



LUCAS GUEDES COSTA

**USO DE DRONES E GEOTECNOLOGIAS ABERTAS PARA
O MONITORAMENTO DA COBERTURA DO SOLO EM
UMA ÁREA DE RESTAURAÇÃO DA MATA ATLÂNTICA**

LAVRAS – MG

2026

LUCAS GUEDES COSTA

**USO DE DRONES E GEOTECNOLOGIAS ABERTAS PARA O
MONITORAMENTO DA COBERTURA DO SOLO EM UMA ÁREA DE
RESTAURAÇÃO DA MATA ATLÂNTICA**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do programa de Pós-Graduação em Tecnologias e Inovações Ambientais, área de concentração em Restauração e Conservação de Ecossistemas, para a obtenção do título de Mestre.

Prof. Dr. Luis Antonio Coimbra Borges

Orientador

LAVRAS – MG

2026

**Ficha Catalográfica elaborada pelo Sistema de Geração
de Ficha Catalográfica da Biblioteca Universitária da UFLA, com
dados informados pelo(a) próprio(a) autor(a).**

Costa, Lucas Guedes.

Uso de drones e geotecnologias abertas para o monitoramento da cobertura do solo
em uma área de restauração da mata atlântica / Lucas Guedes Costa. - 2026.
82 p. : il.

Orientador: Luis Antonio Coimbra Borges

Dissertação (Mestrado Profissional) - Universidade Federal de Lavras, 2026.
Bibliografia.

1. Restauração ecológica. 2. Veículos aéreos não tripulados. 3. Google earth
engine. 4. Classificação de cobertura do solo. I. Coimbra Borges, Luis Antonio. II.
Universidade Federal de Lavras. III. Título.

LUCAS GUEDES COSTA

**USO DE DRONES E GEOTECNOLOGIAS ABERTAS PARA O
MONITORAMENTO DA COBERTURA DO SOLO EM UMA
ÁREA DE RESTAURAÇÃO DA MATA ATLÂNTICA**

**USE OF DRONES AND OPEN GEOTECHNOLOGIES FOR MONITORING SOIL
COVER IN AN ATLANTIC FOREST RESTORATION AREA**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do programa de Pós- Graduação em Tecnologias e Inovações Ambientais, área de concentração em Restauração e Conservação de Ecossistemas, para a obtenção do título de Mestre.

APROVADA em 26 de março de 2026.

Prof. Dr. Luis Antonio Coimbra Borges UFLA

Prof. Dr. Ricardo Tayarol Marques IFMG

Prof. Dr. Douglas Machado Leite UFLA

Prof. Dr. Luis Antonio Coimbra Borges

Orientador

LAVRAS – MG

2026

AGRADECIMENTOS

Agradeço à Universidade Federal de Lavras (UFLA), ao Departamento de Ciências Florestais e ao Programa de Pós-Graduação em Tecnologias e Inovações Ambientais da UFLA (PPGTIA/UFLA), pela estrutura oferecida e pela oportunidade de realização do mestrado. Agradeço também aos professores e colegas com quem compartilhei essa trajetória na universidade.

Agradeço ao Instituto SuperAÇÃO, que concedeu-me a primeira experiência profissional após a graduação e permitiu que eu conciliasse as aulas do mestrado e as atividades profissionais durante o primeiro ano do curso. Agradeço também à Fundação SOS Mata Atlântica por incentivar o desenvolvimento deste trabalho e a conclusão do curso, além de permitir o uso de dados institucionais para a realização desta pesquisa.

Sou grato à minha família pelo apoio incondicional à minha formação ao longo da vida. Agradeço também à minha companheira, Aline, que esteve junto comigo e me apoiou em todos os momentos, sendo fundamental para que eu conseguisse equilibrar os desafios da vida adulta e meus objetivos pessoais.

Aos amigos da vida e aos colegas de trabalho, agradeço pela torcida, mesmo à distância, e pelas ricas trocas de experiência que contribuíram para a construção deste estudo. Em especial, aos colegas da equipe de restauração florestal da SOS Mata Atlântica e ao Caymmi, pelas contribuições, especialmente na reta final do trabalho.

Sou grato pela oportunidade de ser orientado pelo Prof. Dr. Luis Antonio Coimbra Borges, pela paciência ao longo do processo de amadurecimento das ideias e elaboração deste trabalho, e pelo apoio sempre presente quando precisei.

Por fim, agradeço pela minha vida, pela minha saúde e por ter tantas pessoas boas ao meu redor, em especial minha querida avó, Lica, que reza por mim todos os dias e a quem dedico a conclusão deste ciclo.

Viva o acesso à educação pública e de qualidade.

RESUMO

A restauração ecológica em larga escala na Mata Atlântica é estratégica para a conservação da biodiversidade e a resiliência ambiental do bioma, e demanda monitoramento padronizado, replicável e auditável para apoiar a gestão adaptativa e a prestação de contas. Este trabalho implementou e avaliou um fluxo digital de monitoramento baseado em dados obtidos por veículos aéreos não tripulados (VANTs) com sensores RGB (vermelho, verde e azul) e multiespectral, métricas estruturais derivadas de fotogrametria, incluindo o modelo de altura do dossel (CHM), índice espectral (NDVI), classificação supervisionada (*Random Forest*) e processamento em ferramentas abertas (*Google Earth Engine* e QGIS). Em uma área piloto de aproximadamente 13,0 ha, foram comparados dois períodos, T0 (abril de 2024) e T1 (janeiro de 2026; cerca de 20 meses pós-plantio), gerando mapas de cobertura do solo, estimativas de mudança líquida, análise de transições entre classes e comparação entre sensores no T1. Os resultados indicaram aumento de vegetação nativa e redução de gramíneas exóticas no período, com mudanças líquidas semelhantes entre sensores (Δ Vegetação Nativa: +2,91 ha no RGB e +3,00 ha no multiespectral; Δ Gramínea Exótica: -3,17 ha no RGB e -3,28 ha no multiespectral). A validação pontual indicou desempenho elevado (acurácia global $\approx$ 0,90–0,91; Macro-F1 $\approx$ 0,89–0,91), e as áreas por classe foram também reportadas com estimativas ajustadas por erro e IC95%, fortalecendo a robustez inferencial dos resultados. A concordância espacial entre RGB e multiespectral no T1 foi alta (86,7%), porém as discordâncias (13,3%) concentraram-se no estrato baixo (CHM < 1 m) e foram dominadas por trocas entre vegetação nativa jovem e gramínea, destacando uma zona crítica de incerteza em levantamentos iniciais. A validação independente por transectos de campo confirmou as estimativas dos mapas para o indicador de cobertura de vegetação nativa. Como contribuição aplicada, o estudo propõe uma estratégia operacional baseada no uso recorrente de RGB como referência de série temporal e no uso direcionado do multiespectral e do CHM como camadas de controle de qualidade e priorização de manejo em áreas críticas.

Palavras-chave: restauração ecológica; veículos aéreos não tripulados; google earth engine; classificação de cobertura do solo.

ABSTRACT

Large-scale ecological restoration in the Atlantic Forest is strategic for biodiversity conservation and environmental resilience and requires standardized, replicable, and auditable monitoring to support adaptive management and accountability. This study implemented and evaluated a digital monitoring workflow based on data obtained by unmanned aerial vehicles (UAVs) with RGB (red, green, and blue) and multispectral sensors, photogrammetry-derived structural metrics, including a canopy height model (CHM), spectral index (NDVI), supervised classification (*Random Forest*), and open-access tools (Google Earth Engine and QGIS). A pilot area of approximately 13.0 ha was assessed across two periods, T0 (April 2024) and T1 (January 2026; approximately 20 months after planting), generating land cover maps, net change estimates, class-transition analyses, and an RGB–multispectral comparison at T1. Results showed an increase in native vegetation and a reduction in exotic grass cover over time, with similar net changes across sensors (Δ native vegetation: +2.91 ha in RGB and +3.00 ha in multispectral; Δ grass: -3.17 ha in RGB and -3.28 ha in multispectral). Point-based validation indicated high performance (overall accuracy $\approx$ 0.90–0.91; Macro-F1 $\approx$ 0.89–0.91), and class areas were also reported as error-adjusted estimates with 95% confidence intervals, strengthening the inferential robustness of the results. Spatial agreement between RGB and multispectral classifications at T1 was high (86.7%); however, deviations (13.3%) were concentrated in the low-height stratum (CHM < 1 m) and were dominated by swaps between young native vegetation and grass, highlighting a critical uncertainty zone in early-stage surveys. Independent field-transect validation confirmed the map-based estimates for native vegetation cover. As an applied contribution, the study proposes an operational strategy based on the recurring use of RGB as a time-series baseline and the targeted use of multispectral data and CHM as layers for quality control and management prioritization in critical areas.

Keywords: ecological restoration; unmanned aerial vehicles; google earth engine; land cover classification.

INDICADORES DE IMPACTO

Este trabalho apresenta potenciais impactos principalmente nas dimensões tecnológica, social e ambiental. A pesquisa propõe e avalia, em uma área piloto de restauração ecológica na Mata Atlântica, um fluxo de monitoramento baseado em drones, classificação supervisionada, métricas estruturais da vegetação e ferramentas de processamento espacial. Como contribuição tecnológica, o estudo adapta um procedimento de monitoramento com potencial de uso operacional em projetos de restauração florestal, favorecendo maior padronização, rastreabilidade e consistência na produção de informações sobre cobertura do solo e estrutura da vegetação. Os impactos concretos diretos concentram-se, neste momento, na qualificação metodológica e no apoio ao aprimoramento das práticas de monitoramento aplicadas à restauração ecológica pela equipe da Fundação SOS Mata Atlântica (SOSMA). Os públicos potencialmente beneficiados incluem equipes técnicas de restauração, organizações da sociedade civil, proprietários rurais, parceiros institucionais e financiadores de projetos. O trabalho dialoga com a experiência profissional do autor no campo da restauração florestal, incluindo sua atuação na SOSMA, entende-se que a contribuição não se restringe a esse contexto, podendo subsidiar futuras aplicações em diferentes situações de monitoramento e gestão adaptativa. A metodologia encontra-se em fase de consolidação e foi concebida para permitir adaptação a diferentes áreas mediante ajustes mínimos na estrutura do código e substituição dos dados de entrada, embora essa capacidade ainda deva ser testada de forma mais ampla. Nesse sentido, os impactos ambientais e operacionais em maior escala permanecem potenciais e dependem de aplicações futuras do fluxo em novas áreas de restauração. A disponibilização dos scripts utilizados no fluxo de trabalho poderá ampliar a acessibilidade metodológica, favorecer adaptações em outros contextos e estimular o desenvolvimento colaborativo de novas aplicações, contribuindo para democratizar o acesso a soluções de monitoramento digital. O trabalho apresenta caráter aplicado e potencial extensionista, na medida em que seus resultados podem apoiar ações desenvolvidas em parceria com atores externos à UFLA, especialmente no âmbito de projetos de restauração florestal em propriedades privadas e iniciativas do terceiro setor. As áreas temáticas de extensão mais diretamente relacionadas ao estudo são Meio Ambiente e Tecnologia e Produção. Em relação aos Objetivos de Desenvolvimento Sustentável, o trabalho se alinha especialmente ao ODS 13 – Ação contra a mudança global do clima, ao ODS 15 – Vida terrestre e ao ODS 17 – Parcerias e meios de implementação.

IMPACT INDICATORS

This work presents potential impacts mainly in the technological, social, and environmental dimensions. The research proposes and evaluates, in a pilot ecological restoration area in the Atlantic Forest, a monitoring workflow based on drones, supervised classification, vegetation structural metrics, and spatial processing tools. As a technological contribution, the study adapts a monitoring procedure with potential for operational use in forest restoration projects, promoting greater standardization, traceability, and consistency in the production of information on land cover and vegetation structure. At this moment, the direct concrete impacts are concentrated in methodological enhancement and in supporting the improvement of monitoring practices applied to ecological restoration by the team at Fundação SOS Mata Atlântica (SOSMA). The potential beneficiaries include restoration technical teams, civil society organizations, rural landowners, institutional partners, and project funders. The work draws on the author's professional experience in the field of forest restoration, including his role at SOSMA; nonetheless, its contribution is understood not to be restricted to this context and may support future applications in different monitoring and adaptive management settings. The methodology is still being consolidated and was designed to allow adaptation to different areas through minimal adjustments to the code structure and replacement of the input data, although this capability still needs to be tested more broadly. In this sense, larger-scale environmental and operational impacts remain potential and depend on future applications of the workflow in new restoration areas. Making the scripts used in the workflow available may broaden methodological accessibility, foster adaptations in other contexts, and stimulate the collaborative development of new applications, contributing to democratizing access to digital monitoring solutions. The work has an applied character and extension potential, insofar as its results may support actions developed in partnership with stakeholders outside UFLA, especially within the scope of forest restoration projects on private lands and third-sector initiatives. The extension thematic areas most directly related to the study are Environment and Technology and Production. Regarding the Sustainable Development Goals, the work is especially aligned with SDG 13 – Climate Action, SDG 15 – Life on Land, and SDG 17 – Partnerships for the Goals.

LISTA DE FIGURAS

Figura 1 – Ortomosaico RGB da área de estudo (projeto piloto) em T0 e T1.	34
Figura 2 – Modelo de altura de dossel - CHM e ortomosaico - T0 - (Abril/2024).	38
Figura 3 – Distribuição das parcelas na Área de estudo - T1/Janeiro de 2026.....	42
Figura 4 – Registro fotográfico durante coleta de dados em campo.	43
Figura 5 – Modelos de altura de dossel - CHM no T0 e T1.....	46
Figura 6 – Uso e cobertura do solo no T0 (RGB).	48
Figura 7 – Uso e cobertura do solo nos momentos T0 e T1 (RGB).....	48
Figura 8 – Uso e cobertura do solo nos momentos T0 (RGB) e T1 (Multiespectral).	49
Figura 9 – Área por classe em T0 e T1 - Classificações de cobertura do solo com sensores RGB e Multiespectral (MS).	49
Figura 10 – Estabilidade do desempenho por amostragem aleatória repetida (n=20) – Acurácia Global (OA).	50
Figura 11 – Classificação de cobertura do solo no T1 utilizando sensores RGB e Multiespectral.....	51
Figura 12 – Mapa de discordância entre sensores no T1 (RGB × MS).....	51
Figura 13 – Relação CHM × NDVI: pixels em acordo vs discordância.	53
Figura 14 – Diagrama de fluxo entre classes de cobertura do solo em T1 para os modelos de classificação RGB e MS.....	54
Figura 15 – Gráfico de dispersão CHM x NDVI por classe - amostra de pixels estratificada.	56
Figura 16 – Mapa de transição da cobertura do solo de T0 (RGB) para T1 (RGB).....	59
Figura 17 – Diagrama de fluxo das classes na transição T0 → T1 (RGB).	60
Figura A1 – Variáveis preditoras mais importantes no modelo RGB em T1.	80
Figura A2 – Variáveis preditoras mais importantes no modelo multiespectral em T1.	81

LISTA DE TABELAS

Tabela 1 – Parâmetros dos Voos, Processamento de dados e Delineamento Experimental. ...	45
Tabela 2 – Área (ha) e percentual (%) de cobertura do solo por classe em T0 e T1.....	47
Tabela 3 – Métricas globais, validações e estabilidade dos modelos (T0 e T1).....	50
Tabela 4 – Discordância RGB×MS por faixa de CHM e tipo de troca (T1).....	52
Tabela 5 – Interpretação da discordância de classificação entre modelos RGB e MS.....	52
Tabela 6 – Diferença líquida de área por classe nos modelos de classificação RGB e MS no T1.....	53
Tabela 7 – Área por classe nos modelos de classificação RGB e MS no T1 e IC 95%.	55
Tabela 8 – Área ocupada por cada classe e a mediana de seus respectivos CHM e NDVI.	55
Tabela 9 – Área ocupada por cada classe, relacionando faixas de CHM e NDVI médio.	57
Tabela 10 – Valores de área e discordância por faixa de CHM x mediana de NDVI para a classificação multiespectral no T1.....	57
Tabela 11 – Cobertura arbórea nativa observada em campo (n=17 parcelas).....	58
Tabela 12 – Comparação do indicador “cobertura de vegetação nativa (%)” (campo e classificações de cobertura de vegetação nativa em T1).	58
Tabela 13 – Pares de transição de classes de cobertura do solo de T0 para T1.	59
Tabela 14 – Síntese do balanço de vegetação nativa entre T0 e T1 (ganho, perda e estabilidade).	60
Tabela 15 – Distribuições das principais transições T0 → T1 por faixa de altura relativa.....	61
Tabela B1 – Síntese dos relatórios de processamento fotogramétrico em T0 e T1.....	82

LISTA DE SIGLAS

ABC+	Plano de Agricultura de Baixa Emissão de Carbono.
AE	Árvore exótica.
CBERS	China-Brazil Earth Resources Satellite.
CBRN	Coordenadoria de Biodiversidade e Recursos Naturais.
CH	Corpo hídrico.
CHM	<i>Canopy Height Model</i> (Modelo de Altura do Dossel).
CSV	Comma-Separated Values.
DSM	Digital Surface Model (Modelo Digital de Superfície).
DTM	Digital Terrain Model (Modelo Digital de Terreno).
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária.
EPSG	European Petroleum Survey Group.
EVI	Enhanced Vegetation Index (Índice de Vegetação Aprimorado).
F1-score	Métrica baseada na média harmônica entre precisão e revocação.
FAO	Food and Agriculture Organization (Organização das Nações Unidas para a Alimentação e a Agricultura).
GCP	Ground Control Point (Ponto de Controle em Solo).
GE	Gramínea exótica.
GEE	Google Earth Engine.
GLCM	Gray Level Co-occurrence Matrix (Matriz de Coocorrência de Níveis de Cinza).
GLI	Green Leaf Index.
GNSS	Global Navigation Satellite System.
GSD	Ground Sampling Distance (Distância de Amostragem do Solo).
IBGE	Instituto Brasileiro de Geografia e Estatística.
IC95%	Intervalo de confiança de 95%.
INMET	Instituto Nacional de Meteorologia.
INPE	Instituto Nacional de Pesquisas Espaciais.
LiDAR	Light Detection and Ranging.
MDS	Modelo Digital de Superfície.
MDT	Modelo Digital de Terreno.
MMA	Ministério do Meio Ambiente.
MODIS	Moderate Resolution Imaging Spectroradiometer.
MS	Multispectral.

NDRE	Normalized Difference Red Edge (Índice de Vegetação com Red Edge).
NDVI	Normalized Difference Vegetation Index (Índice de Vegetação por Diferença Normalizada).
NIR	Near Infrared (Infravermelho Próximo).
OA	Overall Accuracy (Acurácia Global).
ODS	Objetivos de Desenvolvimento Sustentável.
ONU	Organização das Nações Unidas.
PA	Producer's Accuracy (Acurácia do Produtor).
Planaveg	Plano Nacional de Recuperação da Vegetação Nativa.
PPK	Post-Processed Kinematic (Pós-Processamento Cinemático).
PROBA-V	Project for On-Board Autonomy – Vegetation.
QGIS	Quantum Geographic Information System.
RGB	Red, Green, Blue (Vermelho, Verde, Azul).
RMSE	Root Mean Square Error (Raiz do Erro Quadrático Médio).
RTK	Real Time Kinematic.
SE	Solo exposto.
SER	Society for Ecological Restoration (Sociedade Internacional para a Restauração Ecológica).
SfM	<i>Structure from Motion.</i>
SIG	Sistema de Informações Geográficas.
SIMA	Secretaria de Infraestrutura e Meio Ambiente do Estado de São Paulo.
SIRGAS	Sistema de Referência Geocêntrico para as Américas.
SMA	Secretaria do Meio Ambiente do Estado de São Paulo.
SOSMA	Fundação SOS Mata Atlântica.
T0 / T1	Períodos analisados no estudo, sendo T0 a linha de base e T1 o monitoramento posterior.
UA	User's Accuracy (Acurácia do Usuário).
UNEP	United Nations Environment Programme (Programa das Nações Unidas para o Meio Ambiente).
UTM	Universal Transverse Mercator (Projeção Universal Transversa de Mercator).
VANT	Veículo Aéreo Não Tripulado.
VARI	Visible Atmospherically Resistant Index.
VN	Vegetação nativa.

SUMÁRIO

1	INTRODUÇÃO	15
2	OBJETIVOS	18
2.1	Objetivo Geral	18
2.2	Objetivos Específicos.....	18
3	REVISÃO DE LITERATURA.....	19
3.1	Políticas públicas e iniciativas para a restauração ecológica.....	19
3.2	Atores, modelos de implementação e o papel estratégico do monitoramento.....	21
3.3	Sensoriamento remoto aplicado ao monitoramento da restauração	22
3.3.1	Plataformas orbitais e suas contribuições	23
3.3.2	Índices espectrais e métricas derivadas.....	23
3.3.3	Drones, alta resolução e flexibilidade operacional	24
3.4	Fotogrametria com drones, modelos de altura e integração com LiDAR	25
3.5	Integração de dados, aprendizado de máquina e ferramentas abertas	26
3.5.1	Aprendizado de máquina para classificação da cobertura do solo.....	27
3.5.2	Validação e análise de incerteza.....	28
3.5.3	Plataformas abertas e escalabilidade.....	28
3.5.4	Protocolos e indicadores padronizados para monitoramento	29
3.6	Síntese crítica da literatura e direcionamento da pesquisa	31
4	MATERIAL E MÉTODOS	33
4.1	Área de estudo e delineamento experimental.....	33
4.1.1	Fluxo analítico do trabalho.....	35
4.2	Coleta de dados com VANT.....	35
4.3	Processamento fotogramétrico e geração de produtos.....	36
4.3.1	Controle de qualidade do processamento fotogramétrico (T0 e T1)	36
4.3.2	Considerações radiométricas e índices espectrais (NDVI)	37
4.4	Fluxo de trabalho no <i>Google Earth Engine</i>	37
5	RESULTADOS	46
5.1	Área piloto, delineamento amostral e produtos-base.....	46
5.2	Cobertura do solo em T0 e T1 (RGB e Multiespectral)	47
5.3	Desempenho e estabilidade dos modelos de classificação (T0 e T1).....	49
5.4	Comparação de sensores RGB × Multiespectral na classificação de cobertura do solo em T1: concordância, discordância e papel da estrutura (CHM).....	50
5.4.1	Papel de CHM e NDVI (T1 MS): separabilidade por classe e gradientes.....	55
5.5	Dados de campo como checagem independente do indicador de cobertura de dossel	57
5.6	Transições T0 → T1 e decomposição do ganho de vegetação nativa	58
6	DISCUSSÃO	62

6.1	Leitura do avanço da restauração a partir da mudança de cobertura (T0–T1).....	62
6.2	Comparação RGB × Multiespectral no T1: onde os sensores diferem e por quê isso importa	64
6.3	Checagem independente com dados de campo e implicações para indicadores.....	65
6.4	Limitações relevantes e recomendações aplicadas	66
7	CONCLUSÕES	70
	REFERÊNCIAS	72
	GLOSSÁRIO	79
	APÊNDICE A – IMPORTÂNCIA DAS VARIÁVEIS PREDITORAS NAS CLASSIFICAÇÕES SUPERVISIONADAS.....	80
	APÊNDICE B – RELATÓRIOS DE PROCESSAMENTOS FOTOGRAMÉTRICOS.....	82

1 INTRODUÇÃO

A restauração ecológica vem se consolidando, nas últimas décadas, como uma estratégia central no enfrentamento da crise ambiental global, ao responder simultaneamente a desafios relacionados à perda de biodiversidade, às mudanças climáticas e à degradação dos ecossistemas. Mais do que a simples recomposição da cobertura vegetal, a restauração busca reestabelecer a trajetória ecológica, a funcionalidade e a capacidade dos ecossistemas de sustentar a biodiversidade nativa ao longo do tempo, reconhecendo que diferentes contextos de degradação, históricos de uso da terra e estratégias de intervenção podem conduzir a distintas trajetórias e níveis de recuperação (GANN *et al.*, 2019). Nesse contexto, a recuperação de áreas degradadas tem ganhado destaque crescente em agendas internacionais, nacionais e regionais, tanto por seu potencial ecológico, quanto por sua contribuição para soluções baseadas na natureza, com efeitos positivos sobre a regulação climática, a conservação da água, a proteção do solo e a sustentabilidade dos sistemas produtivos.

No Brasil, esse debate assume especial relevância em razão da expressiva diversidade biológica do país, de sua importância para os ciclos biogeoquímicos globais e da magnitude das áreas degradadas passíveis de recuperação. O país vem consolidando instrumentos institucionais relacionados à restauração e à conservação, com destaque para políticas públicas e metas nacionais voltadas à recuperação da vegetação nativa (BRASIL, 2024). A execução dessa agenda, entretanto, envolve uma cadeia complexa de etapas interdependentes, que vai do financiamento e da mobilização institucional à coleta de sementes, à produção de mudas, à implementação em campo e ao monitoramento, sendo intensiva em coordenação, dependente de mão de obra qualificada e exposta a múltiplos riscos operacionais, ecológicos e socioeconômicos. Trata-se, portanto, de um campo que exige articulação entre comunidades locais, proprietários rurais, setor público, iniciativa privada e instituições de pesquisa.

No contexto brasileiro, a Mata Atlântica se destaca como um dos recortes mais relevantes para a restauração ecológica. Reconhecida mundialmente como *hotspot* de biodiversidade, o bioma apresenta elevado grau de endemismo e intensa pressão antrópica histórica, com cerca de 12,4% de matas maduras remanescentes, distribuídas em fragmentos isolados, sob forte competição pelo uso da terra e em um contexto de alta densidade populacional e diversidade de regimes fundiários (MYERS *et al.*, 2000; SOSMA; INPE, 2025). Esse conjunto de fatores torna a restauração na Mata Atlântica particularmente desafiadora, exigindo abordagens capazes de lidar com elevada heterogeneidade ambiental, restrições operacionais e necessidade de ganhos de escala. Por outro lado, o bioma também tem se

constituído historicamente como espaço de inovação e construção de arranjos colaborativos, como evidencia o Pacto pela Restauração da Mata Atlântica, que reúne mais de 350 instituições em torno de metas comuns (RODRIGUES *et al.*, 2011; TOTO *et al.*, 2025).

Entre as dimensões que compõem o ciclo da restauração, o monitoramento ocupa papel estratégico. É por meio dele que se torna possível acompanhar a trajetória das áreas em recuperação, identificar limitações e riscos, orientar ajustes de manejo, comunicar resultados e fortalecer a transparência das intervenções frente a financiadores, gestores e à sociedade. O monitoramento subsidia a gestão adaptativa e transforma dados em informação útil para a tomada de decisão em diferentes estágios do projeto, desde o planejamento à implementação e à avaliação de resultados (GANN *et al.*, 2019; HOLL, 2023; PACTO, 2013).

Apesar de sua relevância, o monitoramento frequentemente compete por recursos com etapas consideradas mais imediatas, como implantação, aquisição de insumos e manutenção, ocupando posição periférica em parte dos projetos. Além disso, a dispersão territorial das áreas, a escassez de recursos, a dificuldade de acesso ao campo e a dependência de equipes especializadas restringem a adoção de métodos presenciais intensivos, comprometendo a produção de informações sistemáticas, comparáveis e oportunas. Esse cenário reforça a necessidade de soluções inovadoras e escaláveis. Nesse sentido, o avanço das geotecnologias, do sensoriamento remoto de alta resolução, dos veículos aéreos não tripulados e de plataformas abertas de processamento de dados geoespaciais abre caminhos promissores para o aprimoramento do monitoramento.

Trabalhos recentes têm demonstrado o potencial de drones de baixo custo para monitorar atributos estruturais de dossel em áreas de restauração, incluindo comparações entre sensores RGB e LiDAR (SANTORO *et al.*, 2025) e entre métodos de estimativa de cobertura por limiar (ALBUQUERQUE *et al.*, 2023). Essas contribuições consolidam a viabilidade técnica do sensoriamento remoto de alta resolução para a restauração florestal. No entanto, a classificação supervisionada multitemporal do uso e cobertura do solo, a quantificação de incertezas nas estimativas de área por classe e a correspondência com protocolos de monitoramento recentemente estabelecidos para a Mata Atlântica, como o Protocolo de Sensoriamento Remoto do Pacto (ALBUQUERQUE *et al.*, 2024), constituem dimensões ainda pouco exploradas, especialmente em contextos de estágios iniciais de restauração, nos quais gramíneas exóticas e vegetação nativa incipiente coexistem em condições estruturais semelhantes. Além disso, a definição de estratégias práticas sobre quando e como empregar cada tipo de sensor, e em quais condições a discordância entre eles é mais relevante para a gestão, constitui uma lacuna com implicações diretas para a tomada de decisão operacional.

Diante desse contexto, esta pesquisa implementa e avalia um fluxo metodológico para o monitoramento multitemporal de áreas em restauração ecológica na Mata Atlântica, integrando imagens obtidas por drones com sensores RGB e multiespectral, métricas estruturais derivadas de fotogrametria, incluindo o Modelo de Altura do Dossel (CHM), classificação supervisionada por aprendizado de máquina e processamento em ferramentas abertas, como *Google Earth Engine* (GEE) e QGIS. O objetivo central é produzir avaliações objetivas, replicáveis e auditáveis, capazes de ampliar a capacidade de observação das trajetórias de restauração, apoiar a priorização de ações de manejo e qualificar a gestão técnica dos projetos, em alinhamento com referenciais nacionais e internacionais de monitoramento.

A contribuição pretendida não é substituir o monitoramento de campo, que permanece essencial para a interpretação ecológica e a validação das trajetórias de restauração, mas oferecer um instrumento complementar, capaz de ampliar o alcance e a frequência das avaliações sem prescindir do rigor analítico. Ao focalizar a detecção e a análise de mudanças em estágios iniciais da restauração, o trabalho busca contribuir para o desenvolvimento de soluções mais objetivas e escaláveis, com potencial de aplicação por organizações do terceiro setor, gestores de projetos e demais atores envolvidos com a restauração florestal na Mata Atlântica, aproximando ciência aplicada, inovação tecnológica e prática de campo.

2 OBJETIVOS

2.1 Objetivo Geral

Implementar e avaliar um fluxo digital de monitoramento multitemporal da restauração ecológica na Mata Atlântica, com uso de drones e geotecnologias abertas, baseado na classificação da cobertura do solo, na análise de mudanças e em métricas estruturais da vegetação.

2.2 Objetivos Específicos

1 - Aplicar, validar e analisar o desempenho de uma rotina de classificação supervisionada do uso e cobertura do solo em dois períodos (pré-restauração e pós- plantio), utilizando produtos de fotogrametria de drone RGB, pontos de amostragem georreferenciados e processamento no GEE, com avaliação baseada em métricas quantitativas, mapas temáticos e análise crítica das limitações.

2 - Integrar dados multiespectrais no período pós-plantio e incorporar métricas estruturais (CHM) e espectrais para: (i) avaliar separabilidade entre classes; (ii) comparar o desempenho e a concordância espacial das classificações RGB e multiespectral no período pós-plantio (T1); e (iii) identificar, com base em métricas estruturais (CHM) e espectrais (NDVI), as zonas críticas de incerteza na separação entre vegetação nativa jovem e gramínea exótica.

3 - Quantificar a dinâmica $T0 \rightarrow T1$ por mudanças líquidas e transições entre classes e reportar incerteza de área por classe em T1 (IC95%), a partir das matrizes de confusão.

3 REVISÃO DE LITERATURA

3.1 Políticas públicas e iniciativas para a restauração ecológica

A agenda global de restauração ecológica ganhou impulso nas últimas décadas com marcos como a Década da Organização das Nações Unidas (ONU) para a Restauração de Ecossistemas, o Desafio de Bonn e a Iniciativa 20x20, que estabeleceram metas ambiciosas e estimularam a articulação entre políticas públicas, ciência e inovação (CHAZDON *et al.*, 2017; FAO; UNEP, 2021). Revisões internacionais, no entanto, indicam que o sucesso dessas iniciativas em países do Sul Global depende menos da definição de metas amplas e mais da capacidade de combiná-las com incentivos econômicos, governança participativa e monitoramento transparente. Em contextos de elevada heterogeneidade fundiária e socioeconômica, como o brasileiro, abordagens exclusivamente centralizadas tendem a apresentar resultados limitados, enquanto arranjos que articulam regulação, assistência técnica e participação local demonstram maior efetividade e permanência (BRANCALION; HOLL, 2020; CHAZDON *et al.*, 2020).

O Brasil ocupa posição central nessa agenda ao implementar o Plano Nacional de Recuperação da Vegetação Nativa (Planaveg), cuja versão 2025-2028 reafirma a meta de restaurar 12 milhões de hectares até 2030 e prioriza ações relacionadas ao monitoramento integrado, ao fortalecimento da cadeia produtiva e à inovação (BRASIL, 2024). Paralelamente, o Plano ABC+, voltado à agricultura de baixa emissão de carbono, estabelece a meta de recuperar 30 milhões de hectares de pastagens degradadas até 2030, criando sinergias com a agenda da restauração ao ampliar estoques de carbono e reduzir a pressão de conversão de uso do solo sobre a vegetação nativa (BARRETTO *et al.*, 2023). Ainda assim, a literatura ressalta que, sem mecanismos robustos de governança e inclusão social, a intensificação produtiva pode gerar impactos desiguais ou novos vetores indiretos de desmatamento, reforçando a necessidade de articulação entre Planaveg, Plano ABC+ e instrumentos de avaliação integrada (BARRETTO *et al.*, 2023; CHAZDON *et al.*, 2020).

No plano legal, a Lei da Mata Atlântica, Lei nº 11.428/2006, estabeleceu normas específicas para a proteção e o uso do bioma, regulamentando a supressão de vegetação, os usos permitidos em diferentes estágios sucessionais e mecanismos de compensação e restauração em Áreas de Preservação Permanente e Reserva Legal. Ao relacionar autorizações ao estado de conservação da vegetação e prever instrumentos voltados à manutenção e à recuperação da cobertura florestal, a lei consolidou um arcabouço jurídico relevante para a restauração em propriedades privadas. Nesse contexto, o Pacto pela Restauração da Mata Atlântica se destaca como importante arranjo de governança colaborativa, reunindo mais de 350 instituições

públicas, privadas e da sociedade civil em torno de metas comuns e da difusão de experiências técnicas e institucionais (RODRIGUES *et al.*, 2011; TOTO *et al.*, 2025). Estudos recentes indicam que regiões com atuação articulada de instituições vinculadas ao Pacto apresentaram incrementos líquidos de cobertura florestal, associados ao fortalecimento institucional local, à assistência técnica e à oferta de incentivos econômicos (FERNANDES *et al.*, 2025; TOTO *et al.*, 2025).

Apesar desses avanços, a implementação da restauração na Mata Atlântica continua condicionada por desafios estruturais expressivos. O bioma concentra cerca de 70% da população brasileira e 80% do produto interno bruto nacional, ao mesmo tempo em que mantém reduzida proporção de remanescentes florestais maduros, distribuídos em fragmentos isolados sob intensa pressão antrópica (SOSMA; INPE, 2025). A persistência do desmatamento em áreas privadas evidencia que a expansão da restauração não pode ser dissociada de estratégias que articulem produção, conservação e regularização ambiental em um mosaico territorial complexo (SOSMA; INPE, 2025). Nessa direção, pesquisas recentes acrescentam uma contribuição importante ao debate ao demonstrar que, entre 2011 e 2021, cerca de 1,67 milhão de hectares de floresta nativa se recuperaram na Mata Atlântica e persistiram até 2023, mas aproximadamente 568 mil hectares de florestas recuperadas no período não persistiram até esse mesmo ano (TONETTI *et al.*, 2026). Os autores argumentam que, embora a regeneração florestal em larga escala revele alto potencial de recuperação no bioma, a baixa persistência temporal de parte dessas áreas compromete os benefícios esperados para biodiversidade, serviços ecossistêmicos e metas de restauração, reforçando a urgência de mecanismos de proteção, incentivos econômicos e monitoramento contínuo.

Esse achado é particularmente relevante para a formulação e avaliação de políticas públicas, pois sugere que o êxito da restauração não deve ser medido apenas pela área inicialmente recuperada, mas também pela capacidade de assegurar a permanência das florestas em regeneração ao longo do tempo. No caso da Mata Atlântica, em que grande parte da recuperação ocorre em paisagens antropizadas e fortemente fragmentadas, a literatura indica que a regeneração natural tem papel estratégico e custo-efetivo, mas depende de ambiente institucional favorável, proteção regulatória e instrumentos que reduzam a vulnerabilidade dessas formações à reconversão do uso da terra (CHAZDON *et al.*, 2020; CROUZEILLES *et al.*, 2020; TONETTI *et al.*, 2026). O próprio Planaveg reconhece esses gargalos ao indicar inteligência espacial, monitoramento sistemático e integração de atores como pilares prioritários. A efetividade dessas políticas, contudo, dependerá da capacidade de adaptá-las às realidades locais, garantir apoio institucional de longo prazo e manter coerência entre

instrumentos legais, econômicos e operacionais já existentes (BRASIL, 2024; CHAZDON *et al.*, 2020; FERNANDES *et al.*, 2025).

3.2 Atores, modelos de implementação e o papel estratégico do monitoramento

A restauração ecológica no Brasil mobiliza uma ampla diversidade de atores, incluindo proprietários rurais, povos tradicionais, comunidades locais, setor privado, organizações da sociedade civil e Estado. A interação entre esses grupos envolve interesses, capacidades e expectativas nem sempre convergentes, o que torna a governança da restauração dependente de arranjos adaptativos, negociação contínua e coordenação multissetorial (BRASIL, 2024; FERNANDES *et al.*, 2025). Nesse contexto, o envolvimento comunitário e o protagonismo local têm sido apontados como fatores relevantes para a legitimidade e a resiliência das áreas restauradas, seja pelo fortalecimento do capital social, seja pela mobilização de conhecimentos tradicionais aplicados ao manejo de espécies, à leitura da paisagem e à identificação de áreas prioritárias (MELI *et al.*, 2017; TOTO *et al.*, 2025).

Na Mata Atlântica, contudo, a implementação da restauração continua condicionada por limitações que vão além da esfera institucional. Apesar da atuação de coalizões amplas e de redes colaborativas, desafios como altos custos iniciais, escassez de mão de obra qualificada, fragmentação fundiária e incerteza quanto aos benefícios de longo prazo ainda restringem a adesão de médios e grandes proprietários rurais (FERNANDES *et al.*, 2025; TOTO *et al.*, 2025). Além disso, a literatura e relatos de campo têm evidenciado problemas estruturais menos visíveis nos debates normativos, como a precarização das etapas de implantação, a informalidade nas relações de trabalho, a carência de viveiros florestais estruturados e a descontinuidade dos projetos após o encerramento dos financiamentos. Esses fatores afetam desde a cadeia de suprimento de sementes e mudas, ainda fortemente dependente de redes informais, até a rastreabilidade, a qualidade genética do material plantado e a sustentabilidade ecológica das áreas restauradas (GUARIGUATA; BRANCALION, 2014; SCHMIDT *et al.*, 2019).

Esses desafios ajudam a explicar por que a restauração ecológica, na prática, assume diferentes modelos de implementação. No Brasil, predominam dois paradigmas principais. O primeiro é a restauração ativa, baseada no plantio de mudas e/ou sementes nativas, no controle de espécies invasoras e em manejo intensivo nos estágios iniciais. O segundo é a restauração passiva, ou regeneração natural, que se apoia na proteção contra distúrbios e na capacidade de resiliência do próprio ecossistema (CROUZEILLES *et al.*, 2020; GANN *et al.*, 2019; MELI *et al.*, 2017). Entre esses extremos, modelos híbridos têm ganhado espaço por combinarem intervenções mais direcionadas com o aproveitamento do potencial regenerativo local,

buscando conciliar eficiência ecológica, viabilidade operacional e redução de custos (CROUZEILLES *et al.*, 2020; TOTO *et al.*, 2025).

A escolha entre esses modelos depende de fatores como histórico de uso do solo, intensidade da degradação, proximidade de remanescentes nativos, disponibilidade de recursos e objetivos ecológicos e socioeconômicos do projeto. Por isso, a permanência e a qualidade dos resultados não decorrem apenas da técnica adotada, mas também da capacidade de ajustar a intervenção às condições locais e de sustentar o acompanhamento ao longo do tempo. Em outras palavras, a restauração não se encerra na implantação. Sua efetividade depende da trajetória posterior da área, da resposta da vegetação, da redução de ameaças e da manutenção das condições necessárias para que o processo ecológico avance. Essa permanência é também relevante para a integridade de iniciativas associadas à provisão de serviços ecossistêmicos e à manutenção de estoques de carbono ao longo do tempo.

É nesse ponto que o monitoramento assume papel transversal e estratégico. Mais do que uma etapa técnica, ele subsidia a gestão adaptativa, permitindo ajustes com base em evidências, qualifica a prestação de contas a financiadores e fortalece a transparência das intervenções perante a sociedade (GANN *et al.*, 2019; HOLL, 2023; PACTO, 2013). A literatura da restauração enfatiza que o monitoramento deve ser planejado desde o início do projeto, com definição de linha de base, indicadores, marcos temporais e mecanismos de revisão. Os padrões internacionais da *Society for Ecological Restoration* reforçam, nesse sentido, a importância de documentar métodos, registrar evidências e comunicar resultados de forma transparente, de modo que a avaliação da trajetória de restauração seja possível ao longo do tempo (GANN *et al.*, 2019).

Na prática, porém, restrições de custo, a dispersão territorial das áreas, a dificuldade de acesso a campo e a dependência de equipes especializadas restringem a adoção de métodos presenciais intensivos, comprometendo a produção de informações sistemáticas, comparáveis e oportunas (SUDING, 2011). Esse cenário reforça a demanda por soluções de monitoramento mais acessíveis, escaláveis e operacionalmente viáveis, capazes de ampliar a frequência e a cobertura das avaliações sem renunciar ao rigor analítico. É nesse contexto que o sensoriamento remoto, o uso de drones e a integração de ferramentas digitais passam a ocupar papel crescente no monitoramento da restauração, tema desenvolvido nas próximas seções.

3.3 Sensoriamento remoto aplicado ao monitoramento da restauração

O sensoriamento remoto consolidou-se como ferramenta central para o monitoramento ambiental, sobretudo por sua escalabilidade, capacidade de automação e potencial para gerar séries temporais consistentes (FRANKLIN; AHMED, 2018). No contexto da restauração

ecológica, sua aplicação permite avaliar mudanças na cobertura do solo, estimar atributos biofísicos da vegetação e subsidiar a tomada de decisão em diferentes escalas espaciais e temporais. Revisões recentes sistematizam o estado da arte do sensoriamento remoto aplicado ao monitoramento da restauração de florestas tropicais, abrangendo desde imagens RGB de altíssima resolução até dados multi e hiperespectrais, LiDAR, radar e sensores termais, e destacam soluções de baixo custo, escaláveis e transferíveis para o acompanhamento da recuperação florestal (ALMEIDA *et al.*, 2025).

3.3.1 Plataformas orbitais e suas contribuições

Entre as plataformas gratuitas disponíveis, os satélites Sentinel-2, da Agência Espacial Europeia, destacam-se por oferecer resolução espacial de 10 m nas bandas do visível e do infravermelho próximo, revisita frequente, de até cinco dias, e bandas na região do *red-edge*, sensíveis a variações na estrutura e no vigor da vegetação. Essas características tornam o Sentinel-2 particularmente valioso para o acompanhamento da dinâmica de mosaicos em restauração. Ainda assim, séries históricas como Landsat e CBERS seguem relevantes para análises multitemporais de longo prazo, especialmente quando o interesse recai sobre trajetórias pretéritas de uso e cobertura do solo (HUETE *et al.*, 2002; NEMANI *et al.*, 2003).

3.3.2 Índices espectrais e métricas derivadas

A aplicação de índices espectrais permite estimar atributos da vegetação de forma padronizada. O NDVI, *Normalized Difference Vegetation Index*, é amplamente utilizado para indicar vigor vegetativo e biomassa verde. O NDRE, *Normalized Difference Red Edge*, por sua maior sensibilidade ao conteúdo de clorofila, pode contribuir para a discriminação de vegetação jovem ou sob estresse. Já o EVI, *Enhanced Vegetation Index*, reduz problemas de saturação em áreas com dossel mais fechado e minimiza parte dos efeitos atmosféricos, ampliando sua utilidade em contextos de maior densidade vegetal (HUETE *et al.*, 2002). Revisões sistemáticas recentes sistematizam esses indicadores em quatro eixos de monitoramento da restauração - floresta, solo, água e atmosfera - posicionando índices de vegetação como NDVI e EVI como *proxies* estruturais do eixo florestal, ao lado de métricas como cobertura vegetal fracionada e índice de área foliar (WANG *et al.*, 2024).

Além dos índices espectrais, métricas texturais têm sido empregadas para refinar a interpretação de mosaicos heterogêneos. Entre elas, destacam-se aquelas derivadas da GLCM, *Gray Level Co-occurrence Matrix*, capazes de capturar informações relacionadas à rugosidade, heterogeneidade e organização espacial dos tons de cinza na imagem, o que favorece a diferenciação de padrões estruturais finos da vegetação e do uso do solo (HARALICK *et al.*,

1973; FARWELL *et al.*, 2020; ALZHANOV *et al.*, 2024). Estudos recentes também exploram o coeficiente de variação em bandas *red-edge* como *proxy* de diversidade funcional em diferentes estágios sucessionais, sugerindo potencial para análises mais sensíveis da heterogeneidade ecológica em áreas em restauração (LABRADOR *et al.*, 2022; PERRONE *et al.*, 2023)

Apesar desses avanços, persistem limitações importantes. Em regiões como a Mata Atlântica, a alta nebulosidade e a fragmentação extrema restringem a obtenção de imagens orbitais com qualidade suficiente para análises multitemporais consistentes (HANSEN *et al.*, 2013; SOUZA *et al.*, 2020). Na Serra do Mar, por exemplo, a janela anual para aquisição de imagens Sentinel-2 com cobertura de nuvens inferior a 20% pode se restringir a aproximadamente três a cinco meses, o que exige estratégias complementares, como o uso de dados de radar, a exemplo do Sentinel-1, ou a integração com sensores embarcados em drones (SOSMA; INPE, 2025).

3.3.3 Drones, alta resolução e flexibilidade operacional

O avanço dos veículos aéreos não tripulados, VANTs, ampliou significativamente as possibilidades de aquisição de dados ambientais ao permitir imagens com resolução espacial centimétrica, maior flexibilidade temporal e custos operacionais relativamente reduzidos em comparação com levantamentos convencionais (ROBINSON *et al.*, 2022; WESTOBY *et al.*, 2012). No contexto da restauração ecológica, esses atributos tornam os drones especialmente úteis para o monitoramento de áreas menores, heterogêneas ou que demandam maior detalhamento espacial.

Câmeras RGB embarcadas em drones permitem a geração de ortomosaicos de alta resolução, revelando padrões estruturais da vegetação e detalhes do uso e cobertura do solo. No entanto, sua capacidade de discriminar estágios sucessionais, espécies ou condições fisiológicas da vegetação é limitada pela ausência de informações além do espectro visível. Sensores multiespectrais, por sua vez, incorporam bandas adicionais, como infravermelho próximo e *red-edge*, permitindo o cálculo de índices como NDVI e NDRE, o que amplia o potencial de avaliação do vigor, da condição fisiológica e, em alguns casos, da heterogeneidade funcional da vegetação (FRANKLIN; AHMED, 2018; PERRONE *et al.*, 2023).

Além disso, evidências empíricas recentes em restauração da Mata Atlântica mostram que a fusão de LiDAR e sensores hiperespectrais permite estimar com precisão atributos estruturais como altura de dossel e biomassa, enquanto a discriminação de diversidade de espécies depende de informação espectral mais fina, não capturada por métricas estruturais isoladas (ALMEIDA *et al.*, 2021).

A escolha entre sensores envolve compromissos entre custo, riqueza de informação e viabilidade operacional. Enquanto sensores multiespectrais oferecem maior detalhamento espectral, seu custo pode ser significativamente superior ao de câmeras RGB, aspecto particularmente relevante em projetos com restrições orçamentárias (SANTORO *et al.*, 2025). Além disso, tanto sensores RGB quanto multiespectrais demandam cuidados com calibração radiométrica¹, de modo a garantir maior comparabilidade entre datas de aquisição e diferentes condições de iluminação. Embora sensores multiespectrais ampliem o potencial de discriminação da vegetação por incorporarem bandas além do espectro visível, sua vantagem prática nem sempre se traduz em ganhos universais de classificação. Em contextos de restauração, esse benefício tende a ser mais evidente em situações nas quais a vegetação jovem apresenta baixa biomassa e forte sobreposição visual com gramíneas, enquanto sensores RGB podem sustentar, com maior viabilidade operacional, o monitoramento recorrente em projetos com restrições de custo e escala. Assim, a comparação entre RGB e multiespectral deve ser compreendida menos como substituição direta e mais como problema de complementaridade, custo-benefício e adequação ao estágio da restauração (ALMEIDA *et al.*, 2021; FRANKLIN; AHMED, 2018; ALBUQUERQUE *et al.*, 2024).

A integração entre dados RGB e multiespectrais, aliada a técnicas fotogramétricas para modelagem estrutural do dossel, constitui uma abordagem promissora no monitoramento da restauração e é aprofundada na seção seguinte.

3.4 Fotogrametria com drones, modelos de altura e integração com LiDAR

A técnica de *Structure from Motion* (SfM), aplicada a imagens adquiridas por drones, possibilita a reconstrução tridimensional da superfície imageada e a geração de produtos como ortomosaicos, isto é, mosaicos de imagens aéreas geometricamente corrigidos e passíveis de medição, além de Modelos Digitais de Superfície (MDS) e Modelos Digitais de Terreno (MDT). A partir da diferença entre esses dois últimos, obtém-se o Modelo de Altura do Dossel, *Canopy Height Model* (CHM), que representa a altura da vegetação em relação ao solo e constitui uma das métricas estruturais mais relevantes para o monitoramento da restauração (FORSMO *et al.*, 2019). O CHM permite acompanhar o desenvolvimento vertical da vegetação ao longo do tempo, apoiar a diferenciação de estágios sucessionais, subsidiar estimativas de biomassa acima do solo e qualificar a avaliação da complexidade estrutural do dossel.

¹ Calibração radiométrica é o processo de conversão dos números digitais registrados pelo sensor em valores comparáveis de reflectância de superfície, permitindo maior consistência entre aquisições realizadas em diferentes datas e condições de iluminação.

A literatura recente indica que produtos derivados de SfM podem apresentar bom desempenho na estimativa de atributos estruturais, especialmente em áreas de dossel mais aberto. Estudos comparativos entre produtos de SfM e LiDAR apontam alta correlação para métricas como altura do dossel e carbono acima do solo, reforçando o potencial da fotogrametria com drones como alternativa de menor custo para o monitoramento florestal e da restauração (ALMEIDA *et al.*, 2021; SANTORO *et al.*, 2025). Em florestas densas, contudo, o método tende a subestimar a altura do dossel em razão da dificuldade de reconstruir adequadamente o terreno sob a cobertura vegetal, limitação inerente ao caráter óptico do SfM, que, diferentemente do LiDAR, não penetra o dossel para registrar a superfície do solo com maior precisão (COOK-PATTON *et al.*, 2020).

Além das limitações relacionadas à estrutura da vegetação, a qualidade dos produtos fotogramétricos depende fortemente da acurácia geométrica do levantamento. Sistemas de correção em tempo real, como o RTK (Real Time Kinematic), contribuem para o posicionamento centimétrico das imagens durante o voo (FAMIGLIETTI *et al.*, 2021). Em projetos com orçamento restrito, estratégias de menor custo, como o uso de pontos de controle em solo (Ground Control Points, GCPs) ou o processamento cinemático pós-processado (Post-Processed Kinematic, PPK), têm se mostrado alternativas viáveis, desde que acompanhadas de rotinas consistentes de controle geométrico e avaliação da qualidade dos produtos gerados (SANTORO *et al.*, 2025).

Consideradas em conjunto, essas abordagens indicam que a fotogrametria com drones oferece contribuições relevantes para o monitoramento estrutural de áreas em restauração, especialmente quando o objetivo é ampliar a capacidade de observação com custos mais acessíveis. Seus produtos devem, no entanto, ser interpretados à luz de suas limitações técnicas, particularmente em contextos de maior densidade de dossel e maior exigência de precisão altimétrica, nos quais a integração com dados LiDAR pode ampliar a robustez analítica. A incorporação do CHM como variável preditora em fluxos de classificação supervisionada, tema desenvolvido na seção seguinte, representa uma das estratégias para aproveitar esse potencial estrutural na análise da cobertura e do uso do solo em áreas monitoradas.

3.5 Integração de dados, aprendizado de máquina e ferramentas abertas

A integração de múltiplas fontes de dados, como imagens orbitais, produtos derivados de drones, levantamentos de campo e séries históricas de uso e cobertura do solo, tem se consolidado como uma das principais tendências no monitoramento da restauração ecológica. Essa abordagem amplia a capacidade de analisar processos em diferentes escalas espaciais e temporais e favorece a produção de diagnósticos mais consistentes, especialmente em contextos

marcados por elevada heterogeneidade ambiental e necessidade de padronização de resultados (GORELICK *et al.*, 2017; WANG *et al.*, 2024). Além disso, a combinação entre diferentes fontes de informação tem se mostrado particularmente relevante em projetos que demandam maior aderência a protocolos de reporte, transparência metodológica e comparabilidade entre áreas e períodos monitorados.

3.5.1 Aprendizado de máquina para classificação da cobertura do solo

No âmbito dessas abordagens integradas, algoritmos de aprendizado de máquina têm ganhado destaque por sua capacidade de lidar com grande número de variáveis preditoras e com conjuntos de dados heterogêneos. Entre eles, o *Random Forest* tem sido amplamente empregado na classificação de uso e cobertura do solo, sobretudo por sua robustez, flexibilidade e bom desempenho em mosaicos ambientais complexos (TALUKDAR *et al.*, 2020; REDDY *et al.*, 2026). Em estudos aplicados de sensoriamento remoto, o uso combinado de bandas espectrais, índices de vegetação, métricas texturais derivadas de GLCM e modelos de altura, como o CHM, tem demonstrado ganhos relevantes de precisão, ao permitir explorar simultaneamente atributos espectrais, espaciais e estruturais da vegetação (KUPIDURA, 2019; RODRIGUEZ-GALIANO *et al.*, 2012).

Apesar desse potencial, a classificação supervisionada em áreas em restauração continua sujeita a desafios importantes. Um dos mais recorrentes é a confusão espectral entre classes com respostas semelhantes em determinadas condições ambientais ou fenológicas, como ocorre, por exemplo, entre gramíneas exóticas e estágios iniciais de regeneração. Nesses casos, a qualidade da classificação depende não apenas do algoritmo empregado, mas também da representatividade das amostras de treinamento, da seleção criteriosa das variáveis preditoras e da consistência dos procedimentos de validação (OLOFSSON *et al.*, 2014). Assim, mais do que automatizar classificações, o uso de aprendizado de máquina exige decisões analíticas bem fundamentadas sobre quais atributos integrar e como interpretar os resultados produzidos.

Cabe registrar que, embora abordagens de aprendizado profundo (*deep learning*), em especial redes neurais convolucionais e modelos de segmentação semântica, venham sendo crescentemente exploradas para classificação de cobertura do solo a partir de imagens de alta resolução, sua adoção não implica, por si só, ganho universal de desempenho. Esses modelos tendem a exigir grandes volumes de amostras rotuladas, maior capacidade computacional e ajustes complexos, o que pode limitar sua aplicabilidade em projetos de restauração com restrições de equipe, dados e orçamento. Estudos comparativos recentes indicam que o *Random Forest* iguala ou supera redes neurais artificiais e máquinas de vetores de suporte em diversos cenários de classificação de uso e cobertura do solo, com a vantagem adicional de menor custo

computacional, maior estabilidade e melhor interpretabilidade (KASAHUN; LEGESSE, 2024; WANG *et al.*, 2024). Essas características sustentam a escolha do *Random Forest* no presente trabalho, alinhada ao objetivo de propor um fluxo replicável e operacionalmente viável, sem prejuízo de que arquiteturas de aprendizado profundo sejam exploradas em etapas futuras, sobretudo quando houver maior disponibilidade de amostras e demanda por discriminação de padrões mais finos.

3.5.2 Validação e análise de incerteza

A avaliação da qualidade dos mapas temáticos costuma se basear em procedimentos consolidados, como a construção de matrizes de confusão e o cálculo de métricas de desempenho, entre elas a acurácia global, a acurácia do produtor e a acurácia do usuário (OLOFSSON *et al.*, 2014). O índice Kappa, embora historicamente difundido nesse contexto, tem sido fortemente criticado na literatura especializada por oferecer interpretação limitada e, em alguns casos, redundante ou potencialmente enganosa para fins de avaliação de acurácia e comparação de mapas, especialmente quando comparado a medidas mais diretamente relacionadas às fontes de erro (PONTIUS; MILLONES, 2011). Essas métricas são úteis para aferir o desempenho geral dos modelos, mas podem ser insuficientes quando o objetivo é estimar áreas por classe, comparar períodos ou subsidiar decisões de gestão e reporte. Nesse contexto, recomenda-se integrar a matriz de confusão às estimativas de área, de modo a produzir áreas ajustadas por erro e respectivos intervalos de confiança, procedimento particularmente importante quando os resultados são utilizados em avaliações agregadas, auditorias ou compromissos de desempenho (OLOFSSON *et al.*, 2014). Essa abordagem é especialmente relevante quando os mapas subsidiam estimativas agregadas por classe e decisões de gestão.

Para a comparação entre mapas classificados, Pontius e Millones (2011) propõem decompor a discordância em componentes de quantidade e alocação, distinguindo diferenças relacionadas à proporção total de classes daquelas associadas à sua distribuição espacial. Essa abordagem permite diferenciar situações em que dois mapas estimam áreas semelhantes, mas divergem espacialmente, daquelas em que divergem também na magnitude das classes mapeadas, oferecendo interpretação particularmente útil em estudos multitemporais voltados à gestão.

3.5.3 Plataformas abertas e escalabilidade

O avanço de plataformas computacionais abertas tem ampliado a viabilidade técnica e operacional desses fluxos de trabalho. O *Google Earth Engine*, por exemplo, permite processar grandes volumes de dados geoespaciais em ambiente de nuvem, automatizar etapas repetitivas

e estruturar rotinas reprodutíveis de análise, sem a necessidade de infraestrutura computacional local complexa (GORELICK *et al.*, 2017). Sua capacidade de integrar dados orbitais, produtos derivados e algoritmos de classificação em um mesmo ambiente favorece a padronização metodológica e amplia o potencial de aplicação em projetos de restauração conduzidos em múltiplas áreas ou períodos.

De forma complementar, o QGIS se consolida como ferramenta importante para análise espacial detalhada, visualização, edição e consolidação dos produtos cartográficos. Estudos nacionais evidenciam a utilidade de ferramentas como o QGIS em análises multitemporais, cálculo de métricas espaciais, geração de mapas temáticos e comunicação de resultados, destacando sua acessibilidade e integração com dados de drones, imagens orbitais e plataformas em nuvem (ALMEIDA *et al.*, 2021; MINATTI *et al.*, 2023). Nesse sentido, a combinação entre ferramentas abertas, algoritmos de classificação e integração de múltiplas fontes de dados configura uma base metodológica que favorece a transparência e a replicabilidade do monitoramento, atributos diretamente relacionados à adoção de protocolos e indicadores padronizados, tema da seção seguinte.

3.5.4 Protocolos e indicadores padronizados para monitoramento

A adoção de protocolos padronizados é condição importante para que o monitoramento da restauração ecológica cumpra suas funções de avaliar o progresso, subsidiar a gestão adaptativa e garantir maior comparabilidade entre projetos. Em contextos marcados por elevada heterogeneidade ambiental, diversidade de arranjos institucionais e múltiplos objetivos de intervenção, a ausência de critérios claros tende a dificultar a interpretação dos resultados, comprometer a transparência e limitar o aprendizado entre experiências. Nesse sentido, referenciais como os Princípios e Padrões Internacionais para a Prática da Restauração Ecológica, da *Society for Ecological Restoration*, e os protocolos do Pacto pela Restauração da Mata Atlântica oferecem bases estruturadas para organizar o monitoramento em torno de metas, indicadores e procedimentos comparáveis (ALBUQUERQUE *et al.*, 2024; GANN *et al.*, 2019; PACTO, 2013).

Nos Padrões da SER, o monitoramento ocupa posição central no planejamento, na documentação, na avaliação e no relato dos projetos. O documento enfatiza o uso de indicadores mensuráveis para acompanhar o progresso da restauração e destaca a importância de manter registros consistentes das etapas de planejamento, implantação, monitoramento e avaliação, de modo a subsidiar o manejo adaptativo e permitir análises futuras. Também reforça que a comparação entre resultados observados e metas declaradas exige referências explícitas e ferramentas de avaliação coerentes com os objetivos do projeto (GANN *et al.*, 2019). Nesse

contexto, uma etapa central é a definição de modelos de referência: a partir de áreas análogas, remanescentes conservados ou dados históricos, estabelecem-se atributos e metas capazes de orientar a avaliação da trajetória de restauração, incluindo aspectos relacionados à redução de ameaças, composição e estrutura da vegetação, funcionamento ecológico e resiliência do ecossistema (GANN *et al.*, 2019; HOLL, 2023).

No contexto brasileiro, o Protocolo de Monitoramento da Restauração da Mata Atlântica e da Amazônia via Sensoriamento Remoto representa avanço importante ao sistematizar indicadores mensuráveis por sensoriamento remoto, cobertura de dossel, altura de dossel, biomassa lenhosa acima do solo, densidade de indivíduos e idade da recuperação da vegetação nativa, além de integrar explicitamente o monitoramento remoto ao trabalho de campo (ALBUQUERQUE *et al.*, 2024). O documento reforça que o sensoriamento remoto amplia a transparência, a rastreabilidade e a escala do monitoramento, mas não substitui integralmente o diagnóstico ecológico presencial, que permanece indispensável para a interpretação dos resultados e para a aferição de atributos não diretamente observáveis nas imagens. Ao propor orientações sobre indicadores, frequência de aquisição, validação e disponibilização de dados cartográficos, o protocolo contribui para maior comparabilidade entre iniciativas e para o fortalecimento da qualidade dos dados reportados.

No estado de São Paulo, a Resolução SMA nº 32/2014, alterada pela Resolução SIMA nº 73/2020, e a Portaria CBRN nº 1/2015 constituem um arcabouço normativo relevante para o monitoramento da restauração, estabelecendo indicadores ecológicos para aferição do progresso dos projetos, entre eles a cobertura do solo com vegetação nativa, a densidade de indivíduos nativos regenerantes e o número de espécies nativas regenerantes, com valores de referência associados ao tempo de desenvolvimento das áreas restauradas (SÃO PAULO, 2014, 2015). Para formações florestais, a metodologia de campo para o indicador cobertura do solo com vegetação nativa baseia-se na soma dos trechos da linha amostral de 25 m cobertos pela projeção de copa de espécies nativas arbustivas ou arbóreas. Essa abordagem reforça a importância de métricas objetivas e comparáveis, passíveis de articulação com abordagens remotas e fotogramétricas, como as exploradas neste trabalho (SÃO PAULO, 2015).

Embora os protocolos apresentados não sejam idênticos em terminologia e finalidade, convergem ao enfatizarem a necessidade de métricas padronizadas, rastreáveis e comparáveis, tanto para avaliação ecológica quanto para cumprimento técnico e legal. O protocolo do Pacto, por exemplo, detalha procedimentos de campo vinculados ao sensoriamento remoto, incluindo métodos de interceptação de pontos em linha ao longo de uma trena de 25 m para estimar cobertura de copas e cobertura do solo por formas de vida (ALBUQUERQUE *et al.*, 2024; SÃO

PAULO, 2015). Em cenários heterogêneos como o brasileiro, essa padronização não deve ser confundida com rigidez, mas entendida como base para equilibrar rigor científico e viabilidade operacional, contemplando desde iniciativas de maior escala até projetos com menor capacidade técnica e financeira.

A combinação entre indicadores bem definidos, métodos de campo transparentes e ferramentas de sensoriamento remoto tende a fortalecer a robustez do monitoramento e ampliar sua utilidade para gestão, reporte e tomada de decisão. Para o presente trabalho, esse conjunto de referenciais oferece base conceitual e metodológica para a seleção dos indicadores analisados e para o diálogo entre medições de campo e produtos derivados de drones e geotecnologias abertas. A adoção desses protocolos, contudo, envolve desafios operacionais e limitações técnicas que permanecem centrais na literatura e ajudam a delimitar o posicionamento da presente pesquisa.

3.6 Síntese crítica da literatura e direcionamento da pesquisa

A literatura revisada indica que o monitoramento da restauração ecológica depende, cada vez mais, da articulação entre protocolos padronizados, observações de campo e ferramentas de sensoriamento remoto capazes de ampliar a escala, a frequência e a comparabilidade das avaliações. A literatura também converge no entendimento de que abordagens integradas, combinando diferentes sensores, métricas espectrais e estruturais, algoritmos de classificação supervisionada e plataformas abertas de processamento, oferecem oportunidades relevantes para qualificar o acompanhamento da trajetória de restauração, especialmente em contextos marcados por elevada heterogeneidade espacial e restrições operacionais.

Ao mesmo tempo, persistem limitações importantes. Entre elas, destacam-se a dificuldade de discriminar classes com respostas espectrais semelhantes em estágios iniciais da restauração, as incertezas associadas à estimativa de atributos estruturais em áreas de dossel mais denso, os desafios de validação e inferência de área a partir de mapas classificados e a necessidade de tornar os fluxos metodológicos simultaneamente robustos e viáveis para aplicação em projetos com restrições de tempo, equipe e orçamento. Em regiões como a Mata Atlântica, essas limitações são agravadas por condições como alta fragmentação, forte variabilidade ambiental e dificuldades recorrentes para aquisição de dados orbitais consistentes ao longo do tempo.

Nesse cenário, a literatura também aponta que a utilidade do monitoramento não depende apenas da sofisticação das ferramentas empregadas, mas de sua capacidade de produzir informações auditáveis, comparáveis e operacionalmente úteis para gestão adaptativa,

prestação de contas e tomada de decisão. Por isso, ganham destaque abordagens que conciliam dados de alta resolução obtidos por drones, métricas estruturais derivadas de fotogrametria, classificação supervisionada de uso e cobertura do solo, validação com análise de incerteza e alinhamento com protocolos de monitoramento reconhecidos.

É nesse ponto que se insere a presente pesquisa. O trabalho parte da lacuna identificada na literatura quanto à disponibilidade de fluxos metodológicos que integrem, de forma replicável e operacionalmente viável, imagens de drones com sensores RGB e multiespectral, variáveis estruturais como o CHM, aprendizado de máquina, ferramentas abertas e procedimentos de validação consistentes, em diálogo com referenciais de monitoramento aplicados à restauração na Mata Atlântica. Ao focalizar áreas em estágios iniciais de restauração, nas quais gramíneas exóticas e vegetação nativa incipiente podem apresentar respostas espectrais e estruturais semelhantes, a pesquisa busca contribuir para o aprimoramento de estratégias de monitoramento compatíveis com as demandas técnicas e institucionais do setor, com potencial para fortalecer uma base metodológica acessível, auditável e adaptável às condições reais dos projetos de restauração no Brasil.

A escalabilidade de fluxos de classificação supervisionada para múltiplas áreas depende não apenas da disponibilidade de código e infraestrutura computacional, mas também da capacidade de lidar com heterogeneidade de paisagem, variações fenológicas, diferenças de iluminação e mudanças na resposta espectral entre campanhas. Nesse sentido, a transferibilidade dos modelos exige cautela, pois preditores e parâmetros úteis em uma área podem não se reproduzir automaticamente em outra. Fluxos mais robustos, portanto, tendem a depender de parametrização adaptativa, validação local e documentação transparente das decisões analíticas, especialmente quando aplicados em paisagens tropicais heterogêneas e em projetos com pretensão de escala (BELGIU *et al.*, 2016; GORELICK *et al.*, 2017).

4 MATERIAL E MÉTODOS

Esta seção apresenta a abordagem utilizada para monitoramento via sensoriamento remoto de uma área em restauração florestal no bioma Mata Atlântica, região Sudeste do Brasil, incluindo coleta de dados com drone, processamento, classificação e análise em ambiente de computação em nuvem (*Google Earth Engine*). O fluxo de trabalho foi desenvolvido com o intuito de ser replicável, com geração de mapas e tabelas que subsidiam a interpretação dos resultados e a discussão de limitações e incertezas.

4.1 Área de estudo e delineamento experimental

A área de estudo está localizada no interior do estado de São Paulo, inserida no bioma Mata Atlântica - região caracterizada por elevada biodiversidade, alto grau de fragmentação florestal e prioridade reconhecida nas políticas nacionais de restauração ecológica (BRASIL, 2024). A escolha da área de estudo deve-se à concentração de projetos institucionais em curso na região, à disponibilidade de dados históricos de restauração e à representatividade do mosaico de usos e desafios encontrados em contextos do Sudeste.

Os remanescentes florestais locais são compostos predominantemente por Floresta Ombrófila Densa e Estacional Semidecidual (IBGE, 2012), em relevo com declividades médias de 20% e solos como Latossolos e Argissolos (EMBRAPA, 2018). O clima, classificado como Cfa, Cfb e Cwa (ALVARES *et al.*, 2013), registra precipitação anual de 1.100-2.000 mm (INMET, 2023). A análise da cobertura e do uso do solo baseia-se em produtos de sensoriamento remoto, em especial os dados do projeto MapBiomas, que indicam a predominância de pastagens e agricultura na região, com vegetação florestal representando cerca de 28% da área total dos municípios estudados em 2022 (MAPBIOMAS, 2023). Esse perfil de uso do solo, associado ao histórico de pressão antrópica sobre os remanescentes nativos, motiva a adoção de estratégias de restauração e monitoramento voltadas à recomposição da cobertura florestal, ao aumento da conectividade entre fragmentos e à recuperação de serviços ecossistêmicos.


Para a condução desta pesquisa, foi delimitada uma área piloto de aproximadamente 13 hectares, a partir de arquivo vetorial *shapefile*, abrangendo o perímetro total da área sob restauração florestal monitorada. O delineamento do estudo é multitemporal, com dois períodos: T0 (linha de base pré-restauração, Abril/2024) e T1 (monitoramento, Janeiro/2026; ~20 meses). As análises foram conduzidas em sistema de referência SIRGAS 2000 / UTM Zona 23S (EPSG:31983), garantindo alinhamento entre os produtos e compatibilidade com SIG.

O plantio ocorre em área total, com densidade e espaçamento aproximado de 2 x 2,5 m e prioriza a seleção de espécies regionais de diferentes grupos funcionais, como: espécies de

recobrimento - visando rápida formação de dossel e competição com exóticas - e espécies de diversidade, com diferentes funções e ciclos ecológicos. A estratégia adotada também reforça a necessidade de manutenção intensiva nos primeiros anos após o plantio, etapa crítica para o estabelecimento dos processos iniciais de restauração florestal em cenários tropicais sob elevada pressão antrópica (SOSMA, 2022). Nesse cenário, o monitoramento é etapa fundamental e a dinâmica de cobertura do solo na área em restauração pode fornecer subsídios para a gestão adaptativa e para o sucesso operacional do projeto.

Por se tratar de propriedade rural privada vinculada a projeto em execução, optou-se por não explicitar o município nem a localização exata da área de estudo, de modo a preservar aspectos de confidencialidade e governança do projeto. Ainda assim, foram mantidos no texto os elementos ambientais, metodológicos e cartográficos necessários para contextualização e reprodutibilidade do fluxo analítico. A Figura 1, a seguir, apresenta imagens aéreas da área piloto monitorada neste estudo, correspondentes aos ortomosaicos RGB dos períodos T0 (abril de 2024) e T1 (janeiro de 2026), elaborados no sistema de referência cartográfica SIRGAS 2000 / UTM 23S, com escala gráfica e indicação do norte.

Figura 1 – Ortomosaico RGB da área de estudo (projeto piloto) em T0 e T1.



Fonte: elaboração própria.

4.1.1 Fluxo analítico do trabalho

O fluxo analítico do trabalho foi organizado em seis etapas principais. (1) Inicialmente foram realizados os voos, gerados os produtos fotogramétricos de cada campanha (T0 e T1) e consolidado o controle de qualidade geométrica a partir dos relatórios de processamento, com atenção às implicações da ausência de base RTK. (2) Em seguida foram construídas as pilhas de variáveis preditoras no *Google Earth Engine* - bandas RGB, índices e texturas, bem como o modelo de altura de dossel para suporte estrutural e, no T1, foram adicionadas variáveis obtidas por sensores multiespectrais. (3) Foram treinados e aplicados classificadores *Random Forest* para produzir os mapas de cobertura do solo em T0 e T1, seguidos de pós-processamento espacial (unidade mínima de mapeamento e filtro por moda) para gerar os mapas finais. (4) A acurácia foi quantificada por validação pontual e por amostragem aleatória repetida, reportando métricas globais e por classe. (5) No T1, os produtos RGB e multiespectral foram comparados em termos de concordância/discordância e comportamento por faixas de altura relativa, subsidiando a justificativa de escolha do modelo operacional. (6) Por fim, foi quantificada a dinâmica T0→T1 por matrizes de transição e sínteses de mudança de cobertura do solo, complementadas por diagnósticos de incerteza, e confrontadas quantitativamente com coleta de dados de campo para checagem independente dos padrões agregados de cobertura.

4.2 Coleta de dados com VANT

A aquisição dos dados primários foi realizada em abril de 2024, por meio de voos com VANT, conduzidos pela equipe técnica de restauração florestal da Fundação SOS Mata Atlântica. O equipamento empregado foi um drone do modelo DJI Mavic 3M Enterprise, equipado com câmera RGB de 20 megapixels e sensores multiespectrais. O sistema não dispõe de correção posicional em tempo real (RTK), o que exige cautela adicional em comparações pixel a pixel e na interpretação de produtos altimétricos.

No T0, foi priorizada aquisição de imagens RGB; no T1, 20 meses depois, foram coletados dados RGB e multiespectrais. Os voos foram planejados a uma altitude de 120 metros e executados em alturas variáveis² entre 120 e 170 m, com sobreposição frontal e lateral de 80% entre as imagens e velocidade horizontal de deslocamento de ~9 m/s. Esses parâmetros são recomendados para maximizar redundância de imagens e reconstrução 3D por fotogrametria (FORSMOO *et al.*, 2019; ROBINSON *et al.*, 2022). No processamento do T1, foram utilizados

² Durante o voo não foi utilizada uma referência fixa de coordenada geográfica no solo (RTK) e, por conta disso, o drone não acompanha o relevo do terreno enquanto faz o mapeamento, o que altera a altura planejada.

9 pontos de controle em solo (GCPs) para melhorar a consistência geométrica entre produtos do T0 e T1.

Foram utilizados procedimentos de alinhamento, calibração e correção geométrica nas etapas de processamento subsequentes, com o intuito de mitigar possíveis imprecisões associadas à ausência de RTK. O registro sistemático dos parâmetros de voo e das condições ambientais foi realizado para garantir rastreabilidade e replicabilidade do método. Os dados obtidos fundamentaram as etapas de processamento digital e análise espacial detalhadas nas próximas subseções

4.3 Processamento fotogramétrico e geração de produtos

O processamento fotogramétrico primário das imagens aéreas foi realizado pela instituição parceira - DAP WEB, utilizando o software Agisoft Metashape. A rotina seguiu parâmetros padrão para ambientes de restauração e envolveu práticas de *Structure from Motion* (SfM) para geração de ortomosaicos e modelos altimétricos: Modelo Digital de Superfície (MDS) e Modelo Digital de Terreno (MDT).

Todos os produtos foram georreferenciados conforme o sistema SIRGAS 2000 / UTM Zona 23S (EPSG:31983) e exportados em formato *GeoTIFF*, garantindo compatibilidade com plataformas de análise espacial e processamento subsequente no GEE e QGIS.

4.3.1 Controle de qualidade do processamento fotogramétrico (T0 e T1)

A qualidade geométrica dos produtos fotogramétricos foi documentada por meio dos relatórios automáticos de processamento gerados no Agisoft Metashape, utilizados como registro técnico e base de rastreabilidade do *pipeline* (Apêndice B). No T0, o processamento foi executado com metadados GNSS embarcados e sem pontos de controle, resultando em distância de amostragem do solo (GSD) de 4,65 cm/pixel e erro médio estimado de posição da câmera de aproximadamente 0,52 m em XY e 4,80 m em Z (Tabela 1). No T1, foram utilizados nove pontos de controle em solo (GCPs), com Raiz do Erro Quadrático Médio (RMSE) total de ~21 cm (X~11,5 cm; Y~16,3 cm; Z~6,8 cm), mantendo GSD semelhante (~4,6 cm/pixel).

Admite-se a existência de incertezas residuais de georreferenciamento e altitude entre T0 e T1; por isso, as análises foram desenhadas para serem pouco sensíveis a pequenos deslocamentos: (i) métricas estruturais baseadas em CHM são analisadas principalmente por faixas de altura, evitando interpretações árvore-a-árvore; e (ii) em todas as análises cruzadas (mudança de classes, discordância entre modelos e estatísticas, utiliza-se uma área válida comum para reduzir a influência de pixels sem dados e diferenças de cobertura espacial entre produtos.

4.3.2 Considerações radiométricas e índices espectrais (NDVI)

Neste trabalho, para a análise de monitoramento no T1, foi utilizado ortomosaico multiespectral (bandas RGB, Green, Red, Red Edge e NIR) para derivação de índices espectrais, como o NDVI, que foi usado como um dos preditores dentro do modelo de classificação MS e para análises exploratórias com CHM, e não como métrica comparativa direta entre datas. Os relatórios de processamento fotogramétrico registram a calibração de câmera no sentido geométrico/fotogramétrico (parâmetros internos e distorções) para a câmera RGB e para cada sensor multiespectral, o que sustenta a consistência da reconstrução SfM e da ortorretificação.

Embora o drone DJI Mavic 3M Enterprise disponha de sensor de luz solar (irradiância) para registrar variações de iluminação durante o voo, neste estudo não foi realizada calibração radiométrica absoluta por painel de reflectância (conversão para reflectância de superfície). Assim, os índices espectrais derivados do ortomosaico multiespectral (ex.: NDVI, NDRE) foram utilizados como variáveis relativas ao levantamento (T1), adequadas para discriminar alvos dentro do mesmo período e apoiar a classificação supervisionada. Por outro lado, comparações diretas de valores de NDVI entre diferentes datas e condições de iluminação devem ser interpretadas com cautela, uma vez que variações de luminosidade podem influenciar produtos ópticos (ortomosaicos), especialmente em análises multitemporais.

A próxima etapa consistiu no processamento secundário, classificação dos dados e extração de indicadores no ambiente *Google Earth Engine*, conforme detalhado a seguir.

4.4 Fluxo de trabalho no *Google Earth Engine*

O processamento secundário dos dados e a classificação dos padrões de uso e cobertura do solo foram conduzidos na plataforma em nuvem do GEE, utilizando linguagem *JavaScript*. O GEE foi escolhido por sua capacidade de processar grandes volumes de dados geoespaciais de forma automatizada, transparente e replicável, o que se alinha aos objetivos de escalabilidade e padronização de metodologias para monitoramento em restauração ecológica.

Os principais insumos empregados incluíram:

- Polígono vetorial delimitando a área de interesse;
- Ortomosaicos RGB e multiespectrais derivados do VANT;
- Modelos digitais de terreno e de superfície;
- Pontos de amostragem para treinamento e validação dos modelos.


A preparação dos dados incluiu padronização dos ortomosaicos, com normalização automática de escala radiométrica (8-bit/16-bit) e aplicação de máscara válida (*alpha*/máscara interna), garantindo que amostragens e cálculos de área não incluíssem pixels sem dados. Para

evitar contaminação por classe nula, o mapa final filtrado utiliza máscara lógica (classe > 0) em todas as estatísticas e cruzamentos.

O procedimento no GEE envolveu as seguintes etapas sequenciais:

- importação dos arquivos *raster* e vetoriais, padronizando o sistema de referência espacial e escala para garantir o alinhamento entre todas as camadas e minimizar erros de georreferenciamento;
- a partir dos modelos altimétricos, foi derivado o Modelo de Altura do Dossel (CHM), definido como $CHM = MDS - MDT$. Valores negativos foram truncados para 0 m, e aplicou-se suavização focal para reduzir ruído local. Em T0, utilizou-se $CHM(T0) = MDS(T0) - MDT(T0)$ (Figura 2) Em T1, adotou-se $CHM(T1) = MDS(T1) - MDT(T0)$, estratégia conservadora diante da ausência de RTK e das limitações da fotogrametria óptica para recuperar o terreno sob vegetação, especialmente em condições de oclusão e sombras (ALBUQUERQUE *et al.*, 2024; SANTORO *et al.*, 2025). O CHM foi utilizado como uma das bandas predictoras na classificação e para determinação de faixas de altura relativa (m) durante análise de mudança de classes entre T0 e T1;

Figura 2 – Modelo de altura de dossel - CHM e ortomosaico - T0 - (Abril/2024).



Fonte: elaboração própria.

- c) cálculo automatizado de texturas estatísticas para cada banda RGB, empregando a Matriz de Coocorrência de Níveis de Cinza (GLCM) em janela de 5 x 5 pixels, totalizando doze bandas adicionais. Essas métricas aumentam a capacidade de discriminar padrões estruturais finos e são amplamente recomendadas em estudos recentes (ALZHANOV *et al.*, 2024);
- d) os atributos preditores foram construídos por empilhamento de informações espectrais, texturais e estruturais: (a) bandas R, G, B; (b) índices RGB VARI e GLI; (c) texturas GLCM em janela 5×5 (estatísticas: entropia, variância e sum average) sobre R/G/B; (d) CHM como variável estrutural. Para o modelo multiespectral em T1 (MS), foram adicionadas bandas *Green*, *Red*, *Red Edge* e NIR e os índices NDVI e NDRE, além de uma variável indicadora para registrar ausência de informação estrutural. Para ampliar a transparência metodológica, foi exportada a importância relativa das variáveis preditoras após o treinamento dos classificadores *Random Forest* em T1. Essa informação foi utilizada como subsídio interpretativo para a comparação entre os modelos RGB e multiespectral, sem função de seleção automática de variáveis. O detalhamento completo do ranking de importância das variáveis em cada modelo é apresentado no Apêndice A;
- e) foram definidas cinco classes temáticas para compatibilidade com monitoramento de restauração e estabilidade do código em cenários de ausência de alguma das classes listadas: (1) Vegetação nativa (VN); (2) Árvore exótica (AE); (3) Gramínea exótica (GE); (4) Solo exposto (SE); (5) Corpo hídrico (CH). As amostras de referência foram selecionadas por interpretação visual em tela, com apoio do ortomosaico de alta resolução e da camada CHM, priorizando pixels internamente homogêneos e evitando bordas entre classes, sombras intensas, áreas com mistura evidente de alvos e regiões sem dados. Buscou-se distribuir os pontos ao longo de diferentes setores da área de estudo, de modo a representar a variabilidade espectral e espacial das seguintes classes existentes na área de estudo: VN, GE e SE, com a inserção de 60 pontos amostrais para cada, totalizando 180 pontos em cada período analisado. As classes ausentes (AE e CH) foram mantidas para estabilidade do código, mas não foram usadas no treinamento/validação, podendo ser incorporadas quando estiverem presentes na área a ser analisada;
- f) a classificação foi realizada com *Random Forest*, com 200 árvores e semente fixa, na escala de 0,20 m. No T0, foi treinado o modelo RGB, enquanto para o T1, foram treinados dois modelos: (RGB) e (MS). Após a classificação, aplicou-se pós-

processamento espacial para reduzir ruído ('efeito sal e pimenta') e impor unidade mínima de mapeamento: (i) filtro de conectividade (mínimo 10 pixels conectados) e (ii) filtro de maioria local (raio de 2 pixels). Pixels removidos foram preenchidos como classe 0, mas excluídos das análises por meio de máscara lógica (classe > 0). Como medida auxiliar para interpretação, foi extraída e exportada a importância das variáveis do classificador *Random Forest* para os modelos finais. Essa informação expõe quais preditores contribuíram para a separação das classes (por exemplo, CHM e índices espectrais no T1), não sendo empregada como critério de seleção/remoção de variáveis nesta etapa;

- g) o desempenho do modelo de classificação foi avaliado por meio de matriz de confusão, acurácia global (OA), e acurácias do produtor e do usuário (PA/UA). As métricas foram calculadas prioritariamente sobre o mapa final classificado e pós-processado espacialmente, por representar o produto cartográfico utilizado nas análises de área e transição. Para transparência, as métricas também foram registradas para o mapa bruto permitindo verificar o efeito do pós-processamento, quando aplicável. A validação adotou divisão estratificada por classe (70% treino/30% validação), estabelecendo o mínimo de 20 pontos por classe no conjunto de validação, quando aplicável. Foi registrado o número efetivo de pontos utilizados após filtragem de amostras sem dados. Para avaliar estabilidade do desempenho e reduzir dependência de um único particionamento, foi implementada amostragem aleatória repetida ($n=20$), exportando OA por repetição e permitindo relatar média e desvio padrão, reforçando a estabilidade do produto para aplicação operacional em múltiplas áreas. Além das métricas OA, precisão do usuário (UA) e precisão do produtor (PA), foi utilizado o F1 por classe, definido como a média harmônica entre UA e PA, e o Macro-F1, calculado como a média do F1 entre as classes. Essas métricas foram empregadas para complementar a interpretação do desempenho dos classificadores, especialmente em cenários de distribuição desigual entre classes;
- h) além das áreas mapeadas diretamente a partir da contagem de pixels por classe, foram estimadas áreas ajustadas por erro de classificação e respectivos intervalos de confiança (IC95%), com base nas matrizes de confusão geradas na validação pontual ($n = 60$) para os modelos RGB e MS no T1. Para cada modelo, as proporções condicionais de classe de referência dado a classe mapeada foram obtidas a partir da matriz de confusão e utilizadas para corrigir as áreas mapeadas (em hectares) por classe. A incerteza foi quantificada por *bootstrap* paramétrico simulando


repetidamente a matriz de confusão por amostragem multinomial estratificada pela classe mapeada, preservando os totais amostrais observados; em seguida, as áreas ajustadas foram recalculadas a cada reamostragem. O IC95% foi obtido pelos percentis 2,5 e 97,5% da distribuição das áreas ajustadas ($n = 80.000$ reamostragens). As estimativas ajustadas e seus IC95% foram usadas para reportar a incerteza associada às taxas de erro estimadas e apoiar inferências de área por classe, sem incluir outras fontes de incerteza (por exemplo, variações fenológicas, diferenças de aquisição e efeitos de georreferenciamento entre campanhas).

- i) a área por classe foi estimada por área de pixel (m^2) convertida para hectares, somando-se os valores por classe dentro do polígono da área de estudo. Foram geradas tabelas de área (ha) e percentual (%) para T0 e para T1 (RGB e MS), utilizadas em gráficos de síntese e como base para o relatório. A comparação entre os modelos (RGB) e (MS) em T1 incluiu: (i) cálculo de concordância/discordância espacial (mapa binário); (ii) métricas de concordância entre mapas; (iii) quantificação de pares dominantes de discordância; e (iv) estratificação da discordância por faixas de altura relativa do CHM, com ênfase em $CHM < 1$ m, onde a confusão entre GE/SE e regenerantes é mais provável, em contexto de incerteza altimétrica;
- j) dinâmica da cobertura do solo: A mudança temporal foi analisada por cruzamento de mapas entre T0 e T1, gerando duas transições: (A) T0 (RGB) $\rightarrow$ T1 (RGB) e (B) T0 (RGB) $\rightarrow$ T1 (MS). Para cada transição, foi construído o *raster* e exportada uma tabela com área por par (de $\rightarrow$ para) em hectares e percentuais. Essas tabelas serviram de base para diagramas de fluxo do tipo *Sankey*, que sintetizam os fluxos dominantes e os saldos líquidos de mudança. Além disso, foi produzido um mapa simplificado focado em vegetação nativa (Mudança na cobertura de dossel) com quatro categorias: ganho de nativa, perda de nativa, nativa estável e gramínea/solo estáveis. Para cada transição, foram exportados *raster* e tabela com área e percentual por categoria;
- k) discordância entre transições e ΔCHM : Para quantificar a sensibilidade do mecanismo de mudança à escolha do modelo no T1, foi calculada a discordância entre transições ($PAR_A \neq PAR_B$), exportando-se tabela resumo (acordo/desacordo) e matriz detalhada por combinação (PAR_A, PAR_B). Como diagnóstico complementar das incertezas altimétricas, foi calculado $\Delta CHM = CHM(T1) - CHM(T0)$. Foram exportadas estatísticas de ΔCHM por classe final

(média, desvio-padrão, mínimo, máximo, nº de pixels) e por categoria da mudança da cobertura do solo, permitindo discutir variação estrutural e componentes sistemáticos associados à fotogrametria e ao alinhamento entre campanhas;

- 1) os dados de campo foram utilizados como checagem independente do indicador agregado de cobertura/vegetação nativa. Adotou-se o método de interceptação de trechos ao longo de trena de 25 m, registrando-se a presença de cobertura nativa acima do topo de uma vareta de 2 m. A porcentagem dos trechos com cobertura corresponde ao indicador de cobertura do dossel, em consonância com referências operacionais do Protocolo do Pacto, da Resolução SMA nº 32/2014 e da Portaria CBRN nº 01/2015, permitindo comparação com o percentual de vegetação nativa estimado pelos mapas em T1 (RGB e MS) em nível de parcela e de área total. Para isso, foram distribuídas de forma aleatória 17 parcelas na área de estudo, conforme exposto na Figura 3, disposta abaixo. Em todas as parcelas, a trena foi esticada na direção norte (Figura 4);

Figura 3 – Distribuição das parcelas na Área de estudo - T1/Janeiro de 2026.



Fonte: elaboração própria.

Figura 4 – Registro fotográfico durante coleta de dados em campo.



Fonte: elaboração própria.

m) as análises quantitativas e as figuras foram produzidas a partir dos produtos exportados do GEE (*rasters GeoTIFF* e tabelas em CSV) gerados pelos scripts de T0, T1 e transição. As tabelas exportadas foram consolidadas e processadas em ambiente local com Python (*pandas/numpy*) para cálculo de métricas adicionais e para sumarizações comparativas. A geração dos gráficos foi realizada em Python (*matplotlib*), incluindo: (i) diagramas de *Sankey* a partir das tabelas de transição (área em ha e % por par de classes); (ii) gráfico de barras para área por classe; (iii) gráficos *boxplot* para avaliar a estabilidade do desempenho (OA) sob amostragem aleatória repetida ($n=20$); e (iv) gráficos de dispersão (CHM×NDVI) com amostragem de pixels exportada do GEE para inspecionar padrões de separação entre classes e concentração de discordâncias entre modelos. Os mapas temáticos finais e layouts cartográficos foram organizados no QGIS a partir dos *rasters* exportados (classificações, CHM, transição de classes e *rasters* de discordância), mantendo simbologia padronizada por classe e escala compatível com o objetivo de monitoramento operacional. Para a análise exploratória do espaço CHM×NDVI e visualização de padrões de separabilidade e discordância entre sensores, foram gerados gráficos de dispersão a partir de amostras de pixels, devido ao alto volume de dados no *raster* completo. Foram adotadas duas estratégias: (i) uma amostra aleatória simples de aproximadamente 40.000 pixels para o gráfico CHM×NDVI distinguindo pixels em acordo e discordância entre os mapas T1 RGB e T1 MS; e (ii) uma amostra estratificada por classe de aproximadamente 360.000 pixels

($n \approx 120.000$ por classe) para o gráfico CHM $\times$ NDVI por classe do modelo multiespectral em T1. Ressalta-se que, devido à autocorrelação espacial entre pixels, essas amostras foram utilizadas exclusivamente para visualização e diagnóstico de padrões, enquanto as estatísticas reportadas nas tabelas (áreas por classe, percentuais e métricas por faixas de CHM e NDVI) foram calculadas considerando todos os pixels válidos. Como desdobramento do fluxo de trabalho, foi desenvolvido um protótipo de painel interativo no *Google Earth Engine (Earth Engine Apps)* para visualização e interpretação dinâmica dos produtos gerados (imagens base, mapas de cobertura do solo, CHM, mudança de vegetação nativa e discordância entre transições). O painel utiliza como dados de entrada exclusivamente *rasters* e tabelas exportados pelos scripts de T0, T1 e transição, não introduzindo novos cálculos nos resultados; seu propósito é apoiar o uso operacional e a comunicação com equipe técnica, gestores, patrocinadores e auditores. A aplicação em múltiplas áreas e uma avaliação formal de usabilidade são propostas como etapa posterior à defesa;

- n) para assegurar reprodutibilidade e facilitar adoção no contexto profissional, os códigos serão disponibilizados em repositório público contendo: (i) *scripts* T0, T1 e Transição, em versão organizada e documentada, com lógica e parâmetros idênticos aos utilizados no texto (*tag/release*); (ii) “Leia-me” com instruções de execução e parâmetros; (iii) lista de dados de entrada/IDs e estrutura de saída de dados; e (iv) descrição do ambiente (Metashape, GEE, QGIS). O repositório está disponível publicamente na conta GitHub do autor³, com histórico de versões controlado por *tag/release*, assegurando a rastreabilidade da versão dos *scripts* utilizada neste trabalho. Quando necessário, produtos sensíveis (p.ex., ortomosaicos de propriedade privada) poderão ser mantidos não públicos, preservando a transparência das estatísticas e parâmetros. O fluxo de trabalho foi estruturado para ser incrementado e replicável, podendo ser adaptado para diferentes áreas e períodos temporais, com parâmetros ajustáveis no início do *script*, o que facilita a sua aplicação em projetos futuros ou outras regiões. Os resultados derivados deste processamento subsidiam as análises multitemporais e a avaliação de indicadores, conforme detalhado na sequência. Os parâmetros gerais de aquisição e análise adotados no estudo estão sintetizados na Tabela 1. Já uma síntese dos relatórios de processamento

³ Disponível em: <https://github.com/lucasguedes15/monitoramento-cobertura-drone-gee/releases/tag/v1.0.dissertacao>. Acesso em: 19 jul. 2026.

fotogramétrico gerados no Agisoft Metashape para T0 e T1, incluindo métricas de alinhamento, densidade da nuvem de pontos, resolução dos produtos e indicadores de controle geométrico, é apresentada no Apêndice B.

Tabela 1 – Parâmetros dos Voos, Processamento de dados e Delineamento Experimental.

Parâmetro/Etapa	Descrição
Área piloto	13 hectares, área rural no interior do Estado de São Paulo
Bioma	Mata Atlântica
Modelo de plantio	~2.000 mudas/ha; espécies de recobrimento e diversidade
Manutenção	Intensiva nos primeiros anos após o plantio
Equipamento VANT	DJI Mavic 3M (câmera RGB e sensores multiespectrais, sem uso de RTK)
Altitude de voo	120 - 170 m
Sobreposição	80% frontal e lateral
Resolução espacial (RGB)	~5 cm (ortomosaico RGB); Análises no GEE padronizadas para 0,20 m
Resolução dos produtos	0,20 metros (CHM, raster de classificação)
Pontos de controle (GCPs)	T0 sem GCPs. 9 pontos de controle no T1
Erro médio posição da câmera XY (m)	T0: 0,51 ; T1: -
Erro médio posição da câmera Z (m)	T0: 4,80; T1: -
RMSE GCP total (m)	T0: Não utilizado; T1: 0,21
RMSE GCP X/Y/Z (m)	T0: Não utilizado; T1: 0,11 / 0,16 / 0,07
RTK/PPK	Não utilizado
Softwares de processamento	Agisoft Metashape (fotogrametria primária); GEE e QGIS (análise)
Períodos analisados	Linha de base (2024), ano 2 (2026)
Principais produtos gerados	Ortomosaico RGB, MDT, MDS, CHM, mapas classificados, Mapa da dinâmica de cobertura do solo, métricas e estatísticas.

Fonte: elaboração própria.


5 RESULTADOS

Esta pesquisa resultou na implementação de um fluxo digital de monitoramento para projetos de restauração ecológica na Mata Atlântica, capaz de gerar (i) mapas da dinâmica de cobertura do solo e (ii) métricas estruturais da vegetação derivadas de fotogrametria (CHM), com processamento em ferramentas abertas (*Google Earth Engine* e QGIS). Os resultados referem-se a uma área piloto de 13 ha, comparando o período pré-restauração (T0; abril/2024) e o período de monitoramento (T1; janeiro/2026; ~20 meses após o plantio), além de avaliar a concordância e incertezas entre classificações geradas a partir de sensores RGB e multiespectral no T1.

5.1 Área piloto, delineamento amostral e produtos-base

A área piloto e o delineamento amostral utilizados para interpretação e validação incluem ortomosaicos de alta resolução obtidos com drone em T0 e T1. As análises altimétricas foram interpretadas prioritariamente por faixas de altura, reduzindo a dependência de valores absolutos pixel a pixel e permitindo identificar zonas de maior sensibilidade na separação estrutural entre classes. No T1, o CHM foi calculado como $MDS(T1) - MDT(T0)$ e interpretado em classes de altura relativa (m). A comparação visual entre CHMs de T0 e T1 (Figura 5) sugere gradientes estruturais consistentes com o estágio inicial do processo, com mudanças ainda discretas no intervalo de ~20 meses.

Figura 5 – Modelos de altura de dossel - CHM no T0 e T1.



Fonte: elaboração própria.

5.2 Cobertura do solo em T0 e T1 (RGB e Multispectral)

A área total analisada foi de 13 ha. Em T0, a classificação indicou predominância de Gramínea exótica com 7,91 ha (60,81%), seguida por Vegetação nativa com 4,58 ha (35,20%) e Solo exposto com 0,52 ha (3,99%) (Tabela 2). Em T1, observou-se aumento expressivo de vegetação nativa para 7,50 ha (57,67%) no modelo RGB e 7,58 ha (58,23%) no modelo multispectral; concomitantemente, a gramínea reduziu para 4,74 ha (36,43%) no RGB e 4,63 ha (35,59%) no MS (Tabela 2). O solo exposto apresentou aumento discreto (0,76–0,80 ha; 5,90–6,17%), sugerindo persistência de clareiras e/ou falhas localizadas, úteis como áreas prioritárias para inspeção e manejo (por exemplo, replantio e controle de gramínea).


Esses padrões são espacialmente coerentes com os mapas temáticos do T0 e T1 (Figuras 6-8), nos quais as classes são representadas por vegetação nativa (verde), gramínea exótica (amarelo) e solo exposto (laranja). A síntese visual de áreas por classe (Figura 9) facilita a leitura das tendências entre períodos e entre sensores, evidenciando o aumento de vegetação nativa e redução de gramínea no intervalo analisado. Em termos líquidos, a variação na proporção de vegetação nativa foi de aproximadamente +22,5 pontos percentuais (p.p) (T0→T1), enquanto a gramínea reduziu cerca de -24 p.p. (Tabela 2; Figura 9).

Tabela 2 – Área (ha) e percentual (%) de cobertura do solo por classe em T0 e T1.

Classe	RGB – T0		RGB – T1		MS – T1	
	(ha)	(%)	(ha)	(%)	(ha)	(%)
Vegetação nativa	4,58	35,20	7,50	57,67	7,58	58,23
Gramínea exótica	7,91	60,81	4,74	36,43	4,63	35,59
Solo exposto	0,52	3,99	0,76	5,90	0,80	6,17
Total	13,01	100,00	13,01	100,00	13,01	100,00


Fonte: elaboração própria.

Figura 6 – Uso e cobertura do solo no T0 (RGB).




Fonte: elaboração própria.

Figura 7 – Uso e cobertura do solo nos momentos T0 e T1 (RGB).




Fonte: elaboração própria.

Figura 8 – Uso e cobertura do solo nos momentos T0 (RGB) e T1 (Multiespectral).



Fonte: elaboração própria.

Figura 9 – Área por classe em T0 e T1 - Classificações de cobertura do solo com sensores RGB e Multiespectral (MS).



Fonte: elaboração própria.

5.3 Desempenho e estabilidade dos modelos de classificação (T0 e T1)

A validação pontual ($n = 60$) indicou desempenho elevado dos modelos (Tabela 3). Em T0 (RGB), a classificação apresentou Acurácia Global (OA) = 0,90. Em T1, ambos os modelos mantiveram desempenho alto, com OA = 0,90 (RGB) e 0,91 (MS). A métrica Macro-F1 (média do F1 por classe) reforçou esse padrão, com valores 0,89 (T0 RGB), 0,90 (T1 RGB) e 0,91 (T1 MS) (Tabela 3).

A estabilidade foi avaliada por amostragem aleatória repetida (20 repetições), resultando em médias de OA $0,92 \pm 0,03$ (T0), $0,942 \pm 0,03$ (T1 RGB) e $0,95 \pm 0,03$ (T1 MS), sugerindo


diferenças pequenas entre sensores no T1 (Tabela 3; Figura 10). A diferença média entre sensores no T1 foi discreta (ΔOA médio $\approx 0,005$; IC95% = - 0,006 a 0,016), indicando que o ganho do multiespectral, nas condições avaliadas, é modesto no nível global.

Tabela 3 – Métricas globais, validações e estabilidade dos modelos (T0 e T1).

Modelo	OA (validação)	Macro-F1 (validação)	n validação	OA (repetições n=20) média $\pm$ dp
T0 RGB	0,90	0,89	60	0,92 $\pm$ 0,03
T1 RGB	0,90	0,90	60	0,94 $\pm$ 0,03
T1 MS	0,91	0,91	60	0,94 $\pm$ 0,02

Fonte: elaboração própria.

Figura 10 – Estabilidade do desempenho por amostragem aleatória repetida (n=20) – Acurácia Global (OA).




Fonte: elaboração própria.

5.4 Comparação de sensores RGB $\times$ Multiespectral na classificação de cobertura do solo em T1: concordância, discordância e papel da estrutura (CHM)


Apesar de métricas globais semelhantes entre os modelos em T1 (Tabela 3; Figuras 10), a comparação espacial entre mapas evidencia uma zona de divergência relevante para uso operacional. A leitura visual dos mapas classificados lado a lado (Figura 11), gerados a partir dos ortomosaicos RGB e multiespectral sobre o mesmo recorte da área piloto, e do mapa binário de discordância (Figura 12), que assinala os pixels com classe divergente entre sensores (RGB $\neq$ MS), mostra concordância global entre sensores, porém com discordâncias concentradas em padrões específicos da paisagem.

Figura 11 – Classificação de cobertura do solo no T1 utilizando sensores RGB e Multiespectral.



Fonte: elaboração própria.

Figura 12 – Mapa de discordância entre sensores no T1 (RGB × MS).



Fonte: elaboração própria.

A concordância entre os mapas T1 (RGB vs MS) foi de 11,28 ha (86,70%), com discordância em 1,73 ha (13,30%). Em termos de tipo de troca, a discordância foi dominada por transições entre vegetação nativa e gramínea exótica no estrato baixo. Em CHM 0-1 m, as trocas VN↔GE somaram 1,29 ha, superando GE↔SE (0,14 ha) e VN↔SE (0,004 ha) (Tabela 4). Notou-se ainda, que 83,30% da discordância ocorreu em CHM 0-1 m, com contribuições menores em 1-2 m (7,46%), 2-3 m (3,05%), 3-5 m (3,79%) e >5 m (2,41%).

Tabela 4 – Discordância RGB×MS por faixa de CHM e tipo de troca (T1).

Faixa CHM (T1)	VN ↔ GE área (ha)	GE ↔ SE área (ha)	VN ↔ SE área (ha)	Total discordante área (ha)
0–1 m	1,29	0,142	0,004	1,44
1–2 m	0,12	0,002	0,002	0,12
2–3 m	0,05	0,000	0,001	0,05
3–5 m	0,06	0,000	0,001	0,06
>5 m	0,03	0,000	0,001	0,04

Fonte: elaboração própria.

Entre os pixels discordantes, os pares dominantes foram GE→VN (0,82 ha; 47,6%) e VN→GE (0,74 ha; 43,3%), enquanto os demais pares tiveram contribuição residual (Tabela 5). Em termos operacionais, isso indica que a principal zona de incerteza na comparação RGB e MS em T1 está na distinção entre vegetação nativa jovem e gramínea em baixa altura.

Tabela 5 – Interpretação da discordância de classificação entre modelos RGB e MS.


Pares dominantes (RGB→MS)	Área (ha)	Percentual de Discordância (%)	Interpretação
GE → VN	0,82	47,6%	MS identifica mais “nativa jovem” em estrato baixo (<1m)
VN → GE	0,74	43,3%	RGB mantém/expande gramínea onde MS indica VN
GE → SE	0,09	5,3%	divergência residual em áreas abertas
SE → GE	0,05	3,2%	pequenas trocas solo/gramínea

Fonte: elaboração própria.

A relação CHM×NDVI para pixels em acordo vs discordância (Figura 13), avaliada a partir de uma amostra aleatória de aproximadamente 40.000 pixels em T1, reforça esse diagnóstico: a discordância se concentra em baixos valores de CHM, região em que o NDVI

(derivado do multiespectral) tende a ser mais variável e a separação entre classes se torna mais sensível.

Figura 13 – Relação CHM × NDVI: pixels em acordo vs discordância.



Além da análise espacial da discordância, foi avaliado se as diferenças entre sensores alteram as tendências agregadas de mudança no período. A mudança líquida por classe entre T0 e T1, definida como a diferença entre a área em T1 e a área em T0 (Δ , em hectares), foi muito semelhante quando comparados T1 RGB e T1 MS (Tabela 6), com aumento de vegetação nativa (+2,91 ha no RGB; +3,00 ha no MS), redução de gramínea exótica (-3,17 ha no RGB; -3,28 ha no MS) e aumento discreto de Solo exposto (+0,25 ha no RGB; +0,28 ha no MS). Em termos percentuais (p.p.), a diferença entre sensores foi pequena frente ao tamanho das mudanças observadas, indicando consistência das tendências independentemente do sensor.

Tabela 6 – Diferença líquida de área por classe nos modelos de classificação RGB e MS (T1).


Classe	Δ (T1 RGB – T0) (ha)	Δ (T1 MS – T0) (ha)	Diferença percentual
Vegetação nativa	+2,91	+3,00	+0,62 p.p
Gramínea exótica	-3,17	-3,28	-0,85 p.p
Solo exposto	+0,25	+0,28	+0,23 p.p

Fonte: elaboração própria.

A partir da Figura 14, disposta abaixo, um diagrama de fluxo em que a espessura dos fluxos é proporcional à área, é possível visualizar a direção e o volume das trocas de classes de

cobertura do solo entre os modelos RGB e MS, estratificadas por faixa de altura do dossel (CHM), evidenciando convergências e divergências entre as classificações.

Figura 14 – Diagrama de fluxo entre classes de cobertura do solo em T1 para os modelos de classificação RGB e MS.



Fonte: elaboração própria.

Para avaliar a incerteza associada aos erros de classificação, estimou-se também a área ajustada por classe e seus intervalos de confiança (IC95%) a partir das matrizes de confusão da validação ($n=60$), por meio de *bootstrap* paramétrico com 80.000 reamostragens (Tabela 7). As estimativas ajustadas sugerem que, embora os mapas indiquem ~58% de vegetação nativa em T1 (Tabela 2), o valor esperado pode estar em torno de ~53% (RGB: 53,9%; MS: 53,0%), com amplitude do IC95% refletindo a incerteza amostral da validação. De forma complementar, o ajuste aumenta a participação estimada de Solo exposto (RGB: 10,5%; MS: 9,4%), sugerindo possível subdetecção dessa classe no mapeamento bruto e reforçando a importância de reportar resultados com incerteza quando o objetivo é inferência de área.

Tabela 7 – Área por classe nos modelos de classificação RGB e MS no T1 e IC 95%.

Classe	T1 RGB mapeada	T1 RGB ajustada (IC95%)		T1 MS mapeada	T1 MS ajustada (IC95%)	
	Área e percentual	Área e percentual	IC95%	Área e percentual	Área e percentual	IC95%
Vegetação nativa	7,50 ha 57,6%	7,01 ha 53,9 %	44,9-61,3%	7,58 ha 58,3%	6,90 ha 53,0%	44,7-58,9%
Gramínea exótica	4,73 ha 36,4%	4,62 ha 35,5%	26,4-45,8%	4,63 ha 35,6%	4,89 ha 37,6%	29,5-46,7%
Solo exposto	0,76 ha 5,8%	1,36 ha 10,5%	5,5-15,8%	0,80 ha 6,1%	1,22 ha 9,4%	5,5-14,7%

Fonte: elaboração própria.

5.4.1 Papel de CHM e NDVI (T1 MS): separabilidade por classe e gradientes

Para interpretar a separabilidade entre classes em T1 e a relação estrutura–vigor, foram cruzadas as camadas CHM e NDVI no modelo multiespectral. A Tabela 8 mostra que a Vegetação nativa ocupou 7,58 ha (58,2%), com CHM mediano 3,47 m e NDVI mediano 0,47. A Gramínea exótica ocupou 4,63 ha (35,6%), concentrada em baixa altura (CHM mediano 0,42 m) e com NDVI mediano 0,07. O Solo exposto totalizou 0,80 ha (6,2%), com NDVI mediano negativo (−0,30).


Tabela 8 – Área ocupada por cada classe e a mediana de seus respectivos CHM e NDVI.

Classe	Área (ha)	Área (%)	CHM mediana (m)	NDVI mediana
Vegetação nativa	7,58	58,2	3,47	0,47
Gramínea exótica	4,63	35,6	0,42	0,07
Solo exposto	0,80	6,2	0,42	-0,30

Fonte: elaboração própria.

O gráfico de dispersão CHM×NDVI por classe (Figura 15) foi gerado a partir de uma amostra estratificada de 360.000 pixels (para visualização) e evidencia a complementaridade entre estrutura (CHM) e resposta espectral (NDVI): solo exposto concentra-se em baixos valores de CHM e NDVI, vegetação nativa ocupa NDVI elevado em uma faixa ampla de alturas, e gramínea predomina em baixos valores de CHM com maior variabilidade de NDVI, indicando zona potencial de confusão sob condições de senescência e mistura de pixel.

Figura 15 – Gráfico de dispersão CHM x NDVI por classe - amostra de pixels estratificada.



Fonte: elaboração própria.

A estratificação por faixas de CHM (Tabela 9) reforça esse gradiente estrutural: em 0-1,0 m, predomina gramínea com 4,32 ha (61,5% da faixa), seguida por vegetação nativa (1,93 ha; 27,5%) e solo exposto (0,77 ha; 11,0%), ao mesmo tempo a participação relativa de vegetação nativa cresce rapidamente com a altura (por exemplo, 80,4% na faixa de 1 a 2m, 93,6% na faixa 2-5 m e 98,2% em >5 m). No conjunto, observa-se aumento do NDVI mediano de 0,11 (CHM 0-0,5 m; 42,25% da área) para 0,51 (CHM >5 m; 20,22% da área), concomitante à redução progressiva das discordâncias (Tabela 10).

Tabela 9 – Área ocupada por cada classe, relacionando faixas de CHM e NDVI médio.

Faixa CHM (m)	NDVI médio	Classe	Área (ha)	Área na faixa (%)
0 - 1	0,44	Vegetação nativa	1,93	27,5
	0,09	Gramínea exótica	4,32	61,5
	0,24	Solo exposto	0,77	11,0
1 - 2	0,43	Vegetação nativa	0,77	80,4
	0,08	Gramínea exótica	0,17	17,9
	-0,20	Solo exposto	0,02	1,7
2 - 5	0,44	Vegetação nativa	2,31	93,6
	-0,01	Gramínea exótica	0,15	5,9
	-0,23	Solo exposto	0,01	0,5
>5	0,49	Vegetação nativa	2,57	98,2
	-0,06	Gramínea exótica	0,06	1,6
	-0,20	Solo exposto	0,01	0,2

Fonte: elaboração própria.

Tabela 10 – Valores de área e discordância por faixa de CHM x mediana de NDVI para a classificação multiespectral no T1.

Faixa CHM (m)	NDVI mediana	Área (ha)	Área total %	Discordância (ha)	Discordância (%) na faixa	Discordância total (%)
0-0,5	0,11	5,50	42,25	1,06	19,20	61,00
0,5-1	0,31	1,46	11,20	0,39	26,47	22,30
1-2	0,39	0,96	7,39	0,13	13,42	7,46
2-5	0,44	2,47	18,94	0,12	4,80	6,84
>5	0,51	2,63	20,22	0,04	2,65	2,41

Fonte: elaboração própria.

5.5 Dados de campo como checagem independente do indicador de cobertura de dossel

Os dados de campo foram utilizados como checagem independente do indicador agregado “cobertura de vegetação nativa (%)”. Foram avaliados 17 trechos de 25 m, resultando em média de 58,17% de cobertura nativa (IC95%: 47,46-68,88%) (Tabela 11). As estimativas derivadas dos mapas do T1 foram consistentes com o campo: 57,67% (RGB) e 58,23% (MS), ambas dentro do intervalo de confiança (Tabela 12). Essa convergência fortalece o uso dos modelos de classificação como possível produto de monitoramento para o indicador de cobertura de vegetação nativa), por apresentar validação independente que complementa as métricas internas do classificador.

Tabela 11 – Cobertura arbórea nativa observada em campo (n=17 parcelas).

Estatística	Valor
n parcelas	17
Média (%)	58,17
Desvio padrão (%)	20,09
IC95% da média (%)	47,46 - 68,88

Fonte: elaboração própria.

Tabela 12 – Comparação do indicador “cobertura de vegetação nativa (%)” (campo e classificações de cobertura de vegetação nativa em T1).

Fonte	Percentual de cobertura de Vegetação nativa (%)	Diferença vs campo (p.p.)
Campo (média 17 parcelas)	58,17	-
Mapa T1 (RGB)	57,67	-0,50
Mapa T1 (MS)	58,23	+0,06

Fonte: elaboração própria.

5.6 Transições T0 → T1 e decomposição do ganho de vegetação nativa


Para as análises multitemporais (T0→T1), foi adotado o modelo RGB como referência principal por garantir comparabilidade direta com a classificação de T0 e apresentar desempenho/estabilidade semelhantes ao MS no T1.

A distribuição espacial das mudanças de cobertura do solo entre T0 (abr/2024) e T1 (jan/2026), a partir das classificações RGB, é apresentada na Figura 16. No período de ~20 meses, observa-se predominância de áreas estáveis (totalizando 77,0% da área), com vegetação nativa estável somando 4,53 ha (34,8%) e gramínea/solo estáveis somando 5,44 ha (42,2%). As áreas de ganho de vegetação nativa representam 2,91 ha (22,7%), distribuídas em manchas heterogêneas ao longo do polígono, indicando conversões localizadas (principalmente de gramínea para vegetação nativa) típicas do estágio inicial de restauração. As perdas de vegetação nativa foram pontuais e pouco representativas (0,03 ha; 0,3%), sugerindo que a dinâmica observada no período é dominada por ganho e consolidação de cobertura nativa, e não por retrocessos generalizados. Assim, o mapa de transição complementa a síntese quantitativa das transições ao explicitar onde ocorreram os principais ganhos e onde persistem áreas estáveis, subsidiando a priorização espacial de manejo e inspeções em campo.

A transição de classe dominante foi GE → VN (2,91 ha; 22,39%), enquanto a mudança GE→SE somou 0,58 ha (4,48%), sugerindo persistência de áreas abertas e/ou falhas localizadas

(Tabela 13). O balanço agregado do ganho de vegetação nativa é sintetizado na Tabela 14, distinguindo ganho, perda e estabilidade.

Figura 16 – Mapa de transição da cobertura do solo de T0 (RGB) para T1 (RGB).



Fonte: elaboração própria.

Tabela 13 – Pares de transição de classes de cobertura do solo de T0 para T1.

Transição	Área (ha)	Percentual de cobertura do total (%)
GE→VN	2,91	22,39
VN→VN (estável)	4,53	34,85
GE→GE (estável)	4,41	33,93
GE→SE	0,58	4,48
SE→GE	0,28	2,22
SE→VN	0,00	0,00
VN→GE	0,03	0,27
VN→SE	0,00	0,00
SE→SE (estável)	0,17	1,35

Fonte: elaboração própria.


Tabela 14 – Síntese do balanço de vegetação nativa entre T0 e T1 (ganho, perda e estabilidade).

Classe	Área (ha)	Porcentagem (%)
Ganho de Nativa	2,91	22,7
Perda de Nativa	0,03	0,3
Nativa Estável	4,53	34,8
Não-Nativa Estável	5,44	42,2

Fonte: elaboração própria.

A estratificação por faixas de altura relativa do CHM auxilia a interpretar onde a restauração avança e onde a classificação tende a ser mais incerta. A leitura dos fluxos entre classes (Figura 17), cujo diagrama representa a transição T0→T1 no modelo RGB com a largura dos fluxos proporcional à área (ha), sugere que o ganho de vegetação nativa ocorre majoritariamente em estratos baixos (<3 m), coerente com o estabelecimento inicial do processo de restauração florestal. A Tabela 15 (transições por faixa de CHM) mostra que, em CHM < 1 m, predomina a estabilidade de gramínea (GE→GE; 4,35 ha; 62,6% da faixa) e a conversão GE→VN (1,53 ha; 21,9%). No estrato 1-3 m, a conversão GE→VN domina (1,31 ha; 74,7% da faixa). Já nos estratos 3-5 m e >5 m, prevalece VN→VN (estável) (94,5% e 98,8%, respectivamente), indicando maior estabilidade em áreas com dossel mais desenvolvido. A ocorrência de solo exposto (GE→SE) concentra-se em CHM < 1 m (0,56 ha; 8,1%), coerente com o esperado para áreas abertas cujo uso do solo histórico é pastagem.

Figura 17 – Diagrama de fluxo das classes na transição T0 → T1 (RGB).



Fonte: elaboração própria.

Tabela 15 – Distribuições das principais transições T0 → T1 por faixa de altura relativa.

Transição de classes	Área acumulada por transição de classe (ha)* e percentual de cobertura na área do projeto		Área (ha) e percentual de cobertura da classe por faixa de altura relativa < 1 m		Área (ha) e percentual de cobertura da classe por faixa de altura relativa 1-3 m		Área (ha) e percentual de cobertura da classe por faixa de altura relativa 3-5 m		Área (ha) e percentual de cobertura da classe por faixa de altura relativa > 5 m	
GE→VN	2,91 ha	22,7 %	1,53 ha	52,6%	1,31 ha	45,0%	0,06 ha	2,1%	0,01 ha	0,3%
VN→VN (estável)	4,54 ha	34,8 %	-	-	0,36 ha	7,9%	1,58 ha	34,8%	2,60 ha	57,3%
GE→GE (estável)	4,41 ha	33,9 %	4,35 ha	98,6%	0,06 ha	1,4%	-	-	-	-
GE→SE	0,58 ha	4,48%	0,56 ha	96,6%	0,02 ha	3,4%	-	-	-	-
SE→GE	0,29 ha	2,2 %	0,29 ha	100,0%	-	-	-	-	-	-
SE→SE (estável)	0,17 ha	1,35 %	0,17 ha	100,0%	-	-	-	-	-	-
SE→VN	0,05 ha	0,42 %	0,05 ha	100,0%	-	-	-	-	-	-
VN→GE	0,03 ha	0,27 %	-	-	-	-	0,02 ha	66,7%	0,01 ha	33,3%
VN→SE	-	-	-	-	-	-	-	-	-	-

Nota: Totais e percentuais podem apresentar pequenas diferenças ($\approx 0,01$ ha) devido a arredondamentos na exportação/relato.

Fonte: elaboração própria.

6 DISCUSSÃO

6.1 Leitura do avanço da restauração a partir da mudança de cobertura (T0–T1)

Os resultados obtidos evidenciam uma trajetória compatível com o avanço inicial do processo de restauração florestal na área piloto, expressa pelo aumento da classe vegetação nativa e pela redução da classe gramínea exótica entre T0 e T1 (Tabela 2; Figuras 6-9). A mudança líquida por classe se manteve consistente entre sensores RGB e multiespectrais no T1 (Tabela 6), apesar de diferenças espaciais localizadas. Em termos de dinâmica ecológica e de manejo, o padrão mais informativo não é apenas o saldo líquido de área, mas a decomposição por transições, na qual a conversão GE→VN surge como componente dominante do ganho de vegetação nativa (Tabela 13; Figura 17). Esse tipo de leitura é coerente com abordagens de monitoramento orientadas a metas, em que indicadores devem apoiar decisões e ajustes de intervenção ao longo do tempo (ALBUQUERQUE *et al.*, 2024; GANN *et al.*, 2019).

A permanência de uma fração relevante de gramíneas (transições estáveis GE→GE) não deve ser interpretada automaticamente como insucesso, mas como evidência da heterogeneidade espacial da trajetória de restauração, especialmente em contextos em que gramíneas invasoras representam barreira persistente à regeneração e ao estabelecimento de mudas. Nesse sentido, a classificação espacial e a análise de transições têm alto valor operacional porque permitem transformar o mapa em ferramenta de priorização: áreas com persistência de gramíneas podem ser direcionadas para intensificação de controle, replantio localizado, reforço de condução da regeneração e ajustes de manutenção (por exemplo, frequência e estratégia de manejo), enquanto áreas com predominância de GE→VN indicam locais em que o processo está avançando com menor necessidade de intervenção corretiva, sendo possível perceber tendências na evolução do processo de restauração (Figuras 16 e 17; Tabela 13).

Esse padrão é coerente com a literatura sobre trajetórias iniciais de restauração tropical, segundo a qual a substituição progressiva de gramíneas por vegetação nativa constitui um dos sinais mais relevantes de avanço sucessional em áreas jovens, ainda que esse processo ocorra de forma espacialmente heterogênea e condicionado pelo contexto local de degradação, manejo e disponibilidade de propágulos. Em termos ecológicos, a predominância de transições de gramínea exótica para vegetação nativa sugere redução relativa da limitação imposta pela cobertura herbácea invasora e indica que parte da área já se encontra em trajetória compatível com o estabelecimento de cobertura lenhosa, embora ainda demande atenção em faixas de baixa altura e maior incerteza. Sob a ótica da gestão, esse comportamento reforça a utilidade do

monitoramento espacialmente explícito para identificar setores com resposta positiva e distinguir áreas que ainda exigem manutenção mais intensiva.

Cabe, contudo, qualificar o significado desse avanço de cobertura. O ganho da classe vegetação nativa observado entre T0 e T1 representa um indicador estrutural da trajetória de restauração - sinônimo de avanço na ocupação do solo por vegetação lenhosa, mas não deve ser lido isoladamente como medida direta da efetividade ecológica da restauração em sentido amplo. Revisões sistemáticas sobre o uso de sensoriamento remoto no monitoramento da restauração destacam que a avaliação da efetividade extrapola o percentual de cobertura, abrangendo também indicadores de solo, água e processos funcionais, e que a escolha de indicadores deve estar alinhada aos objetivos específicos de cada projeto (WANG *et al.*, 2024). Essa ressalva é particularmente pertinente diante do alerta de que indicadores de cobertura e vigor vegetal podem sugerir recuperação mais avançada do que a efetivamente alcançada, ao captarem o crescimento estrutural antes da reorganização composicional e funcional do ecossistema (IHEATURU *et al.*, 2026). Essa leitura é reforçada por revisões que organizam as tecnologias de sensoriamento remoto segundo a dimensão da recuperação que conseguem captar estrutura, cobertura, composição e função, evidenciando que nenhum sensor isolado abrange todas as dimensões e que a escolha deve ser guiada pelos objetivos do monitoramento (ALMEIDA *et al.*, 2025). Assim, o aumento de vegetação nativa documentado neste estudo deve ser interpretado como evidência robusta de progresso estrutural inicial, cujo significado ecológico pleno se consolida quando acompanhado, em etapas futuras de monitoramento, por indicadores complementares de composição e função ecológica.

O aumento discreto de solo exposto observado em T1 (Tabela 2; Tabela 6) exige interpretação cautelosa e contextualizada. Em restauração, incrementos localizados de SE podem refletir falhas de pegamento, clareiras, distúrbios pontuais, efeitos do próprio manejo (roçada/coroamento), ocorrência de processos erosivos no solo ou limitações de separabilidade entre alvos sob determinadas condições fenológicas. No presente estudo, deve-se considerar também que a presença de infraestrutura viária dentro do perímetro analisado tende a manter uma fração estruturalmente estável de solo exposto ao longo do tempo, mesmo com avanço da restauração nas demais porções do polígono. Assim, o valor do SE como “sinal ecológico” cresce quando combinado a evidências espaciais (onde se concentra), às transições associadas (GE→SE, por exemplo) e ao histórico de manejo do talhão (Tabela 13; Figura 7). Essa cautela é particularmente relevante em levantamentos com diferenças na condição da cobertura herbácea (ex.: senescência), que pode alterar a resposta espectral e aumentar confusão com solo.

6.2 Comparação RGB × Multiespectral no T1: onde os sensores diferem e porquê isso importa

Embora os modelos apresentem métricas globais semelhantes no T1 (Tabela 3; Figura 10) e produzam tendências agregadas muito próximas (Tabela 6), a comparação espacial revela uma zona de divergência importante para o uso operacional. A concordância entre os mapas T1 (RGB vs MS) foi alta, e a discordância concentrou-se em estratos de baixa altura (CHM < 1 m) (Tabela 4; Figura 12). Além disso, a discordância foi dominada por trocas VN↔GE (Tabela 5; Figura 14), indicando que a principal incerteza prática em levantamentos iniciais de restauração está na separação entre vegetação nativa jovem ou regeneração e gramínea, especialmente quando a estrutura ainda é baixa.

O detalhamento apresentado no Apêndice A reforça essa interpretação ao mostrar que o CHM foi a variável mais importante em ambos os modelos. No RGB, destacaram-se variáveis ligadas ao espectro visível e à textura, como VARI e textura média da banda vermelha. No modelo multiespectral, além do CHM, ganharam maior peso NDVI, banda NIR e banda *red-edge*, o que ajuda a explicar sua contribuição em áreas de baixa altura e maior ambiguidade visual. Esse resultado é coerente com a interpretação de que, em estratos baixos e em situações de maior sobreposição entre vegetação nativa jovem e gramínea exótica, a informação espectral além do visível aumenta a sensibilidade do classificador, mesmo quando a biomassa e a altura ainda são reduzidas.

A concentração da incerteza no estrato baixo encontra respaldo em evidências independentes da literatura sobre comparação entre sensores em áreas de restauração. Ao confrontar métricas de dossel derivadas de fotogrametria RGB e de LiDAR em plantios de restauração da Mata Atlântica, Santoro *et al.* (2025) observaram que métricas de tendência central, como a altura média de dossel, são reproduzidas com alta fidelidade pelo sensor óptico, ao passo que métricas associadas à variação de altura tendem a ser superestimadas pelo RGB, justamente pela limitação desse sensor em capturar informação confiável de terreno e de sub-bosque sob dossel fechado. Esse comportamento oferece uma explicação plausível para o padrão aqui encontrado: é nos estratos de baixa altura - onde a distinção entre solo, regeneração e gramínea depende de informação estrutural e espectral mais fina - que o sensor RGB encontra suas maiores limitações, o que é consistente com a concentração da discordância RGB×MS observada no CHM inferior a 1 m. Reforça-se, assim, que a divergência entre sensores não decorre de fragilidade do fluxo proposto, mas de uma propriedade conhecida dos dados ópticos, o que sustenta a recomendação de uso direcionado do sensor multiespectral nessas faixas críticas.

Esse resultado tem duas implicações principais. Primeiro, ele sugere que a discrepância entre sensores é predominantemente uma questão de alocação espacial, isto é, de onde o mapa posiciona as classes, mais do que uma diferença de quantidade agregada, uma vez que as mudanças líquidas são muito semelhantes (Tabela 6). Essa distinção é consistente com abordagens que recomendam decompor a discordância em componentes de quantidade e alocação, evitando interpretações excessivas de métricas sintéticas, como o Kappa, quando o interesse é aplicação e tomada de decisão. Pontius e Millones (2011) argumentam que índices desse tipo podem ser enganosos para comparação de mapas e propõem resumir a matriz de confusão por discordância de quantidade e de alocação, o que é particularmente útil quando dois mapas concordam em tendências agregadas, mas divergem espacialmente. Segundo, a concentração da discordância em baixa altura sugere que a melhor estratégia operacional é tratar o RGB como base recorrente, pela acessibilidade e pelo custo, e utilizar o multiespectral de forma estratégica como camada de controle de qualidade e investigação de discordâncias, especialmente em áreas críticas, caracterizadas por baixa altura e NDVI intermediário, como indicado pelos padrões observados (Figuras 13-15; Tabelas 4-5).

A incorporação de áreas ajustadas por erro e intervalos de confiança fortalece a robustez inferencial dos resultados, pois reduz o risco de interpretar diretamente o mapa classificado como verdade espacial absoluta. Em contextos de monitoramento aplicado, esse procedimento é particularmente relevante para reporte técnico, prestação de contas a financiadores e comparação entre campanhas, ao tornar a inferência mais transparente e mais compatível com decisões de gestão e governança. A comparação entre área mapeada e área ajustada (IC95%) em T1 (Tabela 7) indica que parte da diferença entre sensores e parte da variação entre classes deve ser interpretada à luz da incerteza associada à validação. Em particular, o ajuste tende a elevar a participação estimada de SE, sugerindo potencial subdetecção no mapeamento bruto e reforçando que estimativas de área por classe, quando usadas para inferência e reporte a terceiros, devem ser acompanhadas de incerteza e transparência metodológica, em alinhamento com recomendações de padronização e rastreabilidade presentes em protocolos operacionais.

6.3 Checagem independente com dados de campo e implicações para indicadores

A checagem independente com dados de campo reforça a confiabilidade do indicador agregado “cobertura de vegetação nativa (%)”. A média e o intervalo de confiança do levantamento em campo foram consistentes com as estimativas dos mapas no T1 (Tabelas 11 e 12). Esse resultado é importante porque conecta o produto de sensoriamento remoto a um indicador de decisão com evidência independente, fortalecendo o argumento de que o método é adequado para monitoramento operacional e reporte de resultados, desde que as limitações e

a incerteza sejam explicitadas. Em termos de governança, a combinação de (i) mapa, (ii) tabela de áreas, (iii) transições e (iv) evidência independente facilita comunicação com equipes de campo, financiadores e auditorias técnicas. Por outro lado, cabe ressaltar que essa concordância deve ser interpretada com cautela quanto à comparabilidade de escalas. Enquanto o indicador de campo resulta da média amostral obtida em 17 trechos lineares de 25 m, as estimativas derivadas dos mapas representam proporções agregadas para toda a área analisada. Assim, a proximidade entre os valores é muito positiva e fortalece a utilidade operacional do método, mas não deve ser lida como equivalência perfeita entre observações pontuais e representação espacial contínua. É possível que parte da concordância decorra também de compensações espaciais entre erros locais opostos, razão pela qual a checagem de campo deve ser entendida como evidência independente de apoio, e não como validação absoluta do mapa.

6.4 Limitações relevantes e recomendações aplicadas

A principal limitação identificada é que a maior parte da incerteza se concentra em vegetação baixa ($CHM < 1$ m), onde a separação entre gramínea exótica, solo exposto e vegetação nativa jovem é mais difícil e mais sensível a variações fenológicas e de iluminação. Essa limitação é, em parte, inerente ao estágio inicial da restauração e não invalida o método - ela define onde o monitoramento deve ser mais cauteloso e orientado por tendências ao longo do tempo, em vez de decisões baseadas em uma única data.

Para quem vai usar este fluxo em projetos de restauração, quatro recomendações práticas fortalecem a confiabilidade dos resultados:

Use o RGB como base recorrente. O sensor RGB é mais acessível, mais rápido de operar em campo e produz resultados consistentes para acompanhar a trajetória da restauração ao longo do tempo. Ele é adequado como instrumento principal de monitoramento periódico.

Use sensor multiespectral de forma direcionada. O sensor multiespectral agrega valor principalmente nas áreas de dossel baixo, onde a separação entre vegetação nativa jovem e gramínea é mais difícil. Recomenda-se utilizá-lo como camada de verificação e controle de qualidade - por exemplo, ao definir a linha de base de um projeto ou ao investigar áreas com resultados inesperados. Ressalta-se ainda, que índices espectrais derivados do ortomosaico multiespectral foram utilizados neste estudo como variáveis relativas ao levantamento de T1, e não como base para comparação radiométrica direta entre T0 e T1. Por isso, seu uso foi mais apropriado para discriminação intra-levantamento e apoio à classificação do que para inferência multitemporal absoluta de vigor espectral.

Cuide do alinhamento geométrico entre campanhas. A qualidade dos produtos altimétricos (CHM) depende da consistência geométrica entre os levantamentos. Sempre que

possível, utilize sistema RTK, pontos de controle em solo (GCPs) ou posicionamento pós-processado (PPK) para reduzir deslocamentos entre datas. Isso melhora tanto os mapas de transição quanto as estimativas estruturais. Sobre isso, vale reforçar que o CHM foi empregado neste estudo como métrica estrutural relativa, útil para estratificação, interpretação espacial e apoio à classificação, e não como medida altimétrica absoluta árvore a árvore. Da mesma forma, o fluxo proposto é mais apropriado para o monitoramento operacional da cobertura do solo e da trajetória inicial da restauração do que para inferências estruturais detalhadas em qualquer contexto geométrico ou ecológico.

As diferenças de controle geométrico entre T0 e T1, sintetizadas no Apêndice B, devem ser consideradas na interpretação dos produtos altimétricos e das comparações multitemporais. Enquanto o T0 foi processado sem GCPs e apresentou erro médio de posição da câmera de 0,5 m no plano XY e 4,8 m em Z, o T1 contou com 9 pontos de controle em solo e RMSE total de 0,2 m, o que contribui para maior consistência geométrica do processamento mais recente.

Atenção ao equilíbrio e número de amostras de referência: O aumento do número de amostras de referência tende a beneficiar principalmente a representação de condições marginais e zonas de transição entre classes, mais do que necessariamente alterar de forma substantiva as métricas globais de desempenho. No presente estudo, o risco de sobreajuste foi mitigado pela robustez do algoritmo *Random Forest*, pela validação estratificada, pela repetição aleatória dos particionamentos e pelo uso de pós-processamento espacial. Ainda assim, em contextos com maior heterogeneidade de paisagem, conjuntos amostrais mais amplos e mais diversificados poderão reduzir incertezas locais e melhorar a generalização do modelo.

Ao reportar resultados para financiadores ou equipes técnicas, recomenda-se apresentar sempre as estimativas de área acompanhadas de intervalos de confiança, distinguindo o que foi diretamente mapeado do que foi estimado com ajuste por erro. Essa transparência facilita auditorias técnicas, fortalece a credibilidade do monitoramento e é compatível com os protocolos operacionais do Pacto e das normativas estaduais paulistas (ALBUQUERQUE *et al.*, 2024; SÃO PAULO, 2014; SÃO PAULO, 2015).

Adicionalmente, recomenda-se discutir e/ou reportar medidas de discordância que decomponham o erro em componentes úteis para gestão, distinguindo diferenças de quantidade (proporção total de classes) e diferenças de alocação espacial (posicionamento no mapa), o que pode apoiar interpretações mais aplicadas do que métricas sintéticas tradicionais (PONTIUS; MILLONES, 2011). Por fim, a adoção de processamento em nuvem e fluxos reprodutíveis fortalece escalabilidade, padronização e rastreabilidade do monitoramento, alinhando-se à necessidade de transparência e replicabilidade em projetos de restauração em larga escala; nesse

sentido, o *Google Earth Engine* permite operar análises geoespaciais em escala com acesso a capacidade computacional e disseminação de resultados sem a sobrecarga de gestão de infraestrutura (GORELICK *et al.*, 2017).

Além da acurácia e da capacidade de síntese espacial, a adoção de produtos derivados de drones e processamento em nuvem apresenta vantagens operacionais para o monitoramento em restauração: redução de tempo de equipe em campo, possibilidade de inspeção direcionada em áreas críticas, e mitigação de riscos associados a deslocamento em terrenos íngremes ou com condições de segurança adversas.

Cabe ainda ressaltar uma limitação de escopo do próprio indicador adotado. A classificação de cobertura do solo aqui empregada capta primariamente a dimensão estrutural da trajetória de restauração - presença, altura e extensão de dossel, mas não informa diretamente sobre a diversidade de espécies estabelecida na área. Estudos com sensores de maior resolução espectral demonstram que atributos estruturais, como altura de dossel e índice de área foliar, são bons preditores de biomassa, mas a diferenciação de níveis de riqueza de espécies depende de variáveis espectrais mais finas, como o ângulo espectral derivado de dados hiperespectrais (ALMEIDA *et al.*, 2021). Esse achado reforça que o fluxo aqui proposto deve ser interpretado como uma ferramenta de monitoramento estrutural, e não como *proxy* direto de diversidade - uma distinção relevante para a leitura de seus resultados e para o desenho de futuras etapas de monitoramento que incorporem essa dimensão.

Esse ponto dialoga com um debate mais amplo na literatura de sensoriamento remoto aplicado à restauração, segundo o qual indicadores de cobertura e vigor da vegetação tendem a sobrestimar a recuperação real ao confundirem o crescimento estrutural rápido com a reorganização de composição de espécies e a reintegração funcional do ecossistema, processos que ocorrem em escalas temporais muito mais longas (IHEATURU *et al.*, 2026). Nessa perspectiva, a recuperação florestal pode ser compreendida em três dimensões: estrutural, composicional e funcional, cada qual exigindo diferentes sensores e horizontes temporais de observação. O presente trabalho se posiciona deliberadamente na dimensão estrutural, e seus resultados devem ser interpretados como evidência de avanço estrutural da trajetória de restauração, não como confirmação de recuperação composicional ou funcional plena - uma ressalva importante diante do risco de leituras excessivamente otimistas a partir de mapas de cobertura. Esse posicionamento dialoga com a crítica recente de que a biodiversidade tem sido historicamente tratada como aspecto secundário no monitoramento da restauração, devendo ser promovida a desfecho central, com investimento em métodos capazes de captar composição e função, e não apenas cobertura e estrutura (BRANCALION *et al.*, 2025). Reconhecer esse

limite não enfraquece o método proposto, mas o situa com precisão no conjunto de ferramentas necessárias ao monitoramento integral da restauração.

7 CONCLUSÕES

Este trabalho consolidou um fluxo digital de monitoramento de cobertura do solo para áreas em restauração florestal na Mata Atlântica, integrando drones, produtos fotogramétricos, como o modelo de altura do dossel (CHM), variáveis espectrais, classificação supervisionada e processamento em ferramentas abertas, como *Google Earth Engine* e QGIS. A principal contribuição aplicada do estudo está na proposição de um procedimento replicável, capaz de combinar mapas temáticos, análise de transições e camadas estruturais e espectrais para apoiar decisões de gestão, como priorização de manejo, inspeção de campo e manutenção, além de fortalecer a prestação de contas a parceiros e financiadores.

Em relação ao primeiro objetivo específico, a rotina de classificação supervisionada do uso e cobertura do solo foi aplicada e validada nos dois períodos analisados (T0 e T1), com desempenho elevado e estável ($OA \approx 0,90\text{--}0,91$ e $\text{Macro-F1} \approx 0,89\text{--}0,91$), confirmado por amostragem aleatória repetida. Os mapas temáticos e as métricas quantitativas permitiram caracterizar a cobertura do solo e detectar mudanças iniciais com boa estabilidade operacional, explicitando também as limitações associadas, sobretudo nos estratos de baixa altura.

Quanto ao segundo objetivo, a integração de dados multiespectrais e de métricas estruturais (CHM) e espectrais (NDVI) no período pós-plantio mostrou que os modelos RGB e multiespectral apresentaram métricas globais semelhantes e tendências agregadas muito próximas, com alta concordância espacial. As discordâncias concentraram-se no estrato baixo ($\text{CHM} < 1\text{ m}$) e foram dominadas pelas trocas entre vegetação nativa jovem e gramínea exótica, delimitando a principal zona crítica de incerteza. Nesse arranjo, o RGB mostrou-se mais adequado como base recorrente para séries temporais e monitoramento de rotina, enquanto o multiespectral e o CHM agregaram maior valor analítico justamente nessas zonas críticas.

No terceiro objetivo, a dinâmica T0→T1 foi quantificada por mudanças líquidas e por transições entre classes, evidenciando aumento da vegetação nativa e redução da gramínea exótica, com predomínio da transição GE→VN, compatível com o avanço inicial do processo de restauração. A incerteza de área por classe em T1 foi reportada por meio de estimativas ajustadas por erro e respectivos intervalos de confiança (IC95%), fortalecendo a robustez inferencial dos resultados e a sua compatibilidade com reporte técnico, governança e tomada de decisão.

A checagem independente com dados de campo reforçou a utilidade operacional do método para estimativa de cobertura de vegetação nativa, embora a comparação entre amostras lineares em campo e proporções agregadas do mapa deva ser interpretada com cautela quanto à escala.

Como limitações principais, destacam-se a maior incerteza na separação de classes em vegetação baixa, a sensibilidade de índices espectrais a condições fenológicas e a dependência da qualidade do modelo de terreno para a robustez do CHM. Esses aspectos exigem interpretação cuidadosa, especialmente em levantamentos iniciais e em áreas com maior heterogeneidade estrutural e espectral. Além disso, o fluxo proposto é mais apropriado para o monitoramento operacional da cobertura do solo e da trajetória inicial da restauração do que para inferências estruturais detalhadas, como medições altimétricas absolutas árvore a árvore.

Para aplicações futuras, recomenda-se ampliar a validação em condições críticas, reforçar o controle geométrico entre campanhas, sempre que possível com GCPs, RTK ou PPK, e expandir o fluxo para múltiplas áreas e diferentes idades de restauração. Também se destaca o potencial de aperfeiçoamento do método com a abertura dos scripts e a adaptação do fluxo para novos contextos, contribuindo para maior acessibilidade, rastreabilidade e disseminação de soluções de monitoramento digital aplicadas à restauração ecológica.

REFERÊNCIAS

ALBUQUERQUE, R. W. *et al.* **Protocolo de Monitoramento da Restauração da Mata Atlântica e da Amazônia via Sensoriamento Remoto**. São Paulo: The Nature Conservancy do Brasil, 2024. Disponível em: <https://pactomataatlantica.org.br/wp-content/uploads/2024/11/protocolo-sr-pacto-2024.pdf>. Acesso em: 02 jun. 2025.

ALBUQUERQUE, R. W. *et al.* Comparing forest restoration canopy cover measurements using RGB and multispectral sensors onboard drones. In: **SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO**, 20., 2023, Florianópolis. Anais [...]. São José dos Campos: INPE, 2023. Disponível em: <https://proceedings.science/sbsr/sbsr-2023/trabalhos/comparing-forest-restoration-canopy-cover-measurements-using-rgb-and-multispectr?lang=pt-br>. Acesso em: 10 mar. 2026.

ALMEIDA, D. R. A. *et al.* Monitoring restored tropical forest diversity and structure through UAV-borne hyperspectral and lidar fusion. **Remote Sensing of Environment**, v. 264, p. 112582, 2021. DOI: <https://doi.org/10.1016/j.rse.2021.112582>. Acesso em: 19 jun. 2025.

ALMEIDA, D. R. A. *et al.* Remote sensing approaches to monitor tropical forest restoration: current methods and future possibilities. **Journal of Applied Ecology**, v. 62, n. 2, p. 188–206, 2025. DOI: <https://doi.org/10.1111/1365-2664.14830>. Acesso em: 10 jul. 2026.

ALVARES, C. A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013. DOI: <https://doi.org/10.1127/0941-2948/2013/0507>. Acesso em: 10 jun. 2025.

ALZHANOV, A.; NUGUMANOVA, A. Crop classification using UAV multispectral images with gray-level co-occurrence matrix features. **Procedia Computer Science**, v. 231, p. 734–739, 2024. Disponível em: <https://doi.org/10.1016/j.procs.2023.12.145>. Acesso em: 10 jul. 2026.

BARRETTO, A. G. O. P. *et al.* **Impactos das metas de recuperação de pastagens degradadas do Plano ABC+ no Brasil**. Piracicaba: Fundação de Estudos Agrários Luiz de Queiroz, 2023. Relatório técnico. Disponível em: https://www.gov.br/agricultura/pt-br/assuntos/sustentabilidade/planoabc-abcmais/publicacoes/estudo-completo_impactos-da-rpd.pdf. Acesso em: 19 jun. 2025.

BELGIU, M. *et al.* Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 2016. DOI: [10.1016/j.isprsjprs.2016.01.011](https://doi.org/10.1016/j.isprsjprs.2016.01.011). Disponível em: <https://doi.org/10.1016/j.isprsjprs.2016.01.011>. Acesso em: 13 jul. 2026.

BRANCALION, P. H. S.; HOLL, K. D. Guidance for successful tree planting initiatives. **Journal of Applied Ecology**, v. 57, n. 12, p. 2349–2361, 2020. DOI: <https://doi.org/10.1111/1365-2664.13725>. Acesso em: 11 jun. 2025.

BRANCALION, P. H. S. *et al.* Moving biodiversity from an afterthought to a key outcome of forest restoration. **Nature Reviews Biodiversity**, v. 1, n. 4, p. 248–261, 2025. DOI: <https://doi.org/10.1038/s44358-025-00032-1>. Acesso em: 19 jun. 2025.

BRASIL. Ministério do Meio Ambiente. **Plano Nacional de Recuperação da Vegetação Nativa – Planaveg**. Brasília: MMA, 2024. Disponível em: https://www.gov.br/mma/pt-br/composicao/sbio/dflo/plano-nacional-de-recuperacao-da-vegetacao-nativa-planaveg/planaveg_2025-2028_2dez2024.pdf. Acesso em: 06 jun. 2025.

CHAZDON, R. L. *et al.* When is a forest a forest? Forest concepts and definitions in the era of forest and landscape restoration. **Ambio**, v. 46, p. 537–550, 2017. DOI: <https://doi.org/10.1007/s13280-016-0772-y>. Acesso em: 08 jun. 2025.

CHAZDON, R. L. *et al.* Fostering natural forest regeneration on former agricultural land through economic and policy interventions. **Environmental Research Letters**, v. 15, n. 4, p. 043002, 2020. DOI: <https://doi.org/10.1088/1748-9326/ab79e6>. Acesso em: 07 mar. 2026.

COOK-PATTON, S. C. *et al.* Mapping carbon accumulation potential from global natural forest regrowth. **Nature**, v. 585, p. 545–550, 2020. DOI: <https://doi.org/10.1038/s41586-020-2686-x>. Acesso em: 08 jun. 2025.

CROUZEILLES, R. *et al.* Achieving cost-effective landscape-scale forest restoration through targeted natural regeneration. **Conservation Letters**, v. 13, n. 3, p. e12709, 2020. DOI: <https://doi.org/10.1111/conl.12709>. Acesso em: 13 jun. 2025.

EMBRAPA. **Sistema Brasileiro de Classificação de Solos**. 5. ed. Brasília: Embrapa – Empresa Brasileira de Pesquisa Agropecuária, 2018. Disponível em: www.embrapa.br/solos/sibcs. Acesso em: 16 jun. 2025.

FAMIGLIETTI, N. A. *et al.* A Test on the Potential of a Low Cost Unmanned Aerial Vehicle RTK/PPK Solution for Precision Positioning. **Sensors**, v. 21, n. 11, p. 3882, 2021. Disponível em: <https://doi.org/10.3390/s21113882>. Acesso em: 10 jul. 2026.

FAO; UNEP. **The State of the World's Forests 2020**. Rome: FAO, 2021. DOI: <https://doi.org/10.4060/ca8642en>. Acesso em: 13 jun. 2025.

FARWELL, L. S. *et al.* Habitat heterogeneity captured by 30-m resolution satellite image texture predicts bird richness across the United States. **Ecological Applications**, v. 30, n. 8, p. e02157, 2020. Disponível em: <https://doi.org/10.1002/eap.2157>. Acesso em: 10 jul. 2026.

FERNANDES, A. A. *et al.* Determinants of farm-level land use decisions and perceptions of associated ecosystem services in the Brazilian Atlantic Forest. **Restoration Ecology**, v. 33, n. 8, e70089, 2025. DOI: <https://doi.org/10.1111/rec.70089>. Acesso em: 18 jun. 2025.

FORSMOO, J. *et al.* Structure from motion photogrammetry in ecology: does the choice of software matter? **Methods in Ecology and Evolution**, v. 9, n. 23, p. 12964–12979, 2019. DOI: <https://doi.org/10.1002/ece3.5443>. Acesso em: 08 jun. 2025.

FRANKLIN, S. E.; AHMED, O. S. **Remote sensing of vegetation: principles, techniques, and applications**. Boca Raton: CRC Press, 2018.

GANN, G. D. *et al.* International principles and standards for the practice of ecological restoration. Second edition. **Restoration Ecology**, v. 27, p. S1–S46, 2019. Disponível em: <https://www.ser.org/page/SERStandards>. Acesso em: 14 jun. 2025.

GORELICK, N. *et al.* Google Earth Engine: planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 2017. DOI: <https://doi.org/10.1016/j.rse.2017.06.031>. Acesso em: 11 jun. 2025.

GUARIGUATA, M. R.; BRANCALION, P. H. S. Current challenges and perspectives for governing forest restoration. **Forests**, v. 5, n. 12, p. 3022–3030, 2014. DOI: <https://doi.org/10.3390/f5123022>. Acesso em: 11 jun. 2025.

HANSEN, M. C. *et al.* High-resolution global maps of 21st-century forest cover change. **Science**, v. 342, n. 6160, p. 850–853, 2013. DOI: <https://doi.org/10.1126/science.1244693>. Acesso em: 10 jun. 2025.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on Systems, Man, and Cybernetics**, v. SMC-3, n. 6, p. 610–621, 1973. Disponível em: <https://doi.org/10.1109/TSMC.1973.4309314>. Acesso em: 10 jul. 2026.

HOLL, K. D. **Primer of ecological restoration**. Washington, DC: Island Press, 2023.

HUETE, A. R. *et al.* Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1–2, p. 195–213, 2002. DOI: [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2). Acesso em: 14 jun. 2025.

IBGE. **Manual Técnico da Vegetação Brasileira**. 2. ed. Rio de Janeiro: Instituto Brasileiro de Geografia e Estatística, 2012. Disponível em: biblioteca.ibge.gov.br. Acesso em: 09 jun. 2025.

IHEATURU, C. J. *et al.* Remote sensing of tropical forest recovery: a review and decision-support framework for multi-sensor integration. **Remote Sensing of Environment**, v. 335, p. 115257, 2026. DOI: <https://doi.org/10.1016/j.rse.2026.115257>. Acesso em: 19 jun. 2025.

INMET. **Normais Climatológicas do Brasil 1991-2020**. Instituto Nacional de Meteorologia, 2023. Disponível em: <https://portal.inmet.gov.br/normais>. Acesso em: 17 jun. 2025.

KASAHUN, M.; LEGESSE, A. Machine learning for urban land use/cover mapping: comparison of artificial neural network, random forest and support vector machine, a case study of Dilla town. **Heliyon**, v. 10, n. 20, e39146, 2024. DOI: <https://doi.org/10.1016/j.heliyon.2024.e39146>. Acesso em: 19 jun. 2025.

KUPIDURA, P. The Comparison of Different Methods of Texture Analysis for Their Efficacy for Land Use Classification in Satellite Imagery. **Remote Sensing**, v. 11, n. 10, p. 1233, 2019. DOI: 10.3390/rs11101233. Disponível em: <https://doi.org/10.3390/rs11101233>. Acesso em: 01 jun. 2025

LABRADOR, J. P. *et al.* Challenging the link between functional and spectral diversity with radiative transfer modeling and data. **Remote Sensing of Environment**, v. 280, p. 113170, 2022. DOI: 10.1016/j.rse.2022.113170. Disponível em: <https://doi.org/10.1016/j.rse.2022.113170>. Acesso em 05 jun. 2025.

MAPBIOMAS. **Coleção 8.0 da Série Anual de Mapas de Cobertura e Uso do Solo do Brasil**. 2023. Disponível em: <https://brasil.mapbiomas.org/estatisticas/>. Acesso em: 02 jun. 2025.

MELI, P. *et al.* A global review of past land use, climate, and active vs. passive restoration effects on forest recovery. **PLoS ONE**, v. 12, n. 2, p. e0171368, 2017. DOI: <https://doi.org/10.1371/journal.pone.0171368>. Acesso em: 15 jun. 2025.

MINATTI, E. *et al.* Análise multi-temporal de imagens de satélite e NDVI em unidade de conservação. **Research, Society and Development**, v. 12, n. 4, p. e1112440839, 2023. Disponível em: <https://doi.org/10.33448/rsd-v12i4.40839>. Acesso em: 10 jul. 2026.

MYERS, N. *et al.* Biodiversity *hotspots* for conservation priorities. **Nature**, v. 403, n. 6772, p. 853–858, 2000. Disponível em: <https://www.nature.com/articles/35002501>. Acesso em: 19 jun. 2025.

NEMANI, R. R. *et al.* Climate-driven increases in global terrestrial net primary production from 1982 to 1999. **Science**, v. 300, n. 5625, p. 1560–1563, 2003. DOI: <https://doi.org/10.1126/science.1082750>. Acesso em: 08 jun. 2025.

OLOFSSON, P. *et al.* Good practices for estimating area and assessing accuracy of land change. **Remote Sensing of Environment**, v. 148, p. 42–57, 2014. DOI: <https://doi.org/10.1016/j.rse.2014.02.015>. Acesso em: 07 mar. 2026.

PACTO. **Protocolo para o Monitoramento de Projetos de Restauração Florestal**. 2. ed. São Paulo: Pacto Pela Restauração da Mata Atlântica, 2013. Disponível em: <https://www.pactomataatlantica.org.br/wp-content/uploads/2021/05/protocolo-de-monitoramento-pt.pdf>. Acesso em: 05 jun. 2025.

PERRONE, M. *et al.* The relationship between spectral and plant diversity: Disentangling the influence of metrics and habitat types at the landscape scale. **Remote Sensing of Environment**, v. 293, p. 113591, 2023. Disponível em: <https://doi.org/10.1016/j.rse.2023.113591>. Acesso em 10 jul. 2026.

PONTIUS, R. G.; MILLONES, M. S. Death to kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. **International Journal of Remote Sensing**, v. 32, n. 15, p. 4407–4429, 2011. DOI: <https://doi.org/10.1080/01431161.2011.552923>. Acesso em: 05 jun. 2025.

REDDY, Y. D. K. *et al.* Machine learning for land use and land cover mapping in Google Earth Engine: A review of methods, applications, and challenges. **Ecological Frontiers**, v. 46, n. 3, p. 1105–1118, 2026. DOI: [10.1016/j.ecofro.2025.12.015](https://doi.org/10.1016/j.ecofro.2025.12.015). Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S2950509725002357>. Acesso em: 13 jul. 2026.

ROBINSON, J. M. *et al.* Existing and emerging uses of drones in restoration ecology. **Methods in Ecology and Evolution**, v. 13, n. 9, p. 1899–1911, 2022. DOI: <https://doi.org/10.1111/2041-210X.13912>. Acesso em: 07 jun. 2025.

RODRIGUES, R. R. *et al.* Large-scale ecological restoration of high-diversity tropical forests in SE Brazil. **Forest Ecology and Management**, v. 261, n. 10, p. 1605–1613, 2011. DOI: <https://doi.org/10.1016/j.foreco.2010.07.005>. Acesso em: 09 jun. 2025.

RODRIGUEZ-GALIANO, V. F. *et al.* Random Forest classification of Mediterranean land cover using multi-seasonal imagery and multi-seasonal texture. **Remote Sensing of Environment**, v. 121, p. 93-107, 2012. DOI: 10.1016/j.rse.2011.12.003. Disponível em: <https://doi.org/10.1016/j.rse.2011.12.003>. Acesso em: 07 jun. 2025.

SANTORO, G. B. *et al.* Monitoring the structure of restored forests and assessing aboveground carbon density through canopy metrics derived from digital aerial photogrammetry and LiDAR. **Restoration Ecology**, 2025. DOI: <https://doi.org/10.1111/rec.70077>. Acesso em: 06 jun. 2025.

SÃO PAULO. Secretaria Estadual do Meio Ambiente. **Resolução SMA nº 32, de 03 de abril de 2014**. Estabelece as orientações, diretrizes e critérios sobre restauração ecológica no Estado de São Paulo, e dá providências correlatas. Alterada pela Resolução SIMA nº 73, de 16 de setembro de 2020. São Paulo: SMA, 2014. Disponível em: https://smastr16.blob.core.windows.net/home/2024/11/2014-Resolucao-SMA-32_-_Restauracao-Ecologica-alterada-pela-Resolucao-SIMA-73-2020.pdf. Acesso em: 07 mar. 2026.

SÃO PAULO. Secretaria Estadual do Meio Ambiente. Coordenadoria de Biodiversidade e Recursos Naturais. **Portaria CBRN nº 01, de 15 de janeiro de 2015**. Estabelece o Protocolo de Monitoramento de Projetos de Restauração Ecológica. São Paulo: CBRN, 2015. Disponível em: https://smastr16.blob.core.windows.net/legislacao/2016/12/2015_1_15_Procoto_lo_monitoramento_restauracao_vfinal.pdf. Acesso em: 07 mar. 2026.

SCHMIDT, I. B. *et al.* Community-based native seed production for restoration in Brazil – the role of networks and policies. **Perspectives in Ecology and Conservation**, v. 17, p. 15–22, 2019. DOI: <https://doi.org/10.1111/plb.12842>. Acesso em: 13 jun. 2025.

SOSMA. **Aprendizados da restauração florestal na Mata Atlântica: 42 milhões de mudas de árvores nativas plantadas**. São Paulo: Fundação SOS Pró Mata Atlântica, 2022. Disponível em: https://cms.sosma.org.br/wp-content/uploads/2022/04/SOSMA_Restauracao.pdf. Acesso em: 16 jun. 2025.

SOSMA; INPE. **Atlas dos Remanescentes Florestais da Mata Atlântica: Período 2023-2024**. São Paulo: Fundação SOS Mata Atlântica; Instituto Nacional de Pesquisas Espaciais, 2025. Disponível em: <https://sosma.org.br/iniciativas/atlas-da-mata-atlantica>. Acesso em: 11 jun. 2025.

SOUZA, C. M. *et al.* Reconstructing three decades of land use and land cover changes in Brazilian biomes with Landsat archive and Earth Engine. **Remote Sensing**, v. 12, n. 17, p. 2735, 2020. DOI: <https://doi.org/10.3390/rs12172735>. Acesso em: 10 jun. 2025.

SUDING, K. N. Toward an era of restoration in ecology: successes, failures, and opportunities ahead. **Annual Review of Ecology, Evolution, and Systematics**, v. 42, p. 465–487, 2011. DOI: <https://doi.org/10.1146/annurev-ecolsys-102710-145115>. Acesso em: 06 jun. 2025.

TALUKDAR, S. *et al.* Land-use land-cover classification by machine learning classifiers for satellite observations — A review. **Remote Sensing**, v. 12, n. 7, p. 1135, 2020. DOI: [10.3390/rs12071135](https://doi.org/10.3390/rs12071135). Disponível em: <https://doi.org/10.3390/rs12071135>. Acesso em: 13 jul. 2026.

TONETTI, V. *et al.* A long road to resilience: large-scale forest recovery but limited persistence in the Atlantic Forest. **Perspectives in Ecology and Conservation**, v. 24, n. 1, p. 23–28, 2026. DOI: <https://doi.org/10.1016/j.pecon.2025.11.001>. Acesso em: 07 mar. 2026.

TOTO, R. *et al.* Evidence on scaling forest restoration from the Atlantic Forest Restoration Pact in Brazil. **Nature Communications**, v. 16, n. 1, p. 4715, 2025. DOI: <https://doi.org/10.1038/s41467-025-59194-3>. Acesso em: 01 jun. 2025.

WANG, R. *et al.* Remote sensing application in ecological restoration monitoring: a systematic review. **Remote Sensing**, v. 16, n. 12, p. 2204, 2024. DOI: <https://doi.org/10.3390/rs16122204>. Acesso em: 19 jun. 2025.

WESTOBY, M. J. *et al.* Structure-from-Motion photogrammetry: a low-cost, effective tool for geoscience applications. **Geomorphology**, v. 179, p. 300–314, 2012. DOI: <https://doi.org/10.1016/j.geomorph.2012.08.021>. Acesso em: 10 jun. 2025.

GLOSSÁRIO

Bandas *red-edge* - Faixas espectrais localizadas entre o vermelho e o infravermelho próximo, sensíveis a variações na estrutura e composição da vegetação, amplamente utilizadas em índices espectrais para monitoramento do vigor e da saúde das plantas.

Landsat - Programa norte-americano de satélites de observação da Terra, amplamente utilizado em análises multitemporais e monitoramento ambiental.

MapBiomas - Projeto colaborativo brasileiro que produz mapas anuais de uso e cobertura da terra por sensoriamento remoto.

Matriz de confusão - Tabela que compara classificações previstas e observadas, utilizada para avaliar o desempenho de modelos de classificação supervisionada.

Ortomosaico - Imagem composta por diversas fotografias aéreas ortorretificadas, corrigidas geometricamente para representar fielmente a superfície terrestre, com escala uniforme e precisão métrica.

Pipeline - Sequência organizada e automatizada de etapas de processamento de dados, incluindo importação, análise, classificação e exportação de produtos.


Proxy - Indicador indireto ou variável substituta utilizada para inferir características ou processos que não podem ser medidos diretamente.

Random Forest (Floresta Aleatória) - Algoritmo de aprendizado de máquina baseado em múltiplas árvores de decisão, amplamente utilizado para classificação supervisionada em sensoriamento remoto.

APÊNDICE A – IMPORTÂNCIA DAS VARIÁVEIS PREDITORAS NAS CLASSIFICAÇÕES SUPERVISIONADAS


Este apêndice apresenta a importância relativa das variáveis preditoras exportada a partir dos classificadores *Random Forest* ajustados para o T1, tanto no modelo RGB quanto no modelo multiespectral. O objetivo é complementar a interpretação apresentada no corpo do texto, evidenciando quais grupos de variáveis contribuíram com maior peso para a classificação. Em ambos os modelos, o CHM ocupou a primeira posição. No modelo RGB, destacaram-se também variáveis relacionadas ao espectro visível e à textura, enquanto no modelo multiespectral ganharam maior relevância variáveis associadas ao vigor espectral da vegetação, como NDVI, NIR e *red-edge*.

Figura A1 – Variáveis preditoras mais importantes no modelo RGB em T1.



Fonte: elaboração própria.

Figura A2 – Variáveis preditoras mais importantes no modelo multiespectral em T1.



Fonte: elaboração própria.

APÊNDICE B – RELATÓRIOS DE PROCESSAMENTOS FOTOGRAMÉTRICOS

Este apêndice apresenta uma síntese dos relatórios de processamento fotogramétrico gerados no software Agisoft Metashape para os períodos T0 e T1. Seu objetivo é complementar as informações resumidas na Tabela 1 de Materiais e Métodos, reunindo métricas de alinhamento, densidade e resolução dos produtos, características da nuvem de pontos e indicadores de controle geométrico relevantes para a interpretação dos ortomosaicos, modelos altimétricos e demais produtos derivados utilizados no estudo.

Tabela B1 – Síntese dos relatórios de processamento fotogramétrico em T0 e T1.

Indicador	T0	T1	Observação
Data do relatório de processamento	12 jun. 2025	30 jan. 2026	Relatórios exportados do Agisoft Metashape
Software (versão)	Agisoft Metashape Pro 2.2.1 build 19987	Agisoft Metashape Pro 2.2.1 build 19987	Mesmo software e versão nos dois processamentos
Sistema de coordenadas do processamento	SIRGAS 2000 / UTM zona 23S (EPSG:31983)	SIRGAS 2000 / UTM zona 23S (EPSG:31983)	
Nº de imagens	573	3.530	
Área coberta (km²)	0,566	0,463	
Tie points (n)	460.074	691.530	
Projeções (n)	2.132.997	7.141.986	
Erro de reprojeção (pix)	0,814	1,461	
DEM/MDT – resolução (cm/pix)	18,6	18,4	Produto altimétrico base do processamento
Densidade de pontos (pts/m²)	28,9	29,5	
Nº de pontos na nuvem densa (n)	43.691.644	39.191.343	
Ortomosaico – resolução (cm/pix)	4,65	4,60	
Ortomosaico – bandas / profundidade radiométrica	3 bandas, uint8	7 bandas, uint16	
Controle geométrico	GNSS embarcado, sem GCPs	9 GCPs	T1 com pontos de controle em solo
Erro médio de posição da câmera XY (m)	0,519	–	Disponível apenas no relatório T0
Erro médio de posição da câmera Z (m)	4,800	–	Disponível apenas no relatório T0
RMSE GCP total (m)	–	0,211	Disponível apenas no relatório T1
RMSE GCP X/Y/Z (m)	–	0,115 / 0,163 / 0,068	Disponível apenas no relatório T1

Fonte: elaboração própria.