UNIVERSIDADE FEDERAL DO PARANÁ

CLÓVIS CECHIM JÚNIOR

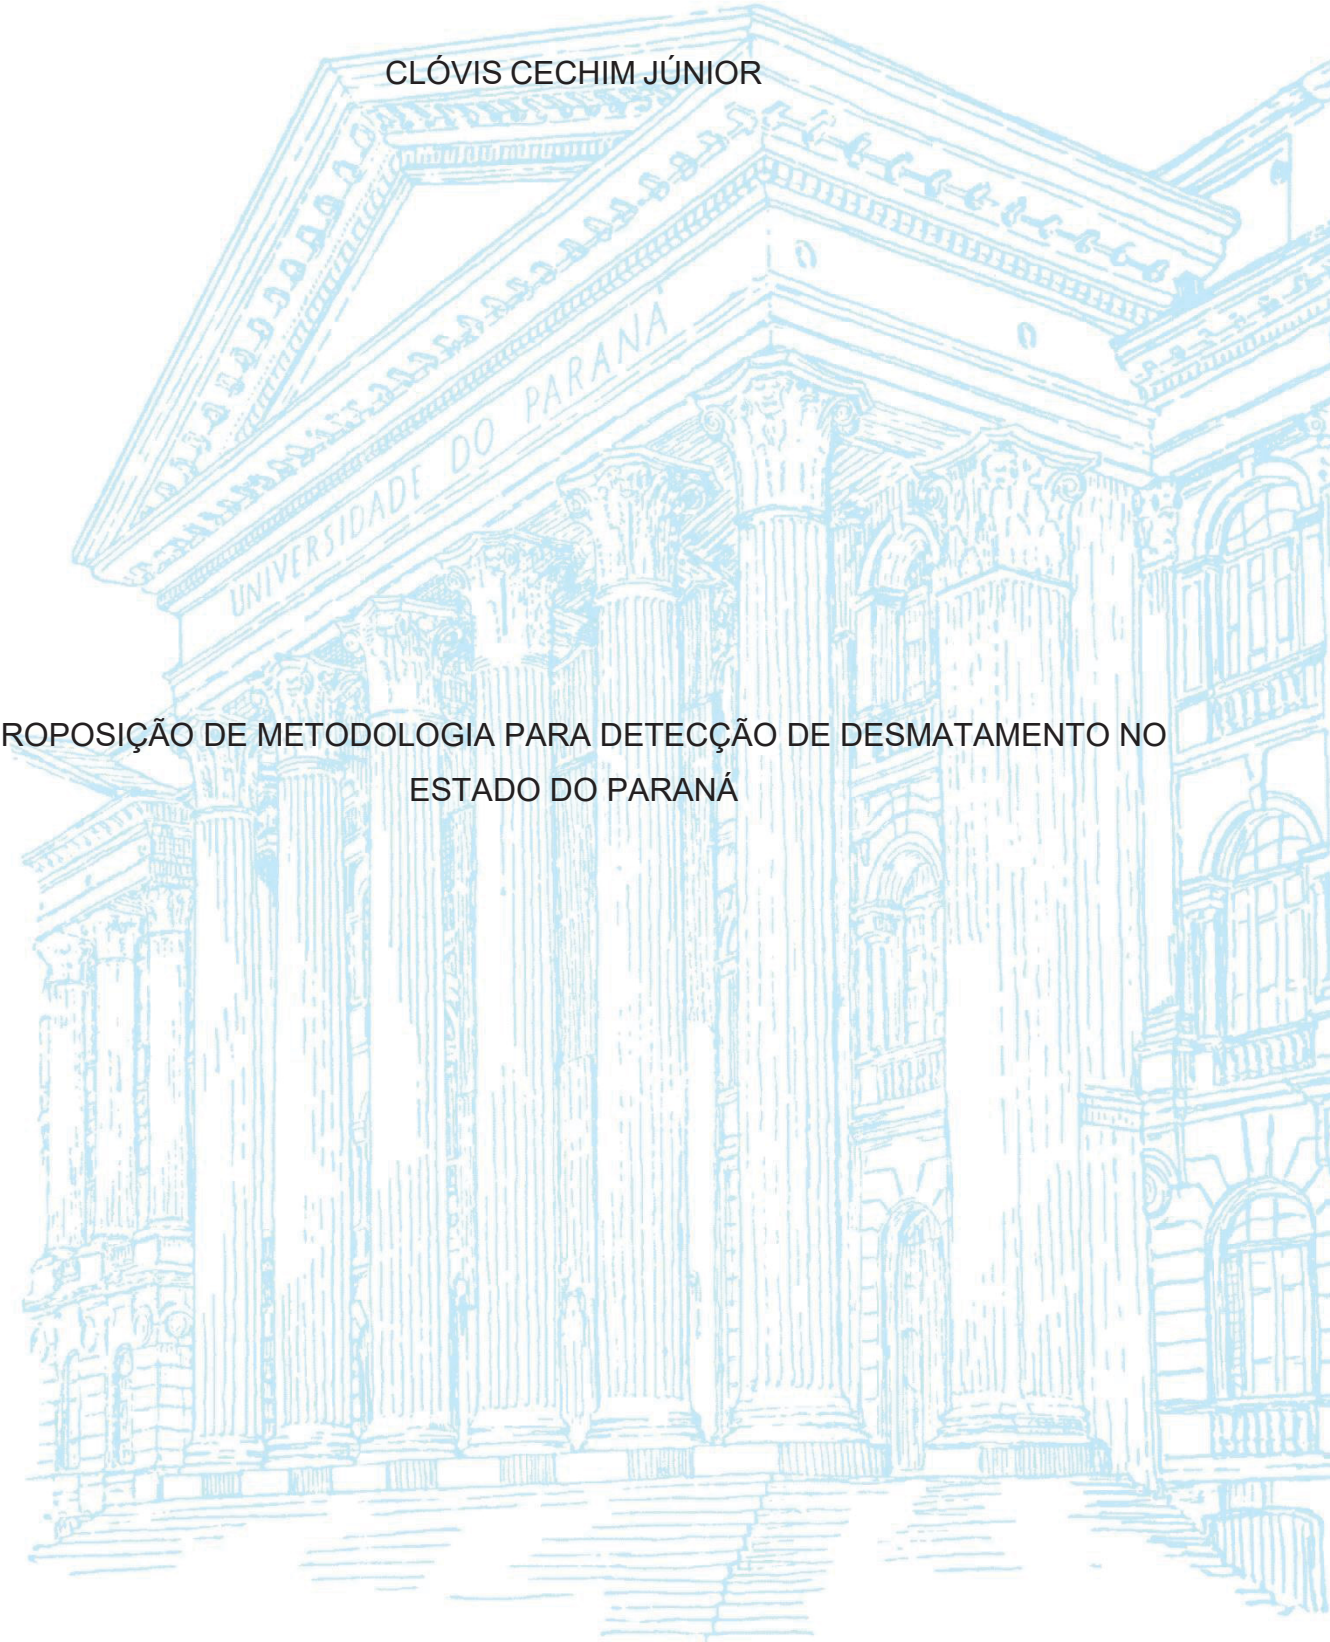

PROPOSIÇÃO DE METODOLOGIA PARA DETECÇÃO DE DESMATAMENTO NO ESTADO DO PARANÁ

CURITIBA - PR

2025

CLÓVIS CECHIM JÚNIOR

PROPOSIÇÃO DE METODOLOGIA PARA DETECÇÃO DE DESMATAMENTO NO ESTADO DO PARANÁ

Tese apresentada ao curso de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra, Área de concentração Fotogrametria e Sensoriamento Remoto, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Ciências Geodésicas.

Orientador: Prof. Dr. Hideo Araki
Coorientador: Prof. Dr. Rodrigo Campos Macedo

CURITIBA - PR
2025

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP)
UNIVERSIDADE FEDERAL DO PARANÁ
SISTEMA DE BIBLIOTECAS – BIBLIOTECA DE CIÊNCIA E TECNOLOGIA

Cechim Júnior, Clóvis
Proposição de metodologia para detecção de desmatamento no estado do Paraná / Clóvis Cechim Júnior. – Curitiba, 2025.
1 recurso on-line : PDF.

Tese (Doutorado) - Universidade Federal do Paraná, Setor de Ciências da Terra, Programa de Pós-Graduação em Ciências Geodésicas.

Orientador: Hideo Araki
Coorientador: Rodrigo Campos Macedo

1. Sensoriamento remoto. 2. Desmatamento – Paraná. 3. Análise de séries temporais. I. Universidade Federal do Paraná. II. Programa de Pós-Graduação em Ciências Geodésicas. III. Araki, Hideo. IV. MacedoRodrigo Campos. V. Título.

Bibliotecário: Elias Barbosa da Silva CRB-9/1894

MINISTÉRIO DAEDUCAÇÃO
SETOR DE CIENCIAS DA TERRA
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO CIÊNCIAS GEODÉSICAS - 40001016002P6

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação CIÊNCIAS GEODÉSICAS da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **CLOVIS CECHIM JUNIOR**, intitulada: **Proposição de metodologia para detecção de desmatamento no estado do Paraná**, sob orientação do Prof. Dr. HIDEO ARAKI, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de doutor está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 26 de Fevereiro de 2025.

Assinatura Eletrônica
26/02/2025 16:50:10.0
HIDEO ARAKI
Presidente da Banca Examinadora

Assinatura Eletrônica
26/02/2025 18:10:31.0
SILVANA PHILIPPI CAMBOIM
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica
26/02/2025 18:09:39.0
ANA PAULA DALLA CORTE
Avaliador Externo (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica
07/03/2025 15:36:01.0
JERRY ADRIANI JOHANN
Avaliador Externo (55002867)

Documento assinado eletronicamente de acordo com o disposto na legislação federal Decreto 8539 de 08 de outubro de 2015.
Gerado e autenticado pelo SIGA-UFPR, com a seguinte identificação única: 424093
Para autenticar este documento/assinatura, acesse https://siga.ufpr.br/siga/visitante/autenticacaoassinaturas.jsp
e insira o codigo 424093

AGRADECIMENTOS

Aos professores doutores Hideo Araki e Rodrigo Macedo, pelos ensinamentos e orientações;

A Universidade Federal do Paraná (UFPR) e ao Programa de Pós-graduação em Ciências Geodésicas (PPGCG);

Ao Sistema de Tecnologia e Monitoramento Ambiental do Paraná (SIMEPAR) pela estrutura tecnológica disponibilizada durante o desenvolvimento desta pesquisa;

“Nossas dúvidas são traidoras e nos fazem perder o que, com frequência, poderíamos ganhar, por simples medo de arriscar” (SHAKESPEARE)

RESUMO

Esta pesquisa teve como proposta o desenvolvivento de um algoritmo de detecção de mudança com uso de análise harmônica para indicar as áreas de ocorrência desflorestamento e a partir do uso de séries temporais de NDVI/Sentinel2, estimar a data de ocorrência de desflorestamento, sendo utilizada a plataforma Google Earth Engine (GEE). O Mapeamento florestal de referência foi gerado para o ano de 2016, período que se iniciou a disponibilização das imagens Sentinel-2, a plataforma GEE foi usada para calcular os índices de vegetação e de fração espectral com análise de mistura espectral sendo foi definido 10 regiões espectrais para a classificação supervisionada com uso de regiões fitoecológicas e as mesorregiões do estado do Paraná. A acurácia obtida no mapeamento com o método híbrido resultou em 0,94 de Índice Kappa (IK) e 96% de Exatidão Global (EG). Este mapeamento florestal foi utilizado como referência para gerar as detecções de mudança somente dentro destes fragmentos para o ano de 2023, para validar as detecções obtidas foi utilizado dados de desflorestamento do MapBiomas, imagens Sentinel-2 e Planet, obteve-se uma EG de 98,6%. Como conclusões, verificou-se que a metodologia proposta para geração do mapeamento de floresta nativa e detecção de desflorestamento foi eficiente para ser utilizada em escala estadual e municipal sendo possível gerar detecção e identificação de desflorestamento em áreas mínimas de 100m^2 o que corresponde a um pixel de 10m de resolução espacial.

Palavras-chave: Sensoriamento remoto; desflorestamento; séries temporais.

ABSTRACT

This research proposed the development of a change detection algorithm was developed using harmonic analysis to indicate the areas of deforestation occurrence and from the use of NDVI/Sentinel2 time series, estimate the date of deforestation occurrence, using the Google Earth Engine (GEE) platform. The reference forest mapping was generated for the year 2016, the period when the Sentinel-2 images began to be available, the GEE platform was used to calculate the vegetation and spectral fraction indices with spectral mixture analysis, and 10 spectral regions were defined for supervised classification using phytoecological regions and the mesoregions of the state of Paraná. The accuracy obtained in the mapping with the hybrid method resulted in 0.94 Kappa Index (KI) and 96% Overall Accuracy (OA). This forest mapping was used as a reference to generate the detections of change only within these fragments for the year 2023, to validate the detections obtained, deforestation data from MapBiomas, Sentinel-2 and Planet images were used, a OA of 98.6% was obtained. In conclusion, it was found that the methodology proposed for generating native forest mapping and deforestation detection was efficient to be used at state and municipal scales, being possible to generate detections and identifications of deforestation in minimum areas of 100m^2, which corresponds to a pixel of 10m spatial resolution.

Keywords: Remote sensing; deforestation; time series.

LISTA DE FIGURAS

FIGURA 1 – MAPA DE PROPORÇÃO E DISTRIBUIÇÃO DE ÁREA GLOBAL FLORESTAL POR REGIÃO CLIMÁTICA, 2020.....24
FIGURA 2 – DIAGRAMA DE CLASSIFICAÇÃO POR SVM.....34
FIGURA 3 – MAPA DE LOCALIZAÇÃO DA ÁREA DE ESTUDO, ESTADO DO PARANÁ 50
FIGURA 4 – REGIÕES FITOECOLÓGICAS DO ESTADO DO PARANÁ.....51
FIGURA 5 – MOSAICO DE IMAGENS PLANET, COMPOSIÇÃO COR NATURAL (RGB-123), JUNHO DE 2016.....60
FIGURA 6 – MAPEAMENTO DE REFERÊNCIA FEITO COM IMAGENS LANDSAT, SUB-BACIA DO RIO IGUAÇU ANO DE 2015.....63
FIGURA 7 – BASE DOS LIMITES DE IMÓVEIS CADASTRADOS NO CAR NO ESTADO DO PARANÁ, 2024 64
FIGURA 8 – FLUXOGRAMA METODOLÓGICO 66
FIGURA 9 – GRADE AMOSTRAL UTILIZADO PARA VALIDAÇÃO DO MAPEAMENTO.....77
FIGURA 10 – ANALISE HARMÔNICA DE SÉRIES TEMPORAIS.....84
FIGURA 11 – TRANSFORMACAO RGB PARA HSV NO GEE 85
FIGURA 12 – ANÁLISE TEMPORAL POR NDVI DE PIXEL FLORESTAL EM IMAGENS SENTINEL-2.....87
FIGURA 13 – LOCALIZAÇÃO DA REGIÃO FITOECOLÓGICA SAVANA 89
FIGURA 14 – COMPARAÇÃO ENTRE CLASSIFICADORES RF (A), GTB (B) e CART (C) 91
FIGURE 15 – PARANÁ PHYTOECOLOGICAL REGIONS: DENSE OMBROPHILOUS FOREST, MIXED OMBROPHILOUS FOREST, SEMIDECIDUOUS SEASONALFOREST, PIONEER VEGETAL FORMATION, SAVANNA (CERRADO), STEPPE (CAMPOS SULINOS), WATER AND AREAS OF ECOTONE (CONTACT ZONES) 97
FIGURE 16 – SCHEMATIC OVERVIEW OF NATIVE FOREST MAPPING METHODOLOGICAL PROCEDURES 98
FIGURE 17 – CLASSIFICATION OF LULC BY OBIA (IMAGES FROM JUNE TO DECEMBER 2016, SENTINEL-2 105

FIGURE 18 – NATIVE FOREST MAPPING BY OBIA AND ML WITH RF (YEAR 2016, SENTINEL-2 IMAGES) 107
FIGURE 19 – ERRORS OF COMMISSION, OMISSION BY DOMAIN AND ALLOCATION COMPONENT AND QUANTITY.....109
FIGURE 20 – INTENSITY OF OMISSION ERRORS, COMMISSION AND DISAGREEMENT GLOBALSOURCE: The author (2025). 110
FIGURE 21 – COMPARISON BETWEEN AREA ESTIMATES USING SENTINEL-2 MAPPING, YEAR 2016. (A) MAP-BIOMAS AND (B) IAT 112
FIGURE 22 – STATE OF PARANÁ, SOUTHERN BRAZIL 127
FIGURE 23 – FOREST AGE MAPPING TO DISCRIMINATE REGENERATION STAGE.....131
FIGURE 24 – QUANTITATIVE AREA BY TYPE OF FOREST AND STAGES OF REGENERATION 132
FIGURE 25 – SCHEMATIC OVERVIEW OF METHODOLOGICAL PROCEDURES 134
FIGURE 26 – DEFORESTATION OCCURRENCE DENSITY MAPPING, YEAR 2023 142
FIGURE 27 – DEFORESTATION DETECTIONS IDENTIFIED IN THE SOUTH-CENTER MESOREGION OF PARANÁ IN 2023.....143
FIGURE 28 – TRANSITION FROM NATIVE FOREST STAGES TO OTHER LAND USE AND COVER CLASSES, YEAR 2016 TO 2024 145
FIGURE 29 – COMPOSITION OF MINIMUM NDVI TIME SERIES VALUES USED TO ESTIMATE DEFORESTATION DATE IN DETECTIONS IN THE NORTHWESTERN MESOREGION OF PARANÁ 146
FIGURE 30 – MINIMUM NDVI TIME SERIES WITH SENTINEL-2 FOR ESTIMATING DEFORESTATION DETECTION DATES IN GEE 147
FIGURA 31 – GERAÇÃO DE MOSAICOS E ÍNDICES ESPECTRAIS, IMAGENS SENTINEL-2 157
FIGURA 32 – PLATAFORMA WEB PARA VISUALIZAÇÃO DE DESFLORESTAMENTOS IDENTIFICADOS EM IMÓVEIS DO CAR 158
FIGURA 33 – MAPEAMENTO GERADO PELO ALGORITMO DE DETECÇÃO DE MUDANÇA DESENVOLVIDO NO GEE.....189

LISTA DE GRÁFICOS

GRÁFICO 1 – TAXA ANUAL DE EXPANSÃO FLORESTAL E DESFLORESTAMENTO, 1990-2020 25

LISTA DE QUADROS

QUADRO 1 – DIFERENÇAS ENTRE DADOS DOS SISTEMAS DE DESFLORESTAMENTO 28
QUADRO 2 – ALGORITMOS DE MACHINE LEARNING (ML) 33
QUADRO 3 – ESPECIFICAÇÕES TÉCNICAS SENTINEL-2, SATÉLITES S-2A E S-2B 58
QUADRO 4 – BANDAS ESPECTRAIS DO SENTINEL-2, SENSOR S2A E S2B 59
QUADRO 5 – CARACTERÍSTICAS DAS BANDAS ESPECTRAIS DAS IMAGENS PLANET 61
QUADRO 6 – CARACTERÍSTICAS DAS BANDAS ESPECTRAIS DAS IMAGENS RAPIDEYE 61
QUADRO 7 – BASES CARTOGRÁFICAS DE REFERÊNCIA 62
QUADRO 8 – RECURSOS COMPUTACIONAIS UTILIZADOS 65
QUADRO 9 – BLOCOS DE MOSAICOS POR DATAS DAS IMAGENS SENTINEL-2, CLASSIFICAÇÃO SUPERVISIONADA POR OBIA 68
QUADRO 10 – AJUSTE DE PARÂMETROS DO ALGORITMO MULTIRESOLUTION SEGMENTATION 69
QUADRO 11 – CLASSES DE USO E COBERTURA DO SOLO DE NÍVEL-1 71
QUADRO 12 – RELAÇÃO DE MOSAICOS POR DATAS DAS IMAGENS SENTINEL-2, USADAS PARA CLASSIFICAÇÃO POR ML NO GEE 73
QUADRO 13 – QUANTIDADE DE IMAGENS PROCESSADAS POR MESORREGIÕES PARA DETECÇÃO DE MUDANÇA NO GEE 188

LISTA DE TABELAS

TABELA 1 – NÚMERO DE ALERTAS GERADOS, SISTEMAS DE DETECÇÃO POR BIOMA 2019.....29
TABELA 2 – NÚMERO DE ALERTAS GERADOS, SISTEMAS DE DETECÇÃO POR BIOMA 2024.....30
TABELA 3 – DESCRIÇÃO DE BASES CARTOGRÁFICAS E APLICAÇÕES.....57
TABELA 4 – BANDAS ESPECTRAIS, ÍNDICES DE VEGETAÇÃO E COMPOSIÇÃO DE FRAÇÕES USADAS NO PROCESSO DE CLASSIFICAÇÃO 75
TABELA 5 – CLASSES DE USO E COBERTURA DO SOLO CLASSIFICADAS NO GEE POR ML.....76
TABELA 6 – AMOSTRAGEM ESPACIAL ET-CQDG DA DSG 2015 76
TABELA 7 – ACURÁCIA ESPACIAL DOS CLASSIFICADORES AVALIADOS 91
TABLE 8 – CHARACTERISTICS OF SENTINEL-2 MSI BANDS USED FOR OBIA .98
TABLE 9 – SPECTRAL BANDS SENTINEL-2 AND VEGETATION INDICES USED IN THE CLASSIFICATION.....101
TABLE 10 – SATELLITE SCALE COMPATIBILITY FROM ET-CQDG SPATIAL SAMPLING FROM DSG 2015 103
TABLE 11 – SPATIAL ACCURACY, KI AND OA(%) OF THE CLASSIFIERS TESTED BY ML IN GEE 106
TABLE 12 – ACCURACY ASSESSMENT CRITERIA FOR THE NATIVE FOREST CLASS 107
TABLE 13 – EVALUATION STATISTICS OF SUPERVISED CLASSIFICATION BY PHYTOECOLOGICAL REGION 108
TABLE 14 – ESTIMATION OF NATIVE FOREST AREA BY DIFFERENT SATELLITES.....111
TABLE 15 – SUCCESSIONAL STAGES OF REGENERATION FROM FOREST AGE ESTIMATION 136
TABLE 16 – DEFORESTATION DEGRADATION IMPACT INTENSITY CLASSIFICATION.....140
TABLE 17 – QUANTITIES FOR DEFORESTATION BY CU, PNHR AND INDIGENOUS LANDS (IL), STATE OF PARANÁ 144
TABLE 18 – DETECTION QUANTITIES BY FISCAL MODULES 147

TABLE 19 – CONFUSION MATRIX BETWEEN MAPBIOMAS/PLANET/SENTINEL-2 AND DEFORESTATION DATA.....148

LISTA DE ABREVIATURAS OU SIGLAS

ACP - Análise de Componentes Principais
AID - *Aerial Image Data set*
ALT - *Adaptive Linear Thresholding*
ANN - *Artificial Neural Networks*
API - Application Programming Interface
AUC - *Area Under the Curve*
AVHRR - *Advanced Very High Resolution Radiometer*
BFAST - *Breaks For Additive Season and Trend*
BI - *Brightness Index*
BOA - *Bottom-Of-Atmosphere*
BRT - *Boosted Regression Tree*
CAPSNET - *Capsule Network*
CAR - Cadastro Ambiental Rural
CART - *Classification And Regression Trees*
CBERS - Satélite Sino-Brasileiro de Recursos Terrestres
CHLRED - *Chlorophyll Red-Edge*
CI - *Colour Index Algorithm*
CMV - Classificação de Máxima Verossimilhança
CTM - Cadastro Territorial Multifinalitário
DETER - Sistema de Detecção do Desmatamento em Tempo Real
DL - *Deep Learning*
DSG - Diretoria de Serviço Geográfico
MDS - Modelo Digital de Superfície
DT - *Decision Trees*
DVI - *Difference Vegetation Index*
EG - Exatidão Global
EI - Erros de Inclusão
EM - Erro Médio
ENVI - *Environment for Visualizing Images*
EO - Erros de Omissão
ESA - *European Space Agency*
ESRI - *Environmental Systems Research Institute*

ET-CQDG - Especificação Técnica para Controle de Qualidade de Dados Geoespaciais

ETM - *Enhanced Thematic Mapper*

EVI - *Enhanced Vegetation Index*

FAO - *Food and Agriculture Organization of United Nations*

FRA - *Forest Resources Assessment*

GBDT - *Gradient Boosting Decision Tree*

GEE - Google Earth Engine

GEOBIA - Análise de Imagens Baseada em Objetos Geográficos

GFC - *Global Forest Change*

GLAD - *Global Land Analysis and Discovery*

GLAI - *Green Leaf Area Index*

GLCM - *Grey Level Co-occurrence Matrix*

GNDVI - *Green Normalized Difference Vegetation Index*

GTB - *Gradient Tree Boost*

GV - *Green Vegetation*

HANTS - *Harmonic Analysis of Time Series*

HSV - *Hue, Saturation e Value*

IA - Inteligência Artificial

IAT - Instituto Água e Terra

IBAMA - Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis

IBGE - Instituto Brasileiro de Geografia e Estatística

IC - *Index Chlorophy II*

IP - Índice de Perturbação

IFDN - Índice de Fração de Diferença Normalizado

IFI - Índice Florestal Integrado

IK - Índice Kappa

INCRA - Instituto Nacional de Colonização e Reforma Agrária Paraná

INPE - Instituto Nacional de Pesquisas Espaciais

IRS - *Indian Remote Sensing*

ISO - *International Organization for Standardization*

K-NN - *K-Nearest Neighbors*

LANDSAT - *Land Remote Sensing Satellite*

LEO - *Low Earth Orbit*
LIDAR - *Light Detection And Ranging*
LLA - Limiar Linear Adaptativo
LGBM - *Light Gradient Boosting Machine*
LISS - *Linear Imaging Self-Scanner*
LSTM - *Long Short-Term Memory Net-works*
LT - Latente Terrestre
LULC - *Land Use and Land Cover*
MARS - *Multivariate Adaptive Regression Spline*
MAXVER - Máxima Verossimilhança
MDS - Modelo Digital de Superfície
ML - *Machine Learning*
MLS - *Maximum Likelihood Classifier*
MNDblue - *Measure the amount of Chlorophy ll-AB*
MODIS - *Moderate Resolution Imaging Spectroradiometer*
MP - Ministério Público
MSI - *Multi Spectral Instrument*
MTCI - *MERIS Terrestrial Chlorophy ll Index*
NAIP - *National Agricultural Imagery Program*
NB - *Naïve Bayes*
NDFI - *Normalized Fraction Difference Index*
NDII - *Normalized Difference*
NDI45 - *Normalized Difference Index*
NDVI - *Normalized Difference Vegetation*
NDVI - *Normalized Difference Vegetation Index*
NDWI - *Normalized Difference Water Index*
NDWI2 - *Normalized Difference Water Index* 2
NIR - *Near Infrared*
NN - *Nearest Neighbor*
NOAA - *National Oceanic Atmospheric Administration*
NPV - *Non-Photosynthetic Vegetation*
OA - *Overall Accuracy*
OBIA - *Object-Based Image Analysis*
OLI - *Operational Land Imager*

PAMGIA - Plataforma de Análise e Monitoramento Geoespacial da Informação Ambiental

PCA - Principal Component Analysis (PCA)

PCT - Pontos de Controle Terrestre

PDI - Processamento Digital de Imagens

PRODES - Projeto de Monitoramento do Desmatamento da Floresta Amazônica Brasileira por Satélite

PSSR - *Pigment Specific Simple Ratio*

PV - *Photosynthetic Vegetation*

RE - *Red-Edge*

REIP - *Red-Edge Inflection Point Index*

RER - *Rural Environment Registry*

RF - *Random Forest*

RGB - Red, Green e Blue

RMSE - *Root Mean Squared Error*

RNA - Rede Neural Artificial

S - Solo exposto

S2REP - *Sentinel-2 Red-Edge Position Index*

SAD - Sistema de Alerta de Desmatamento

SAR - *Synthetic Aperture Radar*

SAVI - *Soil Adjusted Vegetation Index*

SEDEST - Secretaria do Desenvolvimento Sustentável e do Turismo

SFB - Serviço Florestal Brasileiro

SIG - Sistema de Informação Geográfica

SIGEF - Sistema de Gestão Fundiária

SINAFLOR - Sistema Nacional de Controle da Origem dos Produtos Florestais

SIPAM - Sistema de Monitoramento do Desmatamento na Amazônia por Radar

SMA - *Spectral Mixture Analysis*

SPOT - *Satellite Pour l'Observation de la Terre*

SPRING - Sistema de Processamento de Informações Georeferenciadas

SRMSI - *Simple Ratio Moisture Stress Index*

SVM - *Support Vector Machine*

SWIR - *Shortwave Infrared*

TM - *Thematic Mapper*

TS - *Time Series*

UK-DMC - *United Kingdom - Disaster Monitoring Constellation*

UNW - *United Nations World*

VCT - *Vegetation Change Tracker*

VNIR - *Visible and Near-Infrared*

WFS - *Web Feature Service*

WMS - *Web Map Service*

LISTA DE SÍMBOLOS

Σ - somatório de números

Σn_{ij} - soma das amostras da classe de referência j ocorrendo na classe i

d_r - índice de concordância refinado de Willmott

E_i - área estimada

N_i - total de amostras da classe i

O_i - área observada

$\overline{O}$ - área média de floresta nautural observada nos municípios

$\underline{O} n_{ij}$ - amostras da classe de referência j ocorrendo na classe i

pt - sazonalidade

r - coeficiente de correlação de Pearson

r_s - coeficiente de correlação de Spearman

x_{ij} - observações na linha i e coluna i

x_i - total marginal da linha i

x_j - total marginal da coluna j

ϵt - erro aleatório

ω - frequência

$\boldsymbol{\phi}$ - fase

π - (pi) constante matemática

SUMÁRIO

1 INTRODUÇÃO 16
1.1 JUSTIFICATIVA 18
1.2 PROBLEMA DE PESQUISA 19
1.3 CONTRIBUIÇÃO CIENTÍFICA 20
1.4 HIPÓTESE 21
1.5 OBJETIVOS 21
1.5.1 Objetivo geral 21
1.5.2. Objetivos específicos 22
1.6 ESTRUTURA DA TESE 22
2 REVISÃO DE LITERATURA 24
2.1 ÁREA FLORESTAL MUNDIAL 24
2.2 SISTEMAS DE DETECÇÃO DE DESFLORESTAMENTO EXISTENTES 26
2.3 CLASSIFICADORES DE IMAGENS 30
2.4 ANÁLISE DE IMAGEM ORIENTADA A OBJETO (OBIA) 31
2.5 MACHINE LEARNING (ML) 32
2.5.1 Support Vector Machine (SVM) 34
2.5.2 Árvores de decisão e Randon Forest (RF) 35
2.5.3 Gradient Tree Boost (GTB) 37
2.6 SÉRIES TEMPORAIS PARA IDENTIFICAR DESFLORESTAMENTO 38
2.6.1 Análise harmônica de séries temporais 40
2.7 GOOGLE EARTH ENGINE (GEE) 41
2.7.1 Classificação supervisionada de uso e cobertura do solo 42
2.7.2 Detecção de mudanças no GEE 43
2.8 CADASTRO TERRITORIAL MULTIFINALITÁRIO 47
2.9 SÍNTESE DO CAPÍTULO 48
3 ÁREA DE ESTUDO 49
3.1 REGIÕES FITOECOLÓGICAS DO PARANÁ 50
3.1.1 Estepe 52
3.1.2 Floresta Estacional Semidecidual 52
3.1.3 Floresta Ombrófila Densa 53
3.1.4 Floresta Ombrófila Mista 54

3.1.5 Formação Pioneira 55
3.1.6 Savana 56
4 MATERIAL E MÉTODOS 56
4.1 BASES CARTOGRÁFICAS DE REFERÊNCIA.....56
4.1.1 Imagens do satélite Sentinel-2 57
4.1.2 Imagens Planet 59
4.1.3 Bases cartográficas de referência 62
4.2 RECURSOS COMPUTACIONAIS 64
4.3 METODOLOGIA.....65
4.4 MAPEAMENTO FLORESTAL 66
4.4.1 Seleção das imagens Sentinel-2 67
4.4.2 Correção atmosférica 67
4.4.3 Seleção de bandas.....68
4.4.4 Normalização e mosaicagem 68
4.4.5 Segmentação de imagens por OBIA 69
4.4.6 Seleção de conjuntos amostrais.....70
4.4.7 Classificação supervisionada por OBIA.....70
4.4.8 Correção topológica 72
4.4.9 Classificação supervisionada por ML no GEE.....72
4.4.10 Avaliação da acurácia temática.....76
4.4.11 Estimativa de área.....79
4.5 SISTEMA DE DETECÇÃO DE DESFLORESTAMENTO.....81
4.5.1 Detecção de mudança no GEE 81
4.5.2 Identificação de desflorestamento.....85
4.5.3 Estimativa de datas de desflorestamentos 86
4.6 VALIDAÇÃO DE DESFLORESTAMENTO.....87
4.7 ANÁLISE DE IMÓVEIS RURAIS.....88
5 RESULTADOS.....88
5.1 CLASSIFICAÇÃO SUPERVISIONADA DE IMAGENS SENTINEL-2 COM MACHINE LEARNING NO GEE.....88
5.2 OBJECT-BASED IMAGE ANALYSIS (OBIA) AND MACHINE LEARNING (ML) APPLIED TO TROPICAL FOREST MAPPING USING SENTINEL-2 93
5.2.1 Abstract 93
5.2.2 Introduction.....93

5.2.3 Organization of research steps....96
5.2.4 Materials....96
5.2.5 Results and discussion....104
5.2.6 Conclusions....112
5.2.7 Acknowledgement....114
5.2.8 Disclosure statement....114
5.2.9 Funding....114
5.2.10 References....114
5.3 DEFORESTATION DETECTION SYSTEM FOR TROPICAL NATIVE FORESTS USING SENTINEL-2 IMAGES....123
5.3.1 Abstract....123
5.3.2 Introduction....123
5.3.3 Organization of research steps....126
5.3.4 Study area....127
5.3.5 Materials....128
5.3.6 Methods....134
5.3.7 Results and discussion....141
5.3.8 Acknowledgment....149
5.3.9 References....149
6 DISCUSÃO....156
7 CONCLUSÕES....160
8 RECOMENDAÇÕES FUTURAS....163
9 REFERÊNCIAS....164
10 APÊNDICE....188

1 INTRODUÇÃO

As séries de satélites orbitais atuais contam com sensores de melhor resolução espacial e resolução temporal . Adicionalmente, os custos por km^2 imageado vem passando por reduções em função da adoção de novas tecnologias e várias alternativas de fornecedores de imagens, tais como *Airbus Defense and Space*, *Digital Globe* e *European Space Agency* (ESA) (Costa *et al*., 2020), esta redução de custo se deu também em virtude do aprimoramento de sensores em plataformas menores (CubeSats) (Wu *et al*., 2021) e satélites de baixa orbita (*Low Earth Orbit - LEO*) McDowell (2020).

Estes grupos de satélites oferecem alternativas de vários satélites em operação que produzem imagens a partir de sensores ópticos passivos. Como exemplo, podem ser citados: Pleiades-A, Pleiades-B, SPOT-7, SPOT-6, SPOT-5, WorldView-2, WorldView-3, Sentinel-2. Este último, em função da adoção de constelações de dois satélites, a resolução temporal chega a ser semanal.

Os satélites Sentinel-2A e 2B geram imagens multiespectrais para aplicações no monitoramento de uso e cobertura do solo (Zeng *et al*., 2020; Eskandari *et al*., 2020). O diferencial é que estas imagens não apresentam custo de aquisição para os usuários. Porém, faz-se necessário a aplicação de técnicas de processamento de imagens para a geração e extração de informações. Além disso, as imagens destes satélites podem ser utilizadas com diversas finalidades, como, por exemplo, observar alterações dinâmicas das condições de neve e gelo (Zhou; Zheng, 2017); mapeamento de cultivos agrícolas de trigo (Zhou *et al.*, 2017); e para mapeamentos de inundação usando imagens multitemporais (Clement *et al.*, 2017).

Em função de apresentarem características multi-bandas são também utilizadas para estimativa de biomassa; classificação de florestas plantadas (silvicultura); distribuição espacial florestal em áreas urbana; mapeamento florestal e para detecção de supressão florestal (Chen *et al*., 2018; Cheng *et al*., 2019; Duan *et al*. 2019; Eskandari *et al*., 2020; Cissell *et al*., 2021). Sendo assim, a resolução temporal e espectral das imagens Sentinel-2 confere grande potencial para

aplicações em projetos que possuem o objetivo de mapear, estimar a área e identificar a evolução de mudanças de uso e ocupação do solo e detectar desflorestamentos. A detecção de desflorestamento tem um papel estratégico na gestão territorial, sua detecção e monitoramento contínuo a partir do uso de sensoriamento remoto depende, sobretudo, da resolução temporal e espacial das imagens utilizadas.

Outro aspecto se refere a várias iniciativas e projetos envolvendo instituições públicas e privadas, voltadas à geração de mapas de uso e cobertura do solo, em especial para acompanhar a perda de cobertura florestal nativa, tanto para o Estado do Paraná como para o Brasil. Existem diferentes projetos que visam identificar desflorestamento utilizando imagens de satélites, muitas destas iniciativas são desenvolvidas e implementadas utilizando grandes quantidades de dados e de séries históricas, como é o caso das imagens do satélite *Land Remote Sensing Satellite* (LANDSAT), também associados a outros sensores orbitais, utilizadas no sistema de monitoramento global do *Global Forest Change*, no projeto de Monitoramento do Desmatamento da Floresta Amazônica Brasileira por Satélite (PRODES) e SOS Mata atlântica que faz monitoramento para todo o Brasil (Fontes).

Para mapeamentos ou detecção de desflorestamento em grandes extensões territoriais, é necessário uma grande quantidade de imagens de satélites, dependendo da aplicação se faz necessário buscar e utilizar uma plataforma adequada tanto para armazenamento como para rapidez de processamento. Desta forma, uma alternativa disponível é o processamento na nuvem com o uso da plataforma do Google Earth Engine (GEE), que armazena, permite acessar e processar diferentes tipos de dados espaciais e de imagens de satélites, a partir do desenvolvimento e do uso de algoritmos e programação.

A plataforma GEE traz recursos de computação do Google para uma variedade de questões sociais de alto impacto, incluindo desflorestamento, seca, catástrofes, doenças, segurança alimentar, gestão da água, monitoramento de clima e proteção ambiental (Gorelick *et al*., 2017).

A plataforma do GEE, contém a implementação de algoritmos de Aprendizado de Máquina (*Machine Learning* - ML) (Zhou *et al*., 2020), como algoritmos supervisionados de Classificação e Regresão com o *Random Forest (RF)*, *Support Vector Machines (SVM)* e *Boosted Regression Trees* e algoritmos não supervisionados como Redes Neurais Artificias (RNA), K-Means Clustering, K-Nearest Neighbors (kNN) e Análise de Componentes Principais (ACP) (El Naqa e Murphy, 2015), o GEE também permite a integração com o TensorFlow e PyTorch para modelos de treinamento de *Deep Learning (DL).*

Pesquisas indicam sua eficiência sendo utilizadas em diferentes aplicações de mapeamento e classificação supervisionada, dentre estas pesquisas estão o mapeamento de linha costeira para diferenciar tipos de substrato de gelo; para estimar o fluxo do calor latente terrestre; mapeamento da dinâmica da cobertura do solo; classificação de uso do solo; mapeamento de áreas úmidas; monitoramento e mapeamento florestal (Banks *et al*., 2017; Wang *et al*., 2017; Huang *et al.*, 2017; Zheng *et al*., 2017; Hird *et al*., 2017; Brovelli *et al*., 2020; Waśniewski *et al*., 2020).

O GEE tem sido utilizado em diversas aplicações, na análise de cobertura e perdas florestais (Hansen *et al*., 2013), em mudanças de águas superficiais (Pekel *et al*., 2016), estimativas de colheita de culturas agrícolas (Lobell *et al*., 2015), para gerar produtos de cobertura do solo (Sousa *et al*., 2020; Zeng *et al*., 2020), classificações de tipos florestais e coníferas (Kaplan, 2021), estimativa de biomassa de plantações florestais (Theofanous *et al*., 2021), mapeamento de manguezais (Mondal *et al*., 2019), mapeamento de cobertura florestal (Ganz *et al*., 2020), estimativa florestal e detecção de mudanças (Zulfiqar *et al*., 2021) e análise de distribuição de espécies florestais (Xie *et al*., 2021).

1.1 JUSTIFICATIVA

Esta pesquisa se justifica em virtude da necessidade que estado do Paraná tem em gerar dados consistentes de desflorestamento, e como resposta propor uma

iniciativa que auxilie o combate de supressão de floresta nativa ilegal, e gere relatórios e laudos que indiquem os municípios e imóveis rurais onde ocorreram estes impactos ambientais, esta metodologia também visou auxiliar na solução para geração de informações sobre os quantitativos de floresta nativa no Estado do Paraná.

A detecção de desflorestamento a partir do desenvolvimento de uma metodologia com uso de imagens multiespectrais da série de satélites Sentinel-2 permitirá contribuir na geração de subsídios para fiscalização e cumprimento de políticas públicas de conservação ambiental em todo e qualquer licenciamento ambiental ou autorização para supressão florestal. Mais especificamente para dar suporte às atividades de monitoramento de floresta nativa, fornecendo subsídios para a concepção e auxílio no desenvolvimento de políticas públicas do Estado do Paraná, que visem à diminuição do desflorestamento.

1.2 PROBLEMA DE PESQUISA

Os métodos de detecção de supressão de floresta nativa tem certa limitação no que diz respeito ao tamanho das áreas que são detectadas que está associada à resolução espacial dos sensores orbitais utilizados. Tecnicas tradicionais de detecção de mudança frequentemente sofrem com ruídos e baixa precisão, quando aplicadas a ambientes de vegetação densa e dinâmica. A necessidade de métodos que possibilitem a analise continua e sistemática do território se torna premente para a ação de órgãos ambientais e pesquisadores que buscam incorporar ferramentas modernas de monitoramento para identificar e quantificar eventos de desflorestamento com maior acurácia.

A proposta metodológica a ser desenvolvida nesta pesquisa não é existente no Estado do Paraná, nesta escala e nível de detalhamento, desta forma pretende-se aproveitar a evolução e a qualidade da série de satélites Sentinel-2 e sua resolução espacial (10 m) e temporal (5 dias) para detectar fragmentos florestais

naturais cortadas (suprimidas) a partir de áreas mínimas de 100 m^2 em imóveis rurais, os quais não podem ser detectados por outros sensores de média (30 m) e baixa (250 m ou superior) resolução espacial.

1.3 CONTRIBUIÇÃO CIENTÍFICA

Esta pesquisa propõe um avanço inovador na detecção de desflorestamento no estado do Parana, utilizando análise harmônica de series temporias extraídas de imagens do satélite Sentinel-2, destacando a proposta metodológica a capacidade de identificar de maneira eficiente as areas afetadas pela supressão de floresta nativa contribuindo para o monitoramento e gestão ambiental. Dentre a inovação metodológica esta a aplicação da analise harmônica que permite decompor series temporais em componentes sazonais e periódicos, facilitando a identificação de anomalias associadas ao desflorestamento, caracterizadas pela resolução espacial de 10m e detcção semanal, colaborando para a transição de métodos qualitativos e quantitativos, promovendo o monitoramento continuo de florestas nativas no Parana.

A principal contribuição científica desta pesquisa consiste no fato de disponibilizar para a sociedade e estado do Paraná, e para todos os usuários, pesquisadores e órgãos ambientais, um sistema de detecção gerado a partir de imagens de satélites e tecnlogocias gratuitas, que permitam acompanhar pequenas perturbações de perdas florestais não autorizadas por órgãos de licenciamento, que contenha agilidade no processamento, sendo desenvolvido especificamente para a dinâmica florestal nativa no estado do Paraná, sistema este inexistente com estas características.

E que possa ser utilizado também em outras áreas de estudo, a partir da inserção de um mapeamento florestal de referência e que possa apoiar e servir de subsídio a outros sistemas de detecção a partir da geração das detecções e identificações de desflorestamento. Portanto permite contribuir com os avanços no conhecimento técnico sobre mapeamento de floresta nativa e sua detecção de

desflorestamento, esta informação permite estimar a área excedente de floresta nativa para ser usada como compensação ambiental de reserva legal em imóveis rurais que estejam em déficit, de acordo com a Lei 12.651/2012 e a identificação das áreas florestais propícias a licenciamento ambiental.

1.4 HIPÓTESE

Diante disto, esta pesquisa visa verificar a seguinte hipótese: O uso de analise harmônica de series temporais de imagens do satélite Sentinel-2 associado a técnicas de aprendizagem de maquina em ambiente de processamento em nuvem permitem a detecção e identificação de desflorestamentos com área mínima a partir de 100 m^2 (0,01 ha).

1.5 OBJETIVOS

A pesquisa buscou alcançar alguns propósitos, definidos como objetivos gerais - a meta principal da investigação, e específicos, que desdobram o objetivo geral de modo mais detalhado. Essas informações são apresentadas a seguir.

1.5.1 Objetivo geral

Esta pesquisa teve o objetivo desenvolver um método para detectar e identificar desflorestamento de floresta nativa tropical para áreas mínimas de 100 m^2 (0,01 ha) a partir do uso de mapeamento florestal de referência com uso de uma nova abordagem de classificação supervisionada híbrida integrando Análise Orientada a Objeto (OBIA) e *Machine Learning* (ML) com usos de imagens Sentinel-2 no Estado do Paraná.

1.5.2. Objetivos específicos

a) Mapeamento de floresta nativa utilizando Análise de Imagem Orientada em Objeto (OBIA) e *Machine Learning* (ML);

b) Determinação de datas de ocorrência de desflorestamento por análise de séries temporais de *Normalized Difference Vegetation Index* (NDVI) e aplicação de validação das áreas de desflorestamento identificadas;

c) Caracterização da dinâmica de desflorestamento e localização do imóvel com desflorestamento a partir da base de dados do Cadastro Ambiental Rural (CAR).

1.6 ESTRUTURA DA TESE

Esta tese foi estruturada em seis sessões:

No Capítulo 1 (Introdução) são introduzidos questões que são abordadas na tese, bem como a hipótese, a justificativa e os objetivos do estudo.

No Capítulo 2 (Revisão de Literatura) são abordados os principais conceitos e metodologias utilizadas.

No Capítulo 3 (Área de estudo) é apresentada a descrição da área de estudo.

No Capítulo 4 (Material e Métodos) são apresentados os dados e os recursos utilizados, os procedimentos metodológicos e as análises da qualidade, que foram empregados no desenvolvimento da pesquisa.

No Capítulo 5 são apresentados os resultados obtidos no estudo de caso usado para testar diferentes algoritmos de classificação supervisionada. Os resultados da abordagem 1 referente ao mapeamento de floresta nativa a partir de OBIA e ML. E a abordagem 2 referente a detecção de desflorestamento a partir do uso de análise harmônica de series temporais.

No Capitulo 6 são apresentadas as discussões gerais sobre o desenvolvimento desta pesquisa.

No Capítulo 7 as conclusões, a cerca dos resultados obtidos das abordagens desta pesquisa.

E no Capitulo 8 são evidenciadas as recomendações de pesquisas para trabalhos futuros.

2 REVISÃO DE LITERATURA

A presente seção busca apresentar e discutir os principais referenciais teóricos e estudos já realizados no âmbito da presente pesquisa. A partir dessa análise, pretendeu-se contextualizar o problema de investigação, fundamentar o tema de pesquisa e fornecer fundamentação teórica para sustentar a metodologia a ser proposta.

2.1 ÁREA FLORESTAL MUNDIAL

De acordo com *Food and Agriculture Organization of United Nations* (FAO, 2020) a área florestal global é de 4,06 bilhões de hectares (ha), 31% da superfície terrestre, o que equivale a 0,52 ha de área florestal por pessoa. Entretanto, esta distribuição não é igualitária entre os países do mundo ou mesmo geograficamente. A região tropical tem a maior proporção das florestas do mundo (45%), seguido pela região boreal, temperado e subtropical. Mais da metade das florestas do mundo está em apenas cinco países, Rússia (20%), Brasil (12%), Canadá (9%), EUA (8%) e China (5%), conforme pode ser visto na figura 1.

FIGURA 1 – MAPA DE PROPORÇÃO E DISTRIBUIÇÃO DE ÁREA GLOBAL FLORESTAL POR REGIÃO CLIMÁTICA, 2020

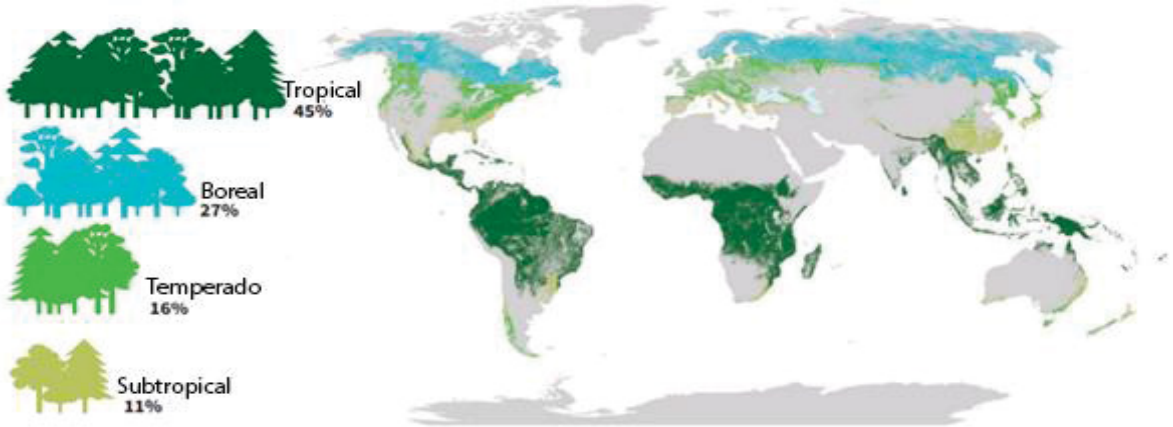

FONTE: Adaptado de *United Nations World* (UNW) (2020).

Já as florestas plantadas cobrem cerca de 131 milhões de hectares, o que representa 3% da área florestal global. A maior parcela está na América do Sul, com 99% da área total de floresta plantadas, e a menor parcela está na Europa, onde representa 0,4% da área total de floresta (FAO, 2020).

A taxa de perda florestal líquida diminuiu substancialmente no período 1990-2020 devido à redução do desflorestamento em alguns países, além de aumento na área florestal em outros a partir da arborização e da expansão nativa das florestas. A taxa de perda florestal líquida caiu de 7,8 milhões de ha por ano na década 1990-2000 a 5,2 milhões ha por ano em 2000-2010 e 4,7 milhões ha por ano em 2010-2020. A taxa de declínio da perda florestal líquida desacelerou na década 2010-2020 devido a uma redução na taxa de expansão florestal (FAO, 2020).

Estima-se que 420 milhões de ha de floresta foram perdidos em todo o mundo com o desflorestamento entre 1990 e 2020, mas a taxa de perda florestal diminuiu substancialmente. No período entre (2015-2020), a taxa anual de desflorestamento foi estimada em 10 milhões de ha, abaixo de 12 milhões ha em 2010-2015 (FAO, 2020), conforme o gráfico 1 abaixo.

GRÁFICO 1 – TAXA ANUAL DE EXPANSÃO FLORESTAL E DESFLORESTAMENTO, 1990-2020

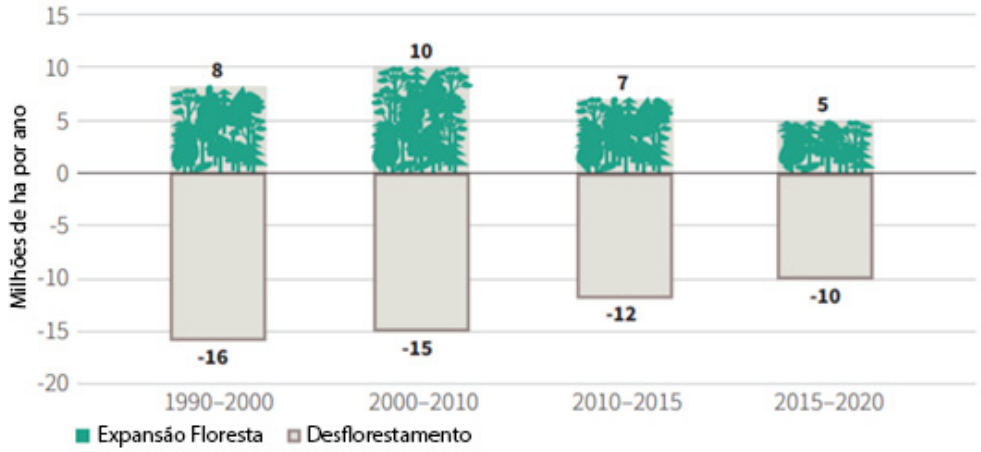

FONTE: Adaptado de UNW (2020).

A FAO define o desflorestamento como a conversão da floresta para outros usos do solo (independentemente de ser antrópico). A mudança líquida de área

florestal é a soma de todas as perdas florestais (desflorestamento) e todos os ganhos florestais (expansão da floresta) em um determinado período. A variação líquida, portanto, pode ser positiva ou negativa, dependendo se os ganhos excedem as perdas, ou vice-versa.

2.2 SISTEMAS DE DETECÇÃO DE DESFLORESTAMENTO EXISTENTES

O *Global Forest Change* (GFC) é um sistema de monitoramento global que faz uso de análise de séries temporais de imagens LANDSAT associado à tecnologia para caracterizar a extensão, perda e ganho florestal, são utilizados dados de treinamento aprimorados para calibrar o modelo de perda, modelos de avaliação de qualidade do sensor para filtrar dados de entrada e recursos espectrais aprimorados de entrada para construir e aplicar o modelo de perda (Hansen *et al*., 2013).

O GFC faz uma comparação direta de mudança, independentemente do tamanho do país ou área absoluta de dinâmica de mudança. Estudos em escala global exigem sistemática aquisição de imagens e o pré-processamento para correção geométrica e radiométrica de imagens de LANDSAT. O sistema de computação avançado, como a Google *cloud*, é eficiente para processar e caracterizar séries temporais em escala global e conjuntos de dados na quantificação da mudança de terra (Hansen *et al*., 2013).

O monitoramento operacional também é tipicamente implementado em grandes áreas, como escalas nacionais. Exemplos para o caso do Brasil incluem o Projeto de Monitoramento do Desflorestamento da Floresta Amazônica Brasileira por Satélite (PRODES), do Instituto Nacional de Pesquisas Espacial (INPE), para monitorar o desflorestamento da Amazônia Legal, desde 1988 gera taxas anuais de desflorestamento na região-(INPE, 2020).

O projeto PRODES faz o monitoramento por satélite do desflorestamento por corte raso na Amazônia Legal. Com uso de imagens de satélites LANDSAT-5,

China-Brasil Earth Resources Satellite (CBERS-2), *Indian Remote Sensing Satellite* (IRS-1) e *United Kingdom - Disaster Monitoring Constellation* (UK-DMC2). Atualmente faz uso das imagens LANDSAT-8/OLI, CBERS-4 e IRS-2. Suas estimativas são consideradas confiáveis por cientistas nacionais e internacionais, atingindo índices de acurácia próximos a 95% (INPE, 2020).

O Sistema de Detecção de Desflorestamento em Tempo Real (DETER) foi criado em 1988, também pelo INPE, para gerar taxas de desflorestamento na Amazônia, operou com base no sensor MODIS a bordo do satélite TERRA, com resolução espacial de 250m. Nesta plataforma a detecção era de áreas maiores que 25 hectares (ha), e em agosto de 2015, uma nova versão foi operada e passou a mapear desflorestamentos com área mínima próxima a 3 ha, para dar suporte à fiscalização do Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA) (Diniz *et al.*, 2015).

O SOS Mata Atlântica juntamente com o INPE faz o mapeamento das formações naturais e monitoramento do desflorestamento do Brasil, a metodologia faz uso de imagens LANDSAT-5/TM sensor (*Thematic Mapper - TM*) e LANDSAT-8/OLI sensor (*Operational Land Imager - OLI*) e do satélite IRS com interpretação visual. Os mapas gerados são validados a partir de imagens de alta resolução do Google Earth na escala de 1:50.000, sendo que a área mínima utilizada é de 3 ha, tanto para áreas alteradas (desflorestamentos) como para fragmentos florestais delimitados (SOS Mata Atlântica, 2019).

O SOS Mata Atântica divulga e gera relatórios (Atlas da Mata Atlântica) que são referente ao monitoramento da vegetação e uso do solo, executados pela empresa ArcPlan. Os dados produzidos são públicos para os governos federais, estaduais e municipais, órgãos de fiscalização, associações e organizações não governamentais, universidades e instituições de pesquisa (SOS Pantanal, 2021).

O MapBiomas Alerta é um sistema de validação, refinamento e de visualização dos alertas de desflorestamento de todos os biomas do estados do Brasil, o objetivo é validar os alertas de desflorestamento emitidos pelo sistema de monitoramento nacionais e internacionais, como DETER/INPE (Amazônia e

Cerrado), Sistema de Alerta de Desmatamento (SAD/IMAZON) e *Global Land Analysis and Discovery* (GLAD/Univ. Maryland) (MapBiomas, 2021), conforme pode ser visualizado no quadro 1.

QUADRO 1 – DIFERENÇAS ENTRE DADOS DOS SISTEMAS DE DESFLORESTAMENTO

Variável	**PRODES Amazônia**	**PRODES Cerrado**	**ATLAS SOS Mata atlântica**	**MAPBIOMAS Alerta**
Área mínima Mapeada	6,25 ha	1 ha	3 ha	0,3 ha
Cálculo de área	Estimativas de taxas de desflorestamento	Soma das áreas observadas	Soma das áreas observadas	Soma das áreas observadas
Limite Territorial	Amazônia Legal Limites estados Acre, Amapá, Amazonas, Mato Grosso, Rondonia, Roraima e Tocantins e Maranhão	Cerrado Limites do Bioma Cerrado subtraídas das áreas de sobreposição com a Amazônia Legal	Mata Atlântica Limites que abrange todos os estados com bioma mata atlântica (Lei da Mata Atlântica)	Brasil Limites que abrange os estados e biomas do IBGE
Tipo de detecção e Tipo de Vegetação Mapeada	Supresão de floresta nativa por corte raso Vegetação florestal primária)	Supresão de floresta nativa por corte raso Vegetação existente em 2000	Supresão de floresta nativa Vegetação primária	Supresão de floresta nativa *Vegetação primária

*Vegetação primária - grande diversidade biológica com mínima ação antrópica;
*Vegetação secundária ou regeneração - formação herbáceas, arbustivas ou arbóreas decorrentes de processos naturas (estágios inicial, média e avançada).

FONTE: O autor (2024).

O MapBiomas Alerta faz uso de um conjunto de sistemas de alertas a partir de imagens de diferentes resolução espacial, o que necessita passar por um processo de validação e verificações de campo antes de serem comprovados como desflorestamento. Desta forma os alertas são refinados definindo uma janela

temporal de ocorrência, sendo gerado um laudo de identificação das imagens antes e depois do desflorestamento. O MapBiomas utiliza os sistemas disponíveis para potencializar e validar os alertas já existentes (MapBiomas, 2021).

Em 2019, de acordo com a quantificação do número de alertas gerados pelos sistemas de detecção disponíveis por Bioma, o maior número de alertas foi gerado no Bioma da Amazônia com 134.866 alertas, seguido pelo Bioma da Mata Atlântica com 14.661 alertas, conforme visualizado na tabela 1.

TABELA 1 – NÚMERO DE ALERTAS GERADOS, SISTEMAS DE DETECÇÃO POR BIOMA 2019

Sistema	**Amazônia**	**Caatinga**	**Cerrado**	**Mata Atlântica**	**Pampa**	**Pantanal**	**Total**
DETER-Cerrado	162	643	12.659	6	-	110	13.580
DETERB-Amazônia	53.681	-	99	-	-	2	53.782
GLAD	115	908	863	14.665	746	2.258	19.545
SAD	77.394	-	319	-	-	-	77.713
SAD (SOS Mata Atlântica)	-	-	-	-	-	-	-
SIPAM-SAR	3.514	-	-	-	-	-	3.514
Total	134.866	1.551	13.940	14.661	746	2.370	168.134

FONTE: MapBiomas (2019).

Em 2024, o bioma da Amazônia teve o maior numero de alertas gerados o que corresponde a 28.986 alertas, seguido do bioma do Cerrado com 4.884 alertas, o bioma da Mata Atlântica teve 2.721 alertas (Tabela 2).

TABELA 2 – NÚMERO DE ALERTAS GERADOS, SISTEMAS DE DETECÇÃO POR BIOMA 2024

Sistema	Amazônia	Caatinga	Cerrado	Mata Atlântica	Pampa	Pantanal	Total
DETER-Cerrado	5	10	4.599	-	-	3	4.617
DETERB-Amazônia	8.102	-	1	-	-	-	8.103
GLAD	-	-	-	-	34	-	34
SAD (Imazon)	20.879	-	284	-	-	-	21.163
SAD (SOS Mata Atlântica)	-	-	5	2.721	1	-	2.726
SIPAM-SAR	-	-	-	-	-	-	-
Total	28.986	10	4.884	2.721	34	3	36.638

FONTE: MapBiomas (2024).

Cabe ressaltar que mapeamentos e detecção com enfoque estadual, municipal e em nível de propriedade, como é o caso do Paraná, a partir de imagens de satélites com reduzida ou baixa resolução espacial (30 a 250m) de maneira geral não são adequados.

2.3 CLASSIFICADORES DE IMAGENS

No processo de desenvolvimento de algoritmos de classificação em sensoriamento remoto, as maiores deficiência está associada a definição da regra de decisão usada para atribuir os pixels a uma classe. O primeiro conjunto de deficiências está diretamente relacionado com a aquisição das imagens. O segundo conjunto é afetado pela estrutura, premissas e hipóteses usadas no

desenvolvimento do método de classificação a ser empregado, diversos trabalhos têm sido produzidos com intuito de sanar essas deficiências (Nishida; Bastos, 1998).

De acordo com Hird *et al*. (2017) os avanços modernos na computação em nuvem e nos algoritmos de aprendizado de máquina estão mudando a maneira como os dados de observação da Terra são usados para monitoramento ambiental, principalmente à medida que estabelecemos na era dos fluxos de dados de satélite de acesso aberto e gratuitos.

Venkatapp *et al*. (2019) determinou valores de limiares a partir de índice de vegetação para classificar as categorias de uso da solo no Camboja por meio da análise de comportamento fenológico e desenvolvimento de um método de classificação baseado em fenologia para o monitoramento a longo prazo das mudanças na cobertura do solo. No GEE foi usado o *Enhanced Vegetation Index* (EVI) e regressão harmônica para identificar comportamentos fenológicos, foram gerados perfis de EVI de fenologia média para as classes LULC, o mapa classificado foi avaliado usando imagens de alta resolução, a acurácia obtida foi de 88% para LULC e para a classe de cobertura florestal foi de 85%.

Pesquisas recentes tem explorado a combinação de dados de diferentes sensores, como os satélites Sentinel-1 e Sentinel-2 com base em ML, para melhorar a precisão do mapeamento de uso e cobertura do solo. Essa abordagem permite a criação de algoritmos mais robustos, considerando tanto características espectrais quanto espaciais (Chatziantoniou *et al*., 2024).

2.4 ANÁLISE DE IMAGEM ORIENTADA A OBJETO (OBIA)

Com o aumento das resoluções espacias das imagens de sensoriamento remoto, alternativas foram desenvolvidas visando derivar objetos compostos de vários pixels, o processo de geração de objetos mais utilizado e a segmentação de imagens, que remonta a década de 1970. A partir da década de 2000, os (SIGs) e o processamento de imagens começaram a crescer rapidamente por meio da OBIA,

que cria objetos gerando atributos espectrais, texturais, morfológicos, que podem ser empregados em analise de imagens (Blaschke, 2010).

O princípio da OBIA é considerar objetos gerados por conjuntos de pixels, em vez de analisar uma imagem apenas com base em seus pixels, Uma segmentação da imagem, a partir do nível de pixel, cria um nível de abstração. Outra segmentação pode ser realizada em nível dos objetos para criar diferentes abstrações de objetos da imagem (Koop *et al.*, 2021).

Os segmentos gerados no processo de segmentação consistem nas regiões geradas por critérios de homogeneidade em uma ou mais dimensões, assim os segmentos tem informações espectrais adicionais em comparação com pixels individuais (valores médios, mediana, mínimos e máximos e variância por banda), mais a vantagem maior é a informação espacial adicional para objetos (Blaschke e Strobl, 2001).

2.5 MACHINE LEARNING (ML)

O Aprendizado de Máquina (*Machine Learning* - ML) é um campo da Inteligência Artificial (IA) que fornece a capacidade de aprender ou fazer previsões usando métodos computacionais (Chi; Kim, 2017). O aprendizado de máquina tem sido usado extensivamente em diversas aplicações, como biologia, visão computacional, economia e sensoriamento remoto (Pedregosa *et al*., 2011).

De acordo com Silva e Vanderlinde (2012) o aprendizado de máquina, possibilita que novas formas de programação sejam realizadas, e vários métodos estão disponíveis por meio de softwares e aplicativos (Quadro 2), dentre os algoritmos mais utilizados em classificacação supervisionada estão *Support Vector Machine* (SVM), *Random Forest* (RF) e *Decision Trees* (DT).

QUADRO 2 – ALGORITMOS DE MACHINE LEARNING (ML)

Um-Supervised Learning			***Reinforcement Learning***			***Semi-Supervised Learning***
K-Means Clustering	*Principal Component Analysis (PCA)*	*Apriori Algorithm*	*AdaBoost (Adaptive Boosting)*	*Light Gradient Boosting Machine (LightGBM)*	*Long Short-Term Memory Net-works (LSTM)*	*Artificial Neural Networks (ANN)*
Supervised Learning Algorithms						
Naïve Bayes Classifier Algorithm	*Support Vector Machine (SVM) Algorithm*	*Linear Regression Algorithm*	*Logistic Regression Algorithm*	*Decision Trees Algorithm*	*Random Forests Algorithm*	*K-Nearest Neighbours Algorithm*

FONTE: Adaptado de GeeksforGeeks (2025).

Na década de 2000, surgiram soluções para os problemas de alta demanda computacional típicos das redes neurais, permitindo o desenvolvimento de redes neurais mais complexas e mais profundas. O Aprendizado Profundo (em inglês, *Deep Learning* - DL) se tornou um subcampo de rápido crescimento de ML. Nas geociências, a aquisição de grandes volumes de dados de sensoriamento remoto está se acelerando devido à proliferação de técnicas e fontes de dados de sensoriamento (Chi; Kim, 2017).

2.5.1 Support Vector Machine (SVM)

O classificador SVM, conforme Burges (1998) faz uso de um conjunto de parâmetros personalizados, sem informações a priori sobre a natureza física do problema de predição, os parâmetros ideais são desconhecidos.

O SVM consiste em uma metodologia promissora de aprendizado de máquina. Este método é particularmente atraentes no campo de sensoriamento remoto devido sua capacidade de generalizar amostras de treinamento limitadas. Entretanto também podem sofrer com problemas relacionados à atribuição de parâmetros que podem afetar significativamente os resultados obtidos (Mountrakis; Ogole, 2011). Dentre algumas aplicações de algoritmos de SVM estão trabalhos de diferentes aplicações, como no estudo de fluxo de calor terrestre e monitoramento de mudanças florestais.

São modelos de aprendizado supervisionado usados para classificação e análise de regressão. O SVM é um classificador definido por um hiperplano de separação, faz uma representação do conjunto de treinamento como pontos no espaço, executa classificação linear e não linear, mapeando implicitamente suas entradas em espaços de recursos de alta dimensão (Geeksforgeeks, 2025) (Figura 2).

FIGURA 2 – DIAGRAMA DE CLASSIFICAÇÃO POR SVM

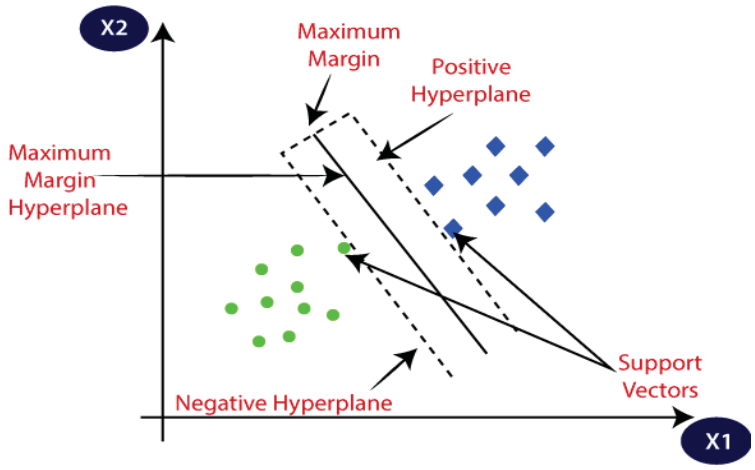

FONTE: Javatpoint, (2025).

O algoritmo (SVM) é amplamente utilizado para tarefas de classificação e regressão. No contexto de imagens de satélite, o SVM ganhou destaque devido à sua capacidade de tratar dados de alta dimensão e limites de decisão não lineares, tornando-o particularmente eficaz para o uso da solo e mapeamento florestal (Mansor *et al*., 2024).

Apesar de seus pontos fortes, o SVM enfrenta desafios como altas demandas computacionais e a necessidade de grandes conjuntos de dados rotulados. Além disso, problemas de qualidade de dados, como baixa separabilidade, podem afetar a precisão da classificação (Lemenkova, 2024).

2.5.2 Árvores de decisão e Randon Forest (RF)

Árvores de Classificação e Regressão (*Classification and Regression Trees* - CART) se refere a um método estatístico, introduzido por Breiman *et al*. (1984), para construir preditores de árvore (também chamados de árvores de decisão) para problemas de regressão e classificação (Genuer; Poggi, 2020).

CART é um classificador não paramétrico que não requer nenhum pressuposto estatístico a priori quanto à distribuição dos dados pode ser baseado em pixels que usa níveis de número digital (*Digital Numbers* - DN) das amostras de treinamento para criar uma árvore de decisão que classifica os pixels da imagem (Lobo *et al*., 2018).

CART começa analisando todas as variáveis explicativas e determinando qual divisão binária de uma única variável explicativa (que pode ser um atributo ou banda de uma imagem) produz melhor o desvio na resposta variável (Breiman *et al*., 1984; Efron; Tibshirani, 1991; Venables; Ripley, 1997).

A classificação CART pode ser realizada com dados com variáveis ou atributos contínuos ou categóricos. No caso da classificação de imagens de satélites, as variáveis explicativas consistem em dados espectrais e auxiliares, se contínuo ou categórico, e a variável resposta é a lista de classes de uso e cobertura

do solo (Lawrence; Wright, 2001). Dentre algumas aplicações de algoritmos CART estão os mapeamento de áreas de mineração, áreas úmidas e florestal.

O algoritmo Floresta Aleatória (*Randon Forest* - RF) é uma combinação de preditores de árvore de decisão, de modo que cada árvore depende dos valores de um vetor aleatório amostrado de forma independente e para todas as árvores. O erro de generalização converge para um limite à medida que o número de árvores se torna grande. O erro depende da força das árvores individuais e da correlação entre elas, as estimativas internas monitoram o erro, a força e a correlação são usadas para mostrar a resposta ao aumento do número de características ou atributos usados na divisão. Estimativas internas também são usadas para medir a importância das variáveis que se aplicam à regressão (Breiman, 2001).

O RF, um método de aprendizado conjunto, combina várias árvores de decisão para melhorar a robustez e a precisão do modelo. Ao treinar cada árvore em uma amostra de bootstrap dos dados e um subconjunto aleatório de recursos, as RFs reduzem o sobreajuste e melhoram a generalização. A previsão final é feita pela média (regressão) ou votação (classificação) em todas as árvores. Essa abordagem é amplamente utilizada em sensoriamento remoto devido à sua capacidade de processar dados de alta dimensão e relações não lineares (Zanella *et al*., 2017; Weinmann and Weidner, 2018; Liu *et al*., 2024).

As árvores de decisão são componente fundamental do CART. Eles operam particionando recursivamente os dados em subconjuntos com base nos valores dos recursos, criando uma estrutura semelhante a uma árvore em que cada nó representa uma decisão ou divisão. As divisões são determinadas minimizando uma função de perda, como impureza ou ganho de informação, para maximizar a separação de classes. As árvores de decisão são interpretáveis e podem ser aplicadas em tarefas de classificação e regressão (Najm *et al*., 2024).

2.5.3 Gradient Tree Boost (GTB)

Os algoritmos do tipo GTB utilizam um conjunto de árvores de decisão. No entanto, sua abordagem básica difere no que limita a complexidade de árvores, confinando cada árvore individual a um modelo de previsão. GTB alcança a acurácia de classificação iterativamente, minimizando uma diferente função de perda em cada etapa, seguindo um gradiente por processo descendente, em cada iteração, uma subamostra dos dados de treinamento é extraída aleatoriamente (sem substituição) do conjunto de dados de treinamento completo. Essa subamostra selecionada aleatoriamente é então usada no lugar da amostra completa para ajustar e calcular a atualização do modelo para a iteração atual (Friedman, 2002).

Já os modelos estatísticos do tipo *Boosted Regression Tree* (BRT), consistem em uma das várias técnicas que visam melhorar o desempenho de um único modelo ajustando muitos modelos e combinando-os para predição. BRT usa dois algoritmos: o algoritmo de árvores de regressão que são do grupo de modelos de classificação por árvore de decisão, e o algoritmo do tipo impulsionar (*Boosting)* que constrói e combina uma coleção de modelos (Elith *et al*., 2008).

GTB é um método de aprendizado de conjunto que combina vários modelos fracos para criar um modelo preditivo forte. É particularmente eficaz para processar relações complexas e não lineares em dados, tornando-o adequado para tarefas de mapeamento LULC onde variáveis espectrais, espaciais e temporais geralmente interagem de maneiras intrincadas (Jiang *et al*., 2024).

O GBT, outro método de conjunto, constrói árvores de decisão de maneira sequencial, com cada árvore abordando os resíduos da árvore anterior. Essa abordagem de aumento de gradiente otimiza o modelo minimizando a função de perda iterativamente. O GBT é particularmente eficaz para conjuntos de dados complexos, pois pode capturar padrões e interações entre variáveis. A análise da importância das características no GBT também é valiosa para entender a contribuição de diferentes preditores, como bandas espectrais ou características de textura, na classificação do uso do solo (Najm *et al*., 2024; Jiang *et al*., 2024).

2.6 SÉRIES TEMPORAIS PARA IDENTIFICAR DESFLORESTAMENTO

O uso de séries temporais de dados de sensoriamento remoto mostra que as mudanças na cobertura de terra nem sempre ocorrem de forma progressiva e gradual, mas eles também podem mostrar períodos de mudança rápida e abrupta seguido por um rápido período de recuperação para condições de pré-mudança (Lambin; Linderman, 2006).

Masek *et al.* (2013) fez uso de séries temporais LANDSAT para identificar tendências de perturbação florestal dos Estados Unidos, como conclusão sugerem que futuros estudos baseados em dados de satélite em escala regionais e nacionais devem se concentrar em análises com intervalo de tempo anual para se obter maior acurácia.

Olofsson *et al.* (2016) utilizou series temporais de todas as imagens LANDSAT disponíveis adquiridas entre 1985 e 2011 para monitorar as mudanças de uso e cobertura em toda a Nova Inglaterra no nordeste dos Estados Unidos, Constatou-se que a área florestal vem diminuindo ao longo do período em cada região desde a década de 1980.

Shimizu *et al*. (2019) fez uso de série temporal de imagens LANDSAT-8 e Sentinel-1 para detectar mudanças em florestas tropicais sazonais na região de Bago no centro de Mianmar. Foi utilizado um algoritmo de aprendizado de máquina, para prever a probabilidade de perturbação de cada observação LANDSAT-8 e Sentinel-1, para caracterizar sazonalidade e mudanças relacionadas a perturbações. Os resultados mostraram que a combinação entre LANDSAT-8 e Sentinel-1 alcançou uma acurácia geral de 83.6% para detecção de distúrbios florestais.

Hasan *et al*. (2017) desenvolveu um método para avaliar e mapear diferentes níveis de degradação florestais na Amazônia oriental em Paragominas, fez uso de série temporal LANDSAT (2000-2015) e o software CLASlite gerando três bandas Vegetação Fotossintética (PV), Vegetação não Fotossintética (NPV) e Solo exposto (S). Para a validação foram usadas observações de campo de florestas degradas, com base em indicadores de estrutura florestal.

Bullock e Woodcock (2020) fez monitoramento da degradação de floresta tropical no Estado de Rondônia, Brasil, usando análise de série temporal com imagens LANDSAT no GEE, a metodologia detecta mudanças na estrutura e condições da floresta. Para avaliar o desempenho do método foram utilizados mapas de desflorestamento e degradação para estratificar a área de estudo para coleta de dados amostrais, a estimativa de desflorestamento foi feita de 1990 a 2013. A degradação e o desflorestamento foram mapeados com 88,0% e 93,3% de acurácia de usuário.

A análise empregada nas séries temporais de imagens de sensoriamento remoto permite principalmente caracterizar a fenologia da vegetação, baseada em mudanças que ocorrem na superfície terrestre, as quais facilitam a compreensão da dinâmica temporal da cobertura vegetal (Jakubauskas, 2001).

A estrutura teórica para a utilização de imagens de satélite de séries temporais para identificar o desmatamento e mapear o uso da terra é cada vez mais sofisticada, aproveitando técnicas avançadas de classificação e fontes de dados robustas. Estudos recentes destacam a eficácia de várias metodologias, incluindo classificadores bayesianos recursivos e redes neurais convolucionais, que aumentam a precisão e a confiabilidade da detecção de desmatamento. As seções a seguir detalham as principais abordagens e descobertas de pesquisas recentes.

Dentre as Técnicas de Análise de Séries Temporais estão os Classificador Bayesiano Recursivo (CBR): Este método melhora a robustez da classificação em ambientes multitemporais, alcançando uma melhoria de precisão de até 15,25% na detecção de desmatamento usando dados Sentinel-2 (Calatrava et al., 2024).

As Redes Neurais aplicadas às imagens SAR do Sentinel-1 detecta efetivamente os padrões de desflorestamento, superando os métodos tradicionais, o uso de Sentinel-2 e Sentinel-1 fornecem imagens de alta resolução, cruciais para monitorar a supressão florestal. O conjunto de dados BraDD-S1TS, composto por 25.000 sequências de imagens, serve como referência para avaliar métodos de detecção (Karaman et al., 2023).

European Forest Disturbance Atlas (EFDA): Este conjunto de dados abrangente rastreia distúrbios florestais em toda a Europa, oferecendo dados de referência valiosos para classificação do uso da terra (Viana-Soto; Senf, 2024).

Embora esses avanços apresentem um progresso significativo no monitoramento de desflorestamento, os desafios permanecem, particularmente para garantir a generalização do modelo em diversas áreas geográficas e condições ambientais variadas. A pesquisa contínua é essencial para refinar essas metodologias e aprimorar sua aplicabilidade em cenários do mundo real.

2.6.1 Análise harmônica de séries temporais

A análise harmônica é um ramo da matemática que busca a representação de funções ou sinais como uma superposição de funções periódicas (Zhou *et al*., 2012; Zhou *et al*., 2015). A análise harmônica ou análise de Fourier tem sido usada para analisar séries sucessivas de imagens de sensoriamento remoto (Jakubauskas *et al*., 2001). A análise harmônica vem sendo usada no estudo de séries temporais de índices de vegetação para examinar as mudanças que ocorrem na superfície terrestre, com a finalidade de encontrar evidências de alterações no desenvolvimento da vegetação e demonstrar padrões da dinâmica temporal (Jia *et al*., 2011). Esta análise possibilita representar uma função complexa, como a somatória de ondas (termos) senoidais e cossenoidais, onde cada onda define-se por um valor único de amplitude e de fase (Davis, 1986).

De acordo com Zhou *et al*. (2012) nas últimas décadas, pesquisadores desenvolveram métodos e modelos para reconstruir séries temporais de observações com espaçamento irregular de dados de sensoriamento remoto por satélite, dentre estes métodos a Análise Harmônica de Séries Temporais (*Harmonic Analysis of NDVI Time-Series* - HANTS) que utiliza índices de vegetação. As imagens de amplitude evidenciam a variação máxima do índice de vegetação para todo o período. Tais imagens têm o mesmo intervalo de valores que os índices de vegetação (0 e 1). Altos valores de amplitude indicam elevado grau de variação e o

termo em que essa variação ocorre indica a periodicidade do evento (Jakubauskas *et al*., 2001).

A aplicação da análise harmônica na decomposição de índices de vegetação é utilizada para caracterizar a cobertura da terra (Liu *et al*., 2016), para modelagem de atributos de dados de inventário florestal (Wilson *et al*., 2018), monitoramento contínuo de perturbação florestal (Zhu *et al*., 2012) caracterização de mudanças fenológicas (Verbesselt *et al*., 2010) e identificação de culturas agrícolas (Jakubauskas *et al*., 2002).

2.7 GOOGLE EARTH ENGINE (GEE)

O GEE é uma plataforma de computação que permite análises geoespacias na infraestrutura do ambiente Google, contém também uma *Application Programming Interface* (API) em linguagem de programação Python a partir da instalação de bibliotecas, e também um catálogo de petabytes de múltiplas imagens de satélites atualizadas de forma constante quase em tempo real e conjuntos de dados geoespaciais com recursos de análise e processamento, a partir de um editor de código em linguagem de programacao JavaScript baseado na web permitindo o desenvolvimento de algoritmos.

As plataformas de computação geoespacial baseadas em nuvem e os inventários de imagens de satélites orbitais de multissensores do GEE oferecem a possibilidade de mapear grandes extensões territoriais com exatidão atendendo aos requisitos de monitoramento e conservação ambiental (Gorelick *et al.,* 2017).

Muitos algoritmos de processamento de imagens já foram desenvolvidos e estão operacionais na plataforma, porém é possível desenvolver novos algoritmos e aplicações a partir da necessidade para soluções complexas, otimizando o processamento de grande quantidade de imagens e também implementar e programar algoritmos para mapeamentos específicas (Zeng *et al*., 2022).

De acordo com Wang *et al.* (2020) é uma plataforma de domínio público, que disponibiliza a comunidade científica dados de sensoriamento remoto a nível global, já o uso do conjunto de dados e o desenvolvimento de algoritmos inovadores de processamento de dados fornecidos pelo GEE ajudam a processar grande quantidade de dados e imagens de satélite e implementá-los para apoiar uma variedade de decisões de gerenciamento.

O GEE permite análises geoespaciais na nuvem e contém uma larga escala de dados de sensoriamento remoto, para processamento no ambiente da Google, o que permite a disseminação dos resultados gerados em tempo real, para outros pesquisadores e áreas de estudo, podendo ser aplicado para processamento em escala global (Gorelick *et al.,* 2017).

Dado o ritmo acelerado dos avanços tecnológicos, é crucial consultar a documentação oficial do GEE e os recursos que estão sendo desenvolvidos para obter as informações precisas e atualizadas. O GEE está em constante expansão, Velástegui-Montoya *et al*. (2023) enfatiza o desenvolvimento e evolução contínuos da plataforma.

Dentre diversas aplicações e resultados de pesquisas que fazem uso do ambiente de processamento em nuvem do GEE, estão mapeamentos de cultivos agrícolas, classificações supervisionadas LULC, perdas de áreas florestais, mapeamento de cobertura florestal e de mudanças no estoque de carbono.

2.7.1 Classificação supervisionada de uso e cobertura do solo

Xie *et al*. 2019 fez uso de GEE para classificação de uso e cobertura do solo LULC, o método proposto é automático para classificação supervisionada e utiliza imagens de séries temporais e composições por percentil e de mediana mensais do LANDSAT, com amostras de treinamento obtidas do sensor MODIS, foram inseridos no classificador RF, resultando em uma acurácia de 99,2%.

Orieschnig *et al*. (2021) avaliou os classificadores supervisionados disponíveis na plataforma GEE: *Naïve Bayes* (NB), CART, RF, GTB e SVM. Fez

uma análise LULC multitemporal usando Sentinel-1 e 2, para uma área de estudo no Delta do Mekong. O desempenho do classificador é comparado para diferentes combinações de imagens de entrada, conjuntos de banda e conjuntos de dados de treinamento. Os resultados mostram que GTB e RF produziram as maiores acurácias, com 94% e 93%.

Praticò *et al*. (2021) fez uso do GEE para classificar uma área nativa protegida na Calábria (Sul da Itália), que é particularmente representativa do Ambiente de floresta de montanha mediterrânea. Na pesquisa, (RF), (SVM), e (CART) algoritmos foram usados para realizar classificação supervisionada baseada em pixels com base no uso de imagens do Sentinel2. Os melhores resultados foram alcançados usando RF com os índices NDVI, *Enhanced Vegetation Index* (EVI) e *Normalized Burn Ratio* (NBR) com um *Overall Accuracy* (OA) de 0,83.

Venkatappa *et al*. (2020) fez uso de GEE aplicando o método de classificação baseado em fenologia para detectar e mapear a cobertura florestal e as mudanças no estoque de carbono no Camboja entre 1990 e 2018. Os mapas foram validados usando imagens históricas de alta resolução do GEE, obtendo 92% de acurácia e 0,9 de Índice Kappa. Desta forma foi possível detectar mudanças na cobertura florestal e estimar mudanças no estoque de carbono, foi constatada uma taxa de desflorestamento anual de 1,3%.

Silva Júnior *et al.* (2020), avaliou a extensão e idade das florestas secundárias para o Brasil durante o período 1986 e 2018. Como dados de entrada foram usados mapas de uso e cobertura do solo LULC do projeto MapBiomas, implementando um algoritmo no GEE. O conjunto de dados resultante forneceu informações espaciais para apoiar a redução de emissões de carbono, biodiversidade e políticas de restauração, planejamento territorial e subsidiar a aplicação da legislação ambiental.

2.7.2 Detecção de mudanças no GEE

As detecções de mudanças indicam as alterações espaciais na superfície terrestre, devido a fenômenos naturais ou artificiais, a partir da análise de imagens de satélite multitemporais. São de grande importância em sensoriamento remoto, monitoramento de mudanças ambientais e detecção de mudanças de uso e cobertura da terra. Os satélites de sensoriamento remoto adquirem imagens de satélite em resoluções variadas, sendo estas usadas para detecção de alterações (Asokan; Anitha, 2019).

A seguir são apresentados diferentes metodologias utilizando diferentes sensores espectrais para detecção de mudanças e supressão florestal implementados no GEE, em diferentes áreas de estudos.

Hansen *et al*. (2016) fez uso dados LANDSAT, para gerar alertas para o Peru, República do Congo e Kalimantan (Indonésia); foram utilizadas bandas do LANDSAT-7/ETM+ sensor (*Enhanced Thematic Mapper Plus – ETM+*), LANDSAT-8/OLI, e *Thermal Infrared Sensor* (TIRS) (temperatura de brilho), que foram utilizadas para a criação de métricas de séries temporais, mas não como variáveis do mapeamento de cobertura florestal. As observações foram normalizadas radiometricamente, cada imagem foi convertida em reflectância no topo da atmosfera e depois normalizada em reflectância espectral, foi gerado o NDVI e um valor médio de reflectância para as bandas do infravermelho e de ondas curtas para formar uma composição de percentil. Cobertura de nuvens, neblina, água e sombra foram identificadas separadamente.

Fadli *et al*. (2019) fez o monitoramento por satélite utilizando o GEE para detectar mudanças da cobertura florestal na Indonésia no período entre 2000 e 2016, usando um conjunto de dados de cobertura florestal baseado no LANDSAT. De acordo com o autor, o desflorestamento é um dos problemas ambientais mais importantes, sendo uma tarefa urgente para proteção ambiental da região.

Osei *et al*. (2019) fez uso do GEE para monitorar reservas florestais de Gana entre 1990 e 2018, e constatou uma perda de mais de 33,7% de sua floresta desde o início de 1990, a taxa de desflorestamento foi estimada em 2,19% por ano. Foram utilizadas imagens LANDSAT, MODIS, *National Oceanic Atmospheric Administration*

(NOAA) do sensor *Advanced Very High Resolution Radiometer* (AVHRR), nas resoluções espaciais de 30 m, 250 m e 7 km e classificadas de forma supervisionada.

Zhu *et al.* (2014) desenvolveu um algoritmo para detecção e classificação contínua de mudanças para cobertura da terra usando todos os dados disponíveis do LANDSAT, sendo usado como área de estudo uma cena na Nova Inglaterra, a partir da disponibilidade de novas imagens, mapas de uso do solo foram gerados, sendo eliminados ruídos de nuvens, sombra, também foram utilizados estimativa de reflectância de superfície e temperatura de brilho. O modelo de série temporal é atualizado de forma dinâmica a partir da diferença entre imagens, obteve uma acurácia do produtor de 98% e de usuário de 86%.

Huang *et al.* (2017) fez uso de séries temporais anuais do NDVI para detectar a dinâmica de cobertura do solo em Beijing, China, com uso do GEE mapeou a cobertura do solo, e obteve um mapa de classificação com uma acurácia geral de 86,61%. Constatou que cerca de 1.162,71 km^2 foram convertidas em áreas urbanas, enquanto 918,36 km^2 foram convertidos para áreas de cultivo, florestas e pastagens.

Pang *et al*. (2013) utilizou séries temporais LANDSAT/ETM de 1999 a 2010 em uma floresta tropical na província de Yunna, China, para detectar automaticamente desflorestamento. Foi comparado duas versões de algoritmos *Vegetation Change Tracker* (VCT) baseado no Índice Florestal Integrado (IFI) e Índice de Perturbação (IP). Os resultados foram avaliados em 376 parcelas de campo, as acurácias obtidas foram de 82,7% e 79,9%, respectivamente. O uso de IP aumentou a separabilidade entre áreas agrícolas e florestais.

Schultz *et al*. (2016) avaliou o desempenho da série temporal LANDSAT de oito índices de vegetação para monitorar desflorestamento nos trópicos. Foi utilizado o método de monitoramento *Breaks For Additive Season and Trend* (BFAST) e um banco de dados para avaliar o desempenho, com uso de NDFI obtiveram 78,8% de acurácia.

DeVries *et al*. (2016) fez uso da série temporal LANDSAT e analisaram dados de desflorestamento e degradação florestal ao longo de 3 anos em uma área

florestal no sudoeste da Etiópia. Com uso de todas as bandas espectrais e um conjunto de índices adicionais, previram desflorestamento e degradação em florestas estáveis usando modelos de previsão treinados com dados de especialistas e métricas espectro-temporais. Os modelos de previsão de desflorestamento e degradação obtiveram estimativa de erro geral de 29%.

Fortin *et al*. (2019) usou o GEE a partir de análise temporal perto do rio Roosevelt no Estado do Mato Grosso, MT, Brasil, para identificar mudanças florestais, no período de 45 anos. A acurácia geral de toda a série temporal teve uma média de 98% no cálculo imparcial e 90% na formulação padrão. Em 1980 as alterações de uso e cobertura do solo em larga escala já haviam começado a mudar a escala regional. A série temporal completa de classificação mostra o desenvolvimento da região de uma área quase não cultivada para uma área em processo de conversão constante para paisagem agrícola, conversões mais extensas são observadas em Rondônia a oeste e Mato Grosso a leste.

Bullock *et al*. (2018) fez uso de GEE para monitoramento da degradação de florestas tropicais usando de séries temporais LANDSAT, as estimativas de área foram calculadas de 1990 a 2013 para Rondônia. A metodologia faz uso de séries temporais e análise de mistura espectral para detectar degradação e desflorestamento em paisagens florestais, os dados são transformados em frações espectrais e usadas para calcular o Índice de Fração de Degradação Normalizada (IFDN), (*Normalized Fraction Difference Index - NDFI*), os mapeamentos de degradação tiveram 88,0% e 93% de acurácia de usuário e 68,1% e 85,3% de acurácia do produtor.

Doblas *et al.* (2020) fez uso de duas técnicas de estabilização de séries temporais (*Time Series - TS*), Análise harmônica e estabilização espacial e duas técnicas de detecção de desflorestamento, Limiar Linear Adaptativo (LLA) (*Adaptive Linear Thresholding - ALT*) e Classificação por Máxima Verossimilhança (CMV) *(Maximum Likelihood Classifier – MLC)*. Fez uso do GEE para processar os dados em toda a bacia amazônica brasileira, os resultados de detecção mostraram

melhoria na abordagem MLC, com 94% de acurácia global e ALT com 95,1% de acurácia, independentemente do método de estabilização.

Hansen *et al.* (2013) desenvolveu um algoritmo com uso do GEE para analisar a perda de áreas florestais, processando imagens do LANDSAT no período compreendido entre 2000-2019, gerou mapas de cobertura florestal a nível global. Os trópicos foram o único domínio climático a exibir tendência de perda de floresta, também observou redução de desflorestamento no Brasil e aumento na Indonésia, Malásia, Paraguai, Bolívia, Zâmbia, Angola. A silvicultura intensiva praticada em florestas subtropicais resultou nas maiores taxas de mudança florestal.

A detecção de mudança é uma parte importante da análise de séries temporais, pois a presença de um ponto de mudança indica uma mudança abrupta e significativa no processo de geração de dados. Embora existam muitos algoritmos para detecção de mudança, pouca atenção tem sido dada à avaliação de seu desempenho em séries temporais do mundo real. Os algoritmos são normalmente avaliados em dados simulados e um pequeno número de séries comumente usadas com verdades não confiáveis (Van der Burg; Williams, 2020).

2.8 CADASTRO TERRITORIAL MULTIFINALITÁRIO

O Cadastro Territorial multifinalitário (CTM) no Brasil, particularmente no Estado do Paraná, desempenha um papel crucial no aprimoramento do planejamento e governança urbana. O CTM serve como uma ferramenta abrangente para gerenciar informações sobre a terra, o que é essencial para um planejamento urbano e governança eficazes. O uso de tecnologias *Business Intelligence*, aumenta a eficiência dos sistemas de informação fundiária do CTM (Silva et al., 2012).

O CTM é essencial para os processos de regularização fundiária, potencialmente reduzindo custos e tempo (Santos Silva e Antunes, 2020). Suas aplicações se expandiram aos propósitos fiscais para incluir a proteção ambiental e o desenvolvimento sustentável (Paixão *et al*., 2012). A implantação do CTM em

municípios de pequeno porte é viável utilizando os conceitos propostos pela Portaria nº 511/2009 do Ministério das Cidades, apesar dos recursos econômicos limitados. No entanto, ainda existem desafios, como informações dispersas, desatualizadas e incompletas em muitos municípios, evidenciando a necessidade de melhoria dos dados (Pimentel e Carneiro, 2012).

No estado do Paraná, a institucionalização do planejamento tem sido um fator significativo no desenvolvimento do estado, com iniciativas que remontam à década de 1940 e à criação do Instituto Paranaense de Desenvolvimento Econômico e Social (IPARDES) em 1973, que visava modernizar e organizar o arcabouço administrativo do estado (Cestaro, 2024). A região litorânea enfrenta desafios únicos devido à sua heterogeneidade socioeconômica e ambiental, necessitando de abordagens de governança integrada que respeitem as variabilidades locais (Deron et al., 2018).

2.9 SÍNTESE DO CAPÍTULO

Neste item foi evidenciado o estado da arte que corresponde a uma síntese de pesquisas que fizeram uso de GEE para diferentes aplicações envolvendo mapeamentos de LULC, e uso de séries temporais de imagens de satélite para detectar desflorestamento, estes autores serviram de direcionamento deste trabalho.

Venkatapp et al. (2019) utilizou o Enhanced Vegetation Index (EVI) no GEE para classificar categorias de uso do solo, focou no monitoramento a longo prazo das mudanças na cobertura do solo no Camboja.

Silva Júnior et al. (2020) empregou mapas de uso e cobertura do solo do projeto MapBiomas no GEE para avaliar florestas secundárias no Brasil de 1986 a 2018.

Hansen et al. (2013) desenvolveu um algoritmo no GEE para analisar perda de áreas florestais globalmente usando imagens LANDSAT entre os anos de 2000 a 2019.

Estes estudos fornecem informações para políticas ambientais, planejamento territorial e legislação. Os resultados apoiam o monitoramento e a gestão de recursos florestais em diferentes escalas.

3 ÁREA DE ESTUDO

A área de estudo compreende o Estado do Paraná, na região Sul do Brasil, situado entre os paralelos 22º 29’ S e 26º 43’ S e os meridianos 48º 2’ W e 54º 38’ W, como pode ser observado na figura 3.

As características climáticas do estado são variáveis, o sistema de classificação climática de Koppen e Geiger (1928) estabelece como mais predominante a classe Cfa (temperado quente com verão quente) e Cfb (temperado úmido com moderado verão quente), ainda há ocorrência de Cwa (temperado úmido com inverno seco) e Aw (savana tropical úmida) que são encontrados no Norte do Estado (Aparecido *et al*., 2016).

No Estado do Paraná, a partir de mapeamento realizado com imagens óticas ortorretificadas WorldView-2 e Pléiades-1A e 1B (período de 2011 e 2016), com 2 metros de resolução espacial, foi estimado que a área de floresta nativa corresponde a 5.819.950,07 ha (29,12%), plantios florestais a 1.292.507,40 ha (6,47%), agricultura anual a 33,014%, campos e pastagens a 25,32%, várzeas a 1,35%, corpos d’água a 2,06% e outras classes de uso e cobertura a 2,69% (SEDEST, 2020).

A distribuição de alertas de desflorestamentos emitidos pelo MapBiomas no ano de 2020, indicou que a maior concentração, com quase (30%) de alertas está localizado nas mesorregiões Centro-Sul, Sudeste, Centro Oriental e Metropolitana, melhor compreendido na figura abaixo.

FIGURA 3 – MAPA DE LOCALIZAÇÃO DA ÁREA DE ESTUDO, ESTADO DO PARANÁ

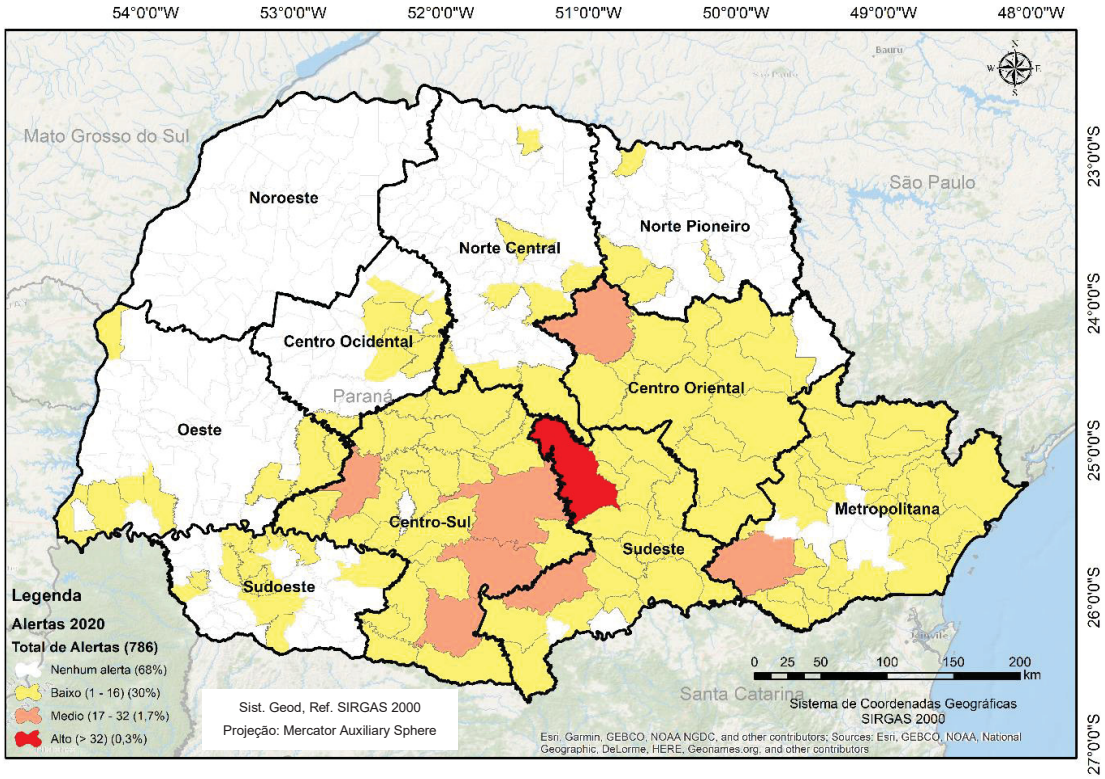

FONTE: MapBiomas Alerta (2020).

3.1 REGIÕES FITOECOLÓGICAS DO PARANÁ

A grande diversidade de paisagens do país, fruto da interação entre componentes bióticos (vegetação e animais) e abióticos (clima, rocha, relevo e solo), resulta em diferentes ambientes e inúmeros tipos de vegetação que constituem as regiões fitoecológicas que são espaços definidos por uma florística de gêneros típicos e de formas biológicas características que se repetem dentro de um mesmo clima, podendo ocorrer em terrenos de litologia variada, mas com relevo definido (IBGE, 2012) (Figura 4).

O estado do Paraná no Brasil é caracterizado por diversas regiões fitoecológicas dentro do bioma Mata Atlântica. Três fitofisionomias principais são

identificadas: Floresta Ombrófila Mista (FOM), Floresta Ombrófila Densa (FOD) e Floresta Estacional Semidecidual (FES) (Wrege *et al*., 2017). Essas regiões exibem alta biodiversidade, com estudos relatando até 78 espécies em uma única área de floresta remanescente (Caraminan *et al*., 2023).

As classificações históricas reconheceram a complexidade da vegetação paranaense, dividindo-a em várias zonas com base na altitude e no clima (Troppmair, 2011). Projeta-se que as mudanças climáticas impactem significativamente essas regiões fitoecológicas, com modelos prevendo uma redução de 96% na FOM e um aumento de 72% na FES até 2090 (Wrege *et al*., 2017). As diversas zonas ecológicas do estado também influenciam as práticas agrícolas, como demonstrado por estudos sobre a produção de sementes de soja, que identificaram regiões ótimas com base nas condições de temperatura e umidade (Costa *et al*., 1992).

FIGURA 4 – REGIÕES FITOECOLÓGICAS DO ESTADO DO PARANÁ

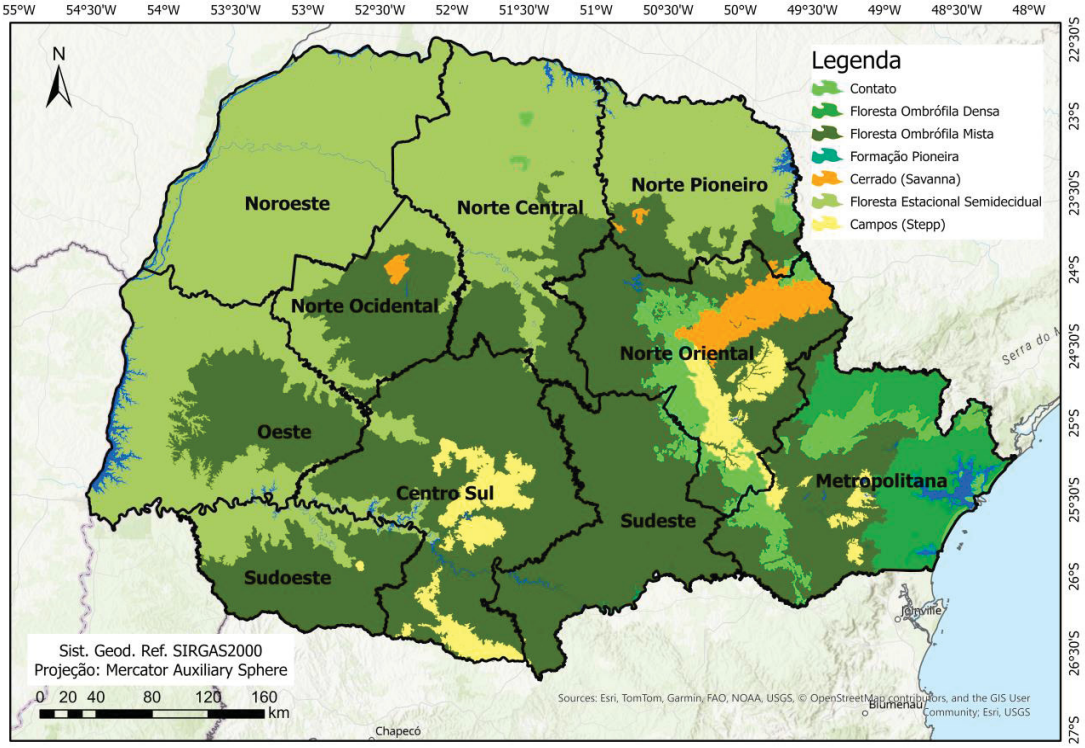

3.1.1 Estepe

As regiões de estepe (campos) caracterizam-se por áreas com relevo plano ou suave-ondulado e vegetação herbácea contínua e dupla estacionalidade, uma fisiológica (provocada pelo frio das frentes polares) e outra seca (devido ao déficit hídrico). No Paraná, esse tipo de vegetação pode apresenta-se na região de Ponta Grossa, no Estado do Paraná, estando presente nos denominados Planalto das Araucárias.

A região dos Campos Gerais no Paraná representa o limite sul do bioma Cerrado, cobrindo aproximadamente 20.000 km² (Ritter *et al*., 2010; Seger *et al*., 2018). Essa área é caracterizada por um mosaico de tipos de vegetação, incluindo campos, e cerrado (Ritter *et al*., 2010). A paisagem única da região tem atraído interesse científico desde o século 19, com pesquisadores como Reinhard Maack identificando evidências geomorfológicas de mudanças climáticas do Quaternário (Martins e Vieira, 2015). Vários sistemas de classificação têm sido propostos para a vegetação paranaense, considerando fatores como altitude, latitude e clima (Troppmair, 2011).

A área dos Campos Gerais é propensa a incêndios florestais, especialmente após o inverno, quando a vegetação morta se acumula. Estudos têm caracterizado o material combustível fino neste ecossistema, encontrando uma média de 7,98 $Mg.ha^{-1}$ de material combustível, o que indica consistência com os valores relatados para vegetação de pastagem semelhante (Seger *et al*., 2018).

3.1.2 Floresta Estacional Semidecidual

A vegetação pertencente a esse tipo de formação caracteriza-se por estar presente em regiões cujo clima estacional determina a semideciduidade da folhagem, estando presente nas regiões tropicais, com secas hibernais e intensas chuvas de verão, e subtropicais, com clima sem período seco e inverno rigoroso. (IBGE, 2012).

A Floresta Estacional Semidecidual (FES) é encontrada nas partes norte e oeste do estado do Paraná, espera-se que esta região se expanda em 72% devido à sua adaptabilidade às mudanças nas condições climáticas (Wrege et al., 2017).

A localização do Paraná dentro da zona de transição entre climas tropicais e subtropicais contribui para a presença de florestas semideciduais. Essas florestas prosperam em áreas com estações úmidas e secas distintas, onde o período seco é pronunciado, mas não tão extremo quanto em florestas totalmente decíduas.

Estudos em diferentes regiões do Paraná têm revelado diversas composições florísticas, com destaque para famílias como *Myrtaceae*, *Fabaceae* e *Rutaceae* (Del Quiqui *et al*., 2007; Caraminan e Gasparetto, 2023). O índice de diversidade de Shannon nessas florestas varia de 3,44 a 3,56, indicando alta biodiversidade (Del Quiqui *et al*., 2007; Caraminan e Gasparetto, 2023). No entanto, alguns fragmentos apresentam sinais de degradação e requerem intervenções de manejo (Gorenstein *et al*., 2022).

Perina *et al*., (2019) discute padrões fenológicos em uma floresta estacional no sul do Brasil, demonstrando a influência das variações sazonais (temperatura e fotoperíodo) na queda das folhas, floração e frutificação. Embora este estudo não seja especificamente no Paraná, ele ilustra a influência climática geral nas florestas sazonais da região.

3.1.3 Floresta Ombrófila Densa

A vegetação característica da Floresta Ombrófila Densa (FOD) pertence a ambientes com temperaturas elevadas, com 25°C de média, e com alta precipitação bem distribuída ao longo do ano, praticamente não havendo período seco. A vegetação característica é composta por fanerófitos, lianas lenhosas e epífitas, e pode ser dividida em cinco classes de acordo com suas faixas altimétricas (IBGE, 2012).

A Floresta Ombrófila Densa é localizada principalmente nas áreas costeiras, esse tipo de floresta é menos afetada pelas mudanças climáticas, mantendo sua distribuição atual (Wrege *et al*., 2017).

(Oliveira-Filho *et al*., 2013) discute a composição de espécies em florestas atlânticas subtropicais, abrangendo a área de distribuição onde ocorre a Floresta Ombrófila Densa no Paraná. Compreender as variações na composição de espécies ao longo dos gradientes ambientais dentro desta região mais ampla é crucial para caracterizar áreas específicas de FOD.

É essencial notar que os remanescentes de FOD no Paraná são altamente fragmentados e muitas vezes intercalados com outros tipos de floresta, tornando o mapeamento preciso desafiador. Além disso, as florestas secundárias (regenerando-se após perturbação) podem apresentar características semelhantes à Floresta Ombrófila Densa primária, adicionando complexidade à classificação. (Socher et al., 2008) enfoca a estimativa de biomassa em uma floresta aluvial ombrófila mista em Araucária, Paraná. Embora o estudo não aborde explicitamente a FOD, ele destaca a importância de considerar tipos específicos de floresta dentro do contexto mais amplo de ambientes aluviais.

3.1.4 Floresta Ombrófila Mista

A Floresta Ombrófila Mista (FOM) é a região caracterizada pela presença de Araucaria angustifolia e é encontrada predominantemente nas partes sul e central do Paraná. É altamente sensível às mudanças climáticas, com projeções indicando uma redução potencial de 96% até 2090 (Wrege *et al*., 2017; Cordeiro *et al*., 2013).

A FOM é conhecida também como mata de araucárias, possui como gêneros característicos *Drymis*, *Araucaria* (australásicos) e *Podocarpus* (afro-asiático) (IBGE, 2012).

A FOM no estado do Paraná, Brasil, é um ecossistema sensível e com alta biodiversidade. Estudos documentam sua presença na região há pelo menos 13.400 anos, com expansão há cerca de 4.210 anos indicando um clima mais frio e úmido

(Bertoldo *et al*., 2014). Pesquisas recentes em áreas de transição entre Araucária e Mata Atlântica revelam alta diversidade de espécies, sendo as famílias Myrtaceae e Lauraceae particularmente abundantes (Reginato e Goldenberg, 2007).

Um estudo na Floresta Nacional de Irati encontrou Araucaria angustifolia como a espécie dominante e ecologicamente mais importante, com a floresta mostrando sinais de avanço da sucessão ecológica (Sawczuk *et al*., 2014).

3.1.5 Formação Pioneira

Ao longo do litoral, planícies fluviais e depressões aluviais encontram-se espécies de primeira ocupação de caráter edáfico, que se estabelecem em solos em constante rejuvenescimento (IBGE, 2012).

As formações pioneiras são caracterizadas por sua capacidade de colonizar habitats perturbados ou recém-criados. Eles são tipicamente compostos por espécies adaptadas a condições adversas, como luz solar intensa, temperaturas flutuantes e solos pobres em nutrientes. Essas espécies geralmente exibem crescimento rápido e altas taxas reprodutivas, permitindo que se estabeleçam rapidamente e dominem os estágios iniciais da sucessão ecológica.

No Paraná, as formações pioneiras estão associadas principalmente a áreas impactadas por distúrbios naturais, como inundações e deslizamentos de terra, bem como por atividades humanas, como desmatamento e agricultura. (Wrublack *et al*., 2013).

Kozera et al., (2009) aborda diretamente uma formação pioneira influenciada pelo rio Iguaçu, enfatizando o papel das inundações na formação de sua composição. O estudo destaca a alta diversidade de espécies encontradas nesses ambientes de várzea e a importância dos esforços de conservação, dada a sua vulnerabilidade aos impactos humanos.

Silva et al., (2016) examina a composição florística de diferentes campos no Paraná, que podem representar vários estágios de sucessão, incluindo formações pioneiras. O estudo sugere uma influência significativa da flora do Cerrado,

indicando uma potencial ligação entre as espécies adaptadas aos ambientes abertos do Cerrado e aquelas encontradas nas formações pioneiras do Paraná.

3.1.6 Savana

Conforme o IBGE (2012), também conhecida como Cerrado, a savana é uma vegetação xeromorfa, ocorrendo sobre uma variedade de climas, mas predominantemente o estacional.

As áreas de transição entre as formações FOM, FOD e FES exibem alta diversidade de espécies, como evidenciado por um estudo em Jardim Alegre, que identificou 78 espécies em 27 famílias (Caraminan et al., 2023). A região centro-oeste do Paraná contém remanescentes de vegetação de cerrado, sugerindo condições paleoclimáticas diferentes do clima atual (Liberali e Ferreira, 2014). As projeções de mudanças climáticas indicam mudanças potenciais nessas fitofisionomias, com a FOM devendo diminuir em 96% e a FES aumentar em 72% até 2090, enquanto as áreas de FOD permanecem relativamente estáveis (Wrege et al., 2017).

Silva e Lacher (2019) menciona como a região do Cerrado, embora não apenas no Paraná, enfrenta uma expansão agrícola significativa, sugerindo o potencial de surgimento de formações pioneiras em áreas perturbadas.

4 MATERIAL E MÉTODOS

Nessa seção serão apresentadas as bases cartográficas de referência consideradas para análise e obtenção de resultados, assim como as especificidades das características dessas informações.

4.1 BASES CARTOGRÁFICAS DE REFERÊNCIA

As bases cartográficas de referência e imagens de satélites utilizados nesta pesquisa, bem como imagens de mapas base, mapeamentos de referência e dados vetoriais de limites oficiais do Estado do Paraná, provenientes do Instituto Água e Terra (IAT) e Instituto Brasileiro de Geografia e Estatística (IBGE) estão descritos, na tabela abaixo.

TABELA 3 – DESCRIÇÃO DE BASES CARTOGRÁFICAS E APLICAÇÕES

Dados	**Aplicação**
Imagens Sentinel-2	Classificação OBIA e ML
Imagens Planet	Validação do mapeamento
Google Earth, Bing	Seleção de amostras e validação
Mapeamento e amostras do MapBiomas	Seleção de amostras e validação
Mapeamento de referência do Baixo Iguaçu	Seleção de amostras e validação
Limites regiões fitoecológicas IBGE	Diferenciar tipos de vegetação
*Base de imoveis do CAR e SIGEF	Identificação do imóvel com desflorestamento
*Banco de Dados SINAFLOR	Autorização de licenciamento
Limites municipais IAT	Localização de área de desflorestamento
Limite mesorregiões IBGE	Localização de área de desflorestamento

*CAR - Cadastro Ambiental Rural e SIGEF - Sistema de Gestão Fundiária.

* SINAFLOR - Sistema Nacional de Controle da Origem dos Produtos Florestais.

FONTE: O autor (2025).

4.1.1 Imagens do satélite Sentinel-2

A série Sentinel-2 é formada pelos satélites Sentinel-2A e 2B, as imagens são fornecidas sem custo de aquisição pela ESA, já ortorretificadas com base em um Modelo Digital de Superfície (MDS) gerado a partir de imagens de radar do satélite do Centro Aeroespacial da Alemanha Missão TanDEM-X, lançado em 2010, sendo utilizados Pontos de Controle Terrestre (PCT) para refinar o modelo geométrico e a geolocalização. Estas imagens foram utilizadas para o mapeamento de floresta nativa e desflorestamento (Quadro 3).

QUADRO 3 – ESPECIFICAÇÕES TÉCNICAS SENTINEL-2, SATÉLITES S-2A E S-2B

Especificações	**Sentinel-2A**	**Sentinel-2B**
Data de lançamento	23 de junho de 2015	7 de março de 2017
Nº de bandas	13 (*Visible and Near-Infrared* - VNIR) ao (*Shortwave Infrared* - SWIR)	13 (VNIR ao SWIR)
Comprimento de onda (nm)	442,7 - 2202,4 nm	442,3 - 2185,7 nm
Sensor (Instrumento)	Multiespectral	Multiespectral
Faixa imageada	290 km	290 km
Faixa de afastamento	180º	180º
Altitude de orbita	786 km	786 km
Inclinação	98,62º	98,62º
Peso	1140 kg	1140 kg
Órbita	Síncrona ao sol	Síncrona ao sol
Formato de imagens	JPEG2000	JPEG2000
Projeção cartográfica	UTM/WGS84	UTM/WGS84
Resolução temporal	10 dias, combinada é de 5 dias (sobre o Equador)	10 dias, combinada é de 5 dias (sobre o Equador)
Resolução espacial (m)	10, 20 e 60 m	10, 20 e 60 m
Geolocalização	Melhor que 12,5 m	Melhor que 12,5 m
Registro multitemporal	Melhor que 0,5 pixels	Melhor que 0,5 pixels
Resolução radiométrica	12 bits (0 a 4095 valores)	12 bits (0 a 4095 valores)
Vida útil mínima em orbita	7 anos	7 anos
Local de lançamento	Kourou, Guiana Francesa	Kourou, Guiana Francesa
Agência	ESA	ESA

FONTE: ESA (2020).

O sensor *Multi Spectral Imager* (MSI) gera imagens multiespectrais que podem ser usadas para aplicações no monitoramento de uso e cobertura solo, com bandas de 10 a 60 m de resolução espacial, e resolução temporal de 5 dias.

Apresentando compatibilidade espectral com outros sensores, tais como o OLI e o ETM+, do satélite LANDSAT. Ao total são 13 bandas espectrais com diferentes comprimentos de onda 442,3 a 2202,4 nm (nanômetros) e diferentes resoluções espaciais, como pode ser visto no quadro 4.

QUADRO 4 – BANDAS ESPECTRAIS DO SENTINEL-2, SENSOR S2A E S2B

S2A			**S2B**	
Número da banda	Comprimento de onda central (nm)	Largura de banda (nm)	Comprimento de onda central (nm)	Resolução espacial (m)
1	442,7	21	442,3	60
2	492,4	66	492,1	10
3	559,8	36	559,0	10
4	664,6	31	665,0	10
5	704,1	15	703,8	20
6	740,5	15	739,1	20
7	782,8	20	779,7	20
8	832,8	106	833,0	10
8A	864,7	21	864,0	20
9	945,1	20	943,2	60
10	1373,5	31	1376,9	60
11	1613,7	91	1610,4	20
12	2202,4	175	2185,7	20

FONTE: ESA (2020).

4.1.2 Imagens Planet

A empresa Planet opera as constelações PlanetScope, SkySat e RapidEye, coletando imagens e as processando em vários formatos para diferentes usos. A constelação PlanetScope possui um conjunto de satélites, capazes de orbitar todo o planeta todos os dias, as imagens são capturadas em faixas contínuas de quadro únicos, chamadas de cenas, que podem ser adquiridas com bandas do visível (Red,

Green e Blue - RGB) (Vermelho, Verde e Azul) ou com bandas RGB e (*Near Infrared* - NIR) (Infravermelho Próximo) (Figura 5).

FIGURA 5 – MOSAICO DE IMAGENS PLANET, COMPOSIÇÃO COR NATURAL (RGB-123), JUNHO DE 2016

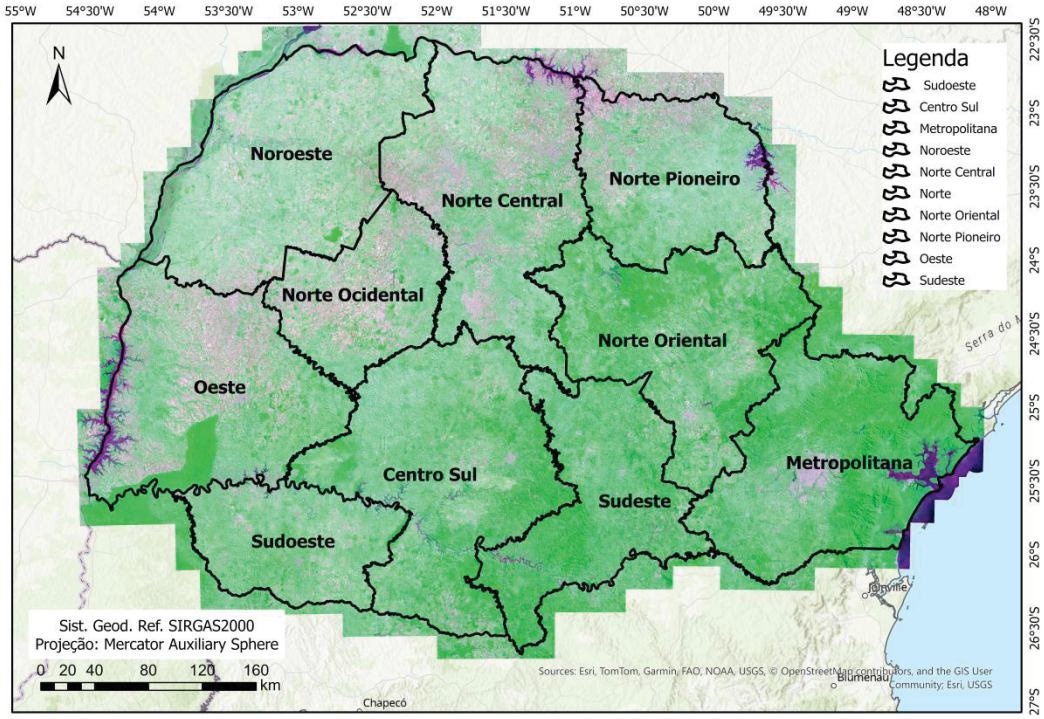

FONTE: O autor (2025).

As imagens não são ortorretificadas, o sensor possui 4 bandas espectrais incluindo uma banda NIR. As imagens variam de 12 bit a 16bit de resolução radiométrica e a exatidão de posição é inferior a 10 m de *Root Mean Squared Error* (RMSE) (Planet, 2016), como visualizado no quadro 5.

QUADRO 5 – CARACTERÍSTICAS DAS BANDAS ESPECTRAIS DAS IMAGENS PLANET

Bandas	Resolução espacial	Resolução radiométrica	Comprimento de onda (nm)
Azul	3 m	12 a 16 bit	455-515
Verde			500-590
Vermelho			590-670
Infravermelho Próximo (NIR)			780-860

FONTE: O autor (2025).

As imagens da constelação de satélites Planet foram obtidas por meio da página web *Basemap Viewer* fornecidas pela Planet, onde é possível selecionar imagens de composições mensais, havendo também a opção de escolha por composição de mosaicos de imagens mensal ou anual. A base de imagens pode ser acessada por meio do link <https://www.planet.com/basemaps/#>, sendo necessário realizar um cadastro para ter acesso ao produto.

As imagens do satélite RapidEye passam por um processamento onde são aplicadas as correções radiométricas e todas as imagens são dimensionados para uma faixa dinâmica de 16 bits (Planet, 2016), como visualizado no quadro 6.

QUADRO 6 – CARACTERÍSTICAS DAS BANDAS ESPECTRAIS DAS IMAGENS RAPIDEYE

Bandas	Resolução espacial	Resolução radiométrica	Comprimento de onda (nm)
Azul	5 m	16 bit	440-510
Verde			520-590
Vermelho			630-690
Borda do Vermelho (*Red-Edge* – RE)			690-730
Infravermelho Próximo NIR			760-880

FONTE: O autor (2025).

4.1.3 Bases cartográficas de referência

Como bases cartográficas de referência e dos limites estaduais e municipais, do Estado do Paraná.

A base do Sistema de Gestão Fundiária (SIGEF) do Instituto Nacional de Colonização e Reforma Agrária (INCRA) e os dados dos limites declarados pelo Cadastro Ambiental Rural (CAR) para o Estado do Paraná disponibilizados pelo Sistema Nacional de Cadastro Ambiental Rural (SICAR), as bases dos imóveis cadastrados foram utilizadas posteriormente para identificação da localização das propriedades com desflorestamentos, como visualizado na figura 7.

QUADRO 7 – BASES CARTOGRÁFICAS DE REFERÊNCIA

Bases	**Link**	**Formato**
CAR/	https://geoserver.car.gov.br/geoserver/sicar/wfs	Serviço WFS
SIGEF/INCRA	http://acervofundiario.incra.gov.br/i3geo/ogc.php?tema=certificada_sigef_publico_pr http://acervofundiario.incra.gov.br/i3geo/ogc.php?tema=certificada_sigef_particular_pr http://acervofundiario.incra.gov.br/i3geo/ogc.php?tema=imoveiscertificados_publico_pr	Serviço WFS
SINAFLOR/ IBAMA	https://pamgia.ibama.gov.br/server/services/app_dadosabertos/asv_aasv_sinaflor_a/MapServer/WFSServer?request=GetCapabilities&service=WFS	Serviço WFS

Cada identificação de desflorestamento gerado, foi analisado com base nas informações públicas, incluindo as localizações dos embargos e autorizações de desflorestamento do Sistema Nacional de Controle da Origem dos Produtos

Florestais (SINAFLOR) do Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA).

4.1.3.1 Mapas de referência temática

Como conjunto amostral foi usado o mapeamento e amostras do MapBiomas para o ano de 2016, coleção 6 (Souza *et al.*, 2020), sendo utilizado como referência para amostras de treinamento e validação para obtenção de acurácia temática.

Foi utilizado tambem o mapeamento de referência da bacia do Rio Iguaçu, ano de 2015, na resolução espacial de 30 m, usado como referência para seleção de amostras e validação temática (Sanquetta; Dalla Corte, 2017), como podemos visualizar na figura 6.

FIGURA 6 – MAPEAMENTO DE REFERÊNCIA FEITO COM IMAGENS LANDSAT, SUB-BACIA DO RIO IGUAÇU ANO DE 2015

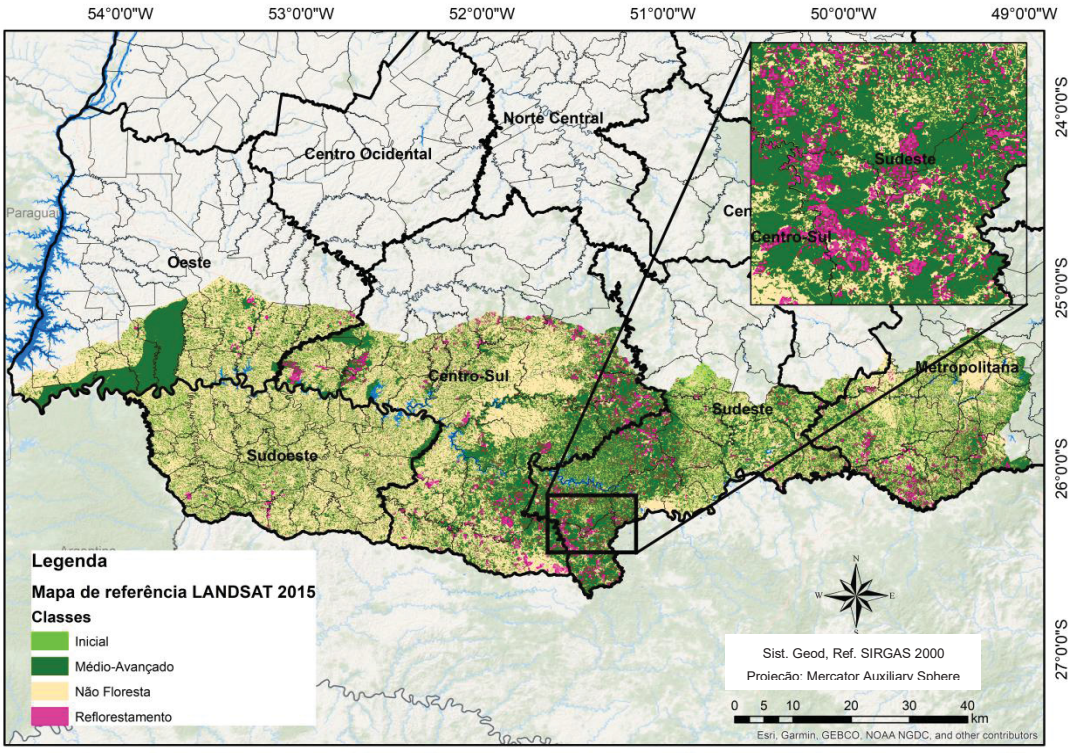

FONTE: Adaptado de Sanquetta e Dalla Corte (2017).

Os dados de referência para validação temática incluíram também imagens de alta resolução espacial das plataformas da Planet, Google Earth, Bing, *Environmental Systems Research Institute* (ESRI) e de outras fontes.

FIGURA 7 – BASE DOS LIMITES DE IMÓVEIS CADASTRADOS NO CAR NO ESTADO DO PARANÁ, 2024

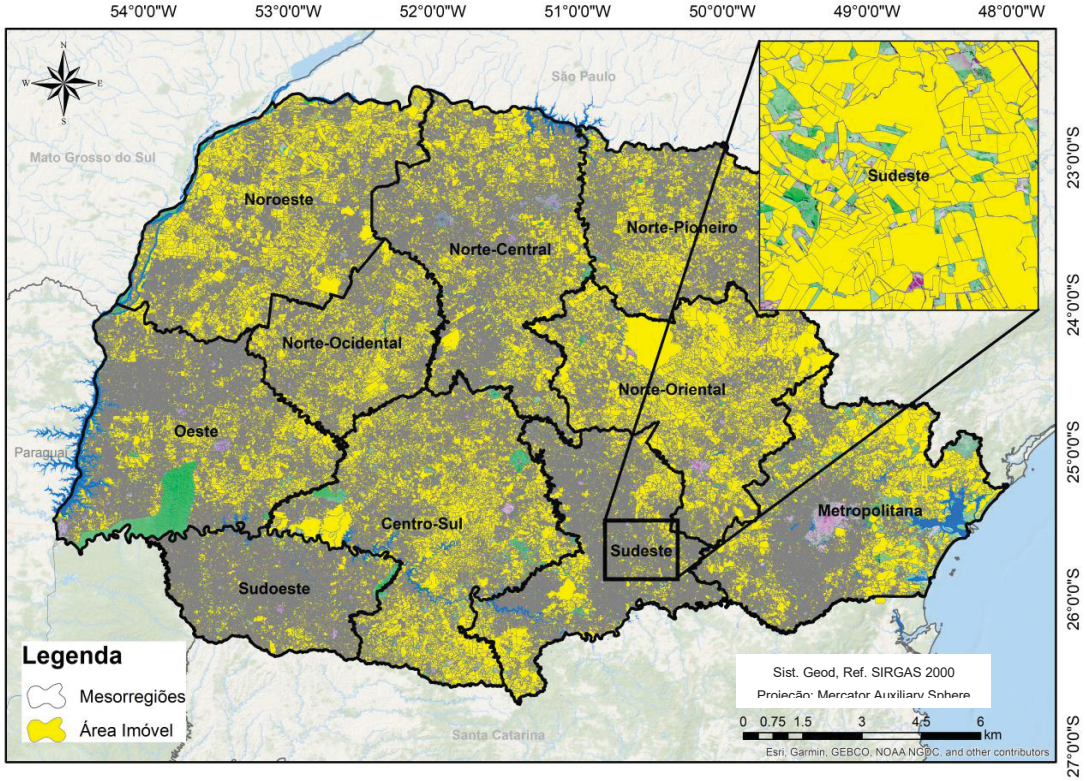

FONTE: SICAR, (2024).

4.2 RECURSOS COMPUTACIONAIS

A maior parte dos recursos computacionais incluindo softwares, Sistema de Informação Geográfica (SIG), bibliotecas, extensões, plugins, dentre outros, utilizados nesta pesquisa para o desenvolvimento da metodologia para mapeamento de floresta nativa e para detecção de desflorestamento são de licença livres e gratuita, conforme o quadro 8.

QUADRO 8 – RECURSOS COMPUTACIONAIS UTILIZADOS

Denominação	**Tipo**	**Licença**	**Aplicação**
SNAP 11.0/ESA (Sen2Cor255)	Software Plugin	Gratuito Livre	Correção Atmosférica
Terra View 5.7.1	Software SIG	Gratuito Livre	Normalização radiométrica
ArcGis PRO	Software SIG	SIMEPAR	Identificação de desflorestamentos Validação e avaliação da acurácia espacial
ArcGIS 10.2	Software SIG	SIMEPAR	Composições RGB e mosaicos Correção topológica
ENVI 5.1	Software	SIMEPAR	Avaliação da acurácia
Ecognition/Trimble 10.0	Software	TRIAL	Imagens de textura, Índices de vegetação e Segmentação e classificação supervisionada OBIA *Nearest Neighbor* (NN)
GEE	Plataforma computacional de processament na nuvem (*cloud*)	Gratuito para pesquisa	Geração de métricas de frações, índices de vegetação Classificação supervisionada ML e aplicação de filtro espacial, Detecção de mudança e análise de series temporais
QGis 3.4	Software SIG	Gratuito Livre	Correções de topologia e estimativa de área
Qgis2web 3.24	Software Plugin	Gratuito Livre	Localização de imóveis com desflorestamentos

FONTE: O autor (2025).

4.3 METODOLOGIA

O desenvolvimento da metodologia desta pesquisa consistiu em 2 etapas, cada qual correspondente a uma abordagem científica da tese; a figura 8 representa as etapas do procedimento metodológico relativas a cada abordagem. O item 4.4 descreve o procedimento metodológico do mapeamento florestal (Abordagem 1) e o item 4.5 o procedimento metodológico do sistema de detecção de desflorestamento (Abordagem 2).

FIGURA 8 – FLUXOGRAMA METODOLÓGICO

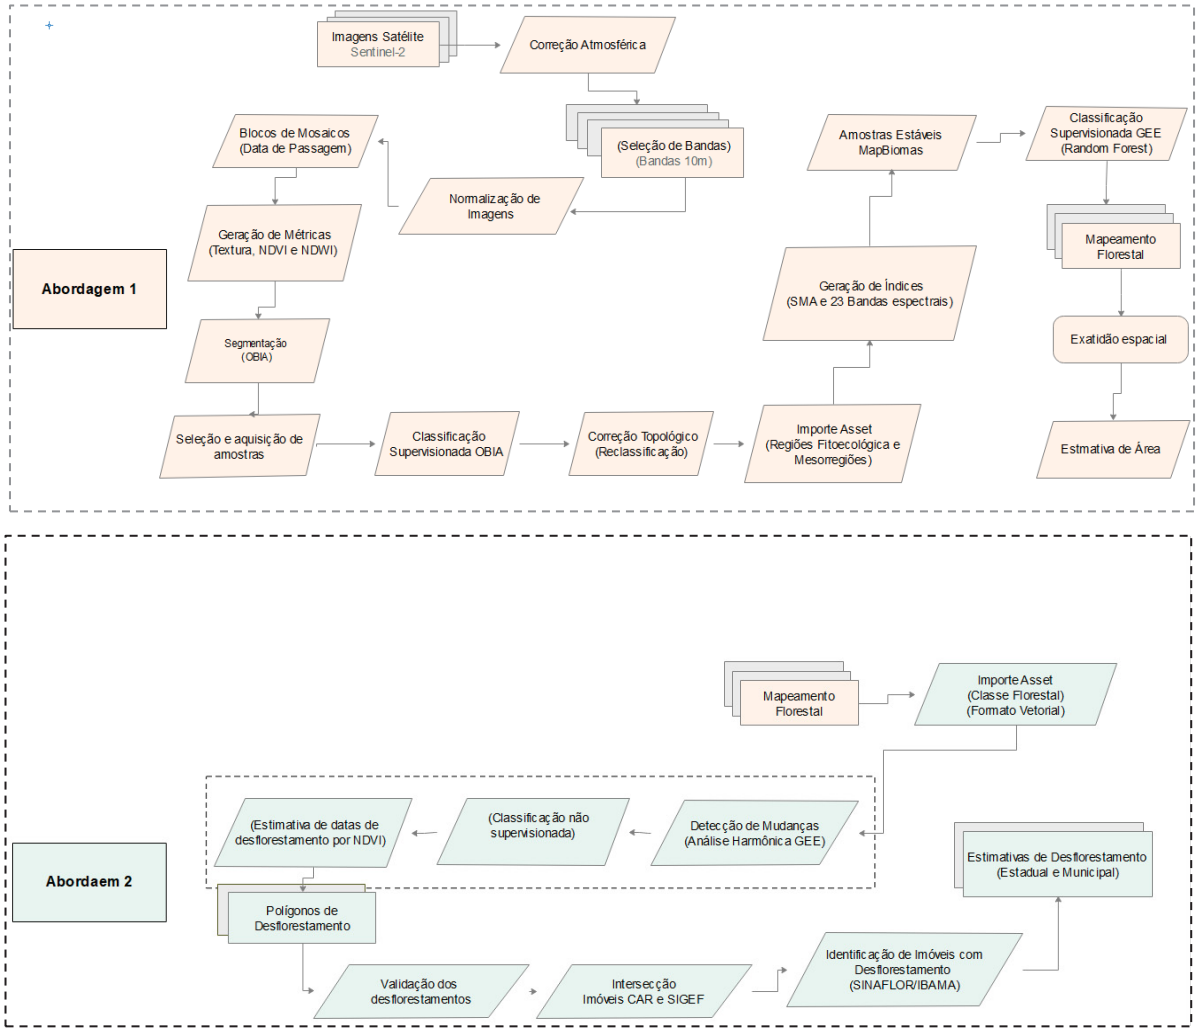

FONTE: O autor (2025).

4.4 MAPEAMENTO FLORESTAL

O método de pesquisa da abordagem 1 consistiu nas seguintes etapas: (1) Seleção de dados: Aquisição de imagens de satélite (Sentinel-2); (2) Correção Atmosférica das imagens Sentinel-2 (Main-Knorn *et al*., 2017), Seleção de bandas, composição RGB, aplicação de normalização radiométrica e mosaicos (INPE, 2021); (3) Geração de imagens de textura *Grey Level Co-occurrence Matrix* (GLCM) e índices de vegetação como (NDVI e *Normalized Difference Water Index* (NDWI); (4)

Segmentação de Imagens: Definição de parâmetros de segmentação; (5) Seleção de amostras homogêneas e aplicação de classificação supervisionada *Nearest Neighbor* (NN); (7) Correção topológica; (8) Reclassificação para classes de floresta e não floresta; (9) Importação de vetores na forma de Asset GEE das regiões fitoecológicas, mesorregiões e das classes de floresta e não floresta para o GEE; (10) Geração de métricas de frações e índices de vegetação no GEE; (11) Uso de amostras do MapBiomas por mesorregião; (9) Classificação supervisionada por ML; (12) Aplicação de filtro espacial; (13) Avaliação da acurácia espacial; (14) Estimativa de área florestal.

4.4.1 Seleção das imagens Sentinel-2

Foram obtidas todos as orbitas pontos das imagens do ano de 2016, que estão contidas dentro do limite do estado do Paraná. Para a seleção das imagens Sentinel-2 foram considerados imagens que correspondem a datas de mesma passagem do satélite Sentinel-2A e 2B, usando como critério imagens disponíveis livres de nuvens e períodos de entressafra agrícola (baixo vigor vegetativo).

4.4.2 Correção atmosférica

Como algoritmo de correção atmosférica foi utilizado o pluguin Sen2Cor disponível no software SNAP toolbox da ESA desenvolvido de forma especifica como um processador para geração e formatação de produtos Sentinel-2 nível-2A (imagens de reflectância de superfície ortoretificadas Bottom-Of-Atmosphere - BOA)), para executar a correção atmosférica dos dados de entrada nível-1C (Main-Knorn *et al*., 2017). O Sen2Cor efetua a correção atmosférica individualmente para cada banda da imagem, removendo e atenuando a presença de nuvens e vapor da água convertendo as imagens em valores de reflectância para todas as bandas de 10 m, 20 m e 60 m de resolução espacial (ESA, 2021).

4.4.3 Seleção de bandas

Após a correção atmosférica foram selecionadas somente as bandas de resolução espacial de 10 m, sendo as 3 bandas do visível (b2, b3 e b4) e a banda b8 do infravermelho próximo, desta forma foram geradas as composições de imagens para cada orbita/ponto que cobrem o Estado do Paraná.

As composições de bandas das imagens Sentinel-2, foram geradas utilizado a ferramenta ‘‘*Composite Bands’’*, do ArcGis e as composições de cor verdadeira e falsa cor foram usadas como apoio visual, para auxiliar no processo de seleção e aquisição amostral, também foi feito uma padronização dos sistemas de coordenadas geográficas para o Datum SIRGAS2000.

4.4.4 Normalização e mosaicagem

Para a normalização radiométrica da seleção de bandas e das composições geradas foi utilizado o método de mistura espectral, onde foi efetuada a reamostragem do vizinho mais próximo, sendo desta forma, gerados 6 blocos de mosaicos de imagens, como pode ser visto no quadro 9.

QUADRO 9 – BLOCOS DE MOSAICOS POR DATAS DAS IMAGENS SENTINEL-2, CLASSIFICAÇÃO SUPERVISIONADA POR OBIA

Satélite Sentinel2	**Sensor/Imagem**	**Nível**	**Datas**
Mosaico 1	MSI	2A	10/09/2016
Mosaico 2			25/07/2016
Mosaico 3			06/12/2016
Mosaico 4			01/08/2016
Mosaico 5			10/09/2016
Mosaico 6			23/09/2016

FONTE: O autor (2025).

4.4.5 Segmentação de imagens por OBIA

Na sequência foram geradas imagens de textura de Haralick (propõem 14 medidas de textura) e índices de vegetação NDVI e NDWI, este procedimento inicial serviu de preparação dos dados para segmentação e extração de informação. Foi usado Análise de Componentes Principais (ACP) para definir qual variável de textura melhor representa a distinção de reflorestamento (silvicultura) de floresta nativa.

Os parâmetros de segmentação utilizados levam em consideração na definição de regiões homogêneas, fatores de características de cada imagem, a delimitação das regiões pode ser representada por um conjunto de pixels agrupados de acordo com parâmetros espectrais de homogeneidade.

A segmentação de imagens e a parametrização foram configuradas de acordo com as características das imagens sendo utilizado o software Ecognition 10.0. Pesos foram atribuídos para serem utilizados na segmentação, a partir de três parâmetros; (*Scale*, *Shape* e *Compactness*) que corresponde a Escala, Forma e Compacidade dos objetos gerados (Baatz; Schäpe, 2000).

Foi utilizado o algoritmo "*Multiresolution segmentation"* (Trimble, 2014). Os parâmetros foram ajustados para cada imagem, e determinados a partir de experimentos que foram testados, definidas as configurações e características espectrais para cada bloco de mosaico de imagens, como visto no quadro 10.

QUADRO 10 – AJUSTE DE PARÂMETROS DO ALGORITMO MULTIRESOLUTION SEGMENTATION

Parâmetros	**Descrição**
Algorithm	*Multiresolution Segmentation*
Domain	*Image Object Lever*
Number of cycles	1
Level Usage	*Create Below*
Scale	150
Shape	0,1
Compactness	0,5

FONTE: O autor (2025).

O processo de classificação por OBIA é um processo interativo de experimentação, independentemente do método ou algoritmo de classificação utilizado. Desta forma, algumas classes de uso do solo foram segmentadas, utilizando diferentes parametrizações.

4.4.6 Seleção de conjuntos amostrais

Para os processos de amostragem foram utilizados dados de referência para treinar e orientar o algoritmo de classificação. Também denominados dados de "verdade de campo". Estas áreas então foram identificadas por interpretação visual nas imagens Sentinel-2 e Planet, sendo utilizados também dados de mapeamentos de referência do MapBiomas (Souza *et al*., 2016) e da Sub-bacia do Rio Iguaçu (Sanquetta; Dalla Corte, 2017).

4.4.7 Classificação supervisionada por OBIA

Após o processo de segmentação e extração de informações derivadas das imagens foram geradas as informações e variáveis estatísticas dos objetos extraídas das imagens (tamanho, forma, brilho) que foram usadas para classificar as classes de uso e cobertura do solo, como floresta nativa e silvicultura.

No processo de classificação, foram utilizados diferentes tipos de composições RGB (falsa-cor) para diferenciar diferentes tipos florestais como floresta nativa de silvicultura.

Também foram utilizadas diferentes bases cartográficas de referência como informação adicional para auxiliar no processo de classificação. Como bandas adicionais foi gerado e utilizado o (NDVI e NDWI) e a imagem de textura Haralick definida pela ACP (Haralick, 1973; 1979; Conner; Harlown, 1980).

O algoritmo de classificação utilizado é o NN, que é um método de classificação supervisionado derivado da teoria da aprendizagem estatística (Cover;

Hart, 1967). O mapeamento gerado corresponde a uma classificação de Nível-1 e foram adotadas 9 classes temáticas, conforme o quadro 11.

QUADRO 11 – CLASSES DE USO E COBERTURA DO SOLO DE NÍVEL-1

Classes	Descrição
1-Agricultura	Corresponde à agricultura anual (milho, soja, trigo, entre outras) e agricultura perene, identificada como sendo de alto, baixo e médio vigor vegetativo;
2-Água/Espelho d'água	Lagos, lagoas, açudes, rios, barragens, tanques, não tendo diferença para lagoas de tratamento de resíduos, minério ou de qualquer outro tipo;
3-Floresta	Corresponde à remanescentes de floresta nativa, com exceção dos manguezais (Classe 8), não tendo distinção de diferentes estágios sucessionais;
4-Silvicultura	Plantios florestais homogêneos, independente da espécie, como Pinus e Eucaliptos;
5-Pastagem	Corresponde a todos os tipos de pastagem, nativas ou exóticas, naturais ou plantadas;
6-Agricultura semi-perene	Corresponde às áreas de cultivos agrícolas de cana-de-açúcar, e outros cultivos temporários (semi-perenes);
7-Área alagada	Corresponde às áreas pantanosas, denominadas regionalmente de banhados ou marismas (influência salina). Caracterizam-se pela ocorrência de plantas aquáticas emergentes, submersas ou flutuantes. Ocupam planícies e depressões do terreno com solo encharcado e as margens rasas de lagoas ou reservatórios de água.
8-Manguezal	Corresponde à formações florestais, densas, sempre-verdes, frequentemente inundadas pela maré e associadas ao ecossistema costeiro de Manguezal;
9-Mancha Urbana	Inclui áreas urbanizadas ou concretadas, e malha viária.

FONTE: Adaptado de MapBiomas (2020).

4.4.8 Correção topológica

Foram aplicadas correções topológicas no mapeamento de nível-1 e feito junções dos mosaicos de classificação no formato vetorial (shapefile) com uso das ferramentas (*merge* e *dissolve*) do ArcGis.

As funções de análise topológica foram aplicadas levando em consideração todas as classes. Como ferramentas topológicas, foram utilizadas as ferramentas "Reparar e Correção de geometria" no sotware Qgis, na sequência a ferramenta "*Intersect*", para identificar áreas ou bordas sobrepostas entre as classes seguidos das ferramentas "*Symmetrical difference*" e "*Erase*" do ArcGis, para identificar inconsistências geradas pelo algoritmo de classificação.

Tambem no ArcGis foi usado a função "*Dissolve*" aplicada nas classes de uso e cobertura do solo para agrupar classes em um único arquivo no formato vetorial shapefile (.shp). Posteriormente, foram aplicadas as funções "*Check geometry*" e "*Repair geometry*", para corrigir inconsistências nas geometrias ou na tabela de atributos. A partir destas análises de topologia foi aplicada a ferramenta "*Explode*" para transformar a classe de floresta em polígonos independentes (ferramenta "*Multipart to Singlepart*"), sendo estes separados por mesorregião, região fitoecológicas e importados em blocos na forma de Asset no GEE.

4.4.9 Classificação supervisionada por ML no GEE

O mapeamento de nível-1 com 9 classes temáticas foi reclassificado para as classes de floresta e não floresta e desta forma importados na forma de Asset no GEE e usados como regiões de interesse, e desta forma um novo processo de classificação supervisionado foi iniciado, desta vez, por ML, sendo usadas as amostras estáveis do MapBiomas para o ano de 2016 como conjunto amostral pelo método amostragem aleatório proporcional, servindo de base para treinamento do classificador e para validação (Souza *et al*., 2020).

Sendo assim foram testadas algumas alternativas de classificadores supervisionados como SVM, CART, GTB e RF. A classificação supervisionada digital foi realizada por regiões fitoecológicas contidas em cada mesorregião do estado do Paraná, método usado para facilitar o processo de classificação e considerar regiões homogêneas por tipos de florestas. Para avaliar qual o melhor método de classificação foi dividido o conjunto amostral em 66% como amostras de treinamento e 33% como amostra para validação.

Para o processo de classificação supervisionada a pixel por ML no GEE foi utilizado um níveis de filtragem de nuvem especifico para cada mesorregião do estado do Paraná, foi gerado um novo mosaico de imagens considerando uma composição de pixels de mediana e datas disponíveis em períodos de entressafras agrícolas para as culturas anuais com maior predomínio no Paraná, como soja, milho (verão) e trigo (inverno), que têm alto vigor vegetativo, como mostra agrupamento do quadro 12.

QUADRO 12 – RELAÇÃO DE MOSAICOS POR DATAS DAS IMAGENS SENTINEL-2, USADAS PARA CLASSIFICAÇÃO POR ML NO GEE

Mesorregião	**Sensor**	**Nível**	**Nuvens (%)**	**Período de Datas**
Noroeste	MSI	2A e 2B	20	2016-09-01 a 2016-09-30
Norte Central			20	2016-09-01 a 2016-09-30
Norte Pioneiro			20	2016-09-01 a 2016-09-30
Centro Sul			50	2015-06-01 a 2016-12-30
Sudeste			10	2015-06-01 a 2016-12-30
Sudoeste			20	2016-09-01 a 2016-09-30
Oeste			20	2016-09-01 a 2016-09-30
Centro Oriental			10	2016-01-01 a 2016-12-30
Centro Ocidental			20	2016-09-01 a 2016-09-30
Metropolitana			50	2015-06-01 a 2016-12-30

FONTE: O autor (2025).

Foram usadas no processo de classificação as bandas espectrais do visível e infravermelho na resolução espacial de 10 m do Sentinel-2, as frações espectrais *Spectral Mixture Analysis* (SMA) e índices de vegetação (Tabela 3), em um total de 23 bandas espectrais. As frações espectrais denominadas de SMA foram geradas a partir do cálculo das frações *Green Vegetation* (GVs), *Non-Photosynthetic Vegetation* (NPV), *Soil e Shade*, implementadas no GEE.

O SMA é modelo de mistura espectral que utiliza o processamento de imagem com base física para extração de informações qualitativas e quantitativas, auxiliando na derivação repetida e precisa de informações quantitativas de sub-pixel (Roberts *et al*., 1999; Smith *et al*., 1990). Alguns trabalhos fizeram o uso de SMA, na estimativa e mapeamento de resíduos de culturas agrícolas (Bannari *et al*., 2006; Pacheco; McNairn, 2010).

O SMA trabalha com a suposição de que um espectro calculado por um sensor considera uma combinação linear dos espectros de todos os componentes dentro do pixel e as proporções espectrais dos membros finais são consideradas refletindo as proporções da área ocupada por características definidas na superfície terrestre (Adams *et al*., 1995; Lu *et al*., 2004).

Os índices de vegetação utilizados foram calculados no GEE também com base na composição de imagens de mediana (Ganz *et al*., 2020), sendo estes: NDVI, EVI, Pigment Specific Simple Ratio (PSSR), *Index Chlorophyll* (IC), GNDVI, *Simple Ratio Moisture Stress Index* (SRMSI), *Normalized Difference* (NDII), *MERIS Terrestrial Chlorophyll Index* (MTCI), *Chlorophyll Red-Edge* (CHLRED-edge), *Measure the amount of Chlorophyll-AB* (mNDblue), *Sentinel-2 Red-Edge Position Index* (S2REP), *Red-Edge Inflection Point Index* (REIP), *Difference Vegetation Index* (DVI), *Normalized Difference Index* (NDI45), *Soil Adjusted Vegetation Index* (SAVI), *Brightness Index* (BI), *Colour Index Algorithm* (CI), *Normalized Difference Water Index 2* (NDWI2), descritos na tabela 4.

TABELA 4 – BANDAS ESPECTRAIS, ÍNDICES DE VEGETAÇÃO E COMPOSIÇÃO DE FRAÇÕES USADAS NO PROCESSO DE CLASSIFICAÇÃO

Bandas	***Spectral Mixture Analysis* (SMA)**	**Índice de Vegetação (IV)**
B2, B3, B4, B8 B5, B6, B7, B8A B11	(GVs, NPV, Soil, Shade)	NDVI, EVI2, PSSR, IC, GNDVI, MSI, NDII, MTCI, CHLRED, mNDblue, S2REP, REIP, DVI, NDI45, SAVI, BI, CI, NDWI2

FONTE: O autor (2025).

Após o processo de classificação supervisionado a pixel foi aplicado um filtro espacial para evitar modificações indesejadas nas bordas dos grupos de pixels, este filtro espacial foi construído utilizando a função "*connectedPixelCount*". Disponível e implementada na plataforma GEE, esta função localiza componentes conectados (vizinhos) que compartilham o mesmo valor de pixel. Assim, apenas pixels que não compartilham conexões com um número predefinido de idênticos vizinhos são considerados isolados. Neste filtro, pelo menos seis pixels conectados são necessários para alcançar o valor mínimo de conexão. Consequentemente, a unidade de mapeamento mínima é diretamente afetada pelo filtro espacial aplicado, sendo definido como 6 pixels (~ 0,5 ha) (Souza *et al*., 2020).

O mapeamento final de floresta nativa do Estado do Paraná, consistiu em duas classes temáticas sendo estas, as classes de Floresta nativa e Floresta não nativa onde estão contidas as áreas de plantios florestais como pinus e eucalipto, conforme a tabela abaixo.

TABELA 5 – CLASSES DE USO E COBERTURA DO SOLO CLASSIFICADAS NO GEE POR ML

Classes OBIA	Classes ML
Floresta nativa	Floresta nativa
Agricultura Água/Espelho d'água Silvicultura (Plantio florestal) Pastagem Cana-de-açúcar Área alagada Mangue Mancha urbana	Floresta não nativa

FONTE: O autor (2025).

4.4.10 Avaliação da acurácia temática

A metodologia de avaliação da acurácia espacial e validação temática seguiu como base a norma de Especificação Técnica para Controle de Qualidade de Dados Geoespaciais (ET-CQDG) da Diretoria de Serviço Geográfico do exército brasileiro (DSG, 2015), a qual adota os planos de amostragem descritos nas normas *International Organization for Standardization* (ISO) 19157 do Manual do IBGE.

A amostragem espacial foi feita particionando as células de forma combatível com escala do mapeamento a ser avaliado, usando valores inteiros na forma de grade. O número de células depende da escala e do tamanho da área de estudo (Tabela 6).

TABELA 6 – AMOSTRAGEM ESPACIAL ET-CQDG DA DSG 2015

Escala	Espaçamento (m)
1:10.000	400 x 400
1:25.000	1000 x 1000
1:60.000	2400 x 2400
1:160.000	6400 x 6400

FONTE: O autor (2025).

A partir da definição da escala 1:60.000, foi gerada a grade e o número de pontos a serem usados para validação. A geração da grade e dos pontos foi feita com o uso da ferramenta "*Fishnet"* do ArcGis, o conjunto de pontos populacional é gerado a partir do centróide da grade, o conjunto de pontos gerados foi de 34.708 pontos para todo o Estado do Paraná, um ponto de referência a cada 2,4 km, como pode ser visualizado na figura 9.

FIGURA 9 – GRADE AMOSTRAL UTILIZADO PARA VALIDAÇÃO DO MAPEAMENTO

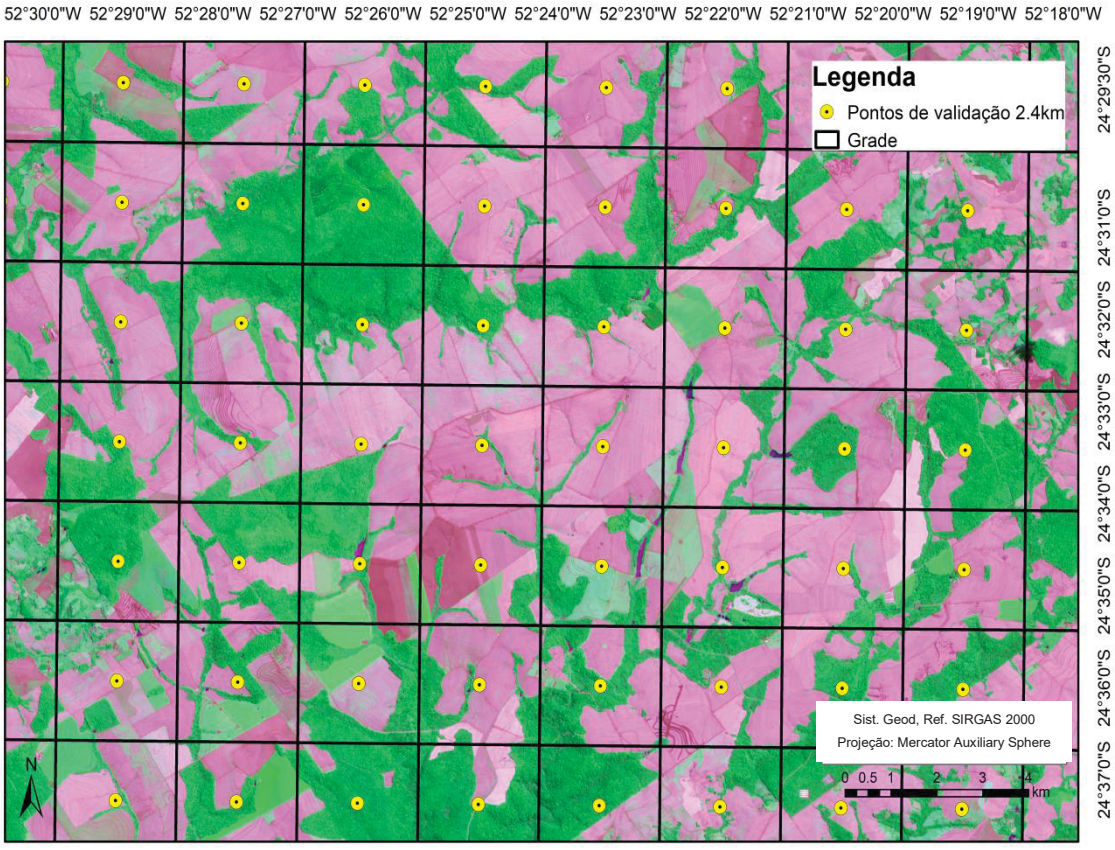

FONTE: O autor (2025).

A partir do uso da tabela de atributos da base de pontos gerada foram selecionadas as classes correspondentes a cada um dos pontos, utilizando dados de mapeamento de referência do MapBiomas de 2016 (Souza *et al*., 2020) e dados de mapeamento feito na Sub-bacia do Rio Iguaçu (Sanquetta; Dalla Corte, 2017).

Desta forma todos os pontos do conjunto foram identificados nas imagens Sentinel-2 e Planet de forma visual por interpretação de imagem, e desta forma sendo definida a matriz de pontos de referência, padronizada para duas classes temáticas (Floresta nativa e Não floresta nativa) (Foody, 2009; Olofsson *et al*., 2014; Stehman, 2014).

A análise de validação dos mapeamentos consistiu na avaliação da acurácia a partir da matriz de confusão, para isto foram utilizadas as medidas estatísticas Índice Kappa (IK), Exatidão Global (EG), Erros de Inclusão (EI) e Erros de Omisão (EO) (Congalton, 1991; Congalton; Green, 1999; Finegold *et al*., 2016).

A matriz de confusão consite na avaliação de modelos de classificação, e fornece o desempenho de tais modelos por meio de sua representação sistemática de positivos verdadeiros, falsos positivos, falsos negativos e negativos verdadeiros. Essas métricas são essenciais para avaliar a eficácia de modelos preditivos de forma abrangente.

A matriz de confusão foi gerada utilizando a ferramenta "*Band Threshold to Roi Band"* do software ENVI para importar o mapeamento final, seguida pela ferramenta de "*Post classification*, *Confusion Matrix"*, que gera o IK e EG, conforme as equações apresentadas a seguir.

$$IK = \frac{[n * \sum_{i=1}^{r} x_{ij} - \sum_{i=0}^{r} (x_i * x_j)]}{[m^2 - \sum_{i=1}^{r} (x_i * x_j)]} \quad (1)$$

$$EG = \frac{A}{m} * 100 \quad (2)$$

em que:

n = número de observações (pixels amostrais);

A = acerto geral (pixels amostrais classificados corretamente);

m = número de pixels amostrais;

r = número de linhas da matriz de erro;

x_{ij} = observações na linha i e coluna i;

x_i = total marginal da linha i;

x_j = total marginal da coluna j.

4.4.11 Estimativa de área

Após a avaliação da acurácia por meio de validação do mapeamento de floresta nativa, foram geradas as estimativas de área florestal, para isto foi usado o Datum: SIRGAS2000 na projeção Cônica Equivalente de Albers (*Albers Equal Area*), conforme orientações do IBGE, com os parâmetros: Longitude de origem: -54°, Latitude de origem: -12°, Paralelo padrão 1: -2° e Paralelo padrão 2: -22°''.

O mapeamento foi então quantificado pela contagem de pixels contidos por classes e em cada município do Estado do Paraná, para isto foi utilizado a ferramenta "Estatísticas zonais" do QGIS, que permite fazer a contagem de pixels contidos por município e, posteriormente, convertidos em hectares (ha).

A estimativa de área de floresta nativa foi obtida para os 399 municípios do Estado do Paraná, onde a somatória de área estimada em nível municipal foi quantificada para as 10 mesorregiões, totalizando desta forma o quantitativo a nível estadual. E desta forma comparadas com o mapeamento oficial IAT, (2012/2016) gerado com imagens do satélite WorldView de 2012 a 2016 com 2m de resolução espacial e dados do mapeamento de uso e cobertura do solo do MapBiomas de 2016 na resolução espacial de 30m.

A análise estatística dos resultados consistiu na comparação pareada entre as estimativas de área florestal geradas, os conjuntos de dados, em nível municipal, foram submetidos ao Teste de Shapiro-Wilk a 5% de significância para testar a hipótese de normalidade, onde a hipótese nula (H_0) indica que os dados possuem normalidade e a hipótese alternativa (H_1) indica que os dados não possuem normalidade.

A análise de suposições de normalidade se faz necessária para indicar qual coeficiente de correlação deve ser utilizado na comparação, o coeficiente de correlação de Pearson (r) e utilizado quando as suposições de normalidade são

atendidas, caso não atenda às suposições de normalidade, o coeficiente não paramétrico de Spearman (r_s) deve ser utilizado.

Indicadores estatísticos como o Erro Médio (EM) e o índice de concordância refinado de Willmott (d_r) definidos respectivamente, nas equações 3 a 4, foram usados para avaliar é comparar as estimativas de áreas municípais.

$$EM = \frac{1}{n} * \sum_{i=1}^{n} (O_i - E_i)^2 \quad (3)$$

$$d_r = 1 - \frac{\sum_{i=1}^{n} |E - \underline{O}|}{2 * \sum_{i=1}^{n} |O - \underline{O}|} \quad (4)$$

em que,

E_i = área florestal estimada do município;

O_i = área florestal nativa observada dos municípios;

$\underline{O}$ = área média de floresta nativa observada nos municípios;

n = números de municípios.

O EM representa o afastamento médio dos valores estimados em relação aos observados, de forma geral mede a média dos erros. Já o índice de concordância refinado de Willmott (dr) foi proposto por Willmott *et al*. (2012) em reformulação ao índice desenvolvido por Willmott *et al*. (1985) e é usado para medir os valores de dispersão dos dados correlacionados em torno da reta 1:1. Ou seja, indica o grau de afastamento dos valores estimados em relação aos observados, variando de -1,0 para nenhuma concordância, a +1,0 que corresponde à concordância perfeita.

4.5 SISTEMA DE DETECÇÃO DE DESFLORESTAMENTO

As detecções geradas foram feitas usando como base as áreas dos fragmentos obtidos no mapeamento de floresta nativa desenvolvido na abordagem 1.

O sistema de detecção de desflorestamento que compreende o algoritmo de detecção, identificação e estimativa de datas foi desenvolvido na abordagem 2 para isto foram utilizadas 3 componentes: detecção de mudança, classificação não supervisionada para identificar as mudanças correspondentes aos desflorestamentos e estimativa de datas de desflorestamento por análise temporal de NDVI.

É importante mencionar que embora as imagens utilizadas disponíveis no GEE sejam corrigidas atmosfericamente e livres de nuvens, foi aplicada uma máscara de nuvens, pois, alguns pixels nublados (ou sombras) ainda podem estar presentes nas imagens filtradas, uma vez que a máscara de nuvem pode ainda conter nuvem de baixa intensidade ou pixels afetados pela presença de nuvens.

O sistema de detecção desenvolvido consiste na sequência das etapas: análise de mudança por diferença de imagens a partir de series temporais de índice de vegetação NDVI, classificação não supervisionada para identificar desflorestamentos e análise de séries temporais de NDVI, usada para estimar as datas de ocorrência dos desflorestamentos identificados.

4.5.1 Detecção de mudança no GEE

A detecção de mudança consistiu em aplicar uma máscara de nuvem e de sombra e gerar a análise harmônica com composiçoes de imagens de séries temporais de NDVI livres ou com baixa incidência de nuvens (filtro de 2 a 3%) e desta forma fixando uma imagem inicial e fazendo sua diferença em relação a todas as outras imagens disponíveis em um determinado período de tempo, evidenciando assim as áreas que ocorreram alterações, este procedimento foi feito utilizando

códigos de programação javascript e funções disponíveis na plataforma GEE, usando como área de interesse somente os fragmentos contidos dentro do mapeamento florestal gerado na Abordagem 1.

A análise harmônica de séries temporais de NDVI foi implementada no GEE para a caracterização biofísica e fenológica de florestas naturais. Esta análise harmônica permitiu identificar algum tipo de padrão, variação e periodicidade do desflorestamento.

Há muitos autores na literatura que descrevem matematicamente a série harmônica (ou de Fourier) para uso em sensoriamento remoto. Zhou *et al*. (2012), Zhou *et al*. (2015) e Wilson *et al*. (2018), por exemplo, descrevem cada série de dados como sendo aproximada como um polinômio trigonométrico, como na equação 5.

$$Y = a_0 + \sum_{j=1}^{m} a_j cos\left(\frac{j2\pi t}{n}\right) + b_j sin\left(\frac{j2\pi t}{n}\right) \quad (5)$$

em que,

Y = série harmônica;

a e b = são vieses;

t = valor da frequência composta;

n = comprimento do ciclo, (onde ordem do polinômio é igual ao número de harmônicos na aproximação);

m = ordem do polinômio que é igual ao número de harmônicos na aproximação.

Para estimar tendências lineares ao longo do tempo, considerou-se o seguinte modelo linear, onde ϵt é um erro aleatório, como na equação 6.

$$y = \beta 0 + \beta 1 X1 + \cdots + BnXn + \epsilon t \quad (6)$$

Este modelo foi utilizado para diminuir a tendência dos dados de entrada (imagens) (explicar o movimento ascendente ou descendente destes dados

subtraindo os valores observados dos valores do modelo ajustado), o objetivo foi descobrir os valores dos coeficientes beta.

Para ajustar este modelo de tendência à série NDVI baseada em imagens Sentinel-2 foi usando a técnica estatística de otimização dos Mínimos Quadrados Ordinários – (MQO), (*Ordinary Least Squares* - OLS), sendo utilizado como redutor a função “linearRegression()”, a imagem resultado gerada é uma imagem de duas bandas em que cada pixel contém valores para β0 e β1 (Figura 10).

No procedimento a seguir, a sazonalidade (pt) foi estimada usando um modelo harmônico linear, onde (ϵt é o erro aleatório, A é a amplitude, ω é a frequência e $\boldsymbol{\phi}$ é a fase), como na equação 7.

$$pt = \beta 0 + \beta 1t + Acos(2\pi\omega t - \phi) + \epsilon t \quad (7)$$

Senso assim decompor a função em elementos considerando medidas de cosseno e seno separados, e assim quebrar curvas de ondas complexas em um conjunto de ondas simplificadas com um termo aditivo Jakubauskas ***et al***. (2001), como na equação 8.

$$pt = \beta 0 + \beta 1t + \beta 2cos(2\pi\omega t) + \beta 3sin(2\pi\omega t) + \epsilon t \quad (8)$$

E desta forma havendo uma tendência sazonal, a natureza ordenada de uma curva cosseno provavelmente poderá aproximá-la. Para ajustar este modelo à série temporal, foi definido ω=1 (um ciclo por unidade de tempo) e utilizada a regressão MQO como medida de redução de erros, e assim adicionar as variáveis harmônicas (o terceiro e quarto termos da equação 7) à coleção de imagens e aos coeficientes na equação 7, a fim de obter uma série temporal de valores ajustados, a série temporal pode ser então decomposta a partir da soma de senóides em diferentes frequências.

As imagens de amplitude geradas servem para identificar a variação do índice de vegetação NDVI durante todo o período. Tais imagens possuem uma

mesma escala de valores, para isto foi feito uma padronização contida entre os valores (0 e 1). Altos valores de amplitude indicam alto grau de variação e o termo em que essa variação ocorre indica a periodicidade do evento (Jakubauskas *et al*., 2001).

FIGURA 10 – ANALISE HARMÔNICA DE SÉRIES TEMPORAIS

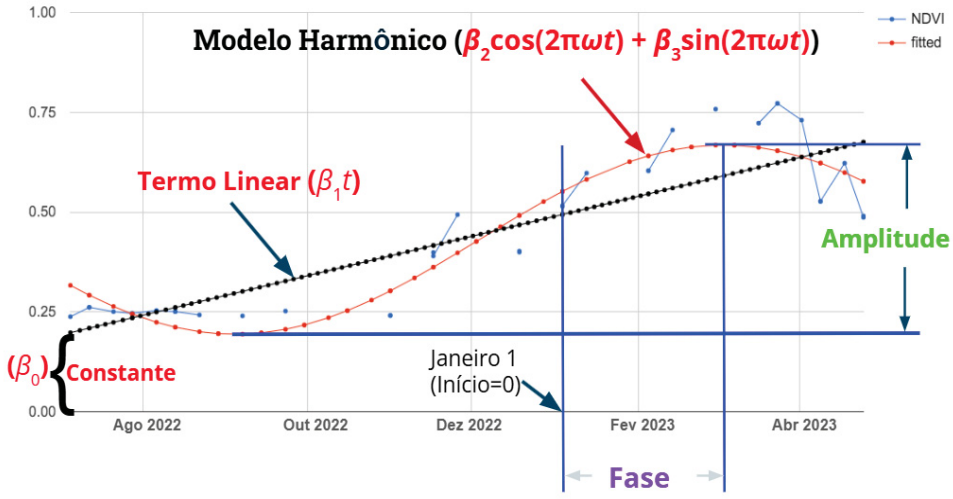

Foi aplicada também uma transformação de espaço de cor RGB para *Hue, Saturation* e *Value* (HSV), na composição da imagem de mudança obtida por análise harmônica, para facilitar a visualização e identificação das mudanças de uso e cobertura do solo (Figura 11). A detecção de mudança é usada como um indicador da localização e da existência de alteração, sendo assim, a composição HSV consistiu na representação do método de detecção para realçar as mudanças e auxiliar no processo de identificação de desflorestamentos.

FIGURA 11 – TRANSFORMACAO RGB PARA HSV NO GEE

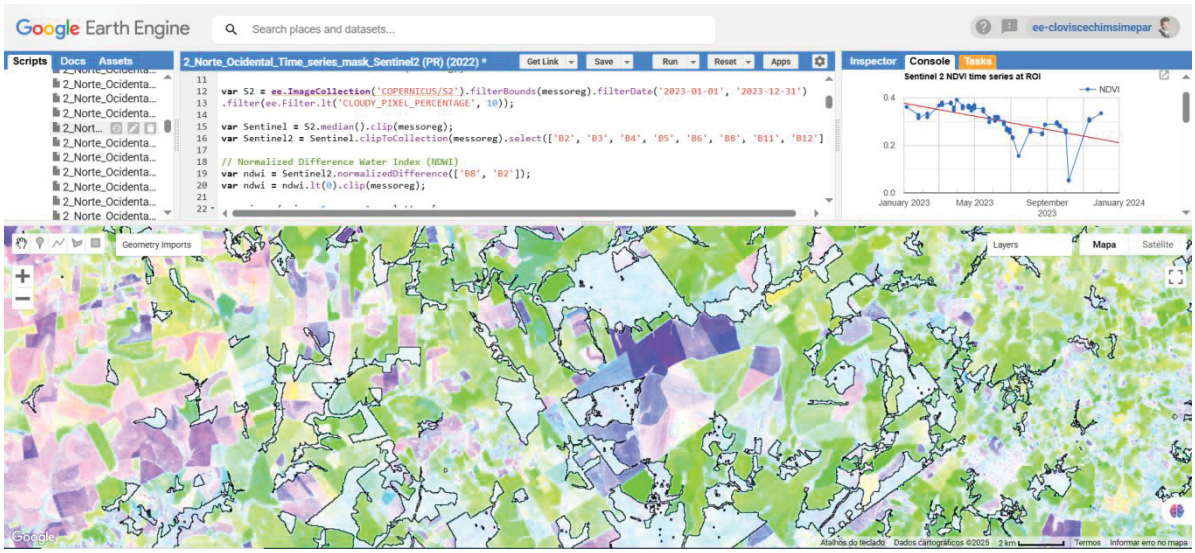

FONTE: O autor (2025).

4.5.2 Identificação de desflorestamento

A partir da aplicação da análise harmônica e transformação do espaço RBG para HSV, foi possível classificar as regiões correspondentes aos pixels onde houve realce de cor, que são os pixels de perturbação que caracterizam supressão florestal. Este processo de classificação consiste em selecionar e converter os pixels com mesma característica de cor para a forma vetorial, gerando assim os polígonos de desflorestamento.

É importante destacar que este procedimento se faz necessário para identificar de fato se a detecção consiste em supressão de floresta nativa e por se tratar de um refinamento da detecção de mudança, pois pode haver algum tipo de resíduo proveniente do processamento das imagens, como sombras ou outras imperfeições inerentes das imagens ou do mapeamento de referência, que não foram totalmente atenuados nas etapas anteriores, podendo não consistir em floresta nativa suprimida.

Para este procedimento de classificação das detecções de mudanças optou-se em utilizar o conjunto de ferramentas de IA do ArcGIs-Pro, pelo fato do GEE

ainda não ter métodos robustos de segmentação e classificação de imagens por IA e OBIA e desta forma muitos pixels isolados poderiam entrar como erro de detecação de desflorestamento, se fosse usado um método de classificação a pixel disponível no GEE. Foram utilizados as ferramentas de IA de classificação de imagens disponíveis, foi utilizado o método de classificação não supervisionada *ISO Cluster* com os parâmetros de segmentação (*Spectral detail,* 15.50) e (*Minimum segment size in pixels,* 20), este último constitui o número mínimo de pixels que foram agrupado para formar um segmento de objeto, foi definido 2 classes de classificação: Classe 1 (Desflorestamento), Classe 2 (Não Desflorestamento).

Na sequência para identificação de desflorestamento foi realizado uma classificação supervisionada considerando os polígonos detectados como desflorestamento, para isto foi utilizado o algoritmo RF e imagens Sentinel-2 (Cechim Junior *et al*., 2023), considerando imagens do ano anterior ao ano usado para detecção de mudança, para desta forma definir a transição de uso e cobertura do solo. Para ser considerado desflorestamento os polígonos gerados devem ser mapeados como floresta nativa no ano anterior à detecção.

4.5.3 Estimativa de datas de desflorestamentos

As séries temporais de NDVI foram usadas para determinar as datas de ocorrência de desflorestamento identificadas. E desta forma, verificar a dispersão do NDVI e a curvas de amplitude, evidenciando os *outliers* que representam os valores de NDVI mínimos, que correspondem a um padrão não característico de floresta nativa, de forma a estimar suas respectivas datas de ocorrência, como na figura 12.

FIGURA 12 – ANÁLISE TEMPORAL POR NDVI DE PIXEL FLORESTAL EM IMAGENS SENTINEL-2

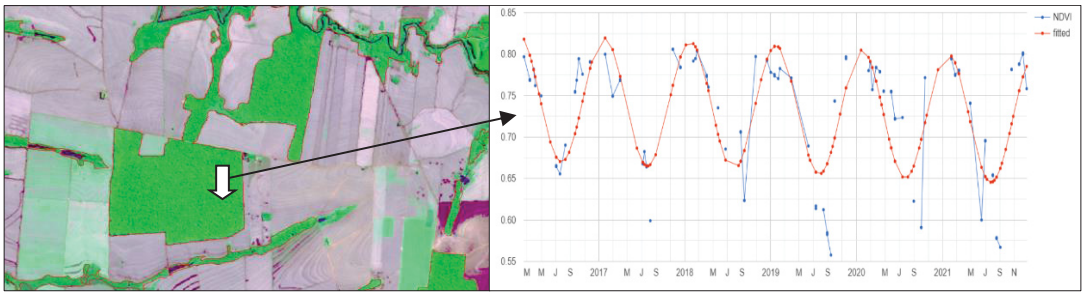

FONTE: O autor (2025).

Para isto foi necessário programar e desenvolver uma rotina específica no GEE considerando a extração de valores mínimos de NDVI e sua respectiva data de ocorrência, para isto foi analisado cada polígono independente e exportado o valor mínimo de NDVI, considerando o centróide de cada polígono de desflorestamento para o formato de tabela em valores separados por vírgula, estabelecendo assim a informação de data obtida para cada polígono de supressão florestal.

4.6 VALIDAÇÃO DE DESFLORESTAMENTO

A avaliação consistiu em validar a identificação dos desflorestamentos gerados e em comprovar se houve ou não de fato a supressão do desflorestamento. Consistiu-se em realizar inspeção visual por interpretação de imagens em todos os polígonos identificados de forma independente, fazendo uma comparação com imagens Sentinel-2, Planet e polígonos de desflorestamento do MapBiomas ano de 2023, considerando imagens de antes e depois da identificação, e partir disto foi gerado uma matriz de confusão, para verificar a eficiência do método gerado usando as métricas IK e EG% e outras medidas derivadas da matriz como IO% e IE%.

4.7 ANÁLISE DE IMÓVEIS RURAIS

Os polígonos identificados como desflorestamentos foram analisados com base na intersecção com a base do CAR referente ao mês de agosto de 2024, esta base é disponibilizada na forma vetorial para todo o estado do Paraná e com atualização de forma mensal. Os imóveis SIGEF/INCRA, no formato de serviço *Web Map Service* (WMS) e *Web Feature Service* (WFS), também foram utilizados para localizar os imóveis com desflorestamento, para este procedimento foi utilizado o QGis usando a ferramenta "*Selecionar por localização*".

A identificação dos imóveis com licenciamento e autorização foi gerada a partir da análise de intersecção com dados da Plataforma de Análise e Monitoramento Geoespacial da Informação Ambiental (PAMGIA), base de Autorização de Supressão de Vegetação do SINAFLOR que é disponibilizada na forma de serviço WFS.

5 RESULTADOS

Neste capitulo são apresentados os resultados obtidos no estudo de caso referente a diferentes algoritmos de classificação supervisionada testados usando imagens do satélite Sentinel-2 no GEE e de das duas abordagens quem compõem esta pesquisa. A abordagem 1 referentes ao método hibrido de classificação supervisionadas utilizando OBIA e ML para mapeamento de floresta nativa e a abordagem 2 referente a metodologia de detcção de desflorestamento a partir de analise harmônica de series temporais de NDVI.

5.1 CLASSIFICAÇÃO SUPERVISIONADA DE IMAGENS SENTINEL-2 COM MACHINE LEARNING NO GEE

O objetivo deste estudo de caso foi avaliar diferentes métodos de classificação supervisionada por ML e sua acurácia para mapeamento de uso e cobertura do solo (*Land Use and Land Cover* - LULC) usando imagens Sentinel-2. Para esta comparação de classificação foram utilizados os classificadores (CART), (RF) e (GTB), implementados no (GEE). A região de estudo usada na classificação foi a região fitoecológica Savana, localizada no estado do Paraná (Figura 13).

FIGURA 13 – LOCALIZAÇÃO DA REGIÃO FITOECOLÓGICA SAVANA

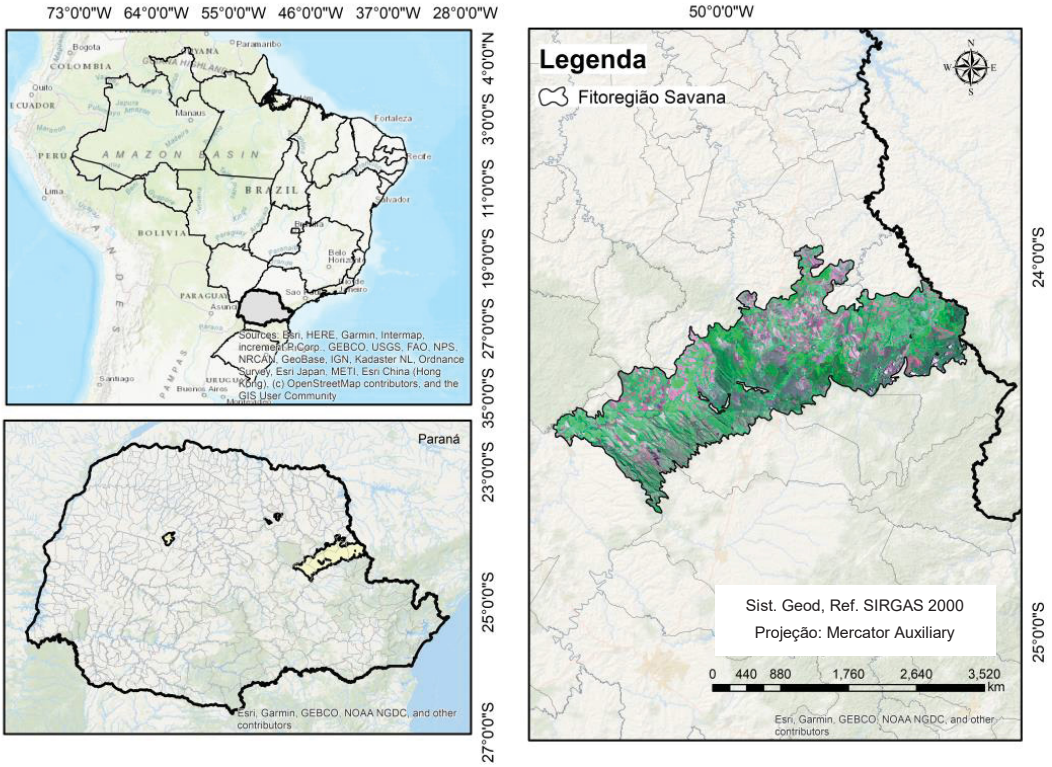

A metodologia pode ser dividida em 4 etapas, sendo: (I) Seleção de imagens Sentinel-2; (II) Geração de amostras de treinamento; (III) Classificação supervisionada usando ML no GEE e (IV) Validação de desempenho (acurácia espacial).

A seleção de imagens Sentinel-2 (*European Union*/ESA/Copernicus, 2021), se deu a partir de períodos de entressafra agrícola, período compreendido entre

agosto e setembro de 2016, sendo gerada uma composição de mediana, selecionando imagens com menor incidência de nuvens, procedimento feito no GEE.

Foi aplicada também uma máscara de nuvens, utilizando a banda de qualidade que indica a presença nuvem do Sentinel-2 (QA60) de 60m de resolução espacial, para filtrar eventuais nuvens ou algum tipo de vapor de água, da composição de mediana usada para classificação.

Foi gerado uma composição incluindo as bandas do visível (B2, B3, B4) e infravermelho (NIR) (B8), com 10m de resolução espacial, e as bandas de borda do vermelho (B5, B6, B7) e a banda do infravermelho de ondas curtas (SWIR) (B8A) com resolução espacial de 20m, totalizando 8 bandas espectrais.

A segunda etapa consistiu na geração de amostras de treinamento, sendo utilizado o conjunto de amostras estáveis produzido pelo MapBiomas para o ano de 2016. Foram gerados 11.000 pixels amostrais, para as seguintes classes de uso do solo: Formação Florestal; Floresta Plantada; Formação Campestre; Pastagem; Infraestrutura Urbana; Outra Área não vegetada; Rio, Lago e Oceano; Lavoura Perene; Soja e Outras Lavouras Temporárias.

A terceira etapa consistiu nos testes de classificação por ML, utilizando 3 classificadores distintos, (CART), (RF) e (GTB), utilizando o mesmo conjunto amostral. Para os classificadores RF e GBT, foram utilizados como parâmetro de entrada 70 árvores de decisão a serem criadas. Para o classificador CART não foi definido nenhum limite para o parâmetro de entrada.

A quarta etapa consistiu na análise de acurácia espacial das classificações geradas, para isto foram usados o (EG%) e o índice de concordância (IK). Para a obtenção das medidas estatísticas de acurácia foi utilizado o método de amostragem aleatória estratificada não proporcional com 100 pontos amostrais (Pixels) sorteados em toda área de estudo, distribuídas para cada uma das classes mapeadas. Estes pontos amostrais utilizados na validação foram gerados de forma independente do conjunto amostral usado no treinamento dos classificadores.

Para a classificação por RF obteve-se um IK de 0,94 com uma EG de 96.00% (Tabela 6). A classificação por GTB obteve um IK de 0,86 com um EG de 90,82%

(Tabela 6). Para a classificação CART, obteve-se um IK de 0,73 com uma EG de 81,00% (Tabela 6). Nesta classificação foi observado que houve uma maior confusão entre as classes de uso do solo (Figura 14-C).

FIGURA 14 – COMPARAÇÃO ENTRE CLASSIFICADORES RF (A), GTB (B) e CART (C)

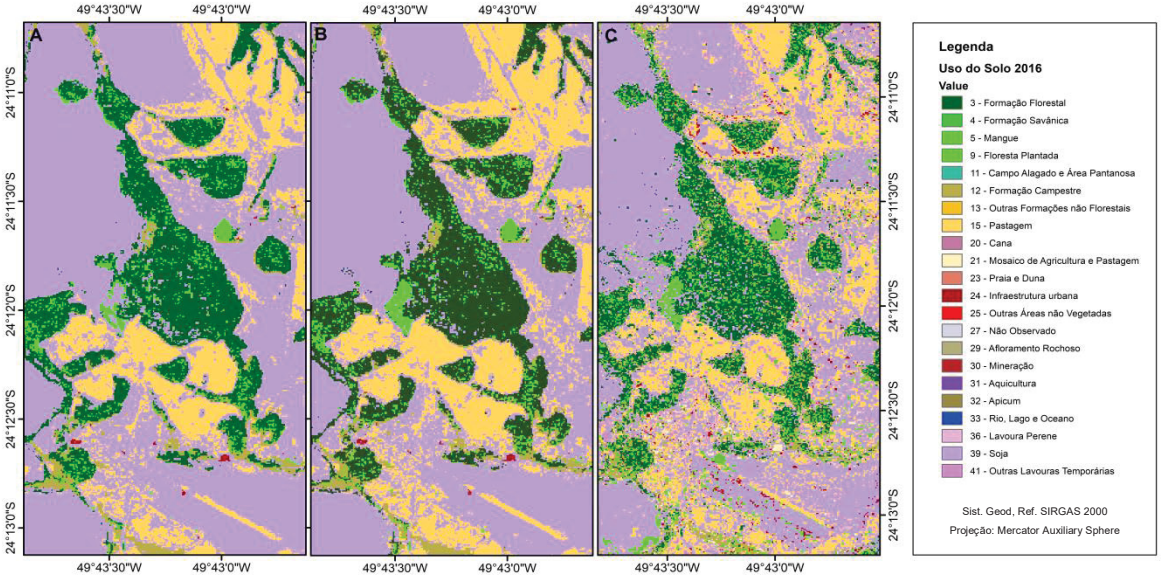

Foi observado que as maiores confusões observadas foram entre as classes de Formação Florestal e Floresta Plantada, e entre áreas de Pastagens e Agricultura. A tabela 7 contém os resultados das médidas estatísticas de avaliação de acurácia espacial.

TABELA 7 – ACURÁCIA ESPACIAL DOS CLASSIFICADORES AVALIADOS

Médidas **de acurácia**	**RF**	**GTB**	**CART**
IK	0,94	0,86	0,73
EG(%)	96,0	90,82	81,0

Dentre os classificadores utilizados, o classificador RF obteve o melhor resultado de acurácia na classificação de uso e cobertura do solo. Os algoritmos de classificação e sua performance foram avaliados neste estudo de caso, utilizando

um mesmo conjunto amostral para uma mesma área de estudo. Este experimento comparativo com diferentes algoritmos de classificação supervisionada por ML, orientou a utilização de RF no experimento referente a Abordagem 1.

5.2 OBJECT-BASED IMAGE ANALYSIS (OBIA) AND MACHINE LEARNING (ML) APPLIED TO TROPICAL FOREST MAPPING USING SENTINEL-2

5.2.1 Abstract

The purpose of this research was to distinguish and estimate native forest areas at Paraná, Brazil. Forest plantations (Silviculture) and native forests have high annual vegetative vigor, as well as agricultural areas in the periods of agricultural harvests, which can bring classification errors between these classes of Land Use and Land Cover (LULC), these classes have similar spectral signatures, but have a distinct texture that can be separated in the supervised classification process, with the joining of object and pixel-to-pixel classification method approaches. Thus, image segmentation techniques through Object-Based Image Analysis (OBIA) and Machine Learning (ML) made forest mapping possible over a large territorial extension. The Google Earth Engine (GEE) platform was used to calculate the vegetation indices (VIs) and Spectral Mixture Analysis (SMA) fraction spectral from Sentinel-2 images, and the creation of homogeneous spectrally shaped regions under supervised classification of phytoecological regions and mesoregions. The overall precision obtained in the mappings resulted in 0.94 Kappa Index (KI) and 96% of Overall Accuracy (OA), which indicates a high performance in large-scale forest mapping. The proposed dataset, source codes and trained models are available on Github (https://github.com/Cechim/simepar-brazil/), creating opportunities for further advances in the field.

5.2.2 Introduction

The global forest area is 4.06 billion hectares (ha), which represents 31% of the planet's total surface area, more than half of the world's forests (54%) are concentrated in five countries: Russia (20%), Brazil (12%), Canada (9%), the USA (8%), and China (5%) FAO, (2020). The mapping of native forests plays a strategic

role in forest management and policies, conservation, and environmental licensing purposes. The native forests area estimation using remote sensing depends on the method and the spatial resolution of the images. The new series of satellites have sensors with a high spatial and temporal resolution, which relates to the capability of revisiting the same area Segarra *et al*. (2020). Furthermore, the adoption of new technologies and several alternative image providers, such as Planet (Nanosatellites), AIRBUS, Digital Globe, and ESA (European Space Agency), reduced the image cost per km^2. These provider groups offer several operating satellites alternatives, such as Pleiades A, Pleiades B, SPOT 7, SPOT 6, SPOT 5, WorldView-2, WorldView-3, and Sentinel-2. The Sentinel-2 images are produced from passive optical sensors, and the temporal resolution is generally weekly due to the use of satellite constellations Vrdoljak and Kilić Pamuković (2022).

Sentinel 2A and 2B satellites generate multispectral images (bands 2 to 4 and 8) with a 10-meter spectral resolution and a 5-day temporal resolution with the advantage that these images have no acquisition cost for the user. Due to its multispectral bands, Sentinel-2 images are used for forest type classification Chen *et al*. (2018), biomass estimation Duan *et al*. (2019), urban forest spatial distribution Eskandari *et al*. (2020), forest removal Pałas and Zawadzki (2020), mapping of land cover and land use Zeng *et al*. (2020), forest and mangrove mapping Cissell *et al*. (2021). Therefore, the temporal and spectral resolution of Sentinel-2 images have great potential for projects based on mapping, area estimation, and the identification of changes in LULC. There are also various initiatives and projects involving public and private institutions focused on the development of LULC maps both in Brazil and in Paraná state, the focus of this study.

This large database can be processed for vast territorial extensions using the almost real-time processing from the GEE cloud platform, which presents computing capabilities that can be applied for several high impact social issues, including deforestation, drought, catastrophes, diseases, food security, water management, climate monitoring, global water surface changes Pekel *et al.* (2016), and environmental protection Gorelick *et al*. (2017). In the study of forests, this platform

has been used for the analysis of forest cover and forest loss Hansen *et al*. (2013), estimation of crop harvest Lobell *et al*. (2015), to generate land cover products (Sousa *et al*. (2020) and Zeng *et al*. (2020)), for coniferous forest classification Kaplan (2021), biomass estimation of forest plantation Theofanous *et al*. (2021), mangrove mapping Mondal *et al*. (2019), forest cover mapping Ganz *et al*. (2020), forest estimation and detection of forest change Zulfiqar *et al*. (2021), and analysis of forest species distribution Xie *et al*. (2021). The GEE platform uses ML algorithms and many works indicate its efficiency in different mapping applications and supervised classification. Some examples are shoreline mapping in order to differentiate substrate types Banks *et al*. (2017) and to estimating terrestrial latent heat flux Wang *et al*. (2017), mapping of land cover dynamics Huang *et al*. (2017), land use classification Hird *et al*. (2017), mapping of wetlands Brovelli *et al*. (2020), and forest mapping and monitoring Waśniewski *et al*. (2020).

Therefore, the mapping of native forests with a new methodological approach employing multispectral images from the Sentinel-2 satellite series and ML in GEE will contribute to the enforcement oversight public policies in any process of environmental licensing or authorization for forest suppression. This is especially important in order to support the monitoring of native forest resources and to subside the monitoring large-scale deforestation. The aim of this work was the development of a methodological approach for the mapping of native forests. Thus, the main objective of this work was to map and estimate areas the native forest formation of the Atlantic forest biome in Paraná state, Southern Brazil, using OBIA process with ML supervised classification using images from the Sentinel-2 satellite implemented in GEE computing environment with spectral fraction and VIs applied for each biome phytoecological.

5.2.3 Organization of research steps

The article was divided in the following steps: (1) Introduction; (2) Definition of the study area (southern Brazil), data selection and satellite images acquisition; (3) Research methods (Methodological procedures): OBIA including extraction of texture index of Grey Level Co-occurrence Matrix (GLCM), image segmentation, topology correction, supervised classification in GEE including asset importation from OBIA, selection of dates with low cloud incidence by mesoregion, cloud mask application, fraction spectral acquisition and calculation of VIs, independent samples selection by phytoecological region, supervised classification by ML, spatial filter application, validation methodology and spatial accuracy evaluation and native forest area estimation; (4) Results and discussion and (5) Conclusions.

5.2.4 Materials

5.2.4.1 Study area

The state of Paraná is located in Southern Brazil, between the parallels 22°29'S and 26°43'S latitude, and between the meridians 48°2'W and 54°38'W longitude (Figure 1). Paraná has an annual average precipitation between 1100 mm to 1920 mm, an average temperature between 15 °C and 24 °C Aparecido *et al*. (2016), and annual average evapotranspiration of 700 mm to 1600 mm Caviglione *et al*. (2000).

The state's climatic characteristics have regional variations, yet the Koppen and Geiger (1928) climate classification system establish the Cfa (warm temperate with hot summer) and Cfb (humid temperate with moderate hot summer) as the most predominant classes. However, Cwa (humid temperate with dry winter) and Aw (humid tropical savanna) are also present in the state's North portion Aparecido *et al*. (2016).

As a result of the interaction between biotic (vegetation and animals) and abiotic (climate, rock, topography, and soil) components, the state has a

greatdiversity of landscapes and numerous types of vegetation. The phytoecological regions are spaces defined by typical floristic genera and characteristical biological forms that are recurrent within the same climate, occurring on land of varied lithology, but with defined topography IBGE (2012) (Figure 15).

FIGURE 15 – PARANÁ PHYTOECOLOGICAL REGIONS: DENSE OMBROPHILOUS FOREST, MIXED OMBROPHILOUS FOREST, SEMIDECIDUOUS SEASONALFOREST, PIONEER VEGETAL FORMATION, SAVANNA (CERRADO), STEPPE (CAMPOS SULINOS), WATER AND AREAS OF ECOTONE (CONTACT ZONES)

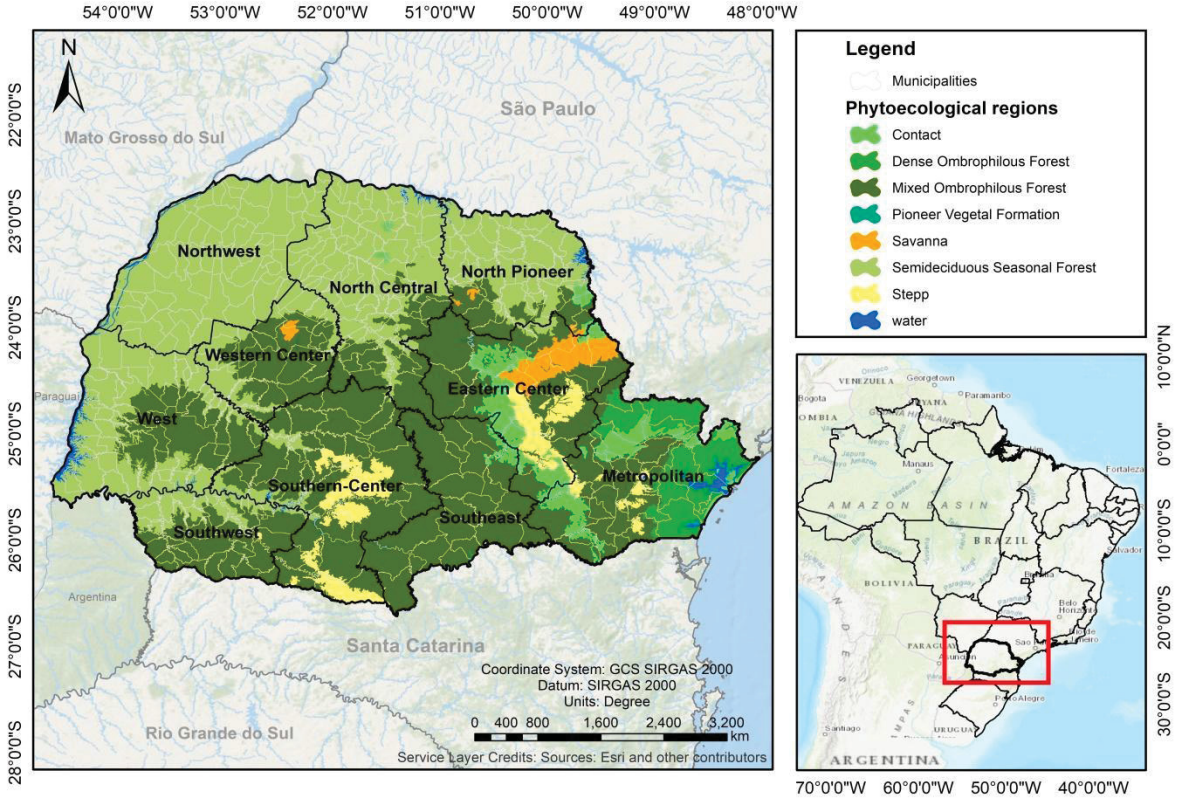

SOURCE: The author (2025).

5.2.4.2 Data selection

Sentinel-2 satellite images from June to December 2016 were used for native forest classification. We used as a selection criterion the periods without predominant

agricultural crops – such as soybean, corn (summer) and wheat (winter), and with low cloudiness at the time of image acquisition Table 8.

TABLE 8 – CHARACTERISTICS OF SENTINEL-2 MSI BANDS USED FOR OBIA

Satellite	Used bands	Wavelength (nm)	Res. spatial (m)	Period
Sentinel-2	B2 (Blue)	490	10	June to December 2016
Sentinel-2	B3 (Green)	560	10	June to December 2016
Sentinel-2	B4 (Red)	665	10	June to December 2016
Sentinel-2	B8 (Near Infrared)	856	10	June to December 2016

SOURCE: The author (2025).

5.2.5.3 Methodological procedures

The research method was divided in the following steps (Figure 16).

FIGURE 16 – SCHEMATIC OVERVIEW OF NATIVE FOREST MAPPING METHODOLOGICAL PROCEDURES

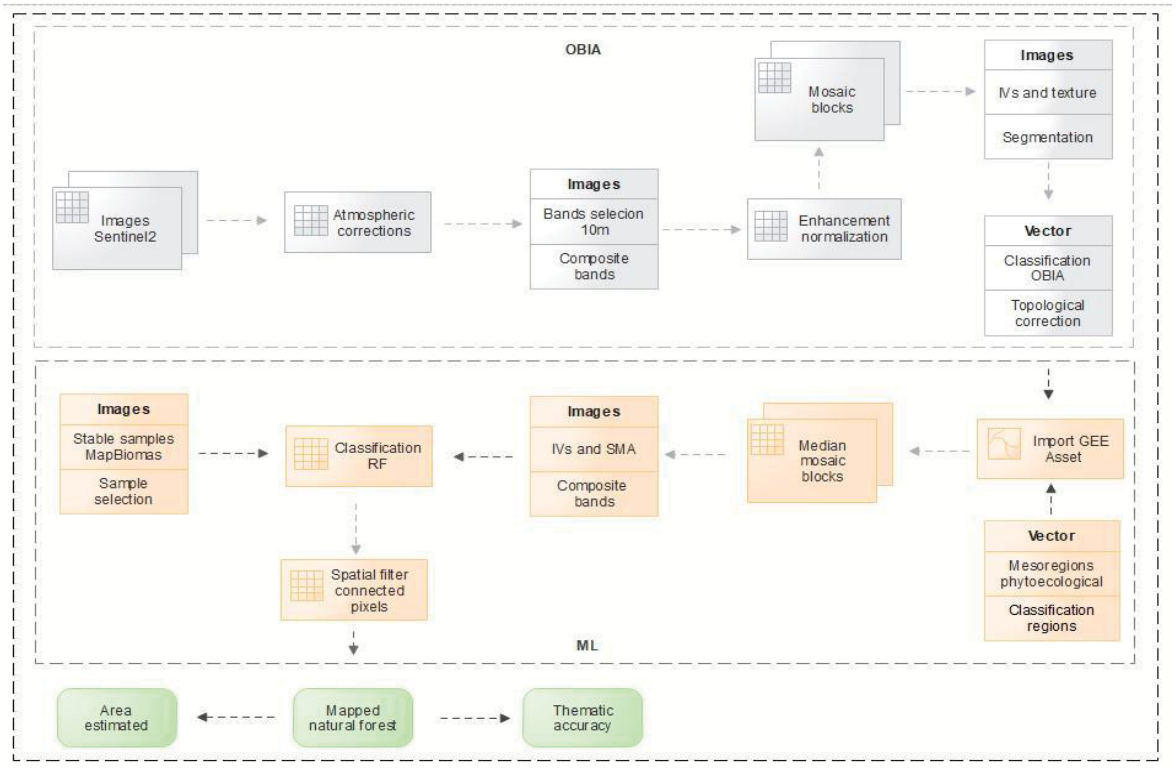

SOURCE: The author (2025).

5.2.4.4 Object-based image analysis (OBIA)

The supervised classification method was used by acquiring samples from the images with different types Sentinel-2 color composites to discrimination forest types, as native forest formation (native) of forest plantation (Silviculture). For the native forest class, 1,885 sampling distributed throughout the state of Paraná were selected. The classification method used was segmentation with (OBIA) in eCognition Software. Different parameters were tested for the segmentation using the algorithm “Multiresolution Segmentation” and the base parameters Scale, Shape and Compactness” were set to 150, 0.1, and 0.5 respectively. To assist in the classification process, different official reference cartographic bases from the state of Paraná were used as extra information.

The Normalized Difference Vegetation Index (NDVI) and the Normalized Difference Water Index (NDWI), Haralick texture index (GLCM Homogeneity) Haralick *et al.* (1973), Haralick (1979) and Conners and Harlow (1980) were generated and used as additional bands. The classification process is iterative, thus, some classes of land use were segmented with different parameterizations, is considered as both a qualitative assessment based on visual interpretation and a quantitative assessment using reference data Costa *et al*. (2018) and measures that report on the overall accuracy of segmentation Clinton *et al*. (2010), and consequently reclassified more than once until a better result was achieved regarding the performance and the desired classification. We used the Nearest Neighbor (NN) classification algorithms from eCognition Developer, a supervised classification method derived from statistical learning theory Cover and Hart (1967). The result was submitted to a class editing, a post classification process to correct possible inconsistencies in the classification, which are mainly related to wrongly labeled classes.

5.2.4.5 Topological analysis

After the OBIA classification, topological analyses were applied taking into account all classes, ArcGis 10.8.1 software was used for this. As topological tools, “Intersect” was used to identify overlapping areas or edges between classes, and “Symmetrical difference” and “Erase” to identify areas not classified by the NN algorithm. The “Dissolve” function was applied to the Forest class, the functions “Check geometry” and “Repair geometry” have been applied to correct inconsistencies in the geometries or the attribute table. From these topology analyses the” Explode” tool was applied to break the forest class into polygons, which were then cut and separated by mesoregion and further imported into GEE.

5.2.4.6 Supervised classification in GEE

The OBIA supervised classification was imported in Asset form into GEE. In the ML supervised classification process, the stable samples – training and calibration samples that were extracted from classes that did not change their values during all years of the 6.0 collection (from 1985 to 2020) – from MapBiomas for the year 2016 were used as reference. The digital classification was performed by phytoecological region contained in each mesoregion using the Random Forest (RF) algorithm available in GEE, and running 70 interactions Breiman (2001).

This classifier is an algorithm less sensitive to the quality of training samples and overfitting due to the large number of decision trees produced by the random selection of a training sample subset Belgiu and Dra˘gu¸t¸ (2016). A total of 23 Sentinel-2 visible and infrared spectral bands at 10m spatial resolution, Spectral Mixture Analysis (SMA) spectral fractions and Vegetation Indices (VIs) were used in the classification process (Table 2). The SMA was generated from the calculation of the Green Vegetation (GV), Non Photosynthetic Vegetation (NPV), Soil and Shade fractions implemented in GEE.

SMA is a physically based form of image processing that aids in the repeated and accurate derivation of quantitative subpixel information (Smith *et al*. 1990). Some studies have already used SMA for the estimation and mapping of agricultural crop residues (Bannari *et al*., 2006; Pacheco; McNairn, 2010). SMA works under the

assumption that a spectrum computed by a sensor considers a linear combination of the spectra of all components within the pixel and the spectral proportions of the end members, which reflect the proportions of the occupied area by defined features on the Earth's surface Adams *et al*. (1995); Lu *et al*. (2004). The VIs Calculated in the GEE and based on the median Ganz *et al*. (2020) (Table 9).

TABLE 9 – SPECTRAL BANDS SENTINEL-2 AND VEGETATION INDICES USED IN THE CLASSIFICATION

Bands	VIs	References
B8 and B4	Normalized Difference Vegetation Index (NDVI)	Rouse and Deering (1973)
B8 and B4	Enhanced Vegetation Index (EVI2)	Jiang *et al*. (2008)
B8 and B4	Pigment Specific Simple Ratio (PSSR)	Blackburn (1998)
B8, B8A and B3	Index Chlorophyll (IC)	Gitelson *et al*. (2003)
B4 and B3	Normalized Difference Infrared Index (NDII)	Kimes *et al*. (1981)
B4 and B3	Green Normalized Difference Vegetation Index (GNDVI)	Gitelson *et al*. (1996)
B4 and B11	Simple Ratio Moisture Stress Index (MSI)	Welikhe *et al*. (2017)
B8, B5 and B4	MERIS Terrestrial Chlorophyll Index (MTCI)	Dash and Curran (2004)
B5 and B7	Chlorophyll Red-Edge (CHLRED-edge)	Gitelson *et al*. (2003)
B8, B2 and B6	Measure the amount of Chlorophyll-AB (mNDblue)	Jay *et al*. (2017)
B7, B5, B6 and B4	Sentinel-2 Red-Edge Position Index (S2REP)	Guyot and Baret (1988)
B8, B5, B6 and B4	Red-Edge Inflection Point Index (REIP)	Guyot *et al*. (1988)
B7 and B4	Difference Vegetation Index (DVI)	Jordan (1969)
B5 and B4	Normalized Difference Index (NDI45)	Delegido *et al*. (2011)
B8 and B4	Soil Adjusted Vegetation Index (SAVI)	Huete (1988)
B4 and B3	Brightness Index (BI)	Escadafal (1989)
B4 and B3	Colour Index (CI)	Pouget *et al*. (1990)
B8 and B3	Normalized Difference Water Index (NDWI)	McFeeters (1996)

SOURCE: The author (2025).

To improve accuracy, a new RF classification was made, such as parameters was used, the number of trees in the random forest classifier varied from 50 to 100 iterations and variables per split from 1, the classifier with 70 trees to Sentinel-2 data resolution, the sample set used were the stable samples from the MapBiomas project for the year 2016 Souza *et al*. (2020).

After the supervised classification process, a spatial filter created with the ["*connectedPixelCount*"] function was applied to avoid unwanted changes to the pixel group edges. This function, available and implemented in the GEE platform, locates connected components (neighbors) that share the same pixel value. Thus, only pixels that do not share connections with a predefined number of identical neighbors are considered isolated. In this filter, at least six connected pixels are required to achieve the minimum connection value. Consequently, the minimum mapping unit is directly affected by the applied spatial filter, and it was defined as 6 pixels (the equivalent of approximately 0.5 ha) Souza *et al*. (2020).

5.2.4.7 Validation methodology

The methodology for validating the native forest classification by ML was divided into two steps: grid generation within the study area, and the generation of point samples within each grid. The number of grids sampled was defined according to the methodology described in the Technical Specification Standard for Quality Control of Geospatial Data (ET-CQDG) of DSG (2015), which adopts the sampling plans described in ISO (International Organization for Standardization) standards. The thematic accuracy validation was defined based on the number of points that were generated from the regular grid (sampling is uniform, non-proportional, and non-random).

The definition of the grid is based on the scale of the generated product, which, in this case, has a spatial resolution of 10m, so the scale would be 1:60,000. Spatial sampling is done by partitioning the cells into 4x4 cm according to the scale of the product to be evaluated, and using integer values in the form of a grid, while the number of cells depends on the scale and size of the study area (Table 10).

TABLE 10 – SATELLITE SCALE COMPATIBILITY FROM ET-CQDG SPATIAL SAMPLING FROM DSG 2015

Scale	Spacing (m)	Spacial resolution	Satellite scale compatibility
1:10,000	400x400	2 m	WorldView, Pleiades, GeoEye and SkySat
1:25,000	1000x1000	5 m	RapidEye and Planet
1:60,000	2400x2400	10 m	Sentinel-2/MSI
1:160,000	6400x6400	30 m	Landsat/OLI

SOURCE: The author (2025).

Following the scale definition, the grid and the number of points to be used for validation were generated with the “Fishnet tool” from ArcGIS, while the population points set was generated by the grid centroid. The resulting population set was 34,708 points for the entire state of Paraná, i.e., one reference point every 2.4 km. From the attribute table, the classes corresponding to each of the points were defined based on the Sentinel-2 images with a spatial resolution of 10 m, and Planet of 5 m. In this way, all points in the population set were visually identified via satellite image interpretation, defining, thus, the standardized reference matrix for two classes: Native forest and Non-forest.

5.2.4.8 Accuracy analysis and area estimation

The classifier performance was evaluated using metrics such as Kappa Index (KI), Overall Accuracy (OA), Inclusion Errors (IE), and Omission Errors (OE) (Congalton (1991), Congalton and Green (2019)) and Global Disagreement (Allocation and Quantity components) Pontius and Millones (2011). The forest area was estimated by counting the pixels contained in each municipality using the QGIS “Zonal Statistics” tool Sherman et al. (2011) and comparing the estimated area of the mapping done with Sentinel-2 images, the area obtained in the 2016 MapBiomas, and the one from IAT (Institute Water and Earth of Paraná) generated with WorldView images from 2012 to 2016.

The Albers Equal Area Projection, and SIRGAS2000 Datum were the standard to generate the area quantitatives. The estimations’ normality analysis was

performed using the Shapiro-Wilk and AndersonDarling tests, as well as the Spearman's correlation coefficient (r_s) to verify the data dispersion when comparing the estimated municipal area obtained from other mappings (IAT and MapBiomas). The Mean Error (ME) (Equation (9)) and the Refined Index of Agreement (d_r) of Willmott *et al*. (2012) (Equation (10)), which measures the precision of the estimated values in relation to the straight line 1:1, which measures the mean of the errors, were used as statistical indicators since they determine the method accuracy, and indicate the distance between the estimated and the observed values. This index ranges from -1 to 1, with positive values close to 1 indicating better agreement.

$$ME = \frac{1}{n} * \sum_{i=1}^{n} (O_i - E_i)^2 \quad (9)$$

$$d_r = 1 - \frac{\sum_{i=1}^{n} \left|E - \underline{O}\right|}{2 * \sum_{i=1}^{n} \left|O - \underline{O}\right|} \quad (10)$$

Where: Ei¼ Estimated forest area; Oi ¼ Observed forest area; O¼ Average observed forest area; n¼ number of municipalities.

5.2.5 Results and discussion

5.2.6.1 Mapping of LULC

For OBIA mapping, samples for 9 thematic classes were selected through NN supervised classification based on the mapping generated with Sentinel-2 images from 2016, this classification for the forest cover class was made for the state of Paraná using the supervised OBIA classification with topological correction imported into GEE, for the native forest class, an KI of 0.87 with OA of 91.05% was obtained (Figure 17).

FIGURE 17 – CLASSIFICATION OF LULC BY OBIA (IMAGES FROM JUNE TO DECEMBER 2016, SENTINEL-2

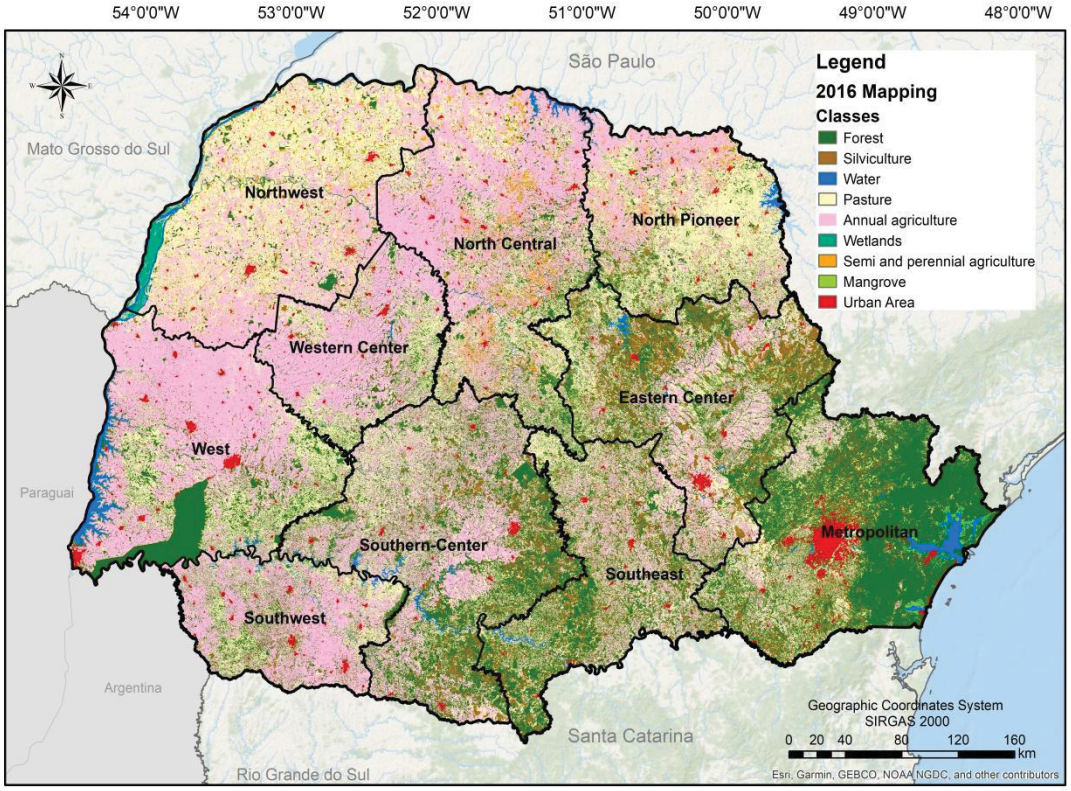

SOURCE: The author (2025).

5.2.6.2 Supervised classification in GEE

The stable samples obtained from the Savanna phytoecological region through the MapBiomas project, year 2016 Souza *et al*. (2020), were used to test the performance of different ML supervised classification algorithms on GEE. The Random Forest (RF) and Gradient Tree Boost (GTB) classifiers showed better performance and similarity, with better definition and smoothing between the mapping classes (Table 11).

TABLE 11 – SPATIAL ACCURACY, KI AND OA(%) OF THE CLASSIFIERS TESTED BY ML IN GEE

Classes	SVM	RF	GBT	CART
Native forest	0.85 (89.5%)	0.94 (96.0%)	0.86 (90.8%)	0.76 (81.0%)
Silviculture	0.84 (89.0%)	0.93 (95.4%)	0.87 (91.2%)	0.77 (81,2%)
Water	0.89 (92.2%)	0.96 (97.5%)	0.88 (92.0%)	0.78 (83.0%)
Pasture	0.87 (91.1%)	0.92 (93.3%)	0.84 (89.5%)	0.72 (80.0%)
Annual agriculture	0.84 (88.7%)	0.93 (94.2%)	0.83 (89.0%)	0.74 (80.5%)
Semi and perennial agriculture	0.82 (88.0%)	0.88 (89.7%)	0.87 (90.2%)	0.71 (79.6%)
Urban area	0.81 (85.5%)	0.84 (86.7%)	0.82 (89.0%)	0.69 (78.5%)

SOURCE: The author (2025).

The Classification and Regression Trees (CART) classifier demonstrated greater spectral confusion among the land use and land cover classes. The accuracy evaluation was done by means of a confusion matrix in GEE according to Stehman (1997) with a sampling of 70% of the data for training and 30% for validation testing. The highest spectral confusions were between Native forest formation and Silviculture (Planted forest) classes, and between Pasture and Agriculture areas.

Among the classifiers used, RF obtained the best accuracy result in LULC classification. The use of any type of spatial filter was not evaluated, but the classification algorithm Support Vector Machine (SVM), RF, GBT and CART and its performance using the same training sample. After defining the best ML algorithm (RF), all classes of LULC were imported as Asset in the GEE, thus a new classification was made with a new sample set for training and validation, improving the performance of thematic accuracy which can be verified by Correctly Classified Pixels (CCP%) and OA% according to matrix adapted of Richards (1993) (Table 5). The proximity between the average, predicted value and the true value is evidenced by the Accuracy score metric, indicated how close is the measured value to the true value, the Macro average indicated average unweighted mean per label and Weighted average indicated average support-weight mean per lable (Table 12).

TABLE 12 – ACCURACY ASSESSMENT CRITERIA FOR THE NATIVE FOREST CLASS

	Precision	Recall	F1-score	Support
Native forest	0.92	0.94	0.93	9,423
Other uses	0.98	0.97	0.97	25,186
Accuracy	0.96	34,609		
Macro avg.	0.95	0.95	0.95	34,609
Weighted avg.	0.96	0.96	0.96	[34,609]

SOURCE: The author (2025).

5.2.6.3 Mapping of native forest formation

It is important to highlight that, in this mapping, the forests' spatial distribution is evident, especially in the South, Southeast, and Metropolitan mesoregions. This map was generated from the initial mapping done by OBIA with supervised classification (NN) and refined by a reclassification process in GEE by ML with RF (Figure 18).

FIGURE 18 – NATIVE FOREST MAPPING BY OBIA AND ML WITH RF (YEAR 2016, SENTINEL-2 IMAGES)

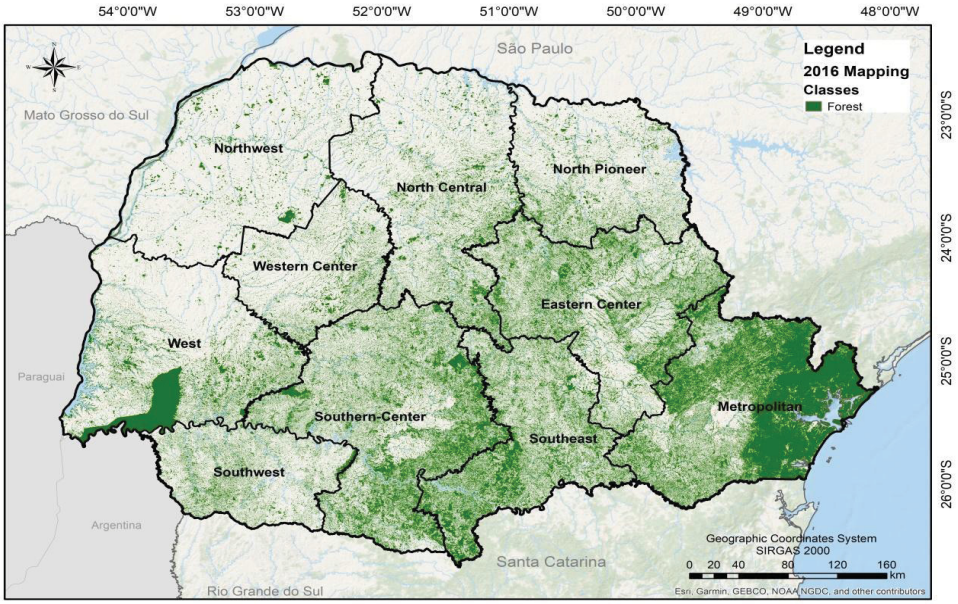

SOURCE: The author (2025).

5.2.6.4 Spatial accuracy assessment

According to the classification proposed by Landis and Koch (1977) for the KI value, the spatial accuracy analysis of the classifications showed excellent thematic quality with KI values between 0.80 and 1.00 (Table 13). The lowest values, in turn, were obtained for the Mixed Ombrophilous Forest, which can be explained by the large number of reforestation areas (Table 13).

TABLE 13 – EVALUATION STATISTICS OF SUPERVISED CLASSIFICATION BY PHYTOECOLOGICAL REGION

Phytoecological Region	KI	OA(%)
Contact	0.95	96.85
Steppe	0.94	96.85
Semideciduous Seasonal Forest	0.92	96.80
Dense Ombrophilous Forest	0.94	96.86
Ombrophilous Mixed Forest	0.90	96.80
Pioneer Formation	0.95	96.85
Savanna	0.95	96.85

SOURCE: The author (2025).

Similar results were found by the mapping of Souza *et al*. (2020) on GEE with Landsat images from the Atlantic Forest Biome in 2016 using RF for the MapBiomas project. It resulted in an OA of 91.4%, an Allocation disagreement of 6.5%, and a Quantity disagreement of 2.9%, the Quantity component, considered as the classification of incorrect proportions of pixels in the classes and by the Allocation component that refers to the incorrect spatial distribution of pixels in classes. Similar results were also obtained by Waśniewski *et al*. (2020) with an accuracy of 92.6% and 98.5% using RF and Sentinel-2 images for forest mapping in Northwestern Gabon; and by Niculescu *et al*. (2018) while monitoring the vegetation with Sentinel-2 and SPOT-6 data in 2017 at France, where he obtained 93% in OA.

The values for IE and OE obtained in this study were 6.4% and 5.4%, respectively, regarding the entire state of Paraná. These results were lower than those for OE and IE obtained by Souza *et al*. (2020) - 14% and 6.2% respectively in the mapping of the forest formation class for the MapBiomas project in 2016. This

improvement in the mapping performance with Sentinel-2 images can be explained by the use of the Paraná state mesoregions (10 homogeneous regions). In addition, the new classification (refined) process performed by RF implemented in GEE was done by forest types and considering the phytoecological regions.

As a function of the KI calculating the accuracy based on randomness arises as an option the analysis of the Global Disagreement (GD) (Allocation and Quantity). Such components provide additional information that assists in explanation of the error in the mappings, the contribution of the allocation component of 2.0% and the proportion of the quantity component with 0.1% indicates the effectiveness of this new approach developed for large-scale forest mapping associating OBIA and ML (Figure 19).

FIGURE 19 – ERRORS OF COMMISSION, OMISSION BY DOMAIN AND ALLOCATION COMPONENT AND QUANTITY

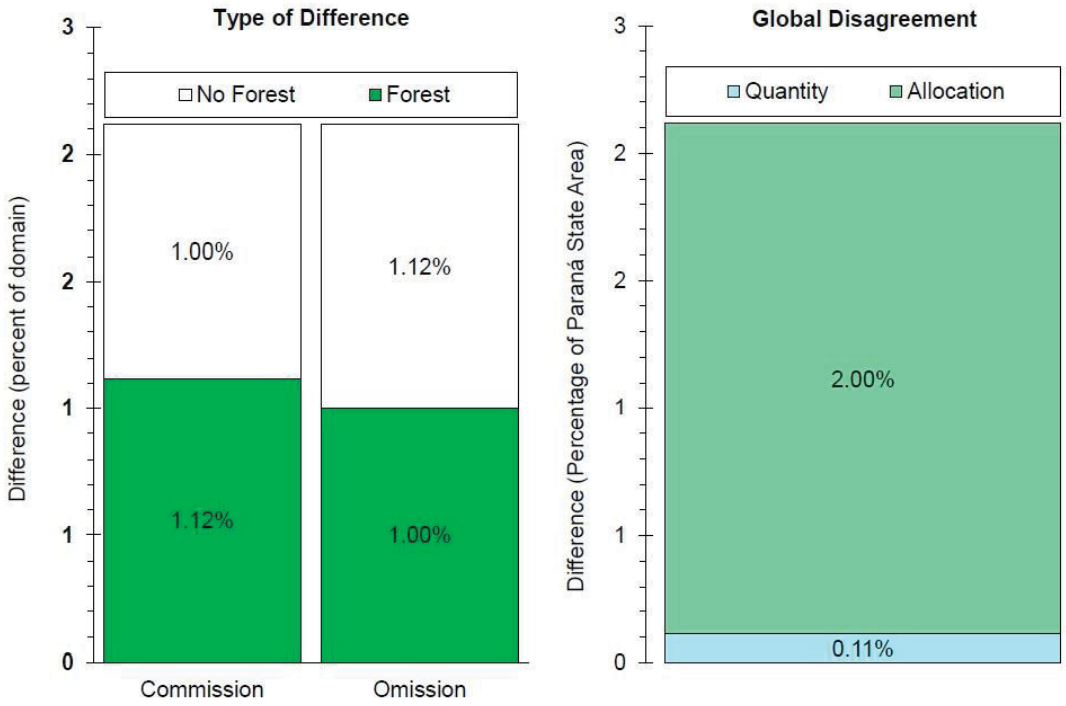

SOURCE: The author (2025).

The determination of GD and metric intensity of omission and commission uses the reference sample set of the classes under study comparing with the population set of pixels of the generated mapping. In the global disagreement graph formed by the percentages allocation component and quantity, it is observed that the contribution of the allocation component in the total disagreement was greater than the quantity component, the which implies incorrect spatial distribution designated pixels in classes (Figure 20).

FIGURE 20 – INTENSITY OF OMISSION ERRORS, COMMISSION AND DISAGREEMENT GLOBAL

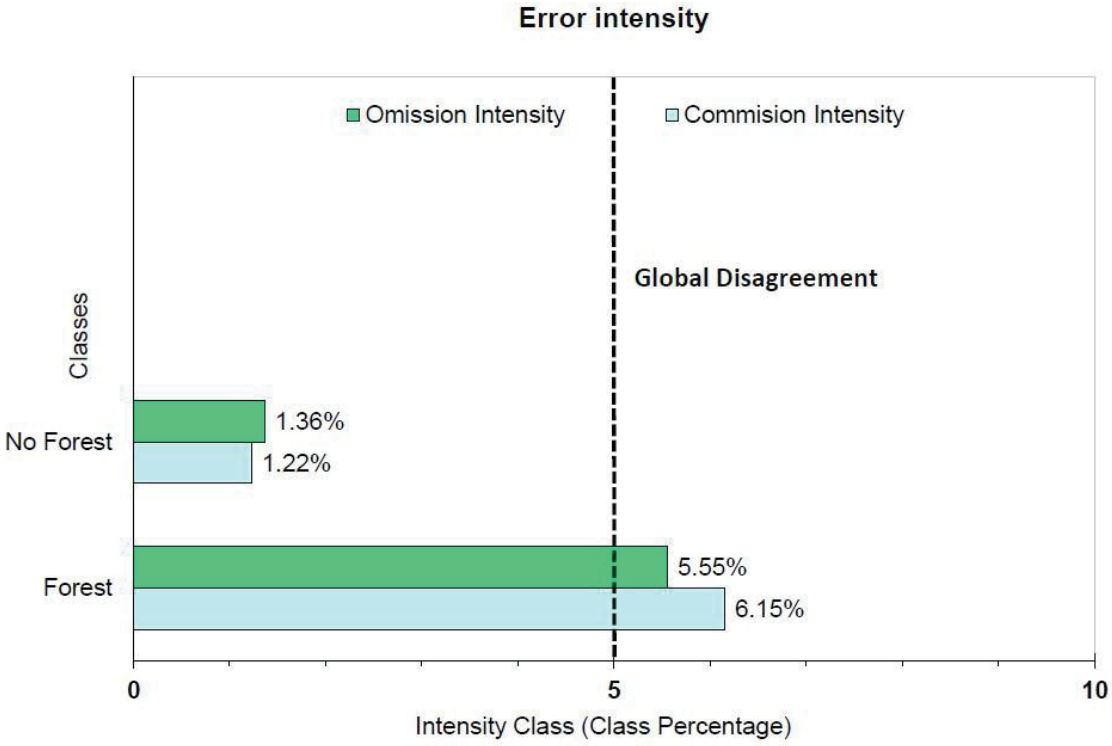

SOURCE: The author (2025).

5.2.6.5 Estimated forest area

The estimation indicated that there was an underestimation of the forest area obtained by RF mapping with Sentinel-2 images, with a difference of 213,164 ha

(3.4%) when compared to mapping from MapBiomas collection 5 from 2016. In contrast, when comparing with IAT mapping done with WorldView images from 2012 to 2016, the area was overestimated, which can be explained by the spectral mixing of some areas contained in the 10 m pixels of Sentinel-2 images. The area estimations were calculated considering the original spatial resolution of each mapping technique (Table 14).

TABLE 14 – ESTIMATION OF NATIVE FOREST AREA BY DIFFERENT SATELLITES

Variables	Sentinel-2	WorldView 2	Landsat
Mapped area (ha)	6,047,779	5,817,942	6,260,944
Difference (ha)		229,837	213,164
Difference (%)		3.9%	3.4%
Spatial Resolution	10 m	2 m	30 m
Year	2016	2012–2016	2016

SOURCE: The author (2025).

As the data of estimated forest area do not follow a normal probability distribution, the Spearman's correlation coefficient (r_s) was used, and the value of r_s 0.99 was obtained when comparing MapBiomas/Landsat and IAT/WorldView2 mapping, indicating a strong correlation between the data obtained in the mapping done with Sentinel-2 images using the methodology associating OBIA and RF (Figure 21).

FIGURE 21 – COMPARISON BETWEEN AREA ESTIMATES USING SENTINEL-2 MAPPING, YEAR 2016. (A) MAP-BIOMAS AND (B) IAT

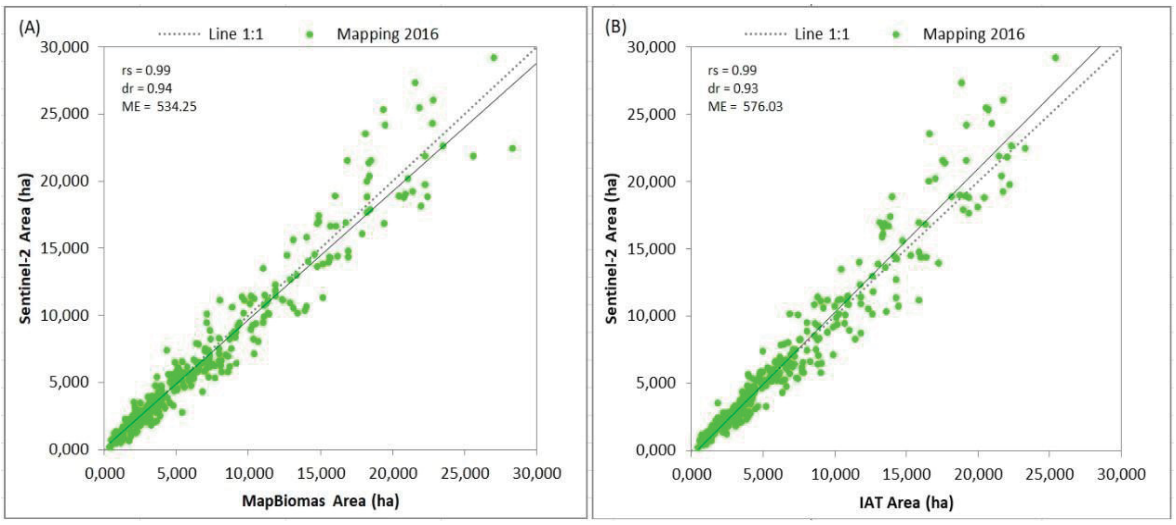

SOURCE: The author (2025).

The analysis of the data compared by statistical metrics indicated that the estimated area had a Mean Error (ME) of 534.25 ha in relation to MapBiomas map ping, and a ME of 576.03 ha when compared to IAT mapping. This dissimilarity can be justified by the detect sensors' spatial resolution difference on the different satellites (Figure 5). Willmott's refined index of agreement (d_r) measured the accuracy between the area estimated with Sentinel-2 mapping, MapBiomas, and IAT mapping using WorldView images. Values of 0.94 (MapBiomas) and 0.93 (IAT) were found, indicating an optimal performance, i.e., high accuracy among the area estimations.

5.2.6 Conclusions

The results indicate the potential of applying OBIA and ML techniques for supervised classification of native forests using VIs and spectral fraction from Sentinel-2 images. Moreover, it was possible to map and estimate the forest area for large territorial extensions such as the entire state of Paraná.

The division of the state by phytoecological region and mesoregions implemented in GEE enabled a better spectral homogeneity of the regions for mapping. This facilitated the selection of images from days without cloud cover, and in periods with agricultural crops at low vegetative vigor, which allowed for a significant improvement in mapping. As a result, there was a decrease in spectral confusion among the LULC classes. The use of vegetation indices and texture improved the performance and accuracy of the classifier.

Furthermore, the use of OBIA facilitated the post-classification editing and enabled the reduction of spectral confusion between classes, and consequently increased the thematic spatial accuracy.

The high performance of this approach demonstrated the methodological efficiency based on the analysis of the IE and OE, the high OA, the area estimation, the statistical indicators such as Spearman's correlation coefficient (rs), Mean Error, and the refined index of agreement, which had an excellent performance in comparison with mappings from other detect sensors.

Therefore, the methodology can be applied in projects involving forest mapping in large territorial extensions that require high thematic precision and area estimation. This makes possible the monitoring and generation of reliable area estimations for subsequent years.

7.7 ALGORITHM

The ML algorithm used for RF classification and the Sentinel-2 mosaic bands, including vegetation indices, SMA fraction, and Sentinel-1 bands, is publicly available at: https://github.com/Cechim/simepar-brazil/

5.2.7 Acknowledgement

The authors would like to thank the Academic Publishing Advisory Center (Centro de Assessoria de Publicação Acadêmica, CAPA – www.capa.ufpr.br) of the Federal University of Paraná (UFPR) for assistance with English language translation and developmental editing.

5.2.8 Disclosure statement

No potential conflict of interest was reported by the author(s).

5.2.9 Funding

This work was supported by the Federal University Paraná (UFPR) and Technology System and Environmental Monitoring of Paraná (SIMEPAR).

5.2.10 References

Adams, J.B., Sabol, D.E., ValerieKapos, F. R.A., Roberts, D.A. O., Smith, M., and Gillespie, A.R. 1995. “Classification of multispectral images based on fractions of endmembers: Application to land-cover change in the Brazilian Amazon.” *Remote Sensing of Environment*, Vol. 52(No. 2): pp. 137–154. doi:10.1016/00344257(94)00098-8.

Aparecido, L.E.O., Rolim, G.S., Richetti, J., Souza, P.S., and Johann, J.A. 2016. “Koppen, € Thornthwaite and Camargo climate classifications for climatic zoning in the State of Paraná.” *Ciência e Agrotecnologia*, Vol. 40(No. 4): pp. 405–417. doi:10.1590/1413-70542016404003916.

Banks, S., Millard, K., Behnamian, A., White, L., Ullmann, T., Charbon-Neau, F., Chen, Z., Wang, H., Pasher, J., and Duffe, J. 2017. “Contributions of actual and simulated satellite SAR data for substrate type differentiation and shoreline mapping in the Canadian arctic.” *Remote Sensing*, Vol. 9(No. 12): pp. 1206.

doi:10.3390/rs9121206.

Bannari, A., Pacheco, A., Staenz, K., McNairn, H., and Omari, K. 2006. “Estimating and mapping crop residues cover on agricultural lands using hyperspectral and ikonos data.” *Remote Sensing of Environment*, Vol. 104(No. 4): pp. 447–459. doi:10.1016/j.rse.2006.05.018.

Belgiu, M., and Drăguţ, L. 2016. “Random forest in remote sensing: A review of applications and future directions.” *ISPRS Journal of Photogrammetry and Remote Sensing* Vol. 114: pp. 24–31. doi:10.1016/j.isprsjprs.2016.01.011. Blackburn, G.A. 1998. “Spectral indices for estimating photosynthetic pigment concentrations: A test using senescent tree leaves.” *International Journal of Remote Sensing*, Vol. 19(No. 4): pp. 657–675. doi:10.1080/014311698215919.

Breiman, L. 2001. “Random Forests.” *Machine Learning*, Vol. 45(No. 1): pp. 5–32. doi:10.1023/A:1010933404324.

Brovelli, M.A., Sun, Y., and Yordanov, V. 2020. “Monitoring forest change in the amazon using multitemporal remote sensing data and machine learning classification on google earth engine.” *ISPRS International Journal of Geo-Information (MDPI)*, Vol. 9: pp. 1–21. doi:10.3390/ijgi9100580.

Caviglione, J.H., Kiihl, L.R.B., Caramori, P.H., de Oliveira, D., Galdino, J., Borrozino, E., Giacomini, C.C.Y., Sonomura, M., and Pugsley, L. 2000. “Cartas climáticas do Paraná”. *Instituto Agronômico do Paraná (IAPAR)*. Londrina: IAPAR, CD-Room.

Chen, L., Ren, C., Zhang, B., Wang, Z., and Xi, Y. 2018.
“Estimation of forest above ground biomass by geographically weighted regression and machine learning with sentinel imagery.” *Forests*, Vol. 9(No. 10): pp. 582. doi:10.3390/f9100582.

Cissell, J.R., Canty, S.W.J., Steinberg, M.K., and Simpson, L.T. 2021. “Mapping National Mangrove Cover for Belize Using Google Earth Engine and Sentinel-2 Imagery.” *Applied Sciences*, Vol. 11(No. 9): pp. 4258. doi:10.3390/app11094258.

Clinton, N., Holt, A., Scarborough, J., Yan, L., and Gong, P. 2010. “Accuracy assessment measures for object-based image segmentation goodness.” *Photogrammetric Engineering & Remote Sensing*, Vol. 76(No. 3): pp. 289–299. doi:10.14358/PERS.76.3.289.

Congalton, R.G. 1991. “A review of assessing the accuracy of classifications of remotely sensed data.” *Remote Sensing of Environment*, Vol. 37(No. 1): pp. 35–46. doi: 10.1016/0034-4257(91)90048-B.

Congalton, R.G., and Green, K. 2019. *Assessing the Accuracy of ReMotely Sensed Data: Principles And Practices*. 3st ed., Boca Raton: CRC Press. doi:10.1201/9780429052729.

Conners, R.W., and Harlow, C.A. 1980. “A Theoretical Comparison of Texture Algorithms.” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 2(No. 3): pp. 204–222. doi:10.1109/TPAMI.1980.4767008.

Costa, H., Foody, G.M., and Boyd, D.S. 2018. “Supervised methods of image segmentation accuracy assessment in land cover mapping.” *Remote Sensing of Environment*, Vol. 205: pp. 338–351. doi:10.1016/j.rse.2017.11.024.

Cover, T.M., and Hart, P. 1967. “Nearest neighbor pattern classification.” *IEEE Transactions on Information Theory*, Vol. 13(No. 1): pp. 21–27. doi:10.1109/TIT.1967.1053964.

Dash, J., and Curran, P. 2004. “The meris terrestrial chlorophyll index.” *International Journal of Remote Sensing*, Vol. 25(No. 23): pp. 5403–5413. doi:10.1080/ 0143116042000274015.

Delegido, J., Verrelst, J., Alonso, L., and Moreno, J. 2011. “Evaluation of sentinel-2 red-edge bands for empirical estimation of green lai and chlorophyll content.” *Sensors*, Vol. 11(No. 7): pp. 7063–7081. doi:10.3390/s110707063.

Duan, Q., Tan, M., Guo, Y., Wang, X., and Xin, L. 2019. “Understanding the spatial distribution of urban forests in China using sentinel-2 images with Google Earth Engine.” *Forests*, Vol. 10(No. 9): pp. 729. doi:10.3390/f10090729.

Escadafal, R. 1989. “Remote sensing of arid soil surface color with landsat thematic mapper.” *Advances in Space Research*, Vol. 9(No. 1): pp. 159–163. doi:10.1016/0273-1177(89)90481-X.

Eskandari, S., Jaafari, M.R., Oliva, P., Ghorbanzadeh, O., and Blaschke, T. 2020. “Mapping land cover and tree canopy cover in Zagros Forests of Iran: Application of Sentinel-2, Google Earth, and Field Data.” *Remote Sensing*, Vol. 12(No. 12): pp.

1912. doi:10.3390/rs12121912.

FAO. 2020. Global Forest Resources Assessment 2020 – Key findings. *Food and Agriculture Organization of the United Nations (FAO)*, pp. 1–16. Rome: FAO. doi:10.4060/ca8753en.

Ganz, S., Adler, P., and Kändler, G. 2020. “Forest cover mapping based on a Combination of aerial images and Sentinel-2 satellite data compared to national forest inventory data.” *Forests*, Vol. 11(No. 12): pp. 1322. doi:10.3390/f11121322.

Gitelson, A.A., Gritz, Y., and Merzlyak, M.N. 2003. “Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves.” *Journal of Plant Physiology*, Vol. 160(No. 3): pp. 271–282. doi:10.1078/0176-1617-00887.

Gitelson, A.A., Kaufman, Y.J., and Merzlyak, M.N. 1996. “Use of a green channel in remote sensing of global vegetation from eos-modis.” *Remote Sensing of Environment*, Vol. 58(No. 3): pp. 289–298. doi:10.1016/S0034-4257(96)00072-7.

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., and Moore, R. 2017. “Google earth engine: Planetary-scale geospatial analysis for everyone.” *Remote Sensing of Environment,* Vol. 202: pp. 18–27. doi:10.1175/1520-0477.

Guyot, G., and Baret, F. 1988. Utilisation de la haute resolution spectrale pour suivre l’etat des couverts vegetaux, In *4. Colloque international, ASE, Aussois*, France. https://hal.inrae.fr/hal-02780265.

Guyot, G., Frederic, B., and Major, D. 1988. “High spectral resolution: Determination of spectral shifts between the red and the near infrared.” *International Archives of Photogrammetry and Remote Sensing*, Vol. 11: pp. 750–760.

Hansen, M.C., Potapov, P.V., Moore, R., Hancher, M., Turubanova, S.A., Tyukavlna, A., Thau, D., *et al.* 2013. “High-resolution global maps of 21st-century forest cover change.” *Science*, Vol. 342(No. 6160): pp. 850–853. doi:10.1126/science.124469.

Haralick, R.M. 1979. “Statistical and structural approaches to texture.” *Proceedings of the IEEE*, Vol. 67(No. 5): pp.786–804. doi:10.1109/PROC.1979.11328.

Haralick, R.M., Shanmugam, K., and Dinstein, I. 1973. “Textural features of image classification.” *IEEE Transactions on Systems, Man, and Cybernetics*, Vol.

SMC-3(No. 6): pp. 610–621. doi:10.1109/TSMC.1973.4309314.

Hird, J.N., DeLancey, E.R., McDermid, G.J., and Kariyeva, J. 2017. “Google earth engine, open-access satellite data, and machine learning in support of large-area probabilistic wetland mapping.” *Remote Sensing*, Vol. 9(No. 12): pp. 1315. doi:10.3390/rs9121315.

Huang, H., Chen, Y., Clinton, N., Wang, J., Wang, X., Liu, C., Gong, P., *et al.* 2017. “Mapping major land cover dynamics in Beijing using all Landsat images in Google Earth Engine.” *Remote Sensing of Environment*, Vol. 202: pp. 166–176. doi:10.1016/j.rse.2017.02.021.

Huete, A. 1988. “A soil-adjusted vegetation index (savi).” *Remote Sensing of Environment*, Vol. 25 (No. 3): pp. 295–309. doi:10.1016/0034-4257(88)90106-X.

IBGE 2012. *Manual Tecnico da Vegetação Brasileira*. 2 ed., p. 272. Rio de Janeiro: IBGE. Instituto Brasileiro de Geografia e Estatıstica (IBGE).

Jay, S., Gorretta, N., Morel, J., Maupas, F., Bendoula, R., Rabatel, G., Dutartre, D., Comar, A., and Baret, F. 2017. “Estimating leaf chlorophyll content in sugar beet canopies using millimeter to centimeter-scale reflectance imagery.” *Remote Sensing of Environment*, Vol. 198: pp.173–186. doi:10.1016/j.rse.2017.06.008.

Jiang, Z., Huete, A.R., Didan, K., and Miura, T. 2008. “Development of a two-band enhanced vegetation index without a blue band.” *Remote Sensing of Environment*, Vol. 112(No. 10): pp. 3833–3845. doi:10.1016/j.rse.2008.06.006.

Jordan, C.F. 1969. “Derivation of leaf-area index from quality of light on the forest floor.” *Ecology*, Vol. 50(No. 4): pp. 663–666. doi:10.2307/1936256.

Kaplan, G. 2021. “Broad-leaved and coniferous forest classification in google earth engine using sentinel imagery.” Environmental Sciences Proceedings (MDPI) 3, 1–6. doi:10.3390/IECF2020-07888.

Kimes, D., Markham, B., Tucker, C., and McMurtrey, J. 1981. “Temporal relationships between spectral response and agronomic variables of a corn canopy.” *Remote Sensing of Environment*, Vol. 11: pp. 401–411. doi:10.1016/0034-4257(81)90037-7.

Landis, J.R., and Koch, G.G. 1977. “The measurement of observer agreement for categorical data.” *Biometrics*, Vol. 33(No. 1): pp. 159–174.

Lobell, D.B., Thau, D., Seifert, C., Engle, E., and Little, B. 2015. “A scalable satellite based crop yield mapper.” *Remote Sensing of Environment* Vol. 164: pp. 324–333. doi:10.1016/j.rse.2015.04.021.

Lu, D., Batistella, M., Moran, E., and Mausel, P. 2004. “Application of spectral mixture analysis to Amazonian Land-Use and Land-Cover classification.” *International Journal of Remote Sensing*, Vol. 25(No. 23): pp. 5345–5358. doi:10.1080/01431160412331269733.

McFeeters, S.K. 1996. “The use of the normalized difference water index (NDWI) in the delineation of open water features.” *International Journal of Remote Sensing*, Vol. 17(No. 7): pp. 1425–1432. doi:10.1080/01431169608948714.

Mondal, P., Liu, X., Fatoyinbo, T.E., and Lagomasino, D. 2019. “Evaluating Combinations of Sentinel-2 Data and Machine-Learning Algorithms for Mangrove Mapping in West Africa.” *Remote Sensing*, Vol. 11(No. 24): pp. 2928. doi:10.3390/rs11242928.

Niculescu, S., Billey, A., and Talab Ou Ali, H. 2018. “Random forest classification using Sentinel-1 and Sentinel-2 series for vegetation monitoring in the Pays de Brest (France).” Paper presented at SPIE Remote Sensing10783. doi:10.1117/12.2325546.

Pacheco, A., and McNairn, H. 2010. “Evaluating multispectral remote sensing and spectral unmixing analysis for crop residue mapping.” *Remote Sensing of Environment*, Vol. 114(No. 10): pp. 2219–2228. doi:10.1016/j.rse.2010.04.024.

Pałas, K.W., and Zawadzki, J. 2020. “Sentinel-2 imagery processing for tree logging observations on the Białowieza Forest World Heritage Site.” *Forests*, Vol. 11(No. 8): pp. 857. doi:10.3390/f11080857.

Pekel, J.F., Cottam, A., Gorelick, N., and Belward, A.S. 2016. “High-resolution mapping of global surface water and its long-term changes.” *Nature*, Vol. 540(No. 7633): pp. 418–422. doi:10.1038/nature20584.

Pontius, R.G., and Millones, M. 2011. “Death to kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment.” *International Journal of*

Remote Sensing, Vol. 32(No. 15): pp. 4407–4429. doi:10.
1080/01431161.2011.552923.

Pouget, M., Floc'h, E., Kamal, S., and Saloum, B. 1990. Utilisation des données SPOT pour la cartographie des ressources renouvelables : application à la région côtière Nord-Ouest de l'Egypte. Cartographie des Etats de Surface (SATCARTO), pp. 103–143.

Richards, J. 1993. *Remote Sensing Digital Image Analysis. An Introduction*, 340. Berlin Heidelberg: Springer-Velarg.doi:10.1007/978-3-642-88087-2.

Rouse, J.W., H.R.S.J., and Deering, D. 1973. Monitoring vegetation systems in the great plains with ERTS. *Proceedings of 3rd Earth Resources Technology Satellite Symposium* 1, 309–317.

Segarra, J., Buchaillot, M.L., Araus, J.L., and Kefauver, S.C. 2020. "Remote sensing for precision agriculture: Sentinel-2 improved features and applications." *Agronomy*, Vol. 10(No. 5): pp. 641. doi:10.3390/agronomy10050641.

Sherman, G.E., Sutton, T., Blazek, R., Holl, S., Dassau, O. B. M., Mitchell, T., and Luthaman, L. 2011. Quantum GIS User Guide – Version 3.16 "Wroclaw".

Smith, M.O., Susan, L.U., Adams, J.B., and Gillespie, A.R. 1990. "Vegetation in deserts: I. A regional measure of abundance from multispectral images." *Remote Sensing of Environment (Elsevier)*, Vol. 31(No. 1): pp. 1–26. doi:10.
1016/0034-4257(90)90074-V.

Sousa, C., Fatoyinbo, L., Neigh, C., Boucka, F., Angoue, V., and Larsen, T. 2020. "Cloud-computing and machine learning in support of country-level land cover and ecosystem extent mapping in Liberia and Gabon." *PLos One*, Vol. 15(No. 1): pp. e0227438. doi:10.1371/journal.pone.0227438.

Souza, C.M., Z. Shimbo, J., Rosa, M.R., Parente, L.L., A. Alencar, A., Rudorff, B.F.T., Hasenack, H., *et al.* 2020. "Reconstructing three decades of land use and land cover changes in Brazilian Biomes with Landsat Archive and Earth Engine." *Remote Sensing*, Vol. 12(No. 17): pp.
2735. doi:10.3390/rs12172735.

Stehman, S.V. 1997. "Selecting and interpreting measures of thematic classification accuracy." *Remote Sensing of Environment*, Vol. 62(No. 1): pp. 77–89. doi:10.1016/

S0034-4257(97)00083-7.

Theofanous, N., Chrysafis, I., Mallinis, G., Domakinis, C., Verde, N., and SiaHalou, S. 2021. “Aboveground biomass estimation in short rotation forest plantations in Northern Greece using ESA’s sentinel medium-high resolution multispectral and radar imaging missions.” *Forests*, Vol. 12(No. 7): pp. 902. doi:10.3390/f12070902.

Vrdoljak, L., and Kilić Pamuković, J. 2022. “Assessment of atmospheric correction processors and spectral bands for satellite-derived bathymetry using sentinel-2 data in the middle adriatic.” *Hydrology*, Vol. 9(No. 12): pp. 215. doi: 10.3390/hydrology9120215.

Wang, X., Yao, Y., Zhao, S., Jia, K., Zhang, X., Zhang, Y., Zhang, L., Xu, J., and Chen, X. 2017. “MODIS-based estimation of terrestrial latent Heat Flux over North America using three machine learning algorithms. *Remote Sensing*, Vol. 9(No. 12): pp. 1326. doi:10.3390/rs9121326.

Waśniewski, A., Hościło, A., Zagajewski, B., and MoukétouTarazewicz, D. 2020. “Assessment of Sentinel-2 satellite images and random forest classifier for rainforest mapping in gabon.” *Forests*, Vol. 11(No. 9): pp. 941. doi:10.3390/f11090941.

Welikhe, P., Essamuah-Quansah, J., Fall, S., and McElhenney, W. 2017. “Estimation of soil moisture percentage using landsat-based moisture stress index.” *Journal of Remote Sensing GIS*, Vol. 06: pp. 200. doi:10.4172/2469-4134.1000200.

Willmott, C.J., Robeson, S.M., and Matsuura, K. 2012. “A refined index of model performance.” *International Journal of Climatology*, Vol. 32(No. 13): pp. 2088–2094. doi:10.1002/joc.2419.

Xie, B., Cao, C., Xu, M., Duerler, R.S., Yang, X., Bashir, B., Chen, Y., and Wang, K. 2021. “Analysis of regional distribution of tree species using multi-seasonal sentinel-12 imagery within Google Earth Engine.” *Forests*, Vol. 12(No. 5): pp. 565. doi:10.3390/f12050565.

Zeng, H., Wu, B., Wang, S., Musakwa, W., Tian, F., Mashimbye, Z.E., Poona, N., and Syndey, M. 2020. “Asynthesizing land-cover classification method based on Google Earth Engine: A case study in Nzhelele and Levhuvu Catchments, South Africa.” *Chinese Geographical Science*, Vol. 30 (No. 3): pp. 397–409. doi: 10.1007/s11769-020-1119-y.

Zulfiqar, A., Ghaffar, M.M., Shahzad, M., Weis, C., Malik, M.I., Shafait, F., and Wehn, N. 2021. “AI-ForestWatch: semantic segmentation based end-to-end framework for forest estimation and change detection using multi-spectral remote sensing imagery.” *Journal of Applied Remote Sensing*, Vol. 15(No. 02): pp. 1–21. doi:10.1117/1.JRS.15.024518

5.3 DEFORESTATION DETECTION SYSTEM FOR TROPICAL NATIVE FORESTS USING SENTINEL-2 IMAGES

5.3.1 Abstract

This paper presents a near real-time system for forest monitoring using Sentinel-2 image vegetation index time series and Machine Learning (ML) techniques to detect changes in forest cover. The objective of this study was to develop a native forest deforestation detection system based on reference forest mapping using Sentinel-2 images with 10m spatial resolution, and was implemented in Google Earth Engine (GEE) platform. The proposed methodology consists in apply harmonic analysis adopting a reference map of the native forest for comparison purposes with more recent images, free of clouds and atmospherically corrected data from the same region for the same forest fragment. The Planet images of year 2023 was used as a base to identify and validate deforestation areas. The transformation of the color space from Red, Green and Blue (RGB) for Hue, Saturation, and Value (HSV) improves perception of changes in native forest reference areas. As a result, it was possible to obtain an Overall Accuracy (AO) of 97.5%.

5.3.2 Introduction

Tropical forests are one of the most biodiverse ecosystems on Earth and comprises the most significant portion of terrestrial species in the world Pimm and Raven (2000); Bradshaw *et al*. (2009); Laurance *et al*. (2012) and Pan *et al*. (2013).

With the growth of industrial development, the consumption of renewable native resources has increased, reflecting in serious environmental changes, including forest lost and degradation Morris (2010) and Nobre *et al*. (2016).

Remote sensing has been fundamental in research applied to the monitoring of forest ecosystems. With the widespread advancement of these technologies and

the increased availability of satellite imagery over short periods of time, it is possible to efficiently monitor the forest loss process Sano *et al*. (2021).

Several national and global deforestation monitoring systems based on optical satellite data are currently operational, such as the Forest Alerts by Global Land Analysis and Discovery (GLAD). This alerting system is meant to complement a current annual global forest cover loss product, implemented in collaboration with Google and the World Resources Institute as part of Global Forest Watch Hansen *et al*. (2016).

In Brazil, the Monitoring of land cover and use changes is done by systems such as developed by Brazilian Institute of Geography and Statistics (IBGE) (IBGE, 2022), and the Real-Time Deforestation Detection System (DETER) (Doblas *et al*.; 2022; Diniz *et al*., 2015) developed and run by the National Institute of Space Research (INPE), and “Map-Biomas Alerta” (Souza *et al*., 2020), a system for validating and refining deforestation alerts in all of Brazil’s biomes, this one making use of detections from other institutions such as INPE, the University of Maryland, Institute of Man and the Environment of the Amazon (IMAZON) and other sources.

However, current monitoring systems do not operate at spatial scales sufficient to detect areas with minor forest disturbances (Zhang *et al*., 2021; Slagter *et al*., 2023).This is due to the limited spatial resolution of the sensors used, such as the Moderate Resolution Imaging Spectroradiometer (MODIS) and LANDSAT satellite. Deforestation has raised concerns about several issues related to the planet’s future, such as loss of biodiversity, increased erosion, soil degradation, carbon emissions, rising temperatures, fluctuations and changes in the hydrological cycle, global warming, climate and social changes, and environmental impacts.

Remote sensing methods and techniques play fundamental roles in the monitoring and evaluation of environmental management. Several change detection methods have been developed over the last few decades, mainly based on the analysis of vegetation index, whereas other less used methods have attempted to gain information through dimension reduction techniques. Access to new satellite techniques and their constellations, such as Sentinel-2 and Planet, with better spatial

and spectral resolution and more information than other satellite programs, provides important opportunities to improve the quality and precision of identifying forest disturbances around the world.

Remote sensing data have been extensively used in recent decades to monitor deforestation (Coppin *et al*., 2002), however, most of the time, time series change methods developed are limited. Verbesselt *et al*. (2010), Singh and Bohra (1990) and Coppin *et al*. (2004) listed several techniques and procedures for change detection (e.g. univariate image differentiation, image regression, Principal Component Analysis (PCA), vegetation indices and post-classification comparison).

Ortega Adarme *et al*. (2022) used Sentinel-1 radar images and convolutional neural networks to detect deforestation in tropical forests. Pacheco-Pascagaza et al. (2022) developed a change detection system for tropical forests using Sentinel-2 and Machine Learning (ML). Torres *et al*. (2021) used convolutional networks with Landsat 8 and Sentinel-2 data to detect deforestation. Solorzano *et al*. (2023) used multispectral and radar images to detect deforestation in a tropical forest in southeast Mexico between 2019 and 2020. Sugimoto *et al*. (2022) used Synthetic Aperture Radar (SAR) to detect deforestation in the Amazon rainforest. Kalinaki *et al*. (2023) used a U-Net model through image segmentation to detect changes in forest vegetation.

Over the last few decades, remote sensing has provided new tools and opportunities to monitor changes in land use and cover Laso *et al*. (2020). Research that has focused on generating forests over maps Myroniuk *et al*. (2020); Johnson *et al*. (2023), aboveground biomass maps Galidaki *et al*. (2017); Hu *et al*. (2020); Spawn (2020), and land cover change maps Souza-Filho *et al*. (2016), as well as improving algorithms to increase their accuracy Purwanto *et al*. (2024). Many of these products are not produced annually or have a fixed delivery schedule, which limits their usability to enable early intervention when the loss of unlicensed forest cover is detected.

In this study, a near-real-time native forest deforestation detection monitoring system was developed based on Sentinel-2 images. An algorithm was developed

based on the JavaScript programming language the GEE, the detection, processing of large quantities of images, and analysis of native forest removal. Native forest reference mapping was performed using Object-Based Image Analysis (OBIA) and refined using (ML) algorithms.

The reflectance bands of the images were stacked and used to generate additional bands with vegetation and texture indices. The classifier was trained using temporal and spectral information. The results were independently validated by using images from the Planet Scope satellite constellation.

The development of this deforestation detection system will consolidate a technological resource that can be used to implement biodiversity conservation actions in Brazil, such as identifying potential areas for creating Conservation Units (CUs), identifying potential areas for the formation of Ecological Corridors (ECs), defining areas for forest suppression according to Article 17 of the Atlantic Forest Law, defining areas for compensatory measures, according to Article 36 of Law No. 9.985/2000, application in Payment for Environmental Services (PES) projects, monitoring of native vegetation, participation in biodiversity and carbon credit, and implementation of other policies to encourage biodiversity conservation.

5.3.3 Organization of research steps

The aim of this study was to develop a forest deforestation detection system on the Google Earth Engine (GEE) platform using Sentinel-2 images and mapping of reference native forests based on change detection. This article describes the following steps: (1) Introduction; (2) Definition of study area (southern Brazil), Reference forest mapping, Forest age estimation, Images and reference base for validation and Brazilian environmental legislation; (3) Research methods (Methodological procedures): GEE, Deforestation detection, Detection period, color space transformation, unsupervised classification, estimation dates of deforestation, transition and intensity of impact; (4) Results and discussion and (5) Conclusions.

5.3.4 Study area

The state of Paraná is located in Southern Brazil, between the parallels 22°29'S and 26°43'S latitude, and between the meridians 48°2'W and 54°38'W longitude. Paraná has an annual average precipitation between 1100 mm to 1920 mm, an average temperature between 15 °C and 24 °C (Aparecido *et al*., 2016), and annual average evapotranspiration of 700 mm to 1600 mm (Caviglione *et al*., 2000) (Figure 22).

The state's climatic characteristics have regional variations, yet the K¨oppen and Geiger (1928) climate classification system establish the Cfa (warm temperate with hot summer) and Cfb (humid temperate with moderate hot summer) as the most predominant classes. However, Cwa (humid temperate with dry winter) and Aw (humid tropical savanna) are also present in the state's North portion (Aparecido *et al*., 2016).

FIGURE 22 – STATE OF PARANÁ, SOUTHERN BRAZIL

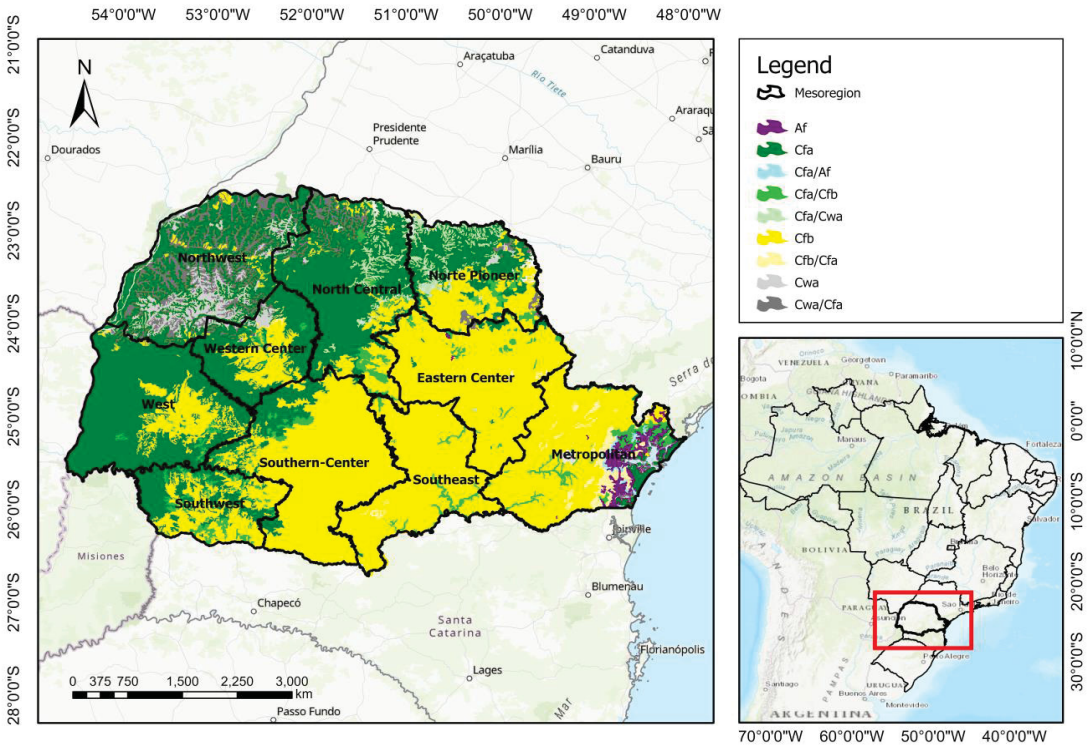

SOURCE: The author (2025).

As a result of the interaction between biotic (vegetation and animals) and abiotic (climate, rock, topography, and soil) components, the state has a great diversity of landscapes and numerous types of vegetation. The phytoecological regions are spaces defined by typical floristic genera and characteristical biological forms that are recurrent within the same climate, occurring on land of varied lithology, but with defined topography IBGE (2022).

5.3.5 Materials

5.3.5.1 Reference forest mapping

The reference forest mapping was generated using Object-Oriented classification (OBIA) and ML using Sentinel-2 images for the year 2016 Cechim Junior et al. (2023). Only the native forest was mapped, not considering silviculture areas. The input reference forest mapping consists of an initial pre-processing including a 3-pixel edge noise removal using negative buffering. The mapping was imported as an Asset in GEE, so a -30m buffer was generated to avoid contamination from the effect of edge pixels. The tool “Smooth polygon” from ArcPro 10.8 was used to smooth the edge, with the “Polynomial Approximation with Exponential Kernel (PAEK)” algorithm, using a tolerance parameter of 50m.

5.14.2 IMAGES AND REFERENCE BASE FOR VALIDATION

5.14.2.1 Sentinel-2

The Sentinel-2 used images is refered as the level 2A product, which already contains atmospheric correction and is available on the GEE. Another important feature of Copernicus Sentinel-2 is the wealth of information retrieved from its 13 spectral bands.

5.14.2.2 Planet

High resolution images from the Planet constellation were used to validate deforestation. To access these datasets, an account was created, and it is possible to access the base image via the link https://www.planet.com/basemaps/#. This platform offers monthly image composition, the researchers access to time series of satellite images from the RapidEye, PlanetScope e SkySat constellations.

5.14.2.3 MapBiomas

Forest mapping (2023) has a scale (1:25.000) to ensure compatibility between the raster and vector information, and possible class fluctuations in the time series, certain criteria had to be established. A 70% correspondence between the Forest class (2023) and the mapping for each year in MapBiomas was considered, and these criteria must be met. That is, a forest remnant polygon (2023) would only be considered if 70% of the pixels present in this polygon were native vegetation and/or forest formation classes, according to the annual mapping of MapBiomas. In addition, to count the age of the remnants, should be identified in a continuous series of years, starting in 1985.

The methodology for mapping pixel frequencies based on historical series from Mapbiomas, indicates consolidated areas of native forest that did not change or suffered little change from 1985 until 2023, highlighting the degree of forest permanence of age associated with its successional regeneration.

If a remnant polygon (2023) was not identified by MapBiomas as native vegetation and/or forest formation in 2022, it was defined as having 0 years, if it was identified as native vegetation and/or forest formation by MapBiomas in any previous year. However, some forest existing in 2023, were not identified as native vegetation and/or forest formation by MapBiomas in any previous year; therefore, they were not used.

MapBiomas Alert is a system for validating and refining deforestation alerts of native vegetation in all Brazilian biomes with high-resolution images. This system is

constantly being developed by the collaborative network of MapBiomas co-creators, with suggestions from government agencies (Ministry of Environment and Climate Change (MMA), Brazilian Institute of the Environment and Renewable Native Resources (IBAMA), Brazilian Forest Service (SFB), Chico Mendes Institute for Biodiversity Conservation (ICMBio), Federal Public Prosecutor's Office (MPF) and Federal Court of Accounts (TCU) and alert providers (INPE, IMAZON, University of Maryland, Socioenvironmental Institute (ISA), and others). MapBiomas Alert publishes any and all loss of native vegetation detected by alert provider systems and validated in high-resolution satellite images. Although there is still a limitation in relation to the spatial resolution of the detections, which is not sufficient to detect the removal of forest with an area of 100m^2.

5.3.5.2 Estimating of forest age

The data from the MapBiomas land use mapping were used to generate an auxiliary intermediate product to understand the dynamics regarding the forest age of removed deforestation.The distribution of native forest fragments in the state of Paraná for the advanced stage. 70.46% were in the Southern-Central mesoregion, 17.49% in the metropolitan region, 18.97% in the Southeast region and 17.76% in the Eastern North region (Figure 23).

FIGURE 23 – FOREST AGE MAPPING TO DISCRIMINATE REGENERATION STAGE

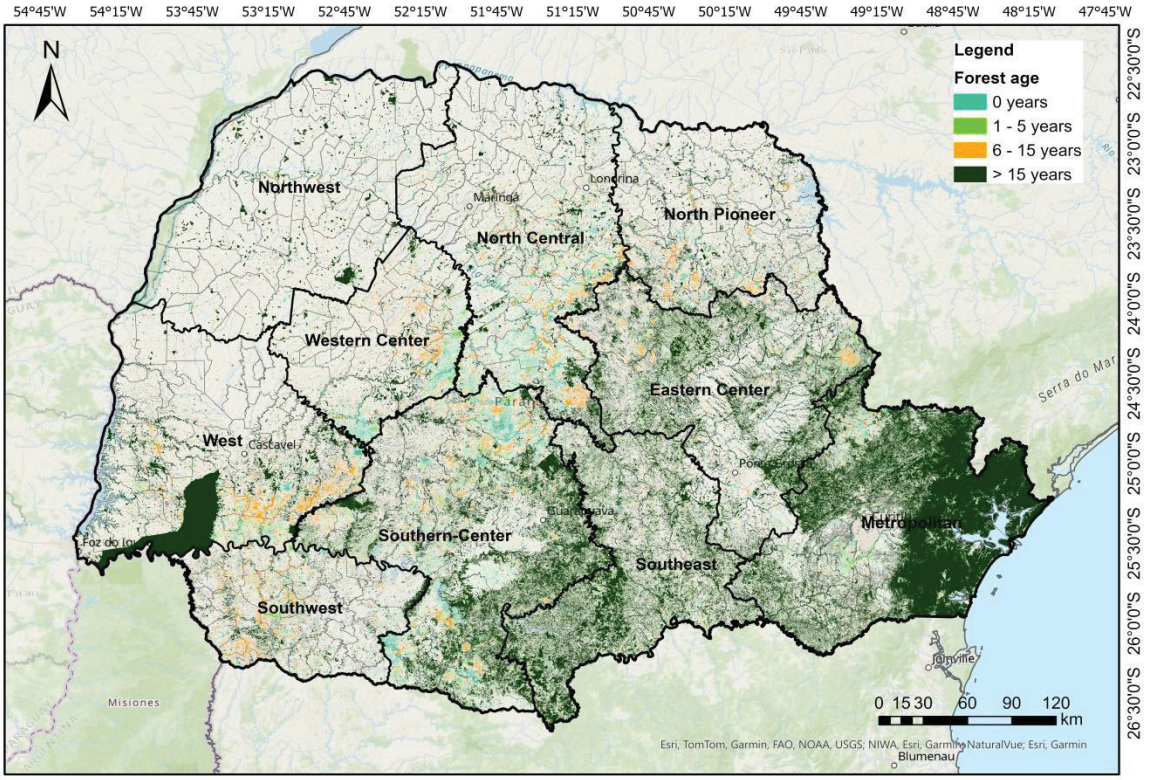

SOURCE: The author (2025).

The largest representation was contained in the Mixed Ombrophilous Forest (MOF) with 45.37% in the advanced regeneration stage. The second largest representation was Dense Ombrophilous Forest (DOF), with 23.17% in the advanced regeneration stage, followed by Semideciduous Seasonal Forest (SSF) (10.32%), grassland physiognomy (3.12%) and Savanna (0.19%) (Figure 24).

FIGURE 24 – QUANTITATIVE AREA BY TYPE OF FOREST AND STAGES OF REGENERATION

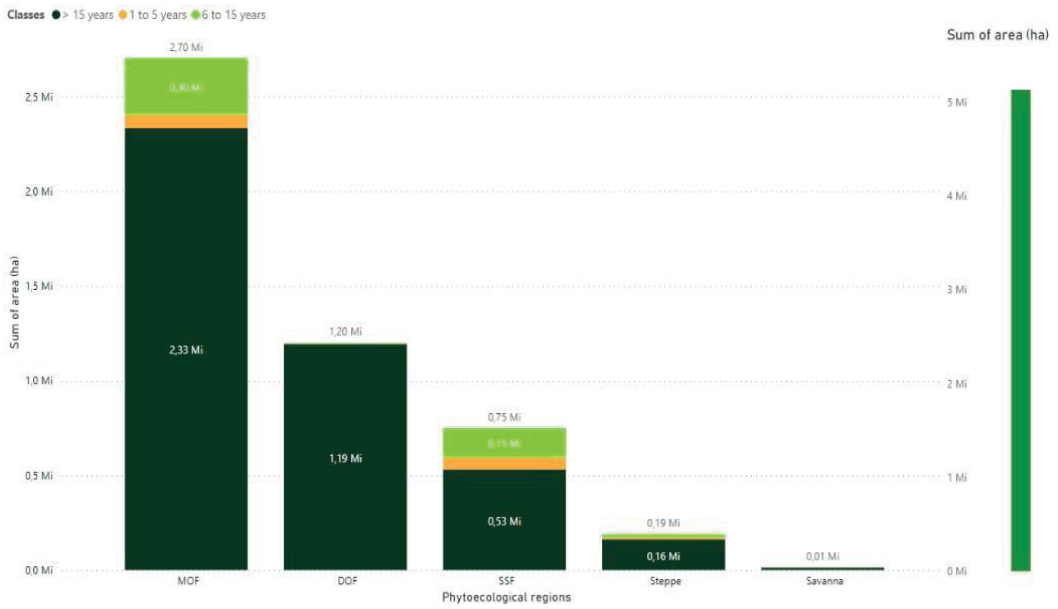

SOURCE: The author (2025).

5.14.4 Rural Environment Registry (RER)

Established by Law 12.651/2012, the Rural Environment Registry (RER) “is a nationwide public registry mandatory for all rural properties, with the purpose of integrating the environmental information of rural properties and possessions, forming a database for control, monitoring, combating deforestation and economic and environmental planning. The RER is a mandatory electronic registry for all rural properties, public or private, in Brazil. The RER aims to: Integrate environmental information from rural properties; Identify areas of environmental preservation; Map degraded areas; Inform about agricultural activities; Controlling, monitoring and combating deforestation; Plan for environmental and economic use.

Regarding the size of the area, rural properties can be classified into: Minifundium: rural property with an area less than the Minimum Fraction of Parceling; Small Property: property with an area between the Minimum Fraction of Installment and 4 fiscal modules; Medium Property: rural property with an area greater than 4

and up to 15 fiscal modules and Large Property: rural property with an area greater than 15 fiscal modules.

The use of the RER database makes it possible to identify the person responsible for the deforestation, and the location of the property where the deforestation was detected and identified.

The registry in the RER is a declaratory process carried out by the owner (possessor), with environmental information on rural properties and possessions relating to Permanent Preservation Areas (PPA) it establishes areas that contribute to water quality and fish life and that prevent the risk of native disasters, which do not allow economic exploitation, its function is to preserve water resources, soil, landscape, biodiversity and the flow between fauna and flora, for restricted use.

The Legal Reserves (LR) is a percentage of the area covered by forest, located within a rural property in Brazil, in the Atlantic Forest Biome corresponding to 20% of the area of the property, remaining forests and other forms of forest, and consolidated areas. Scientific research has used RER as a target and source of study, largely because of the importance of the register in terms of environmental regularization Laudares et al. (2014); Jung et al. (2017); Roitman et al. (2018); Carneiro and Coutinho (2017).

5.14.5 Vegetation suppression authorization

Authorizations for alternative use and suppression of vegetation, as well as management forest plans, are sourced from SINAFLOR/IBAMA, which integrates data from all Brazilian states, with limited updates. The embargoed areas correspond to those available on the IBAMA and ICMBio geoservice http://siscom.ibama.gov.br/geoserver/ and may be incomplete due to state and municipal embargoes. Forest embargoed areas are regions that have suffered environmental damage and are under administrative sanction to prevent the continuation of activities that cause damage to the environment.

The embargo is a precautionary measure or administrative sanction applied by environmental agencies, to protect the environment and allow the regeneration of the biome.

5.3.6 Methods

5.3.6.1 Methodological procedures

The research method was divided in the following steps (Figure 24).

FIGURE 25 – SCHEMATIC OVERVIEW OF METHODOLOGICAL PROCEDURES

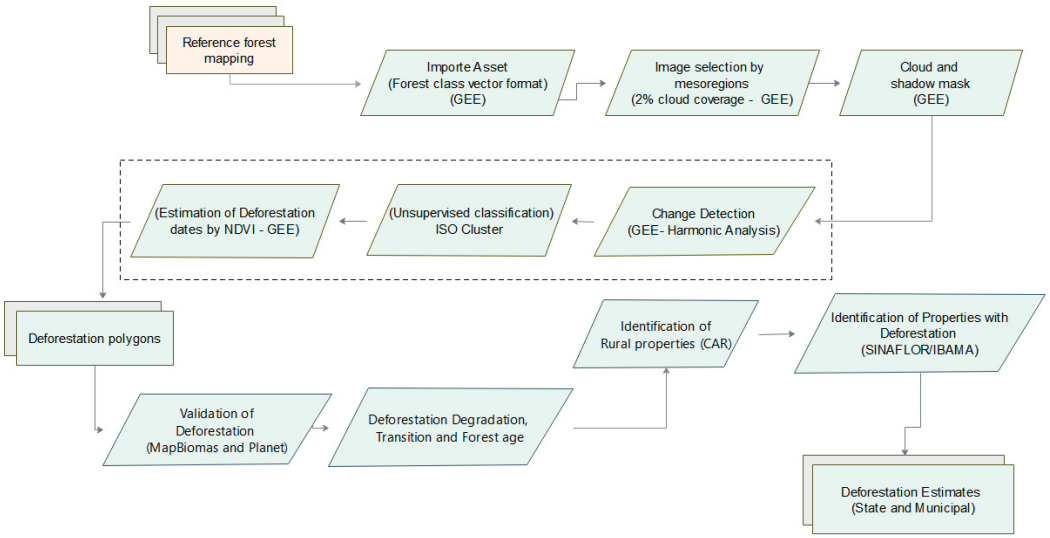

SOURCE: The author (2025).

5.3.6.2 Google Earth Engine (GEE)

The GEE platform is a high-performance processing environment that stores collections of satellite images from long time series for any region of the Earth's surface. The delimitation of deforestation polygons is refined using ML algorithms and cloud processing on the GEE platform.

5.3.6.3 Estimating of forest age

The results from native forest mapping for 2023 were used as a basis, according to the methodology of Cechim Junior *et al*. (2023), considering all detected fragments. Regarding forest fragments, all fragments compatible with the historical forest mapping data from MapBiomas collection 8.0 (Souza *et al*., 2020) were considered.

Considering that there is no information on the successional stages of forest remnants In the Atlantic Forest biome, the age criteria of permanence for forest fragments were used to identify fragments with more than 15 years of permanence. This time interval is similar to that proposed by Chazdon (2013) for the temporal dynamics of the secondary succession found in tropical forest vegetation (15 to 50 years).

The definition of succession time elapsed allowed the establishment of four categories of forest physiognomies: (a) early stage secondary vegetation, representing stages up to 15 years old; (b) mid-stage secondary vegetation, established in places where the succession process takes place over an approximate interval of 15 to 30 years; (c) advanced-staged secondary vegetation, with forests originating from succession that began between 30 and 40 years ago; and (d) consolidated forest, which represents the oldest stretches of secondary forest (over 40 years) or even original ones, but submitted to interventions (selective cutting of timber oredible species).

An important aspect of this work was the use of historical information from MapBiomas on land use and land cover, from 1985 to 2022 (collection 8.0) to solve an impasse in estimating the possible age of native vegetation fragments up to the year of 2023. To this end, the data for each year were consulted, checking whether a particular fragment existed or not, comparing it with previous years, and creating a time history that allowed us to check the ages of each fragment.

This analysis was extremely important for classifying the fragments in each successional stage (early, medium and advanced) and, consequently, for

determining their current conservation status and the degree of maturity of the native forest.

After identifying the age of each forest remnant, they were grouped according to age criteria, thus defining the successional stages of regeneration in accordance with National Council for the Environment, CONAMA Resolution of 1994 (Table 15).

It is highlighted that this methodology was not applied to the native stepp class, as there is no data or reference mapping to this date showing the coverage of native stepp (Campos Sulinos) in the state of Paraná.

TABLE 15 – SUCCESSIONAL STAGES OF REGENERATION FROM FOREST AGE ESTIMATION

Forest age	**Regeneration Stages**
More than 15 years	Represent forests at an advanced stage of regeneration
Between 6 and 15 years	Represent forests at a mid stage of regeneration
Between 1 and 5 years	Considered as forests at early stages of regeneration

SOURCE: The author (2025).

5.3.6.4 Deforestation detection system

The detection system was developed using a GEE algorithm and the JavaScript programming language. All the code can also be translated into Python using the Geemap library, which is a library for interactive geospatial analysis and visualization with GEE.

A location filter using mesoregions of the state of Paraná and a filter for selecting images with up to 2% cloud coverage were applied to Sentinel-2 images. The images used were from January 1 to December 31, 2023. Cloud masking was applied and the *Normalized Difference Vegetation Index* (NDVI) was generated and used to estimate the date of occurrence of deforestation and to classify the intensity of apparent environmental degradation in the soil.

The steps of the methodology of this detection system is to import the vector Assets that correspond to the boundaries of mesoregions, RER properties and

reference forest mapping. Next, the selection of Sentinel-2 images by mesoregion is made, the definition of the annual analysis period and the percentage of cloud cover.

The NDVI is created and added using the function (image) “addVariables” to create NDVI variables such as time and a constant from the Sentinel-2 images, and compute time in fractional years since the epoch. From this it is possible to create graphs and analyze temporal trends.

To estimate linear trends over time, consider the following linear model, where ϵt is a random error (Eq. 11).

$$y = \beta 0 + \beta 1X1 + \cdots + BnXn + \epsilon t \qquad (11)$$

where:

y - dependent variable (or response variable);

β0 - intercept, (represents the expected value of $y$when all predictor variables);

β1, β2,…,β $_n$ - regression coefficients, (corresponding to each predictor variable);

X_1, X_2,…,X_n - independent variables (also called explanatory or predictor variables;

ϵt - random error.

We can use this model to detrend our data (explain the upward or downward movement of the data by subtracting observed values from the fitted model values). For now, the goal is to discover the values of the beta coefficients.

To fit this trend model to the Sentinel-2 based NDVI series using Ordinary Least Squares (OLS), was used the *linearRegression() reducer*, the image generated is a two-band image in which each pixel contains values for β_0 and β_1.

In the following procedure, seasonality was estimated with a harmonic model, considering he following linear model, where (ϵt is random error, A is amplitude, ω is frequency, and $\boldsymbol{\phi}$ is phase) (Eq. 12).

$$pt = \beta 0 + \beta 1t + Acos(2\pi\omega t - \phi) + \epsilon t \quad (12)$$

where:

pt - observed value of the time series at time t;

β0 - the intercept or baseline level of the time series;

β1t - linear trend component;

Acos(2πωt-ϕ) - the seasonal or cyclic component of the model;

A - amplitude of the seasonal variation;

ω - angular frequency;

t - time;

ϕ - phase;

ϵt - random error.

And in this way decompose our function into separate cosine and sine elements, and so breaking up more complex curves into a set of simplified cosine waves with an additive term Jakubauskas et al. (2001) (Eq. 13).

$$pt = \beta 0 + \beta 1t + \beta 2cos(2\pi\omega t) + \beta 3sin(2\pi\omega t) + \epsilon t \quad (13)$$

where:

pt - observed value of the time series at time t, (this could represent any periodic or seasonal phenomenon);

β1t - intercept term, (it represents the baseline level or the average value of the time series when all other terms are zero);

β2cos(2πωt)+β3sin(2πωt) - seasonal (cyclical) component of the model, (these two terms together model periodic fluctuations in the data);

ω - frequency of the cycle (e.g., ω=1 for annual cycles if time is in years);

β2 and β2 - coefficients that determine the amplitude and phase of the seasonal pattern.

ϵt - random error, (the error term or residual, capturing random fluctuations or noise not explained by the model).

If there is a seasonal trend in the data, the ordered nature of a cosine curve can likely approximate it. To fit this model to the time series, been set $\omega=1$ (one cycle per unit time) and used ordinary least squares regression as the metric of error reduction, and so add the harmonic variables (the third and fourth terms of equation 2) to the image collection and the coefficients into equation 2 in order to get a time series of fitted values, a time series can be decomposed as the sum of sinusoids at different frequencies.

The final step is to apply harmonic trend and use these independent variables in harmonic regression, and then add harmonic terms such as new image bands, phase calculation, and amplitude.

Transform the matrix image into a multiband image of coefficients. The output of the regression reduction is a 4x1 matrix image. Next, the matrix image is transformed into a multiband image of coefficients. To highlight the changes, the HSV to RGB transformation is used to display phase and amplitude.

The methodology consists of importing a reference native forest mapping in vector format, and in this way analyzing the changes within the forest fragments/polygons.

5.3.6.5 Color space transformation

The transformation of RGB color space to HSV was used to enhance the representation of deforestation intensity, which can be used to improve contrast in distinguishing spectrotemporal behavior where deforestation has occurred.

5.3.6.6 Forest transition

The areas selected with changes contained in the HSV image format within the native forest fragments was converted into polygons. To determine the forest

transition, a supervised classification was performed using RF in this polygon, using cloud-free Sentinel-2 images (Cechim Junior *et al*. 2023), considering the year prior to the year used for change detection.

8.3.6.7 Estimating deforestation dates

The date of detection is the date on which the polygon was created and does not necessarily represent the moment when deforestation occurred. Deforestation detected on a certain date, for example, may have started or occurred earlier. Data for the current year are always partial and subject to change, because of the availability of images that prove deforestation. When annual data were consolidated, an overlap analysis was carried out using the properties in the Rural Environment Registry (RER). The minimum area of deforestation detected that corresponds to an alert is 0.01 hectares.

5.3.6.8 Impact intensity

The intensity of impact was defined based on the data obtained using the time series from the calculation of NDVI, thus defining the environmental impact of the degradation in relation to change in land use, defining three classes of intensity of impact on environmental degradation, that is, the closer to the exposed soil, the lower the NDVI value and the greater the degradation caused, with the lower the NDVI value, the greater the intensity of impact (Table 16).

TABLE 16 – DEFORESTATION DEGRADATION IMPACT INTENSITY CLASSIFICATION

Degradation	**NDVI**
Low Intensity	Above 0.5
Medium Intensity	Between 0.25 and 0.5
High Intensity	Below de 0.25

SOURCE: The author (2025).

5.3.6.9 Deforestation validation

MapBiomas detections were used for the year of 2023, corresponding to 532 alerts. These polygons were used as references, along with the interpretation of Sentinel-2 and Planet images. The Correctly Classified Pixels (CCP%), Overall Accuracy (OA%), Kappa Index (KI) Omission Errors (OE%) and Inclusion Errors (IE%) Congalton (1991) and Congalton and Green (2019), were calculated according to the matrix adapted from Richards (1993).

5.3.7 Results and discussion

5.3.7.1 Deforestation detection

This allows for a better understanding and visualization of the behavior of changes in land use and land cover. This technique helps to discriminate vegetal cover with distinct spectrotemporal behavior, such as agriculture, pasture and forest cover.

The application of time series using the NDVI allowed the estimation of the deforestation dates for all the detected polygons, considering the lowest minimum NDVI value in the time series among all available images for 2023.

In 2023, 2,859 validated deforestation polygons were detected, with the highest concentrations in the Southeast, Central East, and Central South mesoregions (Figure 26).

FIGURE 26 – DEFORESTATION OCCURRENCE DENSITY MAPPING, YEAR 2023

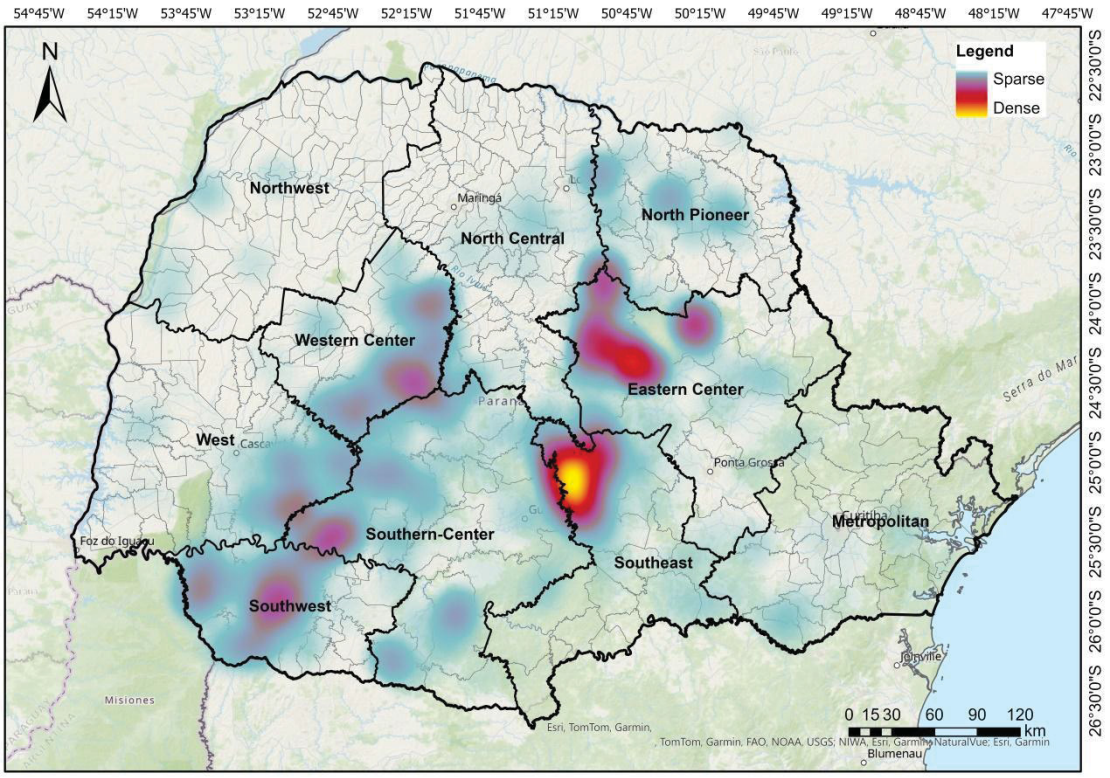

SOURCE: The author (2025).

This corroborates the results obtained for MapBiomas report in Atlantic forest for the year 2023. According to the report generated, the state of Paraná registered the highest rate of deforestation in 2020, which corresponds to 4.349,6 ha (3%), followed by Mato Grosso, representing almost 45% and 16% of total forest loss. The mean distribution of deforestation alerts issued by MapBiomas in 2023 indicates that the highest concentration, with almost 30% of alerts, is located the in South-Central, Southeast, Central-East and Metropolitan mesoregions (Figure 27).

FIGURE 27 – DEFORESTATION DETECTIONS IDENTIFIED IN THE SOUTH-CENTER MESOREGION OF PARANÁ IN 2023

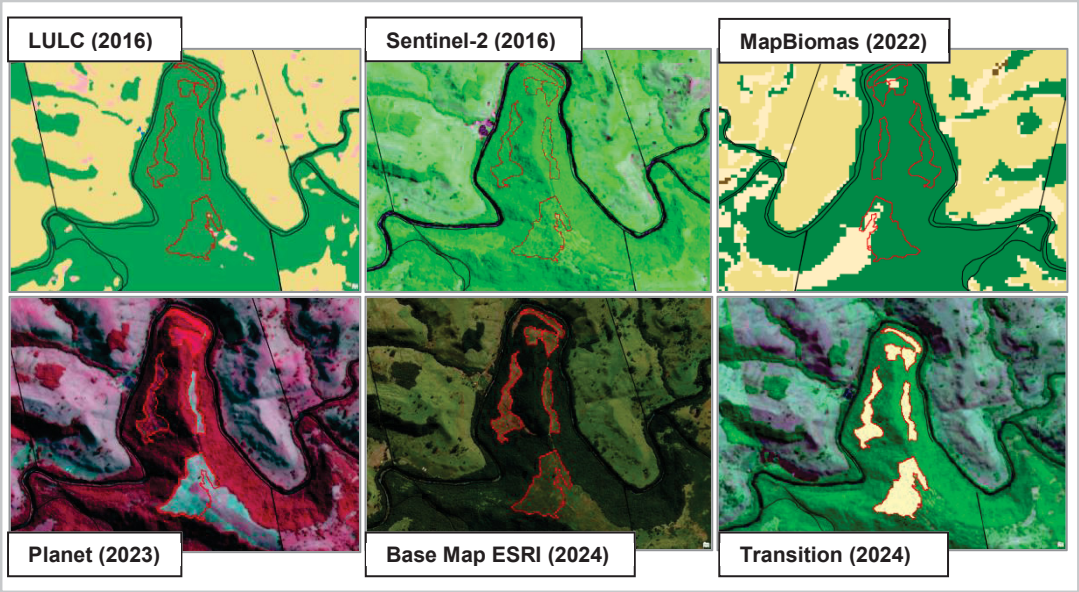

SOURCE: The author (2025).

Deforestation is a critical environmental issue that has garnered significant attention due to its profound impacts on biodiversity, climate change, and ecosystem services. The advent of satellite imagery, particularly from the Sentinel-2 mission, combined with advanced machine learning techniques, has revolutionized the monitoring and detection of deforestation. Sentinel-2, making it a valuable tool for tracking land covers changes over time (Maheswara and Nurwatik, 2024).

Recent studies have demonstrated the efficacy of machine learning algorithms in analyzing Sentinel-2 imagery for deforestation detection. For instance, Alshehri et al. employed a deep learning approach using a transformer-based network to detect deforestation in the Brazilian Amazon, achieving significant improvements in accuracy compared to traditional methods (Alshehri et al. 2024). Similarly, Maheswara and Nurwatik utilized various machine learning algorithms, including Support Vector Machines (SVM), Random Forest, and Convolutional Neural Networks (CNN), to assess forest cover changes in Malang Regency, Indonésia, highlighting the versatility of machine learning in processing Sentinel-2 data

(Maheswara and Nurwatik, 2024). The integration of these algorithms allows for more precise identification of deforested areas, facilitating timely interventions and policy-making.

It is possible to observe that the Federal Private Native Heritage Reserve (PNHR) base had the highest number of detections, 69, followed by Indigenous Lands, with 62 detections. The Federal Conservational Units (FCU) had no evidence of native forests being removed within their boundaries in 2023 (Table 17).

TABLE 17 – QUANTITIES FOR DEFORESTATION BY CU, PNHR AND INDIGENOUS LANDS (IL), STATE OF PARANÁ

	Detections (%)	**Area (ha)**
State and Federal IL	62 (2.17%)	46.1
State CU	45 (1.57%)	49.2
Federal CU	0 (0.00%)	0.0
State PNHR	6 (0.21%)	0.41
Federal PNHR	69 (2.41%)	108.0

SOURCE: The author (2025).

The challenges posed by cloud cover in tropical regions have also been addressed through innovative methodologies. Research by Flores-Anderson et al. emphasized the importance of high-density optical time series data for monitoring deforestation, noting that cloud cover can hinder the effectiveness of satellite observations (Flores-Anderson et al. 2023).

Techniques such as Change Vector Analysis, as demonstrated by Perbet et al., have been employed to improve near-real-time operational deforestation detection by integrating data from multiple sensors, including Sentinel-1 and Sentinel-2 (Perbet et al. 2019). This multi-sensor approach enhances the robustness of deforestation monitoring, particularly in areas with frequent cloud cover.

5.3.7.2 Transition and intensity of impact

The largest transition in area was the conversion of fragments in the advanced stage of the forest to agriculture, which corresponds to 57.10%, followed by the pasture class with 21.04%. The transition from the initial forest stage was 9.96% for

the agricultural class and 4.32% for the pasture class. The advanced medium stage had the lowest transition in area, which corresponded to a 6.55% transition to the agriculture class and 0.76% for the urban area class.

With regard to the intensity of environmental impact on land use degradation, it was found that 1.867 (65.30%) polygons were classified as having a high intensity impact on degradation, which indicates that forest removal left the bare land (exposed soil), without any type of vegetation cover. This occurred because of the forest removal process used. A total of 805 (28.16%) polygons were classified as medium intensity of degradation and 187 (6.54%) were classified as having a low intensity of degradation (Figure 28).

FIGURE 28 – TRANSITION FROM NATIVE FOREST STAGES TO OTHER LAND USE AND COVER CLASSES, YEAR 2016 TO 2024

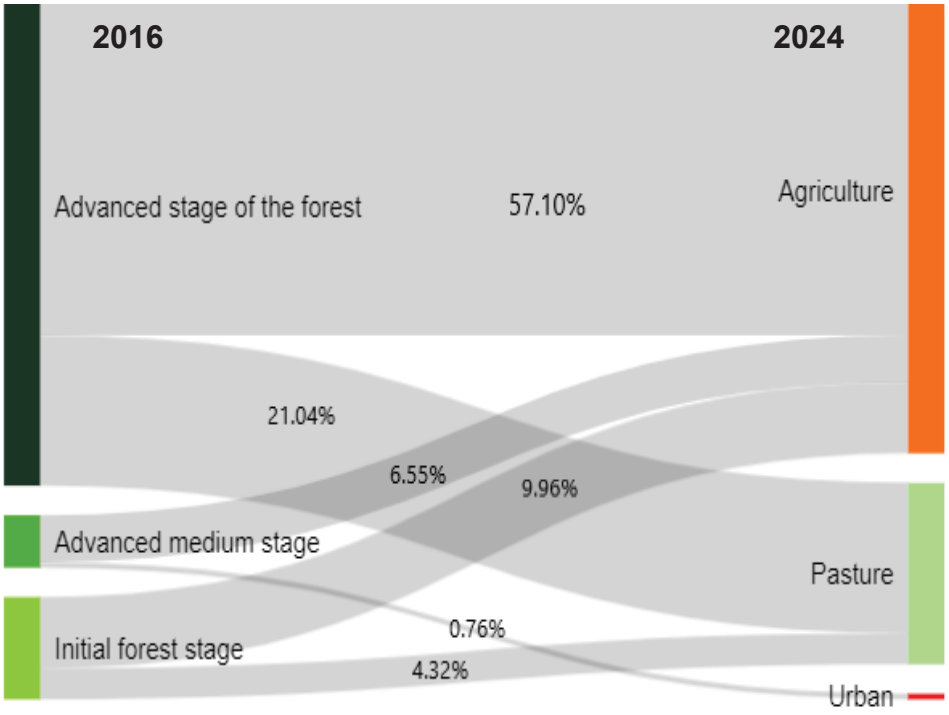

SOURCE: The author (2025).

5.3.7.3 Estimating deforestation dates

To define the date of the image, the minimum NDVI value of the central pixel (Centroid) of each identified polygon was used. The application of time series using the NDVI allowed the estimation of the deforestation dates for all the detected polygons, considering the lowest minimum NDVI value in the time series among all available images for 2023 (Figure 29 and 30).

FIGURE 29 – COMPOSITION OF MINIMUM NDVI TIME SERIES VALUES USED TO ESTIMATE DEFORESTATION DATE IN DETECTIONS IN THE NORTHWESTERN MESOREGION OF PARANÁ

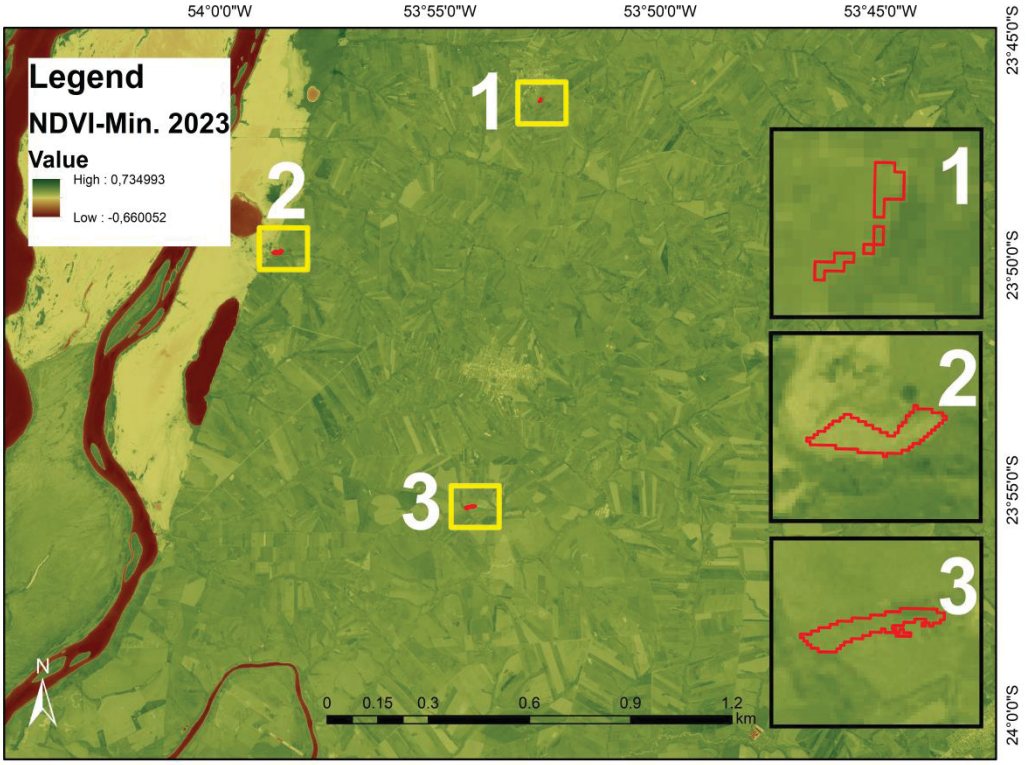

SOURCE: The author (2025).

FIGURE 30 – MINIMUM NDVI TIME SERIES WITH SENTINEL-2 FOR ESTIMATING DEFORESTATION DETECTION DATES IN GEE

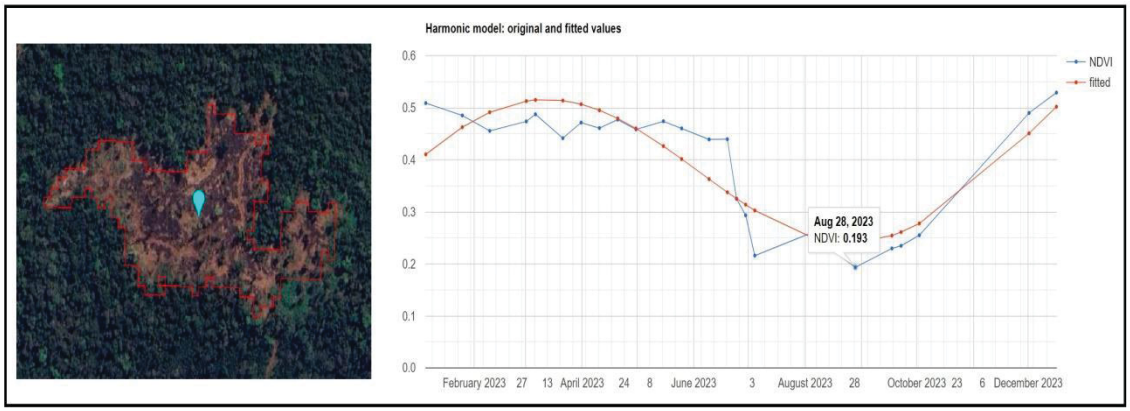

SOURCE: The author (2025).

5.3.7.4 Cross-referencing data RER

By cross-referencing RER data, it was possible to categorize which fiscal module was responsible for the highest number of deforestation detections and also to know which property is responsible based on the registration number (Table 18).

TABLE 18 – DETECTION QUANTITIES BY FISCAL MODULES

Fiscal modules	**Detections**
Small Property	997 (68.95%)
Medium Property	249 (17.22%)
Large Property	200 (13.83%)

SOURCE: The author (2025).

5.3.7.5 Deforestation validation

A OA of 97.5% and KI of 0,84 was obtained, and the Omission Errors (OE%) and Inclusion Errors (IE%) values obtained for the deforestation classes were 0.8% and 0.7%, respectively. These low error rates indicate the efficiency of the developed method in relation to the identification of native forest removal (Table 19).

TABLE 19 – CONFUSION MATRIX BETWEEN MAPBIOMAS/PLANET/SENTINEL-2 AND DEFORESTATION DATA

Classes	Deforestated	Not-deforested	Total	IE (%)	CCP (%)	Precision	Recall	F1-score
Deforestated	**2,859**	42	2,901	1.46	98.5	0.98	0,98	0,98
Not deforested	41	**243**	284	16.9	85.6	0,85	0,85	0,85
Total	2,900	285	3,185					
OE (%)	1.43	17.2						

SOURCE: The author (2025).

Similar results were obtained by Pascagaza et al. 2022 who developed a near real-time change detection system using Sentinel-2 and machine learning for tropical forests in Mexico and Colombia, starting from a mapped forest base and calibrating the model using training samples of different land cover changes. Planet Scope data with visual interpretation was used to validate the results and the overall accuracy was 92.5% (Table 18).

The integration of Sentinel-2 satellite imagery and machine learning techniques represents a significant advancement in the field of deforestation monitoring. The ability to analyze high-resolution data in near real-time allows for improved detection of deforestation events, facilitating timely conservation efforts. As technology continues to evolve, the potential for more sophisticated models and algorithms will likely enhance our understanding and management of forest ecosystems.

5.17 CONCLUSIONS

The Atlantic Forest Biome has a diversity of tree species and other plant species; therefore, it is not considered a homogeneous forest. The proposed methodology provides a procedure for faster and more accurate forest monitoring.

The detection system developed in this study aims to identify every loss of native forest that can be detected in Sentinel-2 images and validated with Planet

satellite images. The mesoregions located in the north of the state had few detections, as they have a smaller proportion of forest fragments in the area.

No assessment had been made regarding the legality, responsibility, and/or restrictions of the deforestation alerts validated. This assessment is the exclusive responsibility of public agencies and private and financial institutions.

The largest area of forest remains is in the Mixed Ombrophilous Forest Formation, the phytogeographic region with the least protection, represented by the Full Protection Conservation Units in Paraná (0.99%). This formation is home to the largest concentration of forest remnants, with great deforestation pressure in the region, making it clear that there is a need for conservation efforts and immediate actions to promote preservation in this phytophysiognomy.

Of the three forest formations, the Semideciduous Seasonal Forest had the lowest incidence of remnants due to the strong anthropogenic action, and loss of habitat, and intense fragmentation.

The semi-deciduous forest formation has low land use suitability and there are not many forest fragments left, which results in less pressure from deforestation when compared to the other forest formations with more significant areas and fragments.

5.3.8 Acknowledgment

The authors are grateful to the Technology System and Environmental Monitoring of Paraná (SIMEPAR), for making the precipitation data available from the meteorological stations.

5.3.9 References

Alshehri, M., Ouadou, A., Scott, G. J. 2024. Deep Transformer-Based Network Deforestation Detection in the Brazilian Amazon Using Sentinel-2 Imagery. IEEE Geoscience and Remote Sensing Letters, 21, 1–5. doi: 10.1109/LGRS.2024.3355104

Aparecido, L.E.O., Rolim, G.S., Richetti, J., Souza, P.S., Johann, J.A., 2016.

Koppen, Thornthwaite and Camargo climate classifications for climatic zoning in the State of Paraná, Brazil. Ciência e Agrotecnologia (SciELO) 40, 405–417. doi:10.1590/1413-70542016404003916.

Bradshaw, C., Sodhi, N., Brook, B., 2009. Tropical turmoil: A biodiversity tragedy in progress. Frontiers in Ecology and the Environment 7, 79–87. doi:10.1890/070193.

Carneiro, R.A., Coutinho, L.S. 2018. Ponderações sobre o CAR – Cadastro Ambiental Rural e sua efetividade. Revista Jurídica Direito Sociedade e justiça 4, n. 5, p. 141-153.

Caviglione, J.H., Kiihl, L.R.B., Caramori, P.H., de Oliveira, D., Galdino, J., Borrozino, E., Giacomini, C.C., Sonomura, M. G. Y., Pugsley, L. 2000. Cartas climáticas do Paraná. Instituto de Desenvolvimento Rural do Paraná (IAPAR).

Cechim Junior, C., Araki, H., Macedo, R.C., 2023. Object-Based Image Analysis (OBIA) and Machine Learning (ML) applied to tropical forest mapping using Sentinel-2. Canadian Journal of Remote Sensing 49, 2259504. doi:10.1080/07038992.2023.2259504.

Chazdon, R., 2013. Tropical Forest Regeneration. pp. 277–286. doi:10.1016/B978-0-12-384719-5.00377-4.

Congalton, R.G., 1991. A review of assessing the accuracy of classifications of remotely sensed data. Remote Sensing of Environment (Elsevier) 37, 35–46. doi:10.1016/0034-4257(91)90048-B.

CONAMA. Conselho Nacional do Meio Ambiente. Resolução n. 1, de 31 de janeiro de 1994. Diário Oficial da República Federativa do Brasil, Brasília, DF. 1994.

Congalton, R.G., Green, K., 2019. Assessing the accuracy of remotely sensed data: principles and practices. 3st ed., CRC press. doi:10.1201/9780429052729.

Coppin, P., Jonckheere, I., Nackaerts, K., Muys, B., Lambin, E., 2004. Review article digital change detection methods in ecosystem monitoring: a review. International Journal of Remote Sensing 25, 1565–1596. doi:10.1080/0143116031000101675.

Diniz, C.G., Souza, A.A.d.A., Santos, D.C., Dias, M.C., Luz, N.C.d., Moraes, D.R.V.d., Maia, J.S., Gomes, A.R., Narvaes, I.d.S., Valeriano, D.M., Maurano, L.E.P., Adami, M., 2015. Deter-b: The new Amazon near real-time deforestation detection system. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 8, 3619–3628. doi:10.1109/JSTARS.2015.2437075.

Doblas, J., Reis, M.S., Belluzzo, A.P., Quadros, C.B., Moraes, D.R.V., Almeida, C.A., Maurano, L.E.P., Carvalho, A.F.A., Sant'Anna, S.J.S., Shimabukuro, Y.E., 2022. Deter-r: An operational near-real time tropical forest disturbance warning system based on Sentinel-1 time series analysis. Remote Sensing 14. doi:10.3390/rs14153658.

Flores-Anderson, A., Cardille, J.A., Azad, K., Cherrington, E. A., Zhang, Y., Wilson, S. 2023. Spatial and Temporal Availability of Cloud-Free Optical Observations in the Tropics to Monitor Deforestation. Scientific Data, 10 (1). https://doi.org/10.1038/s41597-023-02439-x. 673

Galidaki, G., Zianis, D., Gitas, I., Radoglou, K., Karathanassi, V., Tsakiri–Strati, M., Woodhouse, I., Mallinis, G., 2017. Vegetation biomass estimation with remote sensing: focus on forest and other wooded land over the mediterranean ecosystem. International Journal of Remote Sensing 38, 1940–1966. doi:10.1080/01431161.2016.1266113.

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., Moore, R., 2017. Google Earth Engine: Planetary-scale geospatial analysis for everyone. Remote Sensing of Environment 202, 18–27. doi:10.1016/j.rse.2017.06.031.

Hansen, M.C., Krylov, A., Tyukavina, A., Potapov, P.V., Turubanova, S., Zutta, B., Ifo, S., Margono, B., Stolle, F., Moore, R., 2016. Humid tropical forest disturbance alerts using Landsat data. Environmental Research Letters 11, 034008. doi:10.1088/1748-9326/11/3/034008.

Hu, Y., Xu, X., Wu, F., Sun, Z., Xia, H., Meng, Q., Huang, W., Zhou, H., Gao, J., Li, W., Peng, D., Xiao, X., 2020. Estimating forest stock volume in Hunan province, China, by integrating in situ plot data, Sentinel-2 images, and linear and Machine Learning regression models. Remote Sensing 12. doi:10.3390/rs12010186.

IBGE, 2022. Monitoramento da cobertura e uso da terra do Brasil: 2018/2020, IBGE, Coordenação de Meio Ambiente. Instituto Brasileiro de Geografia e

Estatística - IBGE.

Johnson, B.A., Umemiya, C., Magcale-Macandog, D.B., Estoque, R.C., Hayashi, M., Tadono, T., 2023. Better monitoring of forests according to FAOs definitions through map integration: Significance and limitations in the context of global environmental goals. International Journal of Applied Earth Observation and Geoinformation 122, 103452. doi:https://doi.org/10.1016/j.jag.2023.103452.

Jung, S., Rasmussen, L.V., Watkins, C., Newton, P., Agrawal, A., 2017. Brazil's national environmental registry of rural properties: Implications for livelihoods. Ecological Economics 136, 53–61. doi:https://doi.org/10.1016/j.ecolecon.2017.02.004.

Kalinaki, K., Malik, O.A., Ching Lai, D.T., 2023. Fcd-attresu-net: An improved forest change detection in Sentinel-2 satellite images using attention residual U-net. International Journal of Applied Earth Observation and Geoinformation 122, 103453. doi:10.1016/j.jag.2023.103453.

Laso, F.J., Benıtez, F.L., Rivas-Torres, G., Sampedro, C., Arce-Nazario, J., 2020. Land cover classification of complex agroecosystems in the non-protected highlands of the Galapagos islands. Remote Sensing 12. doi:10.3390/rs12010065.

Laudares, S., da Silva, K., Borges, L., 2014. Cadastro Ambiental Rural: Uma análise da nova ferramenta para regularização ambiental no brasil. Desenvolvimento e Meio Ambiente 31. doi:10.5380/dma.v31i0.33743.

Laurance, W., Useche, D., Rendeiro, J., Kalka, M., Bradshaw, C., Sloan, S., Laurance, S., Campbell, M., Abernethy, K., Alvarez-Loayza, P., Arroyo-Rodr´ıguez, V., Ashton, P., Ben´ıtez, J., Blom, A., Bobo, K., Cannon, C., Cao, M., Carroll, R., Chapman, C., Zamzani, F., 2012. Averting biodiversity collapse in tropical forest protected areas. Nature 489, 290–4. doi:10.1038/nature11318.

Maheswara, S.D.A., Nurwatik, N. Using Sentinel-2 Imagery and Machine Learning Algorithms to Estimate Deforestation (Case Study: A District in Malang Regency). IOP Conference Series Earth and Environmental Science, 2024, 1418 (1), 012008–012008. doi:10.1088/1755-1315/1418/1/012008

Morris, R.J., 2010. Anthropogenic impacts on tropical forest biodiversity: a network structure and ecosystem functioning perspective. Philosophical Transac-

tions of the Royal Society, 3709–18. doi:10.1098/rstb.2010.0273.

Myroniuk, V., Kutia, M., J. Sarkissian, A., Bilous, A., Liu, S., 2020. Regional-scale forest mapping over fragmented landscapes using global forest products and Landsat time series classification. Remote Sensing 12. doi:10.3390/rs12010187.

Nobre, C.A., Sampaio, G., Borma, L.S., C., C.R.J., Silva, J.S., M., C., 2016. Land-use and climate change risks in the amazon and the need of a novel sustainable development paradigm. Proc. Natl. Acad. Sci. USA doi:10.1073/pnas.1605516113.

Ortega Adarme, M., Doblas Prieto, J., Queiroz Feitosa, R., De Almeida, C.A., 2022. Improving deforestation detection on tropical rainforests using Sentinel-1 data and convolutional neural networks. Remote Sensing 14. doi:10.3390/rs14143290.

Pacheco-Pascagaza, A.M., Gou, Y., Louis, V., Roberts, J.F., Rodríguez-Veiga, P., da Conceição Bispo, P., Espírito-Santo, F.D.B., Robb, C., Upton, C., Galindo, G., Cabrera, E., Pachón Cendales, I.P., Castillo Santiago, M.A., Carrillo Negrete, O., Meneses, C., Iniguez, M., Balzter, H., 2022. Near real-time change detection system using Sentinel-2 and machine learning: A test for Mexican and Colombian forests. Remote Sensing 14. doi:10.3390/rs14030707.

Pan, Y., Birdsey, R., Phillips, O., Jackson, R., 2013. The structure, distribution, and biomass of the world's forests. Annual Review of Ecology Evolution and Systematics , 593–622.doi:10.1146/annurev-ecolsys-110512-135914.

Pimm, S., Raven, P., 2000. Biodiversity - extinction by numbers. Nature 403, 843–5. doi:10.1038/35002708.

Perbet, P., Fortin, M., Ville, A., Béland, M. Near Real-Time Deforestation Detection in Malaysia and Indonesia Using Change Vector Analysis with Three Sensors. International Journal of Remote Sensing 2019, 40 (19), 7439–7458. doi:10.1080/01431161.2019.1579390

Purwanto, A.D., Wikantika, K., Deliar, A., Darmawan, S., Harto, A.B., Khomarudin, M.R., Ardli, E.R., 2024. Improving the accuracy of mangrove forest mapping using Sentinel image and developed classification algorithm based on Machine Learning. Journal of Spatial Science 0, 1–27.

doi:10.1080/14498596.2024.2337747.

Roitman, I., Vieira, L., Vieira, G., Khan, T., Jacobson, B., Bustamante, M., Silva Marcondes, N.J., Cury, K., Estevam, L., Ribeiro, R., Ribeiro, V., Stabile, M., Miranda Filho, R.J., Avila, M., 2018. Rural environmental registry: An innovative model for land-use and environmental policies. Land Use Policy 76. doi:10.1016/j.landusepol.2018.04.037.

Sano, E.E., Rizzoli, P., Koyama, C.N., Watanabe, M., Adami, M., Shimabukuro, Y.E., Bayma, G., Freitas, D.M., 2021. Comparative analysis of the global forest/non-forest maps derived from SAR and optical sensors. Case studies from brazilian amazon and cerrado biomes. Remote Sensing 13. doi:10.3390/rs13030367.

Singh, S., S.K.D.S.N., Bohra, D.N., 1990. Temporal change detectionin uplands and gullied areas through satellite remote-sensing. Annals of Arid Zone 29,171–177.

Slagter, B., Reiche, J., Marcos, D., Mullissa, A., Lossou, E., Peña-Claros, M., Herold, M., 2023. Monitoring direct drivers of small-scale tropical forest disturbance in near real-time with Sentinel-1 and -2 data. Remote Sensing of Environment. doi:10.1016/j.rse.2023.113655.

Solorzano, J.V., Mas, J.F.; Gallardo-Cruz, J.A., Gao, Y., Fernández-Montes de Oca, A., 2023. Deforestation detection using a spatio-temporal deep learning approach with synthetic aperture radar and multispectral images. ISPRS Journal of Photogrammetry and Remote Sensing 199, 87–101. doi:10.1016/j.isprsjprs.2023.03.017.

Souza, C. M., Z. Shimbo, J., Rosa, M. R., Parente, L. L., A. Alencar, A., Rudorff, B. F. T., Hasenack, H.; Matsumoto, M., G. Ferreira, L., Souza-Filho, P. W. M., Oliveira, S. W., Rocha, W. F., Fonseca, A. V.; Marques, C. B., Diniz, C. G., Costa, D., Monteiro, D., Rosa, E. R., Vélez-Martin, E., Weber, E. J., Lenti, F. E. B., Paternost, F. F., Pareyn, F. G. C., Siqueira, J. V., Viera, J. L., Neto, L. C. F., Saraiva, M. M., Sales, M. H., Salgado, M. P. G., Vasconcelos, R., Galano, S., Mesquita, V. V., Azevedo, T. 2020. Reconstructing three decades of land use and land cover changes in brazilian biomes with Landsat archive and Earth Engine. Remote Sensing 12. doi:10.3390/rs12172735.

Souza-Filho, P.W.M., de Souza, E. B., Silva Júnior, R.O., Nascimento, W.R., Versiani de Mendonça, B.R., Guimarães, J.T.F., Dall'Agnol, R., Siqueira, J.O., 2016. Four

decades of land-cover, land-use and hydroclimatology changes in the Itacaiúnas river watershed, southeastern Amazon. Journal of Environmental Management 167, 175–184. https://doi.org/10.1016/j.jenvman.2015.11.039.

Spawn, Seth A., Sullivan, C.C.T.J.G.H.K., 2020. Harmonized global maps of above and belowground biomass carbon density in the year 2010. Scientific Data 7. doi:10.1038/s41597-020-0444-4.

Sugimoto, R., Kato, S., Nakamura, R., Tsutsumi, C., Yamaguchi, Y., 2022. Deforestation detection using scattering power decomposition and optimal averaging of volume scattering power in tropical rainforest regions. Remote Sensing of Environment 275, 113018. doi:10.1016/j.rse.2022.113018.

Torres, D.L., Turnes, J.N., Soto Vega, P.J., Feitosa, R.Q., Silva, D.E., Marcato Junior, J., Almeida, C., 2021. Deforestation detection with fully convolutional networks in the Amazon forest from Landsat-8 and Sentinel-2 images. Remote Sensing 13. doi:10.3390/rs13245084.

Verbesselt, J., Hyndman, R., Newnham, G., Culvenor, D., 2010. Detecting trend and seasonal changes in satellite image time series. Remote Sensing of Environment 114, 106–115. doi:10.1016/j.rse.2009.08.014.

Zhang, Y., Ling, F., Wang, X., Foody, G.M., Boyd, D.S., Li, X., Du, Y., Atkinson, P.M., 2021. Tracking small-scale tropical forest disturbances: Fusing the Landsat and Sentinel-2 data record. Remote Sensing of Environment 261, 112470. doi:10.1016/j.rse.2021.112470.

6 DISCUSÃO

Na Abordagem 1 foi utilizado classificação supervisionada OBIA com correção topológica de fragmentos importaos no GEE para mapeamento florestal no Paraná. Foi obtido IK de 0,87 e EG de 91,05% para a classe de floresta nativa. Para as outras classes foi observado que a confusão espectral ocorreu principalmente entre floresta nativa e silvicultura, e entre pastagem e agricultura.

Foram comparados algoritmos de aprendizado de máquina, como Random Forest (RF) que apresentando melhor desempenho. A Acurácia final melhorou com nova amostragem e uso de RF, atingindo excelente qualidade temática (Kappa entre 0,80 e 1,00).

Resultados comparáveis a outros estudos, como MapBiomas (91,4% de acurácia) e mapeamentos na França e Gabão (acurácias >92%). Erros de omissão (5,4%) e inclusão (6,4%) foram menores que estudos anteriores.

A Descordancia global mostrou maior contribuição do componente de alocação (2,0%) do que a componente quantidade (0,1%). Forte correlação (r_s 0,99) foi obtida comparando as estimativas de área com mapeamentos do MapBiomas e IAT.

A figura 31 representa a diferença entre os métodos para geração de mosaicos e índices espectrais utilizados para a classificação supervisionada por OBIA e ML em 2016.

FIGURA 31 – GERAÇÃO DE MOSAICOS E ÍNDICES ESPECTRAIS, IMAGENS SENTINEL-2

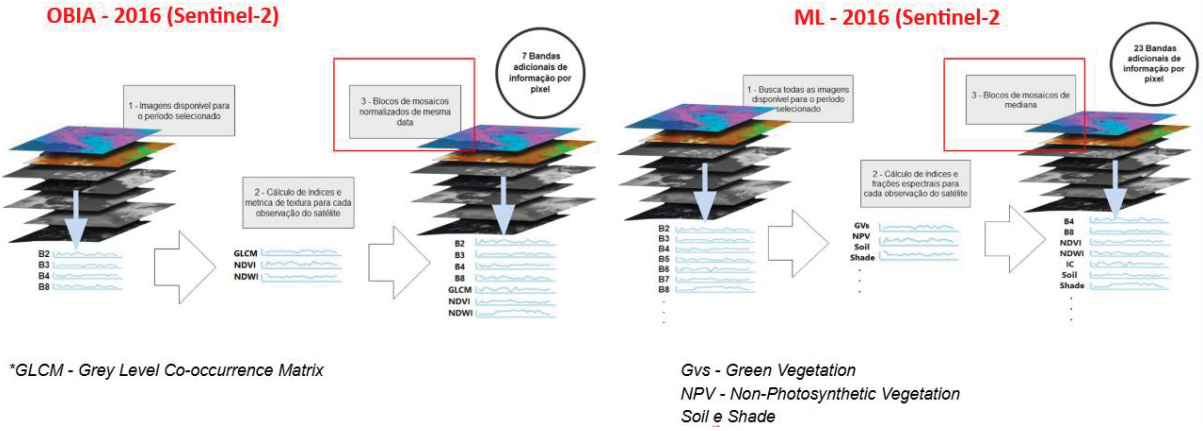

A Abordagem 2, focou na detecção de desmatamento usando séries temporais de NDVI de imagens Sentinel-2. Foram detectados 2.859 areas de desmatamento validados em 2023, concentrados nas mesorregiões Sudeste, Centro-Leste e Centro-Sul do Parana. O que corrobora com relatório do MapBiomas para a Mata Atlântica em 2023. Maior concentração de alertas (30%) nas mesorregiões Centro-Sul, Sudeste, Centro-Leste e Metropolitana.

Integrou algoritmos de aprendizado de máquina para identificação precisa de áreas desmatadas. A maior transição foi de floresta estagio avançada para agricultura (57,10%) e pastagem (21,04%). 65,30% das areas detectadas foram classificados com alto impacto de degradação. Maior período desmatamento detectado foi em junho de 2023 (6,58% das detecções).

Foi obtido EG de 97,5% e Kappa de 0,84 na detecção de desmatamento, Erros de omissão (0,8%) e inclusão (0,7%) muito baixos, indicando eficiência do método. Ambas as abordagens demonstraram alta acurácia e eficácia no mapeamento e monitoramento florestal, utilizando técnicas avançadas de sensoriamento remoto e aprendizado de máquina.

Uma plataforma web foi gerada para visualizar as areas de desmatamento, para isto foi utilizando o pluguin Qgis2Web, o link de acesso esta disponível em:

https://github.com/Cechim/Desforestation, pode ser usada para visualização e consulta de imóveis rurais com desflorestamentos (Figura 32).

FIGURA 32 – PLATAFORMA WEB PARA VISUALIZAÇÃO DE DESFLORESTAMENTOS IDENTIFICADOS EM IMÓVEIS DO CAR

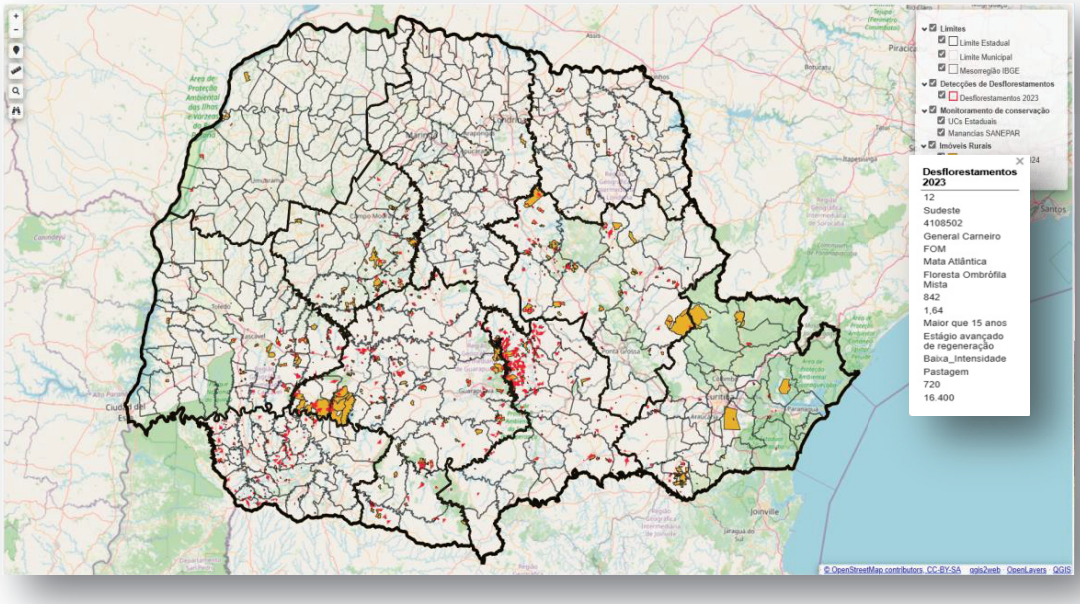

A metodologia desenvolvida possibilitou a detecção de desflorestamento de áreas mínimas de até 100 m², o que possibilita um monitoramento mais detalhado e eficaz das florestas naturais. Isso é crucial para a identificação de atividades ilegais de desmatamento e para a implementação de ações corretivas.

A pesquisa fornece dados consistentes sobre a cobertura florestal, que são essenciais para o Ministério Público (MP) e órgãos ambientais. Esses dados podem ser utilizados para a elaboração de relatórios e laudos que indiquem os municípios e imóveis rurais com desflorestamento, contribuindo para a fiscalização e a aplicação da legislação ambiental.

Os resultados da pesquisa podem servir como base para a formulação de políticas públicas voltadas à conservação das florestas. A identificação de áreas

críticas e a quantificação de remanescentes florestais podem auxiliar na priorização de esforços de conservação e na alocação de recursos.

A metodologia pode ser utilizada por gestores e planejadores territoriais para identificar áreas propensas a desmatamento e para promover práticas de manejo sustentável. Isso é especialmente relevante em um contexto de crescente pressão sobre os recursos florestais.

A tese também contribui para o avanço do conhecimento técnico sobre mapeamento de florestas naturais e detecção de desflorestamento, podendo servir de referência para futuras pesquisas na área. A abordagem híbrida de classificação supervisionada e a utilização de imagens de satélites gratuitos podem ser replicadas em outras regiões e contextos.

A informação gerada pela pesquisa permitiu estimar a área excedente de floresta nativa, que pode ser utilizada como compensação ambiental em propriedades rurais que estejam em déficit, conforme a legislação vigente.

Essas implicações práticas demonstram a relevância da pesquisa não apenas para a área acadêmica, mas também para a sociedade e para a gestão ambiental no estado do Paraná, promovendo um uso mais sustentável dos recursos florestais e contribuindo para a conservação da biodiversidade.

Os resultados obtidos nesta pesquisa sobre o mapeamento de floresta nativa tropical e a detecção de desflorestamento no estado do Paraná revela a eficácia da metodologia proposta, que combina sensoriamento remoto com imagens do satélite Sentinel-2 e técnicas de aprendizado de máquina. A pesquisa não apenas alcançou altos índices de acurácia na detecção de desflorestamento, mas também forneceu uma base sólida para a geração de dados consistentes sobre a cobertura florestal, essenciais para a formulação de políticas públicas e ações de conservação ambiental.

Os resultados demonstraram que a análise harmônica e a transformação de espaço de cor HSV, foram eficazes na identificação de perdas florestais, permitindo um monitoramento detalhado das mudanças na cobertura do solo. A utilização do

GEE facilitou o processamento de grandes volumes de dados, o que é crucial para a análise em larga escala, considerando a extensão territorial do estado do Paraná.

Além disso, a pesquisa identificou a necessidade de estudos futuros, como o mapeamento e monitoramento de áreas de regeneração florestal, que não foram abordados nesta investigação. Isso indica que, embora a metodologia tenha sido bem-sucedida, há espaço para aprimoramentos e novas abordagens que possam contribuir ainda mais para a conservação das florestas naturais.

Em suma, esta tese não apenas contribui para o conhecimento acadêmico na área de sensoriamento remoto e conservação ambiental, mas também oferece ferramentas práticas para a gestão e proteção das florestas nativas no Paraná, destacando a importância de um monitoramento contínuo e preciso das mudanças ambientais. A implementação das recomendações e a continuidade das pesquisas são fundamentais para garantir o desenvolvimento sustentável e a preservação dos ecossistemas florestais na região.

7 CONCLUSÕES

Este estudo investigou a dinâmica do desflorestamto de floresta nativa no estado do Paraná usando sensoriamento remoto, combinando técnicas de aprendizado de máquina e dados cadastrais. A pesquisa buscou atingir três objetivos específicos: (a) mapear a floresta nativa utilizando Análise de Imagens Baseada em Objetos e Machine Learning; (b) determinar as datas de desmatamento usando a análise de séries temporais do Índice de Vegetação por Diferença Normalizada e validar as áreas de desmatamento identificadas; e (c) caracterizar a dinâmica do desflorestamento e localizar as propriedades com desflorestamento utilizando o banco de dados do Cadastro Ambiental Rural.

Em relação ao primeiro objetivo, os resultados demonstram que o uso combinado de OBIA e ML proporcionou um mapeamento preciso da floresta nativa, delineando efetivamente os limites da floresta e identificando áreas fragmentadas.

Isso se alinha com as descobertas de (Obata *et al*., 2020), que enfatiza a aplicação de metodologias robustas para mapeamentos florestais. O estudo aproveitou a eficiência e os benefícios da OBIA para segmentar imagens em objetos significativos e ML para classificar esses objetos com base em suas características espectrais e espaciais.

Para o segundo objetivo, a análise das séries temporais do NDVI permitiu identificar as datas de desflorestamentos. Essa abordagem se mostrou valiosa na captura de mudanças sutis na cobertura vegetal ao longo do tempo, permitindo a detecção precisa de eventos de desmatamento. O processo de validação, conduzido por meio de [descreva seus métodos de validação - por exemplo, observações de campo, comparação com imagens de alta resolução], confirmou a confiabilidade das datas de desmatamento obtidas por meio da análise NDVI. Isso é particularmente importante no contexto do monitoramento, conforme demonstrado pela pesquisa sobre avaliação da degradação florestal usando *Light Detection And Ranging* (LiDAR) e imagens hiperespectrais (Almeida *et al*., 2024).

Finalmente, a integração do banco de dados do CAR e SIGEF/INCRA forneceu um contexto espacial crucial para entender a dinâmica do desflorestamento. Isso permitiu a localização precisa do imovel que sofreu supressão de floresta nativa e facilitou a análise dos padrões de desflorestamento dentro dos limites das propriedades rurais. Vinculação de dados de sensoriamento remoto com informações cadastrais, conforme destacado em vários estudos (Hainosz *et al*., 2018; Paiva *et al*., 2018), é crucial para o desenvolvimento de estratégias eficazes de gestão da terra. Ao associar eventos de desmatamento a propriedades específicas, essa abordagem permite intervenções direcionadas e promove a responsabilidade na gestão ambiental.

A metodologia proposta considerando a junção dos métodos de classificação supervisionada por OBIA e ML utilizando SMA, foi eficaz para o mapeamento de floresta nativa no bioma de mata atlântica que e tem grande diversidade de espécies arbóreas, também foi possível a separação de plantio florestal de forma eficiente, esta metodologia podendo ser utilizada para realização de estimativas de áreas de

floresta nativa em escala municipal. E é uma solução tecnológica rápida e eficiente de baixo custo, que pode ser utilizada por órgãos ambientais oficiais e de gestão ambiental do Paraná, este método também pode ser replicado para qualquer área de estudo.

A metodologia proposta de análise harmônica associada à transformação de espaço de cor RGB e HSV para o desenvolvimento do sistema de detecção nesta pesquisa demonstrou ser eficaz para identificar as perdas de floresta que podem ser detectadas utilizando resolução espacial das imagens Sentinel-2. É um método de baixo custo, e devido às grandes extensões territoriais do estado do Paraná, só foi possível processar esta grande quantidade de imagens devido ao fato de aproveitar o alto desempenho de processamento e armazenamento da nuvem do ambiente de processamento GEE.

A formação de floreta ombrófila mista no estado do Paraná abriga a maior concentração de remanescentes florestais, com grande pressão de desmatamento na região, deixando claro que há uma necessidade de esforços de conservação e ações imediatas para promover a preservação neste tipo de fitofisionomia de florestal nativa.

Nesta pesquisa não foi feita qualquer avaliação quanto à legalidade, responsabilidade e/ou restrições dos alertas de desmatamento validados. Esta avaliação é exclusiva da responsabilidade dos órgãos públicos e das instituições privadas e financeiras. Os maiores quantitativos de área de remanescentes florestais estão na Formação Floresta Ombrófila Mista, a região geográfica com menor proteção, representada pela Proteção Integral de Unidades de Conservação do Paraná.

Diante dos resultados alcançados durante o desenvolvimento desta tese, surgiram demandas de pesquisas futuras, como o mapeamento e monitoramento de áreas de regeneração florestal que não foram abordadas nesta pesquisa.

8 RECOMENDAÇÕES FUTURAS

Como recomendações para pesquisas futuras estão sugere-se incorporar técnicas de inteligência artificial, como redes neurais profundas, para aumentar a precisão e a eficiência na automatização da detecção e identificação de desflorestamento de floresta nativa.

Utilizar dados de outros sensores, como imagens de radar, para gerar detecções em areas em períodos com cobertura de nuvens e estações com alta precipitação no estado do Paraná, usar informações socioeconômicas, para entender melhor os fatores que influenciam o desflorestamento e a conservação florestal.

Desenvolver uma metodologia com uso de sensoriamento remoto para acompanhar ganhos de cobertura florestal, (Regeneração florestal), de floresta nativa.

9 REFERÊNCIAS

ADAMS, J.B.; SABOL, D.E.; VALERIEKAPOS, F. R.A.; ROBERTS, D.A. O.; SMITH, M.; and GILLESPIE, A.R. Classification of multispectral images based on fractions of endmembers: Application to land-cover change in the Brazilian Amazon. **Remote Sensing of Environment,** v. 52, n. 7, p. 137-154, 1995. Disponível em: doi:10.1016/00344257(94)00098-8. Acesso em: 23 dez. 2024.

ALMEIDA, C.T.D.; GALVÃO, L.S.; OMETTO, J.P.H.B.; JACON, A.D.; PEREIRA F.R.D.S.; SATO, L.Y.; SILVA-JUNIOR, C.H.L.; BRANCALION, P.H.S.; ARAGÃO, L.E.O. C. Advancing Forest Degradation and Regeneration Assessment Through Light Detection and Ranging and Hyperspectral Imaging Integration. **Remote Sensing**. v.16, n. 21, p.3935, 2024. Disponível em: https://doi.org/10.3390/rs16213935. Acesso em: 20 mar. 2025.

ASOKAN, A.; ANITHA, J. Change detection techniques for remote sensing applications: a survey. **Earth Science Informatics**, Berlim, v. 12, p. 143–160, 2019. Disponível em: https://doi.org/10.1007/s12145-019-00380-5. Acesso em: 23 dez. 2024.

BAATZ, M.; SCHÄPE, A. Multiresolution segmentation – an optimization approach for high quality multiscale image segmentation. In: Strobl, J.; Blaschke, T. (Ed.) **Angewandte Geographische Informations verarbeitung XII**. Beiträge zum AGITSymposium Salzburg. Karlsruhe: Herbert Wichmann Verlag, p.12-23, 2000.

BANKS, S.; MILLARD, K.; BEHNAMIAN, A.; WHITE, L.; ULLMANN, T.; CHARBONNEAU, F.; CHEN, Z.; WANG, H.; PASHER, J.; DUFFE, J. Contributions of Actual and Simulated Satellite SAR Data for Substrate Type Differentiation and Shoreline Mapping in the Canadian Arctic. **Remote Sensing**, Basel, v. 9, n.12, p. 1206-1243, 2017. Disponível em: https://doi.org/10.3390/rs9121206. Acesso em: 23 dez. 2024.

BANNARI, A.; PACHECO, A.; STAENZ, K.; MCNAIRN, H.; OMARI, K. Estimating and mapping crop residues cover on agricultural lands using hyperspectral and ikonos data. **Remote Sensing of Environment**, v. 104, n. 4, p. 447-459, 2006. Disponível em: https://doi:10.1016/j.rse.2006.05.018. Acesso em: 23 dez. 2024.

BERTOLDO, É.; PAISANI, J. C.; OLIVEIRA, P. E.D. Registro de Floresta Ombrófila Mista nas regiões sudoeste e sul do Estado do Paraná, Brasil, durante o

Pleistoceno/Holoceno. **Hoehnea**, v. 41, n. 1, p. 1–8, 2014. Disponível em: https://doi.org/10.1590/S2236-89062014000100001. Acesso em: 13 mar. 2024.

BLASCHKE, T.; STROBL, J. What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. GIS–Zeitschrift für Geoinformationssysteme, v.14, n. 6, p. 12-17, 2001.

BLASCHKE, T. Object based imagem analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, n. 1, p 2-16, 2010. Disponível em: https://doi.org/10.1016/j.isprsjprs.2009.06.004. Acesso em: 21 jan. 2025.

BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5-32, 2001. Disponível em: doi:10.1023/A:1010933404324. Acesso em: 23 dez. 2024.

BREIMAN, L.; FRIEDMAN, J.; OLSHEN, R. A.; STONE C. J. **Classification and Regression Trees**. 1ª ed., New York, Chapman and Hall/CRC, p. 368, 1984. Disponível em: https://doi.org/10.1201/9781315139470. Acesso em: 01 jan. 2025.

BROVELLI, M. A.; SUN, Y.; YORDANOV, V. Monitoring forest change in the amazon using multitemporal remote sensing data and machine learning classification on Google Earth Engine. **ISPRS International Journal of Geo-Information (MDPI)**, v. 9: p. 1-21, 2020. Disponível em: https://doi:10.3390/ijgi9100580. Acesso em: 23 dez. 2024.

BULLOCK, E. L.; WOODCOCK, C. E.; OLOFSSON, P. Monitoring tropical forest degradation using spectral unmixing and Landsat time series analysis. **Remote Sensing of Environment**, Amsterdã, v. 238, 2020. Disponível em: https://doi.org/10.1016/j.rse.2018.11.011. Acesso em: 23 dez. 2024.

BULLOCK, E.; WOODCOCK, C.; OLOFSSON, P. Monitoring tropical forest degradation using spectral unmixing and Landsat time series analysis. **Remote Sensing of Environment**, Amsterdã, v. 238, 2018. Disponível em: https://doi.org/10.1016/j.rse.2018.11.011. Acesso em: 23 dez. 2024.

BURGES, C. J. A tutorial on support vector machines for pattern recognition. **Data Mining and Knowledge Discovery**, v. 2, p. 121-167, 1998. Disponível em: https://doi.org/10.1023/A:1009715923555. Acesso em: 31 dez. 2024.

CALATRAVA, H.; DUVVURI, B.; LI, H.; BORSOI, R.; BEIGHLEY, E.; ERDOGMUS, D.; CLOSAS, P.; IMBIRIBA, T. Recursive classification of satellite imaging time-series: An application to water and land cover mapping. **Electrical Engineering and**

Systems Science, 2024. Disponível em: https://10.48550/arXiv.2301.01796. Acesso em: 31 dez. 2024.

CARAMINAN, L. M.; SANTOS, M. V.; GASPARETTO, N. V.L. Breve levantamento florístico e fitossociológico de um remanescente florestal localizado em área de transição fitogeográfica da floresta estacional semidecidual e ombrófila mista no estado do Paraná. **Geoingá Revista do Programa de Pós-Graduação em Geografia (PGE/UEM)**, v. 15, n. 2, p. 346–369, 2023.

CARAMINAN, L. M.; VICENTE, N. Parâmetros fitossociológicos, florísticos e fitogeográficos de um remanescente da floresta estacional semidecidual no munícipio de Santa Fé, estado do Paraná. **Geoconexões**, v. 1, n. 15, p. 231–252, 2023. Disponível em: https://doi.org/10.15628/geoconexes.2023.14722. Acesso em: 12 mar. 2025.

CESTARO, L. A institucionalização do planejamento no estado do Paraná e os desdobramentos no território. **Risco Revista de Pesquisa em Arquitetura e Urbanismo (Online)**, v. 22, n. 1, 28, 2024. Disponível em: https://doi.org/10.11606/1984-4506.risco.2024.219308. Acesso em: 12 mar. 2025.

CHATZIANTONIOU, A.; PSOMIADIS, E.; PETROPOULOS, G.P. Co-Orbital Sentinel 1 and 2 for LULC Mapping with Emphasis on Wetlands in a Mediterranean Setting Based on Machine Learning. **Remote Sensing**, Amsterdã, v. 9, n. 12, p. 1259-1278, 2017. Disponível em: https://doi.org/10.3390/rs9121259. Acesso em: 23 dez. 2024.

CHEN, S. W.; NARDARI, G.; LEE, E. S.; QU, C.; LIU, X.; ROMERO, R. A. F.; KUMAR, V. SLOAM: Semantic LiDAR Odometry and Mapping for Forest Inventory. **IEEE Robotics and Automation Letters**, Canberra, v. 5, n. 2, p. 612-619, 2020. Disponível em: https://doi.org/10.1109/LRA.2019.2963823. Acesso em: 23 dez. 2024.

CHEN, L.; Ren, C.; ZHANG, B.; WANG, Z.; Xi, Y. Estimation of forest above ground biomass by geographically weighted regression and machine learning with sentinel imagery. **Forests**, v. 9, n. 10, p. 582, 2018. Disponível em: https://doi:10.3390/f9100582. Acesso em: 23 dez. 2024.

CHENG, K.; WANG, J. Forest Type Classification Based on Integrated Spectral-Spatial-Temporal Features and Random Forest Algorithm - A Case Study in the Qinling Mountains. **Forests**, v.10, n. 7, p. 559, 2019. Disponível em: https://doi.org/10.3390/f10070559. Acesso em: 01 jan. 2025.

CHI, J.; KIM, H.-C. Prediction of Arctic Sea Ice Concentration Using a Fully Data Driven Deep Neural Network. **Remote Sensing**, Amsterdã, v. 9, p. 1305-1324, 2017. Disponível em: https://doi.org/10.3390/rs9121305. Acesso em: 23 dez. 2024.

CISSELL, J.R.; CANTY, S.W.J.; STEINBERG, M.K.; SIMPSON, L.T. Mapping National Mangrove Cover for Belize Using Google Earth Engine and Sentinel-2 Imagery. **Applied Sciences**, v. 11, n. 9, p. 4258, 2021. Disponível em: https://doi:10.3390/app11094258. Acesso em: 23 dez. 2024.

CLEMENT, M. A.; KILSBY, C. G.; MOORE, P. Multi-temporal synthetic aperture radar mapping using change detection. **Journal of Flood Risk Management**, Londres, v. 11, p. 2-17, 2017. Disponível em: https://doi.org/10.1111/jfr3.12303. Acesso em: 23 dez. 2024.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, Amsterdã, v. 37, p. 35-46, 1991. Disponível em: https://doi.org/10.1016/0034-4257(91)90048-B. Acesso em: 23 dez. 2024.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. Boca Raton: CRC Press, 1999. 160 p.

CONNERS, R. W.; HARLOW, C. A. A Theoretical Comparison of Texture Algorithms. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 2, n. 3, p. 204–222, 1980. Disponível em: https://doi:10.1109/TPAMI.1980.4767008. Acesso em: 23 dez. 2024.

CORDEIRO, J.; RODERJAN, C. V.; CURCIO, G. R. Espécies lenhosas de um remanescente de Floresta Ombrófila Mista na região Centro-Sul e análise florística entre áreas florestais no Paraná. **Ambiência**, v.9, n. 3, 563–588, 2013. Disponivel em: https://10.5935/ambiencia.2013.03.08. Acesso em: 13 mar. 2025.

COSTA, N. P.; PEREIRA, L. A. G.; FRANÇA NETO, J. B.; HENNING, A. A.; KRYZYZANOWSKI, F. C. Zoneamento ecológico do estado do Paraná para a produção de sementes de cultivares precoces de soja. **Revista Brasileira de Sementes**, v. 16, n. 1, p. 12–19, 1994.

COSTA, A. R.; SILVA, M. P.; LIMA, F. G. Redução de custos e inovações tecnologics em Sensoriamento Remoto. Revista Brasileira de Geotcnologias, v.15, n.2; p. 123-141, 2020.

COVER, T.M.; HART, P. Nearest neighbor pattern classification. **IEEE Transactions on Information Theory**, v. 13, n. 1, p. 21–27, 1967. Disponível em: doi:10.1109/TIT.1967.1053964. Acesso em: 23 dez. 2024.

DAVIS, J. C. **Statistics and data analysis in geology**. New York: John Wiley and Sons,1986. 656 p.

DEL QUIQUI, E. M.; MARTINS, S. S.; SILVA, I.C.; BORGHI, W. A.; DA SILVA, O. H.; SAKURAGUI, C. M.; BERTON, R. Estudo fitossociológico de um trecho da floresta estacional semidecidual em Diamante do Norte, Estado do Paraná, Brasil. **Acta Scientiarum. Agronomy**, v. 29, n. 2, 2007. Disponível em: https://doi.org/10.4025/ACTASCIAGRON.V29I2.298. Acesso em: 12 mar. 2025.

DERON, J.; DENARDIN, V.; ALVES, A. Governança e desenvolvimento territorial: um estudo sobre a gestão territorial no litoral Paranaense. **Revista Expectativa**, 2021.

DEVRIES, B.; PRATIHAST, A. K.; VERBESSELT, J.; KOOISTRA, L.; HEROLD, M. Characterizing Forest Change Using Community-Based Monitoring Data and Landsat Time Series. **PLoS ONE**, New York, v. 11, n. 3, p. 1-25, 2016. Disponível em: http://doi:10.1371/journal.pone.0147121. Acesso em: 23 dez. 2024.

DINIZ, C. G.; ALMEIDA SOUZA, A. A.; SANTOS, C. D.; DIAS, M. C.; Luz, N. C.; MORAES, D. R. V.; MAIA, J. S. A.; GOMES, A. R.; NARVAES, I. S; VALERIANO, D. M.; MAURANO, L. E. P.; ADAMI, M. DETER-B. The New Amazon Near Real-Time Deforestation Detection System. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing,** Canberra, v. 8, n. 7, p. 3619-3628, 2015. Disponível em: https://ieeexplore.ieee.org/document/7128317. Acesso em: 23 dez. 2024.

DOBLAS, J.; SHIMABUKURO, Y.; SANT'ANNA, S.; CARNEIRO, A.; ARAGÃO, L.; ALMEIDA, C. Optimizing Near Real-Time Detection of Deforestation on Tropical Rainforests Using Sentinel-1 Data. **Remote Sensing of Environment**, Amsterdã, v. 12, n. 23, p. 3922-3941, 2020. Disponível em: https://doi.org/10.3390/rs12233922. Acesso em: 23 dez. 2024.

DSG – Diretoria de Servico Geografico. Ministério da Defesa Exército Brasileiro Departamento de Ciência e Tecnologia Diretoria de Serviço Geográfico. **Norma da Especificação Técnica para Aquisição de Dados Geoespaciais Vetoriais**. 1ª ed., p. 385. 2015.

DUAN, Q.; TAN, M.; GUO, Y.; WANG, X.; XIN, L. Understanding the spatial distribution of urban forests in China using Sentinel-2 images with google earth

engine. **Forests**, v. 10, n. 9, p. 729, 2019. Disponível em: https://doi:10.3390/f10090729. Acesso em: 23 dez. 2024.

ELITH, J, LEATHWICK, J. R.; HASTIE, T. A working guide to boosted regression trees. **Journal of Animal Ecology**, v. 77, n. 4, p. 802-813, 2008. Disponível em: https://doi.org/10.1111/j.1365-2656.2008.01390.x . Acesso em: 01 jan. 2025.

EFRON, B.; TIBSHIRANI, R. Statistical data analysis in the computer age. **Science**, New York, v. 253, n. 5018, p. 390-395, 1991. Disponível em: https://www.science.org/doi/10.1126/science.253.5018.390. Acesso em: 23 dez. 2024.

ESA - European Space Agency (ESA). **Sentinel**. 2021. Disponível em: https://sentinel.esa.int/web/sentinel. Acesso em: 06 jun. 2021.

ESKANDARI, S.; JAAFARI, M.R., OLIVA, P.; GHORBANZADEH, O.; BLASCHKE, T. Mapping land cover and tree canopy cover in Zagros Forests of Iran: Application of Sentinel-2, Google Earth, and Field Data. **Remote Sensing**, v. 12, n. 12, p. 1912, 2020. Disponível em: https://doi:10.3390/rs12121912. Acesso em: 23 dez. 2024.

FADLI, A.; KOSUGO, A.; ICHII, K.; RAMLI, R. Satellite-based monitoring of forest cover change in Indonesia using Google Earth Engine from 2000 to 2016. **Journal of Physics: Conference Series**, Bristol, v. 1317, 2019. Disponível em: https://doi:10.1088/1742-6596/1317/1/012046. Acesso em: 23 dez. 2024.

FARDA, N. M. Multi-temporal land use mapping of coastal wetlands area using machine learning in Google earth engine. **IOP Conference Series: Earth and Environmental Science**, Bristol, v. 98, p. 1-13, 2017. Disponível em: https://doi:10.1088/1755-1315/98/1/012042. Acesso em: 23 dez. 2024.

FINEGOLD, Y.; ORTMANN, A. **Map Accuracy Assessment and Area Estimation: A Practical Guide**. Rome: Food and Agriculture Organization of the United Nations, 2016. 69 p.

FOODY, G. M. Classification Accuracy Comparison: Hypothesis Tests and the Use of Confidence Intervals in Evaluations of Difference, Equivalence and Non-Inferiority. **Remote Sensing of Environment**, Amsterdã, v. 113, n. 8, p. 1658–63, 2009. Disponível em: https://doi.org/10.1016/j.rse.2009.03.014. Acesso em 23 dez. 2024.

FORTIN, J. A.; CARDILLE, J. A.; PEREZ, E. Multi-sensor detection of forest change across 45 years in Mato Grosso, Brazil. **Remote Sensing of Environment**,

Amsterdã, v. 238, p. 1-14, 2019. Disponível em: https://doi.org/10.1016/j.rse.2019.111266. Acesso em 23 dez. 2024.

FAO - Food and Agriculture Organization of United Nations. The Global Forest Resources Assessment (FRA), **Key findings,** 2020. Disponível em: https://doi.org/10.4060/ca8753en. Acesso em 23 dez. 2024.

FRIEDMAN, J. H. Stochastic gradient boosting. **Computational Statistics & Data Analysis**, v. 38, n. 4, p. 367–378, 2002. Disponível em: https://doi.org/10.1016/S0167-9473(01)00065-2. Acesso em 23 dez. 2024.

GANZ, S.; ADLER, P.; K€ANDLER, G. Forest cover mapping based on a Combination of aerial images and sentinel-2 satellite data compared to national forest inventory data. **Forests**, v 11, n. 12, p. 1322, 2020. Disponível em: https://doi:10.3390/f11121322. Acesso em: 23 dez. 2024.

GAROFALO, D. F.; MESSIAS, C. G.; LIESENBERG, V.; BOLFE, E. L.; FERREIRA, M. C. Análise comparativa de classificadores digitais em imagens do Landsat-8 aplicadas ao mapeamento temático. **Pesquisa Agropecuária Brasileira**, Brasília, v. 50, n. 7, p. 593-504, 2015. Disponível em: https://doi.org/10.1590/S0100-204X2015000700009. Acesso em 23 dez. 2024.

GEEKSFORGEEKS - Sanchhaya Education Private Limited. **Top 15 Machine Learning Algorithms Every Data Scientist Should Know in 2025**. Noida, Uttar Pradesh, 2025. Disponível em: https://www.geeksforgeeks.org/about/?ref=outindfooter. Acesso em 24 jan. 2025.

GENUER, R.; POGGI, J.M. CART. **Random Forests with R:** Use R!. Londres: Springer, 2020.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**. Amsterdã, v. 202, p.18-27, 2017. Disponível em: https://doi.org/10.1016/j.rse.2017.06.031. Acesso em 23 dez. 2024.

GORENSTEIN, M.; VUADEN, E.; WEBER, P. V.; LONGHI, J. S.; THOMAS, C.; VISMARA, E. V. CASTRO FARIA, A. B. Estrutura de uma floresta antropizada no sudoeste do Paraná. **Anais do 9º Congresso Florestal Brasileiro**, 2022. Disponível em: https://doi.org/10.55592/cfb.2022.5089282. Acesso em: 12 mar. 2025.

HAINOSZ, F. S.; FERRONATO, E. C. P.; SALAS, C. S. S.; ANDREAZZA, C. J.; HECK, G. C.; SILVEIRA, L. H. S. Use of geospacial techniques to subsidy the cadastral survey of isolated properties in the South-Matogrossen Pantanal area under the universalization of access to electrical energy. **Geografia**, [S.L.], v. 42, n. 3, p. 201-216, 2018. UNESP - Universidade Estadual Paulista. Disponível em: http://dx.doi.org/10.5016/geografia.v42i3.13103. Acesso em: 12 mar. 2025.

HANSEN, M.C.; POTAPOV, P.V.; MOORE, R.; HANCHER, M.; TURUBANOVA, S.A.; TYUKAVINA, A.; THAU, D.; STEHMAN, S. V.; GOETZ, S. J.; LOVELAND, T. R.; HANSEN, M. C.; POTAPOV, P.V.; GOETZ, S.J. TURUBANOVA, S.; TYUKAVINA, A.; KRYLOV, A.; KOMMAREDDY, A.; EGOROV, A. Mapping tree height distributions in Sub-Saharan Africa using Landsat 7and 8 data. **Remote Sensing Environment**, Amsterdã, v. 185, p. 221-232, 2016. Disponível em: https://doi.org/10.1016/j.rse.2016.02.023. Acesso em: 23 dez. 2024.

HANSEN, M.C.; POTAPOV, P.V.; MOORE, R.; HANCHER, M.; TURUBANOVA, S.A.; TYUKAVINA, A.; THAU, D.; STEHMAN, S. V.; GOETZ, S. J.; LOVELAND, T. R.; KOMMAREDDY, A.; EGOROV, A.; CHINI, L.; JUSTICE, C. O.; TOWNSHEND, J. R. G. High-resolution global maps of 21st-century forest cover change. **Science**, Nova York, v. 342, n. 6160, p. 850-853, 2013. Disponível em: https://www.science.org/doi/10.1126/science.1244693. Acesso em: 23 dez. 2024.

HARALICK, R.M. Statistical and structural approaches to texture. **Proceedings of the IEEE**, v. 67, n. 5, p.786-804, 1979. Disponível em: https://doi:10.1109/PROC.1979.11328. Acesso em: 23 dez. 2024.

HARALICK, R.M.; SHANMUGAM, K.; and DINSTEIN, I. 1973. Textural features of image classification. **IEEE Transactions on Systems, Man, and Cybernetics**, v. SMC-3, n. 6, p. 610–621, 1973. Disponível em: https://doi:10.1109/TSMC.1973.4309314. Acesso em: 23 dez. 2024.

HASAN, A. F.; LAURENT, F.; BLANC, L.; MESSNER, F. The use of Landsat time series for indentifiction of forest degradation levels in the eastern Brazilian Amazon (Paragominas). **2017 9th International Workshop on the Analysis of Multitemporal Remote Sensing Images (MultiTemp)**. Brugge, p. 1-4. 2017. Disponível em: http://10.1109/Multi-Temp.2017.8035243. Acesso em: 23 dez. 2024.

HERMANCE, J. F. NDVI data for average annual models by damping model roughness. **International Journal of Remote Sensing**, v. 28, n.12, p. 2801-2819, 2007. Disponível em: https://doi.org/10.1080/01431160600967128. Acesso em: 23 dez. 2024.

HIRD, J.N.; DELANCEY, E.R.; MCDERMID, G.J.; KARIYEVA, K. Google Earth Engine, Open-Access Satellite Data, and Machine Learning in Support of Large-Area Probabilistic Wetland Mapping. **Remote Sensing**, Basel, v. 9, n. 12, p. 1315-1334, 2017. Disponível em: https://doi.org/10.3390/rs9121315. Acesso em: 23 dez. 2024.

HUANG, H.; CHEN, Y.; CLINTON, N.; WANG, J.; WANG, X.; LIU, C. GONG, P.; YANG, J.; BAI, Y.; ZHENG, Y.; ZHU, Z. Mapping major land cover dynamics in Beijing using all Landsat imagens in Google Earth Engine. **Remote Sensing of Environment**, Amsterdã, v. 202, p. 166-176, 2017. Disponível em: https://doi.org/10.1016/j.rse.2017.02.021. Acesso em: 23 dez. 2024.

HUO, L.; BOSCHETTI, L.; SPARKS, A. Object-Based Classification of Forest Disturbance Types in the Conterminous United States. **Remote Sensing**, Basel, v. 11, n. 5, p. 477-495, 2019. Disponível em: https://doi.org/10.3390/rs11050477. Acesso em: 23 dez. 2024.

IBGE - Instituto Brasileiro de Geografia e Estatística. Manual Técnico da Vegetação Brasileira: Sistema fitogeográfico Inventário das formações florestais e campestres Técnicas e manejo de coleções botânicas. **Procedimentos para mapeamentos**. Rio de Janeiro: IBGE, 2012. 274 p.

INPE – Instituto Nacional de Pesquisas Espacial. OBT, Observação da Terra. Disponível em: http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes. Acesso em: 27 fev. 2020.

ISUHUAYLAS, L.A.V.; HIRATA, Y.; SANTOS, L.V.; TOROBEO, N.S. Natural forest mapping in the Andes (Peru): A Comparison of the performance of Machine-Learning Algorithms. **Remote Sensing**, Basel, v. 10, n. 5, p. 782-801, 2018. Disponível em: https://doi.org/10.3390/rs10050782. Acesso em: 23 dez. 2024.

JAKUBAUSKAS, M. E.; LEGATES, D. R.; KASTENS, J. H. Harmonic analysis of time-séries AVHRR NDVI data. **Photogrammetric Engineering and Remote Sensing**, v. 67, n. 4, p. 461-470, 2001.

JAKUBAUSKAS, M. E.; LEGATES, D. R.; KASTENS. J. H. Crop identification using harmonic analysis of time-series AVHRR NDVI data. **Computers and Electronics in Agriculture**, Amsterdam, v. 37, n. 1-3, p.127-139, 2002. Disponível em: https://doi.org/10.1016/S0168-1699(02)00116-3. Acesso em: 23 dez. 2024.

JAVATPOINT – Free Learning Platform For Better Feature. **Support Vector Machine Algorithm**. Noida, India, 2025. Disponivel em: https://www.javatpoint.com/machine-learning-support-vector-machine-algorithm. Acesso em: 27 jan. 2025.

JIA, L.; SHANG, H; HU, G.; MENENTI, M. Phenological response of vegetation to upstream river flow in the Heihe Rive basin by time series analysis of MODIS data. **Hydrology Earth System Sciences**, v. 15, n. 3, p. 1047-1064, 2011. Disponível em: https://doi.org/10.5194/hess-15-1047-2011. Acesso em: 23 dez. 2024.

JIANG, X.; DU, H.; GAO, S.; FANG, S., GONG, Y.; HAN, N.; WANG, Y.; ZHENG, K. An automatic rice mapping method based on an integrated time-series gradient boosting tree using GF-6 and Sentinel-2 images. **GIScience & Remote Sensing**, v. 61, n. 1, 2024. Disponível em: https://doi.org/10.1080/15481603.2024.2367807. Acesso em: 23 dez. 2024.

JIN, Y.; LIU, X.; CHEN, Y.; LIANG, X. Land-cover mapping using Random Forest classification and incorporating NDVI time-series and texture: a case study of central Shandong. **International Journal of Remote Sensing**, Londres, v. 39. p. 8703-8723, 2018. Disponível em: https://doi.org/10.1080/01431161.2018.1490976. Acesso em: 23 dez. 2024.

KAPLAN, G. Broad-leaved and coniferous forest classification in google earth engine using sentinel imagery. **Environmental Sciences Proceedings, (MDPI)**, v.3, p.1–6, 2021. Disponível em: https://doi:10.3390/IECF2020-07888. Acesso em: 23 dez. 2024.

KARAMAN, K.; SAINTE FARE GARNOT, V.; WEGNER, J. D.: Deforestation detection in the Amazon with Sentinel-1 SAR image time series, ISPRS Ann. Photogramm. **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, 835–842. 2023. Disponível em: https://doi.org/10.5194/isprs-annals-X-1-W1-2023-835-2023. Acesso em: 23 dez. 2024.

KOOP, L.; SNELLEN, M.; SIMONS, D.G. An Object-Based Image Analysis Approach Using Bathymetry and Bathymetric Derivatives to Classify the Seafloor. **Geosciences**, Basel, v. 11, n. 2, p. 45-64, 2021. Disponível em: https://doi.org/10.3390/geosciences11020045. Acesso em: 23 dez. 2024.

KOPPEN, W.; GEIGER, R. **Klimate der Erde**. Gotha: Verlag Justus Perthes. 1928. Wall-map 150cmx200cm.

KOZERA, C; KUNIYOSHI, Y. S.; GALVÃO, F.; CURCIO, G. R. Composição florística de uma formação pioneira com influência fluvial em Balsa Nova, PR, Brasil. **Floresta**, v. 39, n. 2, 2009. Disponível em: https://doi.org/10.5380/rf.v39i2.14558. Acesso em: 12 mar. 2025.

LAMBIN, E. F.; LINDERMAN, M. Time series of remote sensing data for land change science. **IEEE Transactions on Geoscience and Remote Sensing**, v. 44, n. 7, p.

1926-1928, 2006. Disponível em: https://doi.org/10.1109/TGRS.2006.872932. Acesso em: 23 dez. 2024.

LAWRENCE, R. L.; WRIGHT, A. Rule-based classification systems using classification and regression tree (CART) analysis. **Photogrammetric engineering and remote sensing**, v. 67, n. 10, p. 1137-1142, 2001.

LEMENKOVA, P. Support Vector Machine Algorithm for Mapping Land Cover Dynamics in Senegal, West Africa, Using Earth Observation Data. **Earth**, *5*, 420-462. 2024. Disponivel em: https://doi.org/10.3390/earth5030024. Acesso em: 12 mar. 2025.

LIBERALI, L.; M. E. C. FERREIRA. O estudo da vegetação xeromórfica e xerofítica na região centro-ocidental Paranaense. **Geografia Ensino & Pesquisa**, v. 18, n. 2, 2014. Disponível em: https://doi.org/10.5902/2236499414937. Acesso em: 12 mar. 2025.

LIU, J.; HEISKANEN, J.; AYNEKULU, E.; MAEDA, E.; PELLIKKA, P. K.E. Land cover characterization in West Sudanian Savannas using seasonal features from annual Landsat time series. **Remote Sensing**, Basel, v. 8, n. 5, p. 365-383, 2016. Disponível em: https://doi.org/10.3390/rs8050365. Acesso em: 23 dez. 2024.

LIU, L.; XIAO, X.; QIN, Y.; WANG, J.; XU, X.; HU, Y.; QIAO, Z. Mapping cropping intensity in China using time series Landsat and Sentinel-2 images and Google Earth Engine. **Remote Sensing of Environment**, Amsterdã, v.239, 2020. Disponível em: https://doi.org/10.1016/j.rse.2019.111624. Acesso em: 23 dez. 2024.

LIU, Z.; LONG, J.; LIN, H.; SUN, H.; YE, Z.; ZHANG, T.; YANG, P.; MA, Y. Mapping and analyzing the spatiotemporal dynamics of forest aboveground biomass in the ChangZhuTan urban agglomeration using a time series of Landsat images and meteorological data from 2010 to 2020. Sci Total Environ, 2024. Disponível em: https://doi.org/10.1016/j.scitotenv.2024.173940. Acesso em: 23 dez. 2024.

LOBELL, D.; THAU, D.; SEIFERT, C.; ENGLE, E.; LITTLE, B. A scalable satellite-based crop yield mapper. **Remote Sensing Environment**, Amsterdã, v.164, p. 324-333, 2015. Disponível em: https://doi.org/10.1016/j.rse.2015.04.021. Acesso em: 23 dez. 2024.

LOBO, F.D.L.; SOUZA-FILHO, P.W.M.; NOVO, E.M.L.d.M.; CARLOS, F.M.; BARBOSA, C.C.F. Mapping Mining Areas in the Brazilian Amazon Using MSI/Sentinel-2 Imagery (2017). **Remote Sensing**, Basel, v. 10, n. 8, p. 1178-1197, 2018. Disponível em: https://doi.org/10.3390/rs10081178. Acesso em: 23 dez. 2024.

LU, D.; BATISTELLA, M.; MORAN, E.; and MAUSEL, P. Application of spectral mixture analysis to Amazonian land-use and land-cover classification. **International Journal of Remote Sensing**, v. 25, n. 23, p. 5345–5358. 2004. Disponível em: https://doi:10.1080/01431160412331269733. Acesso em: 23 dez. 2024.

MAIN-KNORN, M.; PFLUG, B.; LOUIS, J.; DEBAECKER, V.; MÜLLER-WILM U.; GASCON F. Sen2Cor for Sentinel-2. Proc. SPIE 10427, **Image and Signal Processing for Remote Sensing XXII**, 2017. Disponível em: https://doi.org/10.1117/12.2278218. Acesso em: 01 jan. 2025.

MANSOR, N. S., AWANG, H., MALAMI, S. T. S., ZOLKAFLI, A., MOHAMMED, A. T., MAULANA, H. Support Vector Machine for Satellite Images Classification Using Radial Basis Function Kernel Method. Computing and Informatics : 9th International Conference, ICOCI 2023, Kuala Lumpur, Malaysia, September 13–14, 2023, Revised Selected Papers, Part I, 301–312. 2024. https://doi.org/10.1007/978-981-99-9589-9_23

MAPBIOMAS - Projeto MapBiomas Alerta. **Sistema de Validação e Refinamento de Alertas de Desmatamento com Imagens de Alta Resolução**. 2019. Disponível em: http://alerta.mapbiomas.org/. Acesso em: 21 jan. 2021.

MAPBIOMAS - Projeto MapBiomas Alerta. **Sistema de Validação e Refinamento de Alertas de Desmatamento com Imagens de Alta Resolução**. 2021. Disponível em: http://alerta.mapbiomas.org/. Acesso em: 21 jan. 2021.

MAPBIOMAS – Projeto MapBiomas. Methodology Overview. **MapBiomas**. 2020. Disponível em: https://mapbiomas.org/en/visao-geral-da-metodologia?cama_set_language=en. Acesso em: 21 jan. 2021.

MARTINS, T. D.; VIEIRA, B. C. Os campos gerais do Paraná e a contribuição da Geomorfologia Climática. **Revista do Departamento de Geografia**. v.28, 2014. Disponível em: https://doi.org/10.11606/rdg.v28i0.543. Acesso em: 12 mar. 2025.

MASEK, JG.; GOWARD, SN.; KENNEDY, R. E.; WARREN, B. C.; GRETCHEN, G. M.; SCHLEEWEIS, K.; HUANG, C. Tendências de perturbação florestal dos Estados Unidos observadas usando séries temporais Landsat. **Ecosystems**, v. 16, p.1087-1104, 2013. Disponível em: https://doi.org/10.1007/s10021-013-9669-9. Acesso em: 23 dez. 2024.

MCDOWELL, J. C. The Low Earth Orbit Satellite Population and Impacts of the SpaceX Starlink Constellation. **The Astrophysical Journal**, v. 892, n. 2, p. L36,

2020. Disponível em: https://doi.org/10.3847/2041-8213/ab8016. Acesso em: 17 mar. 2025.

MONDAL, P.; LIU, X.; FATOYINBO, T. E.; LAGOMASINO, D. Evaluating Combinations of Sentinel-2 Data and Machine-Learning Algorithms for Mangrove Mapping in West Africa. **Remote Sensing**, v. 11, n. 24, p. 2928, 2019. Disponível em: https://doi:10.3390/rs11242928. Acesso em: 23 dez. 2024.

MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing: A review. ISPRS J. Photogramm. **Remote Sensing**, Basel, v. 66, p. 247–259, 2011. Disponível em: https://doi.org/10.1016/j.isprsjprs.2010.11.001. Acesso em: 23 dez. 2024.

NAJM, S.M.; TRZEPIECIŃSKI, T.; LAOUINI, S.E.; KOWALIK, M.; FEJKIEL, R.; KOWALIK, R. Application of the Gradient-Boosting with Regression Trees to Predict the Coefficient of Friction on Drawbead in Sheet Metal Forming. **Materials***,* 2024, *17*, 4540. Disponível em: https://doi.org/10.3390/ma17184540. Acesso em: 13 jan. 2025.

EL NAQA, I.; MURPHY, M. J. What Is Machine Learning? **Machine Learning in Radiation Oncology**, v. 1, n. 1, p. 3–11, 2015. Disponível em: https://doi.org/10.1007/978-3-319-18305-3_1. Acesso em: 13 jan. 2025.

NISHIDA, W.; BASTOS, L. C. Classificação de imagens de sensoriamento remoto utilizando uma Rede Neural Artificial com Função de Base Radial. In: IX Simpósio Brasileiro de Sensoriamento Remoto, 1998, Santos. **Anais...** Santos: Instituto Nacional de Pesquisas Espaciais, p. 991-1001. 1998.

OBATA, S.; BETTINGER, P.; CIESZEWSKI, C. J.; Lowe III RC. Mapping Forest Disturbances between 1987–2016 Using All Available Time Series Landsat TM/ETM+ Imagery: Developing a Reliable Methodology for Georgia, United States. **Forests**. v.11, n. 3, p. 335, 2020. Disponível em: https://doi.org/10.3390/f11030335. Acesso em: 20 jan. 2025.

OLIVEIRA-FILHO, A. R.; BUDKE, J. C.; JARENKOW, J. A.; EISENLOHR, P. V.; NEVES, D. R. M. Delving into the variations in tree species composition and richness across South American subtropical Atlantic and Pampean forests, **Journal of Plant Ecology**, v. 8, n. 3, p. 242–260, 2015. Disponível em: https://doi.org/10.1093/jpe/rtt058. Acesso em: 13 jan. 2025.

OLOFSSON, P.; HOLDEN, C.; BULLOCK, E.; WOODCOCK, C. Time series analysis of satellite data reveals continuous deforestation of New England since the 1980s. **Environmental Research Letters,** Bristol, v.11, n. 6. 2016. Disponível em: https://doi.org/10.1088/1748-9326/11/6/064002. Acesso em: 23 dez. 2024.

OLOFSSON, P.; FOODY, G. M.; HEROLD, M.; STEHMAN, S. V.; WOODCOCK, C.; WULDER, M. A. Good Practices for Estimating Area and Assessing Accuracy of Land Change. **Remote Sensing of Environment**, Amsterdã, v. 148, p. 42–57, 2014. http://dx.doi.org/10.1016/j.rse.2014.02.015. Acesso em: 23 dez. 2024.

ORIESCHNIG, C. A.; BELAUD, G.; VENOT, J. P.; MASSUEL, S.; OGILVIE, A. Input imagery, classifiers, and cloud computing: Insights from multi-temporal LULC mapping in the Cambodian Mekong Delta. **European Journal of Remote Sensing**, v. 54, n. 1, p. 398-416, 2021. Disponível em: https://doi.org/10.1080/22797254.2021.1948356. Acesso em: 23 dez. 2024.

OSEI, J.D.; ANDAM-AKORFUL, S.A.; OSEI JNR, E.M. Long Term Monitoring of Ghana's Forest Reserves Using Google Earth Engine. **Preprints**, 2019. Disponível em: https://10.20944/preprints201909.0016.v1. Acesso em: 23 dez. 2024.

PACHECO, A., MCNAIRN, H. Evaluating multispectral remote sensing and spectral unmixing analysis for crop residue mapping. **Remote Sensing of Environment**, v. 114, n. 10, p. 2219-2228, 2010. Disponível em: https://doi:10.1016/j.rse.2010.04.024. Acesso em: 23 dez. 2024.

PAIVA, C. A.; ANTUNES, A. F. B.; CAMBOIM, S. A proposal for integrating data of land registry and urban cadastre. **Boletim de Ciências Geodésicas**, [S.L.], v. 24, n. 4, p. 525-544, dez. 2018. FapUNIFESP (SciELO). Disponível em: http://dx.doi.org/10.1590/s1982-21702018000400032. Acesso em: 20 mar. 2025.

PAIXÃO, S. K. S.; NICHOLS, S.; CARNEIRO, A. F. T. Cadastro Territorial Multifinalitário: dados e problemas de implementação do convencional ao 3D e 4D. **Boletim de Ciências Geodésicas**, v. 18, n. 1, p. 3–21, 2012.

PANG, Y.; ZHANG, L.; HUANG, C.; YU, X.; LI, Z. Automatic deforestation detection using time series Landsat images in a tropical forest of China. **IEEE International Geoscience and Remote Sensing Symposium - IGARSS,** Melbourne, VIC, Australia. p. 3872-3875. 2013. Disponível em: https://10.1109/IGARSS.2013.6723677

PAREETH, S.; KARIMI P.; SHAFIEI, M.; DE FRAITURE, C. Mapping Agricultural Landuse Patterns from Time Series of Landsat 8 Using Random Forest Based Hierarchial Approach. **Remote Sensing**, v.11, n. 5, p. 601, 2019. Disponível em: https://doi.org/10.3390/rs11050601. Acesso em: 01 jan. 2025.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V. Scikit-learn: Machine Learning in Python. **Journal of Machine Learning Resource**, v. 12, p. 2825–2830, 2011. Disponível em: https://www.jmlr.org/papers/v12/pedregosa11a.html. Acesso em: 23 dez. 2024.

PEKEL, J.F.; COTTAM, A.; GORELICK, N.; BELWARD, A.S. High-resolution mapping of global surface water and its long-term changes. **Nature Geoscience,** Londres**,** v. 540, n. 7633, p. 418-422, 2016. Disponível em: https://doi.org/10.1038/nature20584. Acesso em: 23 dez. 2024.

PERINA, B. B.; LIBONI, A.P.; MONTANHER, D. R.; MESSETTI, A. V.; PIMENTA, J. A.; BIANCHINI, E . Phenology of the tree community in a seasonal forest in southern Brazil. **Brazilian Journal of Botany**. 42, 477–490, 2019. Disponível em: https://doi.org/10.1007/s40415-019-00545-y. Acesso em: 12 mar. 2025.

PIMENTEL, J. DA S.; CARNEIRO, A. F. T. Cadastro territorial multifinalitário em município de pequeno porte de acordo com os conceitos da portaria n.511 do Mministério das Cidades. **Revista Brasileira de Cartografia**, v. 64, n. 2, 30 abr. 2012.

PLANET. **Planet Imagery Product Specifications, Planetscope & Rapideye**. 2021. Disponível em https://assets.planet.com/docs/Planet_Combined_Imagery_Product_Specs_letter_screen.pdf. Acesso em: 23 dez. 2024.

PRATICÒ, S.; SOLANO, F.; Di FAZIO, S.; MODICA, G. Machine Learning Classification of Mediterranean Forest Habitats in Google Earth Engine Based on Seasonal Sentinel-2 Time-Series and Input Image Composition Optimisation. **Remote Sensing**, Bristol, v. 13, n. 4, p. 586-601, 2021. Disponível em: https://doi.org/10.3390/rs13040586. Acesso em: 23 dez. 2024.

RAMEZAN, A. C.; WARNER, A.T.; MAXWELL, E. A. Evaluation of Sampling and Cross-Validation Tuning Strategies for Regional-Scale Machine Learning Classification. **Remote Sensing**, v.11, n. 2, p.185, 2019. Disponível em: https://doi.org/10.3390/rs11020185. Acesso em: 01 jan. 2025.

REGINATO, M.; GOLDENBERG, R. Análise florística, estrutural e fitogeográfica da vegetação em região de transição entre as Florestas Ombrófilas Mista e Densa Montana, Piraquara, Paraná, Brasil. **Hoehnea**, v. 34, n. 3, p. 349–360, 2007. Disponível em: https://doi.org/10.1590/S1676-06032010000300034. Acesso em: 13 mar. 2025.

RITTER, L. M. O.; RIBEIRO, M. C.; MORO, S. R. Composição florística e fitofisionomia de remanescentes disjuntos de Cerrado nos Campos Gerais, PR, Brasil - limite austral do bioma. **Biota Neotropica**, v. 10, n 3, 2010. Disponível em: https://doi.org/10.1590/S1676-06032010000300034. Acesso em: 12 mar. 2025.

ROBERTS, D.; GARDNER, M.; CHURCH, R.; SUSAN, U.; GEORGE, S.; GREEN, R.O. Mapping Chaparral in the Santa Monica Mountains Using Multiple Endmember Spectral Mixture Models. **Remote Sensing of Environment,** v. 65, n. 3**,** p. 267-279**,** 1998. Disponível em: https://doi.org/10.1016/S0034-4257(98)00037-6. Acesso em: 01 jan. 2025.

ROGAN, J.; FRANKLIN, J.; STOW, D.; MILLER, J.; WOODCOCK, C. ROBERTS, D. Mapping land-cover modifications over large areas: A comparison of machine learning algorithms. **Remote Sensing of Environment**, Amsterdã, v. 112, n. 5, p. 2272-2283. 2008. Disponível em: https://doi.org/10.1016/j.rse.2007.10.004. Acesso em: 23 dez. 2024.

SANQUETTA, C. R.; DALLA CORTE, A. P. Projeto de pesquisa do CNPQ. **Estoques e dinâmica temporal da biomassa e carbono aéreo na Mata Atlântica, O caso da bacia do Rio Iguaçu, PR**. Curitiba, PR. 2017. 137 p.

SANTOS SILVA, S. D. R.; ANTUNES, A. F. B. O Cadastro Territorial Multifinalitário no contexto dos Processos de Regularização Fundiária Urbana. **Revista Brasileira de Cartografia**, v. 72, n. 2, p. 233–252, 2020. Disponivel em: https://doi.org/10.14393/rbcv72n2-48360. Acesso em: 12 mar. 2025.

SAWCZUK, A. R.; FILHO, A. F.; NOGUEIRA DIAS, A.; WATZLAWICK, L. F.; STEPKA, T.F. Alterações na estrutura horizontal, no período de 2002-2008, em Floresta Ombrófila Mista no centro-sul do estado do Paraná. **Ciência Florestal**, v. 24, n. 1, p. 149–160, 2014. Disponível em: https://doi.org/10.5902/1980509813332. Acesso em: 13 mar. 2025.

SCHULTZ, M.; CLEVERS, J. G. P. W.; CARTER, S.; VERBESSEL, J.; AVITABILE, V.; QUANGB, H. V.; HEROLDU, M. Performance of vegetation indices from Landsat time series in deforestation monitoring. **International Journal of Applied Earth**

Observation and Geoinformation, Amsterdã, v. 52, p. 318–327, 2016. Disponível em: http://dx.doi.org/10.1016/j.jag.2016.06.020. Acesso em: 23 dez. 2024.

SEDEST – Secretaria do Desenvolvimento Sustentável e do Turismo. Paraná tem novo mapeamento de cobertura vegetal. 2020. Disponível em: http://www.sedest.pr.gov.br/Noticia/Parana-tem-novo-mapeamento-de-cobertura-vegetal#. Acesso em: 21 jan. 2021.

SEGER, C. D.; BATISTA, A. C.; TETTO, A. F.; SOARES, R. V.; BIONDI, D. Caracterização do material combustível fino da estepe gramíneo-lenhosa no estado do Paraná, Brasil. **Ciência Florestal**, v. 28, n. 2, p. 863–874, 2018. Disponível em: https://doi.org/10.5902/1980509832127. Acesso em: 12 mar. 2025.

SHIMIZU, K.; OTA, T.; MIZOUE, N. Detecting Forest Changes Using Dense Landsat 8 and Sentinel-1 Time Series Data in Tropical Seasonal Forests. **Remote Sensing**, Bristol, v. 11, n. 16, p. 1899-1918, 2019. Disponível em: https://doi.org/10.3390/rs11161899. Acesso em: 23 dez. 2024.

SICAR - Sistema Nacional de Cadastro Ambiental Rural. Base de Cadastro Ambiental Rural do Estado do Paraná. 2024. Disponível em: https://consultapublica.car.gov.br/publico/imoveis/index. Acesso em: 01 jan. 2025.

SILVA, A. R.; ANDRADE, A. L. P.; VELAZCO, S. E.; GALVÃO, F.; CARMO, M. R.B. Florística e fitossociologia em três diferentes fitofisionomias campestres no Sul do Brasil. **Hoehnea**, v. 43, n. 3, p. 325–347, 2016. Disponível em: https://doi.org/10.1590/2236-8906-96/2015. Acesso em: 12 mar. 2025.

SILVA, B. M.; VANDERLINDE, M. **Inteligência Artificial, Aprendizado de Máquina**. Santa Catarina, UDESC, 2012. Disponível em: http://www.ceavi.udesc.br/arquivos/id_submenu/387/brigiane_machado_da_silva___marcos__vanderlinde.pdf. Acesso em: 20 nov. 2021.

SILVA, J. T. C.; REZENDE, J. F.; FIDENCIO, E.; MELO, T.; NEVES, B.; LIMA, J. C.; CARNEIRO, T. S. C. SIGHabitar – Business Intelligence Based Approach for the Development of Land Information Systems: The Multipurpose Technical Cadastre of Ouro Preto, Brazil. In: MURGANTE, B., *et al.* Computational Science and Its Applications – ICCSA 2012. ICCSA. Lecture Notes in Computer Science, vol 7334. Springer, Berlin, Heidelberg, 2012. Disponível em: https://doi.org/10.1007/978-3-642-31075-1_23. Acesso em: 12 mar. 2025.

SILVA JUNIOR, C. HL.; HEINRICH, V. HA.; FREIRE, A. TG.; BROGGIO, I. S.; ROSAN, T. M.;, DOBLAS, J.; ANDERSON, L. O; ROUSSEAU, G. X.; SHIMABUKURO, Y. E.; SILVA, C. A.; HOUSE, J. I.; ARAGAO, L. E. O. C. Benchmark maps of 33 years of secondary forest age for Brazil. **Nature Scientific Data**, Londres, v. 7, n. 269, 2020. Disponível em: https://doi.org/10.1038/s41597-020-00600-4. Acesso em: 23 dez. 2024.

SMITH, M.O.; SUSAN, L.U.; ADAMS, J.B.; GILLESPIE, A.R. Vegetation in deserts: I. A regional measure of abundance from multispectral images. **Remote Sensing of Environment (Elsevier),** v. 31, n 1, p. 1–26, 1990. Disponível em: https://doi:10.1016/0034-4257(90)90074-V. Acesso em: 23 dez. 2024.

SOCHER, L. G.; RODERJAN, C. V.; GALVÃO, F. Biomassa aérea de uma floresta ombrófila mista aluvial no município de Araucária (PR). **FLORESTA**, v. 38, n. 2, 2008. Disponível em: https://doi.org/10.5380/rf.v38i2.11619. Acesso em: 13 mar. 2025.

SONG, D.; HUANG, C.; SEXTON, J. O.; CHANNAN, S.; FENG, M.; TOWNSHEND, J. R. Use of Landsat and Corona data for mapping forest cover change from the mid-1960s to 2000s: Case studies from the Eastern United States and Central Brazil. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdã, v. 103, p. 81-92, 2015. Disponível em: https://doi.org/10.1016/j.isprsjprs.2014.09.005. Acesso em: 23 dez. 2024.

SOS MATA ATLANTICA. **Atlas do Remanescentes Florestais da Mata Atlântica**. Relatório Técnico Período 2017-2018. São Paulo, 2019. 68p. Disponível em: https://www.sosma.org.br/. Acesso em: 23 dez. 2024.

SOS PANTANAL. **Mapeamento da cobertura vegetal da Bacia do Alto Paraguai (BAP).** 2021. Campo Grande, MS. Disponível em: https://www.sospantanal.org.br/. Acesso em: 23 dez. 2024.

SOUSA, C.; FATOYINBO, L.; NEIGH, C.; BOUCKA, F.; ANGOUE, V, LARSEN, T. Cloud-computingand machine learning in support of country-levelland cover and ecosystem extent mapping in Liberia and Gabon. **PLoS ONE,** Califórnia, v. 15, n. 1, 2020. Disponível em: https://doi.org/10.1371/journal.pone.0227438. Acesso em: 23 dez. 2024.

SOUZA, C. M.; SHIMBO, J. Z.; ROSA, M.R.; PARENTE, L. L; ALENCAR, A. A.; RUDORFF, B. F.; HASENACK, H.; MTSUMOTO, M.; FERREIRA, L.G.; SOUZA-FILHO, P. W.; OLIVEIRA, S. W.; ROCHA, W.; FONSECA, A. V.; MARQUES, C.;

DINIZ, C. G.; COSTA, D.; MONTEIRO, D.; ROSA, E. R. VELEZ-MARTIN, E.; WEBER, E. J. Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. **Remote Sensing**, Bristol, v. 12, n. 17, p. 2735-2753, 2020. Disponível em: https://doi10.3390/rs12172735. Acesso em: 23 dez. 2024.

STEHMAN, S. V. Estimating Area and Map Accuracy for Stratified Random Sampling When the Strata Are Different from the Map Classes. **International Journal of Remote Sensing**, Londres, v. 35, n. 13, p. 4923–4939, 2014. Disponível em: https://doi.org/10.1080/01431161.2014.930207. Acesso em: 23 dez. 2024.

SULLIVAN, A.; MCGAUGHEY, R.; ANDERSEN, H-E.; SCHIESS, P. Object-Oriented Classification of Forest Structure from Light Detection and Ranging Data for Stand Mapping. **Western Journal of Applied Forestry**, Washington, v. 24, n. 4, p. 198-204, 2009. Disponível em: https://research.fs.usda.gov/treesearch/38293. Acesso em: 23 dez. 2024.

THEOFANOUS, N.; CHRYSAFIS, I.; MALLINIS, G.; DOMAKINIS, C.; VERDE, N.; SIAHALOU, S. Aboveground biomass estimation in short rotation forest plantations in Northern Greece using ESA's sentinel medium-high resolution multispectral and radar imaging missions. **Forests**, v. 12, n. 7, p. 902, 2021. Disponível em: https://doi:10.3390/f12070902. Acesso em: 23 dez. 2024.

TOLEDO, J. M. **Crop discrimination using harmonic analysis of evi modis time-series data**. 2008. 145 f. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2008.

TRIMBLE Germany GmbH. **eCognition Developer 10.0 Reference Book**, Trimble Germany GmbH, Industrial Technologies, Germany. 2014.

TROPPMAIR, H. Perfil fitoecológico do estado do Paraná. **Boletim de Geografia**, v. 8, n. 1, p. 67, 2011.

TSAI, Y.; STOW, D.; WEEKS, J. Comparison of Object-Based Image Analysis Aproaches to Mapping New Buildings in Accra, Ghana Using Multi-Temporal QuickBird Satellite Imagery. **Remote Sensing**, Bristol, v. 3, n. 12, p. 2707-2726. 2011. Disponível em: https://doi:10.3390/rs3122707. Acesso em: 23 dez. 2024.

UNW - United Nations World. Map proportion and distribution of global forest area by climatic domain, 2020. In: Global Forest Resources Assessment, 2020. **Key findings**. Disponível em: https://doi.org/10.4060/ca8753en. Acesso em: 23 dez. 2024.

VAN DEN BURG, G. J. J.; WILLIAMS, C. K. L. An Evaluation of Change Point Detection Algorithms. **arXiv preprint**, 2020. Disponível em: https://arxiv.org/abs/2003.06222. Acesso em: 23 dez. 2024.

VEERENDRA, T. M.; LATHA, B. M.; RAGHUDATHESH, G. P. Classification of Remotely Sensed Data using ENVI 4.7 Tool. **International Journal of Research in Advent Technology**, v.2, n. 6, p. 62-66, 2014. Disponível em: https://www.academia.edu/10693616/Classification_of_Remotely_Sensed_Data_using_ENVI_4_7_Tool. Acesso em: 23 dez. 2024.

VELASTEGUI-MONTOYA, A.; MONTALVÁN-BURBANO, N.; CARRIÓN-MERO, P.; RIVERA-TORRES, H.; SADECK, L.; ADAMI, M. Google Earth Engine: A Global Analysis and Future Trends. **Remote Sensing**. 2023; v. 15, n. 14, 2023. Disponível em: https://doi.org/10.3390/rs15143675. Acesso em: 13 mar. 2025.

VENABLES, W.N.; RIPLEY, B. D. **Modern Applied Statistics with S-Plus**. 2 ed. New York: Springer, 1997. 548 p.

VENKATAPPA, M.; SASAKI, N.; ANANTSUKSOMSRI, S.; SMITH, B. Applications of the Phenology-Based Threshold Classification Method for Mapping Forest Cover and Carbon Stock Changes in Siem Reap Province, Cambodia. **Remote Sensing**, Bristol, v. 12, n. 18, p. 3110-3128, 2020. Disponível em: https://doi.org/10.3390/rs12183110. Acesso em: 23 dez. 2024.

VERBESSELT, J.; HYNDMAN, R.; ZEILEIS, A.; CULVENOR, D. Phenological change detection while accounting for abrupt and gradual trends in satellite image time series. **Remote Sensing of Environment,** Amsterdã**,** v.114, n. 12, p. 2970–2980, 2010. Disponível em: https://doi.org/10.1016/j.rse.2010.08.003. Acesso em: 23 dez. 2024.

VIANA-SOTO, A.; SENF, C. The European Forest Disturbance Atlas: a forest disturbance monitoring system using the Landsat archive, **Earth System Science Data**. Data Discuss. https://doi.org/10.5194/essd-2024-361, 2024.

WANG, L.; XIAN, G.; DIAO, C.; THAU, D. Remote sensing of land change science with Google Earth Engine. **Remote Sensing of Environment**, Amsterdã, v. 11, n. 13, 2020. Disponível em: https://www.mdpi.com/journal/remotesensing/special_issues/Remote_Sensing_of_Land_Use_and_Land_Change_with_Google_Earth_Engine. Acesso em: 23 dez. 2024.

WANG, X.; YAO, Y.; ZHAO, S.; JIA, K.; ZHANG, X.; ZHANG, Y.; ZHANG, L.; XU, J .; CHEN, X. MODIS-Based Estimation of Terrestrial Latent Heat Flux over North

America Using Three Machine Learning Algorithms. **Remote Sensing**, Bristol, v. 9, n. 12, 1326-1345, 2017. Disponível em: https://doi.org/10.3390/rs9121326. Acesso em: 23 dez. 2024.

WANG, Y.; ZIV, G.; ADAMI, M.; MITCHARD, E.; BATTERMAN, S.; BUERMANN, W.; MARIMON, B.S.; MARIMON JUNIOR, B.; H., REIS, S.; M.; RODRIGUES, D.; GALBRAITH, D. Mapping tropical disturbed forests using multi-decadal 30 m optical satellite imagery. **Remote Sensing of Environment**, Amsterdã, v. 221, 474-488, 2019. Disponível em: https://doi.org/10.1016/j.rse.2018.11.028. Acesso em: 23 dez. 2024.

WAŚNIEWSKI, A.; HOŚCIŁO, A.; ZAGAJEWSKI, B.; MOUKÉTOUTARAZEWICZ, D. Assessment of Sentinel-2 satellite images and random forest classifier for rainforest mapping in gabon. **Forests,** v. 11, v. 9, p. 941, 2020. Disponível em: https://doi:10.3390/f11090941. Acesso em: 23 dez. 2024.

WEINMANN, M.; WEIDNER, U. Land-Cover and Land-Use Classification Based on Multitemporal Sentinel-2 Data. IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium, Valencia, Spain, 4946-4949, 2018. Disponível em: https://10.1109/IGARSS.2018.8519301. Acesso em: 23 dez. 2024.

WILLMOTT, C.; ACKLESON, S.; DAVIS, R.; FEDDEMA, J.;KLINK, K.; LEGATES, D.; O'DONNELL, J.; ROWE, C. Statistics for the Evaluation and Comparison of Models. **Journal of Geophysical Research**, 1985. Disponível em: https://10.1029/JC090iC05p08995. Acesso em: 01 jan. 2024.

WILLMOTT, C. J.; ROBESON, S. M.; MATSUURA, K. A refined index of model performance. **International Journal of Climatology**, v. 32, n. 13, p. 2088-2094, 2012. Disponível em: https://doi:10.1002/joc.2419. Acesso em: 23 dez. 2024.

WILSON, B. T.; KNIGHT, J. F.; MCROBERTS, R. E. Harmonic regression of Landsat time series for modeling attributes from national forest inventory data. **International Journal of Photogrammetry and Remote Sensing**, Washington, v. 137, p. 29-46, 2018. Disponível em: http://doi:/10.1016/j.isprsjprs.2018.01.006. Acesso em: 23 dez. 2024.

WREGE, M. S.; GARRASTAZU, M. C.; SOARES, M. T. S.; FRITZSONS, E.; SOUZA, V. A.; AGUIAR, A. V. Plant vegetation types in the state of Paraná and the new scenarios defined by global climate change. **Ambiência**, v. 13, n. 3, 2017.

WRUBLACK, S. C.; PRUDENTE, V. H. R.; MERCANTE, E.; MACHADO COELHO, S. R. Spatial distribution of Canola culture in the State of Paraná (Brazil) between the agricultural years of 2005 and 2009. **Ciencia e Investigación Agraria**, Santiago, v. 40, n. 3, p. 523-535, 2013. Disponível em: http://dx.doi.org/10.4067/S0718-16202013000300005. Acesso em: 12 mar. 2025.

WU, S.; CHEN, W.; CAO, C.; ZHANG, C.; MU, Z. A multiple-CubeSat constellation for integrated earth observation and marine/air traffic monitoring. **Advances in Space Research**, v. 67, n. 11, p. 3712-3724, 2021. Disponível em: https://doi.org/10.1016/j.asr.2020.04.025. Acesso em: 17 mar. 2025.

XIE, B.; CAO, C.; XU, M.; DUERLER, R.S.; YANG, X.; BASHIR, B.; CHEN, Y.; WANG, K. Analysis of regional distribution of tree species using multi-seasonal Sentinel-1 and 2 imagery within Google Earth Engine. **Forests**, v. 12, n. 5, p. 565, 2021. Disponível em: https://doi.org/10.3390/f12050565. Acesso em: 23 dez. 2024.

XIE, S.; LIU, L.; ZHANG, X.; YANG, J.; CHEN, X.; GAO Y. Automatic Land-Cover Mapping using Landsat time-series data based on Google Earth Engine. **Remote Sensing**, Bristol, v. 11, n. 24, p. 20-20, 2019. Disponível em: https://doi.org/10.3390/rs11243023. Acesso em: 23 dez. 2024.

XIONG, J.; THENKABAIL, PS.; TILTON, JC.; GUMMA, MK.; TELUGUNTLA, P.; OLIPHANT, A.; CONGALTON, RG.; YADAV, K.; GORELICK, N. Nominal 30 m Cropland Extent Map of Continental Africa Integrando Pixel-Based e Object-Based Algorithms Usando Sentinel-2 e Landsat-8 Data on Google Earth Engine. **Remote Sensing,** Bristol, v. 9, n. 10, p. 1065–1082, 2017. Disponível em: https://doi.org/10.3390/rs9101065. Acesso em: 23 dez. 2024.

YANG, L.; MANSARAY, L. R.; HUANG, J.; WANG, L. Optimal Segmentation Scale Parameter, Feature Subset and Classification Algorithm for Geographic Object-Based Crop Recognition Using Multisource Satellite Imagery. **Remote Sensing**, Bristol, v. 11, n. 5, p. 514-533, 2019. Disponível em: https://doi.org/10.3390/rs11050514. Acesso em: 23 dez. 2024.

YANG, Y.; HUANG, Q.; WU, W.; LUO, J.; GAO, L.; DONG, W.; QUE.; HU, X. Geo-Parcel Based Crop Identification by Integrating High Spatial-Temporal Resolution Imagery from Multi-Source Satellite Data. **Remote Sensing**, Bristol, v. 9, n. 12, p. 1298-1315, 2017. Disponível em: https://doi.org/10.3390/rs9121298. Acesso em: 23 dez. 2024.

ZENG, J.; TAN, M.L.; TEW, Y.L.; ZHANG, F.; WANG, T.; SAMAT, N.; TANGANG, F.; YUSOP, Z. Optimization of Open-Access Optical and Radar Satellite Data in Google Earth Engine for Oil Palm Mapping in the Muda River Basin, Malaysia. **Agriculture***,* 2022, *12*, 1435. Disponível em: https://doi.org/10.3390/agriculture12091435. Acesso em: 20 mar. 2025.

ZENG, H.; WU, B.; WANG, S.; MUSAKWA, W.; TIAN, F.; MASHIMBYE, Z.E.; POONA, N.; SYNDEY, M. Asynthesizing land-cover classification method based on Google Earth Engine: A case study in Nzhelele and Levhuvu Catchments, South Africa. **Chinese Geographical Science**, v. 30, n. 3, p. 397-409, 2020. Disponível em: https://doi: 10.1007/s11769-020-1119-y. Acesso em: 23 dez. 2024.

ZHANG, W.; TANG, P.; ZHAO, L. Remote Sensing Image Scene Classification Using CNN-CapsNet. **Remote Sensing**, Bristol, v. 11, n. 5, p. 494-511, 2019. Disponível em: https://doi.org/10.3390/rs11050494. Acesso em: 23 dez. 2024.

ZHOU, C.; ZHENG, L. Mapping radar glacier zones and dry snow line in the Antartic Peninsula Using Sentinel-1 Images. **Remote Sensing**, Bristol, v. 9, n. 11, p. 2-19, 2017. Disponível em: https://doi.org/10.3390/rs9111171. Acesso em: 23 dez. 2024.

ZHOU, J.; JIA, L.; HU, G.; MENENTI, M. Evaluation of Harmonic Analysis of Time Series (HANTS): impact of gaps on time series reconstruction. **Second International Workshop on Earth Observation and Remote Sensing Applications**, v.5, n.8, 2012. Disponível em: https://ieeexplore.ieee.org/document/6261129. Acesso em: 23 dez. 2024.

ZHOU, J.; JIA, L.; MENENTI, M. Reconstruction of global MODIS NDVI time series: Performance of Harmonic ANalysis of Time Series (HANTS). **Remote Sensing of Environment**, Amsterdã, v. 163, n. 8, 2015. Disponível em: https://doi.org/10.1016/j.rse.2015.03.018. Acesso em: 23 dez. 2024.

ZHOU, T.; PAN, J.; ZHANG, P.; WEI, S.; HAN, T. Mapping winter wheat with multi-temporal SAR and optical images in an urban agricultural region. **Sensors**, Bristol, v.17, n. 6, p. 1210-1226, 2017. Disponível em: https://doi.org/10.3390/s17061210. Acesso em: 23 dez. 2024.

ZHOU, T.; GENG, Y.; CHEN, J.; PAN, J.; HAASE, D.; LAUSCH, A. High-resolution digital mapping of soil organic carbon and soil total nitrogen using DEM derivatives, Sentinel-1 and Sentinel-2 data based on machine learning algorithms. **Science of The Total Environment**, v. 729, p. 138244, ago. 2020. Disponível em: https://doi.org/10.1016/j.scitotenv.2020.138244. Acesso em: 13 mar. 2025.

ZHU, Z.; WOODCOCK, C. E.; OLOFSSON, P. Continuous monitoring of forest disturbance using all available Landsat imagery. **Remote Sensing of Environment**, Amisterdã, v.122, p.75-91, 2012. Disponível em: https://doi.org/10.1016/j.rse.2011.10.030. Acesso em: 23 dez. 2024.

ZHU, Z.; WOODCOCK, C. E. Continuous change detection and classification of land cover using all available Landsat data. **Remote Sensing of Environment**, v. 144, p. 152-171, 2014. Disponível em: https://doi.org/10.1016/j.rse.2014.01.011. Acesso em: 01 jan. 2025.

ZULFIQAR, A.; GHAFFAR, M.M.; SHAHZAD, M.; WEIS, C.; MALIK, M.I.; SHAFAIT, F.; WEHN, N. AI-ForestWatch: semantic segmentation based end-to-end framework for forest estimation and change detection using multi-spectral remote sensing imagery. **Journal of Applied Remote Sensing**, v. 15, n. 02, p. 1-21, 2021. Disponível em: https://doi:10.1117/1.JRS.15.024518. Acesso em: 23 dez. 2024.

ZANELLA, L.; FOLKARD, A.M.; BLACKBURN, G.A.; CARVALHO, L. M.T. How well does random forest analysis model deforestation and forest fragmentation in the Brazilian Atlantic forest?. **Environmental and Ecological Statistics**, **24**, 529–549. 2017. Disponível em: https://doi.org/10.1007/s10651-017-0389-8. Acesso em: 23 dez. 2024.

10 APÊNDICE

O quadro abaixo evidencia a quantidade de imagens usadas no processamento do algoritmo de detecção de mudança e resultados gerados para o estado do Paraná ente os anos de 2019 a 2023.

QUADRO 13 – QUANTIDADE DE IMAGENS PROCESSADAS POR MESORREGIÕES PARA DETECÇÃO DE MUDANÇA NO GEE

Mesorregiões		**2019**	**2020**	**2021**	**2022**	**2023**
Noroeste		327	448	324	324	293
Norte Ocidental		220	336	231	230	232
Norte Pioneiro		178	236	147	168	168
Norte Central		217	333	211	350	335
Sudoeste		363	496	339	232	235
Sudeste		86	132	65	79	93
Centro Sul		278	414	263	268	280
Oeste		233	379	258	267	233
Norte Oriental		184	258	150	176	184
Metropolitana		83	113	71	77	83
Total		2.169	3.245	1.996	2.144	2.136

FONTE: O autor (2025).

A figura abaixo evidencia os resultados do processamento de imagens Sentinel-2 livres de incidência de nuvem por mesorregião do estado do Paraná entre os anos de 2019 e 2023.

FIGURA 33 – MAPEAMENTO GERADO PELO ALGORITMO DE DETECÇÃO DE MUDANÇA DESENVOLVIDO NO GEE

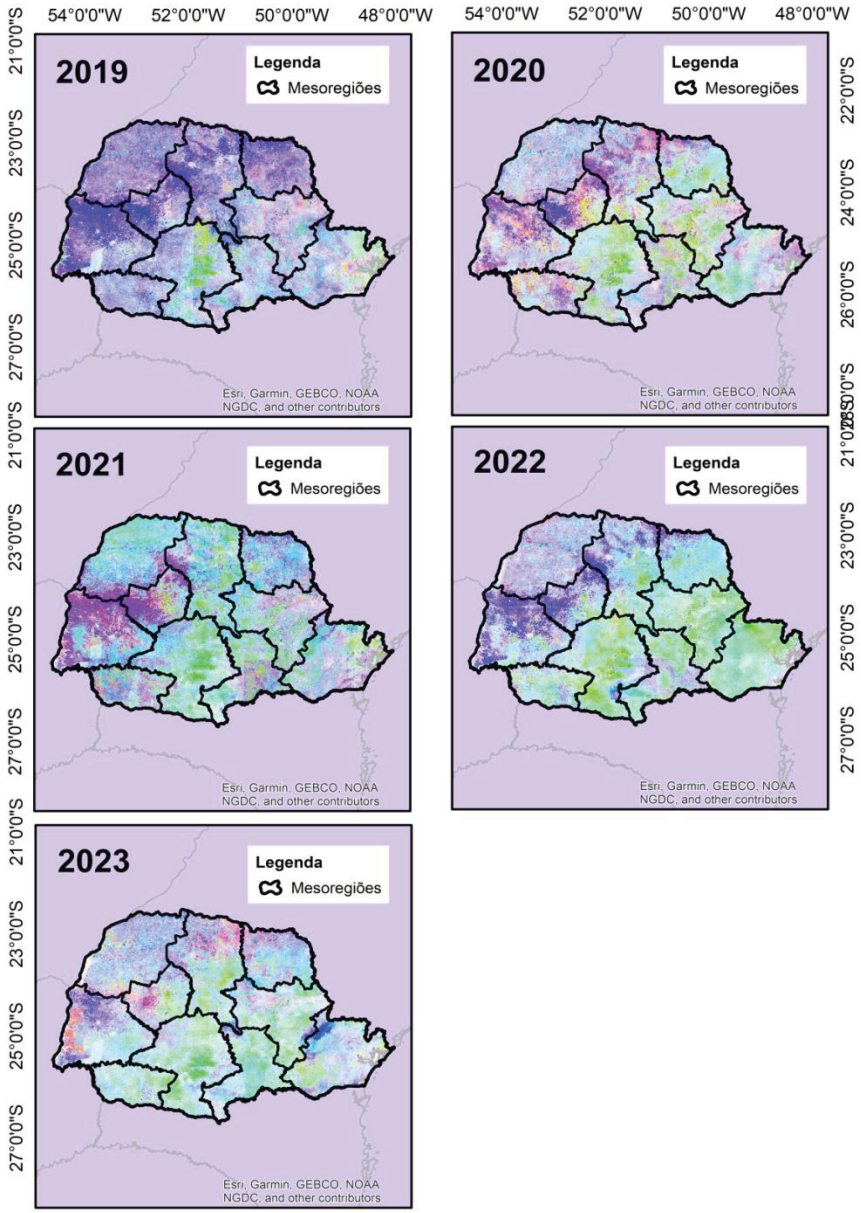

FONTE: O autor (2025).