia com dados de radar (sentinel-1a) utilizando a plataforma *Google Earth Engine* [Texto policopiado]. Brasília: [s.n.], 2018. Dissertação de mestrado.

RUDORFF, Bernardo - Produtos de sensorização remota [Em linha]. [Consult. 16 Nov. 2022]. Disponível na WWW: <<http://www3.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm#top>>

SANTOS, Adeisany *et al.* - Métodos de classificação supervisionada aplicados no uso e ocupação do solo no município de Presidente Médice – RO. Revista Biodiversidade [Em linha]. Vol. 18, nº 1 (2019), p. 150-159. [Consult. 16 Nov. 2022] Disponível na: ISSN 2177-1332

SANTOS, Alexandre; PELUZIO, Telma; SAITO, Nathália - Spring 5.1.2 Passo a Passo: Aplicações Práticas. 1ª Ed. Alegre: CAUFES. 2010. 155 p. ISBN 978-85-61890-06-3

SARTORIO, Letícia *et al.* - Análise de desempenho da metodologia automática para detecção retroativa do desmatamento na Amazônia: etapa Rondônia. Anais do XIX Simpósio Brasileiro de Sensorização Remota [Em linha]. Vol. 19 (2019). [Consult. 01 Out. 2022]. Disponível na: ISBN: 978-85-17-00097-3

SHIHONG, Yue ; PING, Li ; PEIYI, Hao - SVM classification : its contents and challenges. Appl. Math. Chin. Univ. ISSN: 1005-1031 (2003) 332-342.

STEFFEN, Carlos - Introdução ao sensorização remota [Em linha]. [Consult. 16 Nov. 2022]. Disponível na WWW: <http://www3.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm#top>

TRUONG, Viet-Hung *et al.*- A robust method for safety evaluation of steel trusses using Gradient Tree Boosting algorithm. Advances in Engineering Software. ISSN: 0965-9978 (2020) 102825.

UNIVERSIDADE FEDERAL DE PELOTAS (UFPeL). Introdução ao *Google Earth Engine*. 2020. Acessível no portal do Laboratório de Geotecnologias/CDTec/UFPeL, Pelotas, Brasil

VALE, Jones - Análise da dinâmica do uso e cobertura da terra nas áreas desflorestadas do estado do Pará por meio da plataforma *Google Earth Engine*. [Texto policopiado]. Belém: [s.n.], 2019. Trabalho de conclusão de curso.

VALE, Jones *et al.* - Análise comparativa de métodos de classificação supervisionada aplicada ao mapeamento da cobertura do solo no município de Medicilândia. *InterEspaço: Revista de Geografia e Interdisciplinaridade*, [Em linha]. Vol. 4, n. 13, p. 26–44. [Consult. 01 Nov. 2018]. Disponível na: ISSN 2446-6549

VENTURIERI, Adriano. Curso de introdução às técnicas de sensorização remota. Belém, 2007. 84 p. [Consult. 16 Nov. 2022]. Disponível na WWW: < <https://silo.tips/download/curso-de-introducao-as-tecnicas-de-sensorizacao-remota>>

VERÇOSA, João Pedro *et al.* - Uso de sensorização remota e de dados oriundos do projeto mapbiomas para análise do desmatamento no município de Rio Largo/AL. *Estudos Avançados sobre Saúde e Natureza* [Em linha]. Vol. 1 (2021). [Consult. 01 Nov.2022]. Disponível na: ISBN: 978-65-994725-2-7

APÊNDICE A

Script elaborado em Python para obtenção das coordenadas da cidade de Lábrea/AM:

```
# Abra o arquivo coordenadas.txt para leitura
with open('coordenadas.txt', 'r') as arquivo:
    # Leia o conteúdo do arquivo
    coordenadas_originais = arquivo.read()

# Divide as coordenadas em uma lista
coordenadas_lista = coordenadas_originais.split()

# Inicializa uma lista para armazenar as coordenadas no formato desejado
coordenadas_formatadas = []

# Variavel auxiliar para pegar somente determinadas coordenadas
i=0

# Itera sobre as coordenadas originais e as formata no novo formato
for coordenada in coordenadas_lista:
    # Divide cada coordenada em longitude, latitude e altitude
    partes = coordenada.split(',')

    # Extrai a longitude, latitude e ignora a altitude
    latitude = float(partes[0])
```

APÊNDICE A

```
longitude = float(partes[1])

# Formata a coordenada no novo formato
coordenada_formatada = f"[{latitude},{longitude}]"

# Somente os multiplos de 2 entram nas coordenadas formatadas
if i%2==0:
    # Adiciona a coordenada formatada à lista
    coordenadas_formatadas.append(coordenada_formatada)

i+=1

# Junta as coordenadas formatadas em uma única string, separadas por
vírgula
resultado = ','.join(coordenadas_formatadas)

# Abre um novo arquivo para escrita (ou cria um novo se não existir)
with open('coordenadas_formatadas.txt', 'w') as arquivo_saida:
    # Escreve o resultado no arquivo de saída
    arquivo_saida.write(resultado)

# Indica que o processo foi concluído
print("As coordenadas formatadas foram salvas em
coordenadas_formatadas.txt")
```

APÊNDICE B

Script elaborado no Google Earth Engine Code Editor para classificação supervisionada:

```
var areaDeInteresse = ee.Geometry.Polygon([
  //colocar coordenadas
]);

// Filtrar a coleção da imagem dentro do polígono e data especificados
var imagens = ee.ImageCollection('LANDSAT/LC08/C02/T1_L2')
  .filterBounds(areaDeInteresse)
  .filterDate('2022-07-01', '2022-07-31')
  .filterMetadata('CLOUD_COVER', 'less_than', 10);
Map.addLayer(imagens, {bands: ['SR_B5', 'SR_B6', 'SR_B7'], max: 65455
}, 'image');

// Mesclar as coleções de features (classes) como antes
var classes =
areaurbana.merge(agua).merge(soloexposto).merge(vegetacao);

// Criar dados de treinamento usando map
var bands = ['SR_B2', 'SR_B3', 'SR_B4', 'SR_B5', 'SR_B6', 'SR_B7'];

var training = imagens.map(function (imagem) {
  var amostras = imagem.select(bands).sampleRegions({
    collection: classes,
```

APÊNDICE B

```
    properties: ['landcover'],
    scale: 30
  });

  return amostras;
}).flatten();

// Exibir dados de treinamento
print(training);

// Treinar o classificador
var classifier = ee.Classifier.smileCart().train({
  features: training,
  classProperty: 'landcover',
  inputProperties: bands
});

// Executar a classificação em todas as imagens da coleção
var classificadas = imagens.map(function (imagem) {
  var classificada = imagem.select(bands).classify(classifier);
  return classificada.rename('classification')
    .set('system:time_start', imagem.get('system:time_start'))
    .clip(areaDeInteresse); //Para mostrar toda a área, excluir/comentar
a linha 46 e colocar ; na linha 45
});

// Exibir a classificação das imagens
print(classificadas);

// Exibir a coleção de imagens classificadas
```

```

Map.centerObject(areaDeInteresse, 11);

Map.addLayer(classificadas, {min: 0, max: 3, palette: ['yellow', 'blue',
'red', 'green']}, 'classification');

Map.addLayer(classes);

// Mosaico das imagens classificadas em uma única imagem
var mosaicClassified = classificadas.mosaic();

print(mosaicClassified);

// CALCULO AREA -----
// Defina as cores das classes
var classColors = [0, 1, 2, 3];

// Loop através de cada cor e calcular a área
classColors.forEach(function(cor) {
  var areaImagem = mosaicClassified.eq(cor);
  var areaPixels = areaImagem.reduceRegion({
    reducer: ee.Reducer.sum(),
    geometry: areaDeInteresse,
    scale: 30,
    maxPixels: 10e12
  });

  var
                                areaM2
                                =
ee.Number(areaPixels.get('classification')).multiply(ee.Number(30*30))
;

  var areaHectare = areaM2.divide(1e4);

  print('Área de ' + cor + ': ', areaHectare);

```

APÊNDICE B

```
});

// EXPORTAÇÃO -----
// Exportar a imagem mosaico das classificações para o Google Drive
var exportConfig = {
    image: mosaicClassified,
    description: 'classe_labrea_AM', // Nome do arquivo de saída
    folder: 'GEE_EXPORT', // Nome da pasta no Google Drive
    scale: 10, // Resolução espacial em metros
    region: imagens.geometry().getInfo(),
    crs: 'EPSG:4326', // Sistema de coordenadas de saída (WGS84)
    maxPixels: 10e12
};

Export.image.toDrive(exportConfig);
```