



**UNIVERSIDADE FEDERAL DO MATO GROSSO
FACULDADE DE ENGENHARIA FLORESTAL
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS E
AMBIENTAIS**

**ANÁLISE ESPACIAL E MAPEAMENTO DETALHADO DE CADASTROS
AMBIENTAIS RURAIS NO BIOMA CERRADO EM CHAPADA DOS
GUIMARÃES/MT**

ANAANGÉLICA PEREIRA DA SILVA

Magister Scientiae

CUIABÁ - MT

2025

ANAANGÉLICA PEREIRA DA SILVA

ANÁLISE ESPACIAL E MAPEAMENTO DETALHADO DE CADASTROS
AMBIENTAIS RURAIS NO BIOMA CERRADO EM CHAPADA DOS
GUIMARÃES/MT

Dissertação apresentada à Universidade Federal de
Mato Grosso, como parte das exigências do Programa
de Pós-Graduação em Ciências Florestais e
Ambientais da Faculdade de Engenharia Florestal,
para obtenção do título de *Magister Scientiae*.

Orientador: Prof. Dr. Gustavo Manzon Nunes.

CUIABÁ - MT

2025

Dados Internacionais de Catalogação na Fonte.

S586a Silva, Anaangelica Pereira da.
Análise espacial e mapeamento detalhado de cadastros ambientais rurais no bioma cerrado em Chapada dos Guimarães/MT [recurso eletrônico] / Anaangelica Pereira da Silva. – Dados eletrônicos (1 arquivo : 90 f., il. color., pdf). – 2025.
Orientador: Gustavo Manzoni Nunes Nunes.
Dissertação (mestrado) - Universidade Federal de Mato Grosso, Faculdade de Engenharia Florestal, Programa de Pós-Graduação em Ciências Florestais e Ambientais, Cuiabá, 2025.
Modo de acesso: World Wide Web: <https://ri.ufmt.br>.
Inclui bibliografia.

1. Sensoriamento Remoto, Random Forest, Planet SuperDove, Chapada dos Guimarães.. I. Nunes, Gustavo Manzoni Nunes, orientador. II. Título.

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

Permitida a reprodução parcial ou total, desde que citada a fonte.



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE MATO GROSSO
PRÓ-REITORIA DE ENSINO DE PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS EM AMBIENTAIS

FOLHA DE APROVAÇÃO

TÍTULO: ANÁLISE ESPACIAL E MAPEAMENTO DETALHADO DE CADASTROS AMBIENTAIS RURAIS NO BIOMA CERRADO EM CHAPADA DOS GUIMARÃES/MT

AUTORA: MESTRANDA ANAANGÉLICA PEREIRA DA SILVA

Dissertação defendida e aprovada em 27 de fevereiro de 2025.

COMPOSIÇÃO DA BANCA EXAMINADORA

1. DOUTOR GUSTAVO MANZON NUNES (PRESIDENTE BANCA)

INSTITUIÇÃO: UNIVERSIDADE FEDERAL DE MATO GROSSO

2. DOUTOR GUSTAVO MANZON NUNES ORIENTADOR)

INSTITUIÇÃO: UNIVERSIDADE FEDERAL DE MATO GROSSO

3. DOUTOR IBRAIM FANTIN DA CRUZ (EXAMINADOR INTERNO)

INSTITUIÇÃO: UNIVERSIDADE FEDERAL DE MATO GROSSO

4. DOUTOR JOSÉ GUILHERME ROQUETTE (EXAMINADOR EXTERNO)

INSTITUIÇÃO: MINISTÉRIO PÚBLICO DE MATO GROSSO

CUIABÁ, 27/02/2025.



Documento assinado eletronicamente por **GUSTAVO MANZON NUNES**, Docente da Universidade Federal de Mato Grosso, em 27/02/2025, às 18:21, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **IBRAIM FANTIN DA CRUZ, Docente da Universidade Federal de Mato Grosso**, em 27/02/2025, às 20:20, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **José Guilherme Roquette, Usuário Externo**, em 27/02/2025, às 23:27, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufmt.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **7640955** e o código CRC **EBFCDBC7**.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por me conceder forças e oportunidades para chegar até aqui.

Ao meu amado esposo, Helton Cesar, pelo apoio incondicional, amor e cuidado.

Aos meus filhos, Raí Cesar, pela dedicação e ajuda com seus irmãos, Ana Sofia e Romeo Cesar, vocês são minha inspiração diária e motivo do meu esforço.

Aos meus queridos pais, Elvira da Silva Modesto (*in memoriam*) e Osvaldo Pereira da Silva, pelo amor, carinho, por acreditarem em mim e pelo apoio constante ao longo dessa jornada. Aos meus sogro e sogra, Aid Pereira e Nei de Oliveira, pelo carinho e incentivo. À minha comadre Erida Maroto, que, mesmo à distância, sempre me deu apoio e esteve presente em todos os momentos importantes da minha vida.

À Universidade Federal de Mato Grosso (UFMT), por me proporcionar a formação de mestra; ao Programa de Pós-Graduação em Ciências Florestais e Ambientais (PPGCFA), por contribuir para minha jornada acadêmica e expandir meus conhecimentos.

Ao meu orientador, Prof. Dr. Gustavo Manzon Nunes, pela orientação, paciência e ensinamentos fundamentais para a realização deste trabalho. Ao Diego, pelos valiosos ensinamentos e contribuições. A todos os professores da universidade, por serem guias e referências em suas áreas.

E, por fim, a todas as pessoas que, de alguma forma, me acompanharam e continuam me acompanhando nesta caminhada, muito obrigada!

*“À memória da minha mãe, Elvira da
Silva Modesto,
que agora habita a eternidade, mas
cuja presença ainda ilumina meus
caminhos. Que este trabalho honre a
mulher incrível que me ensinou a
nunca desistir.*

RESUMO

ANÁLISE ESPACIAL E MAPEAMENTO DETALHADO DE CADASTROS AMBIENTAIS RURAIS NO BIOMA CERRADO EM CHAPADA DOS GUIMARÃES/MT

O Cadastro Ambiental Rural (CAR) é um instrumento essencial para o monitoramento e regularização ambiental de imóveis rurais no Brasil. No estado de Mato Grosso, sua implementação enfrenta desafios relacionados à confiabilidade dos dados auto declaratórios e à necessidade de análises técnicas que garantam maior precisão. Diante desse contexto, este estudo teve como objetivo mapear a cobertura e o uso do solo no município de Chapada dos Guimarães utilizando imagens de alta resolução do satélite Planet SuperDove e técnicas de aprendizado de máquina, com foco no algoritmo Random Forest. Também foi realizada uma análise espacial dos imóveis cadastrados no CAR, a fim de identificar divergências entre os dados declarados, os validados pela SEMA e os obtidos por meio da classificação temática automatizada em escala 1:25.000.

A metodologia incluiu o pré-processamento das imagens, classificação supervisionada, refinamento visual de áreas críticas e validação dos resultados com o índice Kappa. A classificação atingiu uma acurácia global de 91% e coeficiente Kappa de 0,89. As análises evidenciaram divergências relevantes, como a superestimação de Áreas de Uso Restrito (AUAS) e Reservas Legais (ARL) no CAR em relação aos dados mapeados sendo observada, por exemplo, uma diferença de +1.576 há nas AUAS e 1.414 há nas Áreas de Vegetação Nativa (AVN). Além disso, classes como APP e APPD apresentaram variações de +49,13% e +271,11%, respectivamente. Uma limitação identificada foi a dificuldade de mapeamento automático das veredas, devido à similaridade espectral com outras classes e à variação fenológica, exigindo refinamento manual por interpretação visual.

Os resultados confirmam a utilidade de dados geoespaciais de alta resolução integrados a técnicas de aprendizado de máquina para o aprimoramento da base temática e apontam a necessidade de melhorias nos mecanismos de validação do CAR. O estudo contribui para o fortalecimento da governança ambiental em Mato Grosso, promovendo uma gestão territorial mais precisa, eficaz e alinhada às exigências do Código Florestal.

PALAVRAS CHAVE: Sensoriamento Remoto, Random Forest, Planet SuperDove, Chapada dos Guimarães.

ABSTRACT

SPATIAL ANALYSIS AND DETAILED MAPPING OF RURAL ENVIRONMENTAL REGISTERS IN THE CERRADO BIOME IN CHAPADA DOS GUIMARÃES/MT.

The Rural Environmental Registry (CAR) is an essential instrument for monitoring and environmental regularization of rural properties in Brazil. In the state of Mato Grosso, its implementation faces challenges related to the reliability of self-declared data and the need for technical analyses to ensure greater precision. In this context, the objective of this study was to map land use and land cover in the municipality of Chapada dos Guimarães using high-resolution Planet SuperDove satellite imagery and machine learning techniques, focusing on the Random Forest algorithm. Additionally, a spatial analysis of the properties registered in the CAR was carried out to identify discrepancies between the declared data, those validated by SEMA, and those obtained through automated thematic classification at a 1:25,000 scale.

The methodology included image preprocessing, supervised classification, visual refinement of critical areas, and accuracy assessment using the Kappa index. The classification achieved an overall accuracy of 91% and a Kappa coefficient of 0.89. The analyses revealed significant discrepancies, such as the overestimation of Areas of Restricted Use (AUAS) and Legal Reserves (ARL) in the CAR compared to the mapped data with, for example, a +1,576 ha difference in AUAS and 1,414 ha in Native Vegetation Areas (AVN). Moreover, classes such as Permanent Preservation Areas (APP) and Degraded APP (APPD) showed variations of +49.13% and +271.11%, respectively. A key limitation identified was the difficulty in automatically mapping veredas (palm swamp ecosystems), due to their spectral similarity with other classes and phenological variation, requiring manual refinement through visual interpretation.

The results confirm the usefulness of high-resolution geospatial data integrated with machine learning techniques for improving thematic mapping and highlight the need for enhancements in CAR validation mechanisms. The study contributes to strengthening environmental governance in Mato Grosso, promoting a more accurate, effective, and legally compliant territorial management under the Forest Code.

Keywords: Rural Environmental Registry (CAR), Machine Learning, Random Forest.

LISTA DE TABELAS

Tabela 1. Especificações das bandas do Satélite Planet Super Dove.....	42
Tabela 2. Classes Classificação Supervisionada Random Forest.....	43
Tabela 3. Classes Classificação Supervisionada.....	44
Tabela 4. Matriz de Confusão e Índice Kappa.....	48
Tabela 5. Especificação das bandas espectrais Satélite Super Dove.....	61
Tabela 6. Classes Classificação Supervisionada Random Forest.....	61
Tabela 6. Classes Classificação Supervisionada Random Forest.....	62
Tabela 7. Classes SIMCAR.....	64
Tabela 8. Tabela Valores Classes SIMCAR.....	71
Tabela 8. Tabela Valores Classes SIMCAR.....	72
Tabela 9. Tabela Valores Classes LabSensor.....	73

LISTA DE FIGURAS

Figura 1. Fluxo de radiação no Sensoriamento Remoto.....	16
Figura 2. Representação esquemática do algoritmo Random Forest.....	19
Figura 4. Distribuição Espacial Cadastro SIMCAR.....	28
Figura 1. Mapa da área de Estudo.....	41
Figura 2. Mapa do Resultado da Classificação Supervisionada.....	45
Figura 3. Mapa do Resultado da Classificação por classe.....	46
Figura 4. Áreas protegidas do Município Chapada dos Guimarães.....	50
Figura 1. Mapa de Localização da área de estudo.....	60
Figura 2. Mapa Propriedades Validadas Geoportal.....	67

LISTA DE ABREVEATUTAS

AC - Área Consolidada

ALOS PALSAR - Radar de Abertura Sintética de Banda L tipo Phased Array por Satélite de Observação Avançada

APP - Área de Preservação Permanente

APPD - Área de Preservação Permanente Degradada

ATP - Área Total da Propriedade

AU - Área Úmida

AUAS - Área de Uso Antropizado do Solo

AVN - Área de Vegetação Nativa

CAR - Cadastro Ambiental Rural

DEC.45° - Área com Declive acima de 45°

GEOPORTAL - Plataforma geoespacial utilizado para análise SEMA - MT

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

IBGE - Instituto Brasileiro de Geografia e Estatística

ICMBio - Instituto Chico Mendes de Conservação da Biodiversidade

INPE - Instituto Nacional de Pesquisas Espaciais

LABSENSOR - Laboratório de Sensoriamento Remoto - UFMT

MAPA - Ministério da Agricultura, Pecuária e Abastecimento

MAPBIOMAS - Projeto de Mapeamento Anual da Cobertura e Uso da Terra

MDE - Modelo Digital de Elevação

MMA - Ministério do Meio Ambiente

PRA - Programa de Regularização Ambiental

QGIS - Quantum GIS (Software de SIG)

RF – Random Forest (Algoritmo de Aprendizado de Máquina)

RL - Reserva Legal

SFB - Serviço Florestal Brasileiro

SICAR - Sistema de Cadastro Ambiental Rural

SIMCAR – Sistema Matogrossenses de Cadastro Ambiental Rural

SIG - Sistema de Informação Geográfica

U.R - Uso Restrito

VER – Veredas

SUMÁRIO

1. CAPÍTULO I- INTRODUÇÃO GERAL	12
1.1 REVISÃO DE LITERATURA	16
1.2 MAPA TEMÁTICO	16
1.3 O SENSORIAMENTO REMOTO E SIG NA ANÁLISE ESPACIAL	17
1.4 INTELIGÊNCIA ARTIFICIAL E MACHINE LEARNING NO MAPEAMENTO DE USO DO SOLO	19
1.5 ALGORITMO RANDOM FOREST	20
1.6 O ÍNDICE KAPPA (K) E SUA APLICAÇÃO NO SENSORIAMENTO REMOTO	22
1.7 CADASTRO AMBIENTAL RURAL: CONCEITO E LEGISLAÇÃO	24
1.7.1 EVOLUÇÃO E IMPLEMENTAÇÃO DO CAR EM MATO GROSSO	25
1.7.2 O PAPEL DO CAR NA FISCALIZAÇÃO E MONITORAMENTO AMBIENTAL	27
1.7.3 RESULTADOS E IMPACTOS DO CAR EM MATO GROSSO	28
1.8 REFERÊNCIAS	30
2. CAPÍTULO II - ARTIGO 1: CLASSIFICAÇÃO DA COBERTURA DO SOLO DO MUNICÍPIO DE CHAPADA DOS GUIMARÃES/MT COM O USO DE DADOS PLANET E ALGORITMO DE APRENDIZADO DE MÁQUINA	37
RESUMO	37
2.1 INTRODUÇÃO	38
2.2 MATERIAL E MÉTODOS	40
2.2.1 ÁREA DE ESTUDO	40
2.2.2 BASE DE DADOS UTILIZADA NO PROCESSAMENTO	41
2.2.3 DISTRIBUIÇÃO DE AMOSTRAS	43
2.2.4 CLASSIFICAÇÃO SUPERVISIONADA RANDOM FOREST	44
2.3 RESULTADOS	46
2.3.1 AVALIAÇÃO DA PRECISÃO	47
2.4 DISCUSSÃO	51
2.5 CONSIDERAÇÕES FINAIS	52

2.6 REFERÊNCIAS	53
3. CAPÍTULO III - ARTIGO 2: PROPOSTA METODOLÓGICA PARA GERAÇÃO DE BASE CARTOGRÁFICA DO CADASTRO AMBIENTAL RURAL/MT UTILIZANDO APRENDIZADO DE MÁQUINA RANDOM FOREST	57
RESUMO	57
3.1 INTRODUÇÃO	58
3.2 MATERIAL E MÉTODOS	60
3.2.1 ÁREA DE ESTUDO	60
3.2.2 AQUISIÇÃO E PRÉ-PROCESSAMENTO DE DADOS DE SENSORIAMENTO REMOTO	61
3.2.3 BASE LABSENSOR E BASE SIMCAR	63
3.3 RESULTADOS	66
3.3.1 ANÁLISE DAS PROPRIEDADES VALIDADAS NO MUNICÍPIO DE CHAPADA DOS GUIMARÃES	66
3.4 DISCUSSÕES	76
3.5 CONSIDERAÇÕES FINAIS	78
3.6 REFERÊNCIAS	79
3.7 CONCLUSÃO GERAL	81
APÊNDICES	82
APÊNDICE I – PLANILHA DE CÁLCULOS SIMCAR	83
APÊNDICE II – PLANILHA DE CÁLCULOS LABSENSOR	84

CAPÍTULO I - INTRODUÇÃO GERAL

O Cerrado, um dos biomas mais biodiversos do mundo, tem sofrido intensa conversão para atividades agropecuárias, resultando na degradação de ecossistemas essenciais (Souza et al, 2022). O monitoramento preciso da cobertura vegetal e do uso do solo é fundamental para garantir a conservação da biodiversidade e o cumprimento das normativas ambientais. Nesse contexto, o Cadastro Ambiental Rural (CAR) se destaca como uma ferramenta essencial para a regularização ambiental dos imóveis rurais, permitindo a identificação de áreas protegidas e o monitoramento de passivos ambientais (Brasil, 2012). No entanto, a eficácia dessa ferramenta depende da qualidade das bases de dados geoespaciais e dos métodos utilizados para análise e validação das informações declaradas pelos proprietários e posseiros rurais.

O município de Chapada dos Guimarães, situado a aproximadamente 62 km da capital Cuiabá, abriga remanescentes significativos do Cerrado. A região destaca-se por sua importância ecológica e pela presença do Parque Nacional da Chapada dos Guimarães, unidade de conservação com 32.630 hectares destinados à preservação dos ecossistemas locais, sítios arqueológicos e diversas espécies da fauna e flora (Imcbio, 2023). Sua vegetação predominante compreende fitofisionomias típicas do Cerrado, incluindo formações florestais, campestres e savânicas, que desempenham papel essencial na regulação hídrica e na conservação da biodiversidade (Ribeiro; Walter, 2008). Além disso, a área está inserida na bacia hidrográfica do Alto Paraguai, influenciando diretamente a dinâmica ambiental do Pantanal (Silva et al., 2021). O clima tropical sazonal da região, caracterizado por uma estação chuvosa entre outubro e março e uma estação seca entre abril e setembro, influencia diretamente os padrões de vegetação e disponibilidade hídrica (Alvares et al., 2013).

Diante dos desafios na gestão ambiental, o uso de tecnologias de Sensoriamento Remoto e aprendizado de máquina tem se mostrado essencial para monitorar e compreender mudanças na paisagem (De Luca et al., 2022).

Esses métodos vêm sendo aplicados em Unidades de Conservação no Brasil para aprimorar a fiscalização e planejamento territorial (Borges; Costa, 2023). Entre as tecnologias de destaque, estão as imagens do satélite Planet SuperDove, que, com suas oito

bandas espectrais, possibilitam análises detalhadas, especialmente na agricultura e no monitoramento ambiental especificamente, as bandas Red Edge e NIR (infravermelho próximo) são fundamentais para avaliar a saúde da vegetação, identificar estresses nas plantações e detectar mudanças no crescimento das plantas. O uso dessas imagens proporciona maior precisão no monitoramento de corpos d'água e nas condições do solo, contribuindo para a agricultura de precisão e o gerenciamento sustentável da terra (Planet Labs, 2023).

Além do Sensoriamento Remoto, algoritmos de aprendizado de máquina, como o Random Forest (RF), vêm se destacando pela sua alta precisão na detecção de padrões espaciais e na análise automatizada de grandes volumes de dados geoespaciais para classificação de uso e cobertura do solo quando comparados a outros classificadores (De Luca et al., 2022; Rodrigues, 2025).

O mapeamento e monitoramento preciso das Fitofisionomias do Cerrado e das áreas convertidas são essenciais para embasar estratégias de conservação e gestão sustentável do bioma (Alencar et al., 2020; Sano et al., 2010). A classificação de imagens de Sensoriamento Remoto tem se destacado como uma abordagem eficiente para a extração e categorização de informações sobre a cobertura do solo, utilizando as respostas espectrais dos alvos terrestres para identificar padrões de ocupação e uso da terra (Panigrahi; Verma; Tripathi, 2017). Os mapas temáticos gerados a partir dessas técnicas oferecem uma representação detalhada da superfície terrestre, permitindo análises em diferentes escalas espaciais e temporais (Mohanrajan; Loganathan; Manoharan, 2020).

A ausência de bases de dados geográficos em escalas detalhadas e de ferramentas tecnológicas de alto desempenho compromete significativamente a gestão ambiental e o monitoramento de áreas protegidas, dificultando a avaliação do estado de conservação, a identificação de vetores de pressão e a implementação de estratégias eficazes de mitigação (Marino et al., 2024).

A necessidade de modernização da legislação ambiental desenvolvida na criação do Novo Código Florestal Brasileiro em 2012, pela Lei nº 12.651, que instituiu o CAR, atualizou as regras para APPs e ARL, além de definir mecanismos de compensação ambiental para áreas desmatadas irregularmente até 22 de julho de 2008. O CAR foi uma ferramenta inovadora, criada para promover a regularização ambiental dos imóveis rurais no (Brasilb, 2012).

A implementação do Código Florestal, aliada às inscrições no (CAR), tem possibilitado um monitoramento mais eficaz da vegetação nativa e a regularização das ARL

nos imóveis rurais. Isso ampliou a capacidade de atuação do poder público em um país com vastas dimensões territoriais e significativa diversidade regional. Atualmente, aproximadamente 6,5 milhões de imóveis rurais estão cadastrados no CAR, abrangendo uma área total de cerca de 540 milhões de hectares (São Paulo, 2020).

Embora o CAR seja um importante instrumento de gestão pública, sua eficácia pode estar comprometida pela natureza auto declaratória do cadastro, o que pode resultar em inconsistências nos dados fornecidos. Além disso, a diferença entre os dados orbitais usados pelos proprietários (geralmente de resolução média) e os usados pelos órgãos de análise (de alta resolução) pode gerar divergências, levando à necessidade de ajustes adicionais., ressaltando a importância de tecnologias de Sensoriamento Remoto para garantir a eficácia do monitoramento ambiental (Lopes; Machado; Chiavari, 2022).

Dessa forma, o CAR se configura como uma ferramenta essencial para a gestão e regularização ambiental no Brasil, especialmente no estado de Mato Grosso, onde vastas áreas rurais ainda apresentam passivos ambientais. A implementação de tecnologias de Sensoriamento Remoto de alta resolução e aprendizado de máquina tem sido crucial para a identificação de inconformidades e a correção de dados, promovendo maior eficiência no processo de regularização de imóveis rurais. No entanto, desafios persistem, sobretudo quanto à integração dos sistemas de análise dinamizada e à redução das inconsistências nos dados declaratórios. Nesse contexto, este estudo busca contribuir para o aprimoramento do monitoramento ambiental e a gestão territorial sustentável. (Brasil, 2012; Lopes, Machado e Chiavari, 2023; Júnior, 2022; Ministério do Meio Ambiente, 2020).

Apesar dos avanços tecnológicos, a morosidade na análise e validação dos cadastros do CAR representa um entrave significativo para a regularização ambiental no estado de Mato Grosso. O grande volume de cadastros pendentes de acordo com Secretaria de Meio Ambiente do Estado de Mato Grosso (SEMA) (2024), aliado à natureza auto declaratória do sistema, pode comprometer a confiabilidade das informações e dificultar a fiscalização ambiental (Marino et al., 2024). A disparidade entre os dados orbitais utilizados pelos proprietários e aqueles empregados pelos órgãos ambientais também gera inconsistências que precisam ser ajustadas (Lopes; Machado; Chiavari, 2022).

Diante desse contexto, este estudo tem como objetivo geral mapear a cobertura e o uso do solo no município de Chapada dos Guimarães utilizando imagens de alta resolução espacial do satélite Planet SuperDove e técnicas de aprendizado de máquina, especificamente o algoritmo Random Forest. Além disso, busca-se avaliar a efetividade desses métodos na diferenciação das classes temáticas em uma escala de 1:25.000, bem

como realizar uma análise espacial detalhada dos imóveis cadastrados no CAR, identificando divergências entre a base temática gerada e os cadastros validados disponibilizados pela SEMA.

Para atingir os objetivos propostos, esta dissertação está organizada em dois artigos científicos. O primeiro artigo aborda a classificação da cobertura do solo utilizando aprendizado de máquina e imagens Planet SuperDove, analisando a precisão das classes geradas. O segundo artigo compara os dados do Cadastro Ambiental Rural (CAR) com a base temática gerada, avaliando a precisão cartográfica e a conformidade ambiental. Ambos os estudos foram desenvolvidos para recomendar melhorias na qualidade dos dados espaciais utilizados na gestão territorial e ambiental.

O município de Chapada dos Guimarães, selecionado como área de estudo, faz parte de um projeto maior desenvolvido em parceria entre a Universidade Federal de Mato Grosso (UFMT) e o Ministério Público do Estado de Mato Grosso (MPMT) para avaliar a qualidade dos registros do CAR nos diferentes biomas de Mato Grosso a partir da comparação de mapas de referência construídos em escalas mínimas de 1:50.000.

1.1 REVISÃO DE LITERATURA

1.2. Mapa temático

As mudanças no uso e cobertura da terra representam uma das transformações mais significativas do meio ambiente. Avaliar essas modificações em diferentes escalas espaciais é essencial para a gestão ambiental, planejamento territorial e a promoção do desenvolvimento sustentável, garantindo a preservação dos recursos naturais e a mitigação de impactos ambientais (ALAM, 2020).

As observações terrestres tem sido utilizados para mapear a vegetação, utilizando vários sensores multiespectrais, como MODIS (YIN; et al 2018), Landsat TM, ETM+, OLI, (LIU; et al 2024) Sentinel Mohammadpour et al., 2022; Andreatta et al., 2022).

O Sensoriamento Remoto, aliado a algoritmos de aprendizado de máquina, aprimora a identificação e o monitoramento de uso e cobertura do solo, minimizando erros de classificação e aumentando a precisão dos mapas temáticos. Métodos como RF são amplamente utilizados para lidar com a similaridade espectral entre diferentes classes de uso do solo, permitindo maior confiabilidade na separação de áreas urbanas, vegetação e solo exposto. Essas abordagens são fundamentais para a construção de bases temáticas

mais robustas, que possibilitam análises planejadas e subsidiam políticas ambientais e de planejamento territorial (Delaney, Tansey, Whelan, 2025).

Estudos recentes, apresentaram a eficácia do uso de imagens do satélite PlanetScope combinadas com técnicas de aprendizado de máquina para a geração de mapas temáticos de alta precisão Rodrigues et al. (2025). A abordagem envolve a diferenciação das formações vegetais do Cerrado e o mapeamento de áreas ocupadas por espécies superdominantes dentro de uma área protegida, contribuindo significativamente para o monitoramento ambiental e a conservação da biodiversidade.

O satélite Planet Super Dove se destaca pela capacidade de capturar imagens de alta resolução diariamente, tornando-se uma ferramenta valiosa para diversos estudos ambientais. Sua alta frequência temporal possibilita o monitoramento contínuo das mudanças na paisagem, permitindo a atualização de mapas temáticos com maior precisão e detalhamento. Esse potencial foi demonstrado por Chanda e Hossain (2024), que aplicaram imagens PlanetScope no mapeamento de inundações, evidenciando a relevância desses dados para a gestão de desastres e planejamento territorial. Assim, o uso de sensores de alta resolução, aliado a algoritmos avançados, reforça a importância dos mapas temáticos para análises ambientais de alta precisão, auxiliando na tomada de decisão e na formulação de políticas públicas eficazes.


1.3. O Sensoriamento Remoto e Sistemas de Informações Geográficas na Análise Espacial

Com o avanço tecnológico, a interação entre Sensoriamento Remoto e Sistemas de Informação Geográfica (SIG) tornou-se uma ferramenta indispensável para o monitoramento e a análise ambiental. O INPE (2023) destaca que o Sensoriamento Remoto proporciona uma visão contínua da Terra por meio de satélites, enquanto o SIG organiza e processa esses dados espacialmente, facilitando a tomada de decisões para a gestão sustentável dos recursos naturais.

Segundo Meneses e Almeida (2012), o Sensoriamento Remoto é a ciência que capta imagens da superfície terrestre por meio da medição da radiação eletromagnética que interage com os materiais do planeta. O processo envolve diversas etapas cruciais, como captação, transmissão, recepção e interpretação dos dados. Esses dados são amplamente utilizados em áreas como agricultura, planejamento urbano e monitoramento ambiental, desempenhando um papel fundamental no rastreamento de mudanças ambientais e na criação de mapas georreferenciados.

A Figura 1 ilustra o fluxo do processo de Sensoriamento Remoto, desde a captação da radiação até a interpretação dos dados, destacando as principais etapas envolvidas.

Figura 1. Fluxo de radiação no Sensoriamento Remoto



Fonte: Adaptado de Silva, J.P. (2012). Introdução ao Processamento de Imagens de Sensoriamento Remoto, p. 15

A combinação do Sensoriamento Remoto com SIG possibilita uma ampla gama de aplicações, como modelagem numérica de terreno e processamento digital de imagens. Essas tecnologias oferecem uma visão abrangente e contínua das transformações ambientais ao longo do tempo, permitindo estudos em diferentes escalas, desde levantamentos regionais e continentais até análises planejadas de unidades espaciais específicas (Veiga et al., 2020).

Diversos estudos têm abordado a aplicação do Sensoriamento Remoto em diferentes áreas, incluindo o mapeamento do uso e cobertura do solo (Cardona-mesa et al., 2025), a identificação e mapeamento de culturas agrícolas (Tan et al., 2025), a detecção de solos descobertos (Delaney, Tansey e Whelan, 2025) a avaliação da qualidade com uso profundo (Gongo et al., 2025) e a atenção de áreas de perda de solo em terras cultivadas (Zhang et al., 2025). Além disso, pesquisas exploraram a classificação da cobertura do solo no Cerrado com aprendizado de máquina (Rodrigues et al., 2025), bem como a aplicação de imagens PlanetScope no Cadastro Ambiental Rural para o monitoramento do uso da terra (Pinheiro; Ramos; Marcato Junior, 2019).

1.4 Inteligência Artificial e Machine Learning no Mapeamento de Uso do Solo

O Aprendizado de Máquina ou Machine Learning (ML) é uma área da ciência da computação que utiliza algoritmos e modelos matemáticos para permitir que sistemas computacionais aprendam padrões a partir de dados, sem a necessidade de serem programados de forma explícita para cada tarefa (PAIXÃO et al., 2022). Essa tecnologia revolucionou diversas áreas do conhecimento, especialmente no processamento e análise de grandes volumes de dados espaciais.

A integração da Inteligência Artificial (IA) e do ML na análise geoespacial permite a redução e modelagem preditiva de dados com maior eficiência em comparação com métodos tradicionais. Zhang e Zhang (2022) destacam que essas técnicas possibilitam processamentos mais avançados, sendo capazes de lidar com a alta dimensionalidade e complexidade das imagens de Sensoriamento Remoto.

Os avanços nas aplicações de SR, incluem a elaboração de modelos de aprendizado profundo que tem a capacidade de analisar imagens de satélites de alta resolução a integração de dados multiespectrais e hiperespectrais com algoritmos de aprendizado de máquinas para aperfeiçoar a classificação de uso e cobertura do solo, e monitoramento de vegetação Sharifi, Mahdipour (2024).

Projetos como o MapBiomias utilizam técnicas de aprendizado de máquina para gerar séries temporais de uso e cobertura do solo no Brasil, permitindo análises ambientais mais precisas e em grande escala (Souza et al, 2020). Nesse contexto, a precisão dos mapas gerados por ML tem sido amplamente discutida na literatura recente. Estudos como os de Rodrigues et al. (2025), Zhang et al. (2025), Cardona-Mesa et al. (2025), Tan et al. (2025) e Delaney; Tansey Whelan, (2025) destacam que uma combinação de diferentes algoritmos, sensores e abordagens de aprendizagem de máquina pode aumentar significativamente a confiabilidade da classificação de uso e cobertura do solo, reduzindo erros e aprimorando a detecção de padrões espaciais.


1.5 Algoritmo Random Forest

O Random Forest (RF) é um dos algoritmos de aprendizado de máquina mais populares, amplamente utilizado em Sensoriamento Remoto devido à sua robustez e alta capacidade de processamento. De acordo com Breiman (2001), o RF combina múltiplas

árvores de decisão para gerar previsões mais precisas e reduzir o risco de sobre ajuste, utilizando o método ensemble learning. Essa abordagem permite lidar com grandes volumes de dados sem necessidade de pré-seleção rigorosa de variáveis, tornando-o eficaz na classificação de imagens multiespectrais e hiperespectrais (Belgiu & Drăguț, 2016).

A Figura 2 a seguir ilustra o funcionamento do modelo Random Forest, destacando o processo de criação de múltiplas árvores de decisão e como as previsões finais são feitas com base na média ou votação dessas árvores.

Figura 2. Representação esquemática do algoritmo Random Forest (modelo de floresta aleatória).



Fonte: StatPlace (2023)

A previsão final gerada pelo Random Forest (RF) é baseada na média ou na votação das previsões de todas as árvores de decisão geradas. Uma das principais vantagens do RF é sua capacidade de lidar com alta dimensionalidade e grandes volumes de dados, o que o torna particularmente eficaz em áreas como Sensoriamento Remoto. Bélgica e Drăguț (2016).

destacam o sucesso do RF na classificação de imagens de satélite, enfatizando sua capacidade de lidar com a variabilidade espectral presente nas imagens. Mahdianpari et al.

(2020), reforçam essa eficácia ao aplicar o RF na classificação de imagens multiespectrais e hiper espectrais, utilizando fontes como Landsat e MODIS.

Além disso, uma característica valiosa do RF é sua robustez contra o sobre ajuste. A combinação de múltiplas árvores de decisão proporciona previsões mais estáveis e precisas, evitando o ajuste dos dados de treinamento (Ham et al., 2005). Isso é particularmente importante em tarefas como a classificação de uso e cobertura do solo, especialmente em regiões como o Cerrado brasileiro, onde a variabilidade espacial e temporal do bioma representa um desafio significativo para o mapeamento ambiental.

Diversos estudos demonstram a eficácia do Random Forest na classificação de imagens de satélite, como as imagens capturadas pelo Landsat, além de imagens hiperespectrais e multiespectrais. O algoritmo também é amplamente utilizado na análise de modelos digitais de elevação (Gislason; Benediktsson; Sveinsson, 2006). Comparado a outros algoritmos de aprendizado de máquina, como o Support Vector Machine (SVM), o RF frequentemente apresenta desempenho superior ao lidar com dados multiespectrais. Estudos de Rodríguez et al. (2012) demonstram que o RF supera classificadores baseados em árvores de decisão, tornando-o uma escolha robusta e eficiente para aplicações em classificação de imagens.

1.6 O Índice Kappa (K) e sua Aplicação no Sensoriamento Remoto

O Índice Kappa (K) é amplamente utilizado para medir a concordância entre classificações observadas e esperadas ao acaso. No contexto do Sensoriamento Remoto, ele é uma métrica crucial para avaliar a acurácia de mapas temáticos, fornecendo uma validação robusta para classificações de imagens (Vale et al., 2021). A principal finalidade da avaliação de precisão em Sensoriamento Remoto é determinar a concordância entre os resultados de uma classificação de imagens e a realidade observada, conhecida como a "verdade de referência" (Feizizadeh, 2018). Segundo Foody (2002), a validação de mapas classificados é essencial para identificar discrepâncias entre o mapa gerado e os dados de campo, garantindo a confiabilidade das informações espaciais.

Portanto o índice Kappa (k) é utilizado para avaliar o nível de concordância entre as classificações de diferentes observadores, sendo calculado da seguinte forma:

$$K = \frac{(P_o - P_e)}{(1 - P_e)}$$

$$P_o = \Sigma (X_{ii}) / N$$

$$P_e = \Sigma \left[\frac{(X_i + \times X_{+i})}{N^2} \right]$$

De acordo com Brennan e Prediger (1981), os valores do índice Kappa podem variar de $-1/(n-1)$ a $+1$, onde n representa o número de classes na classificação (sendo n maior que 1). Um valor de Kappa mais alto indica uma maior concordância entre as classificações, enquanto valores de Kappa negativos indicam que a concordância observada é inferior ao esperado pelo acaso (Cohen, 1960). Esse índice é amplamente utilizado em estudos de validação de classificações automáticas para avaliar a precisão e a confiabilidade dos resultados, sendo que valores próximos a 1 demonstram uma alta correspondência entre a classificação gerada e a realidade observada.

A Tabela 1 apresenta as diretrizes propostas por Landis e Koch (1977) para a interpretação dos valores do coeficiente Kappa.

Tabela 1. Coeficiente Kappa

Índice Kappa	Concordância
<0.00	Péssimo
0.00-0.20	Ruim
0.20-0.40	Razoável
0.40-0.60	Bom
0.60-0.80	Muito Bom
0.80-1.00	Excelente

Fonte: Adaptado de Landis e Koch (1977) pela autora (2025)

A matriz de confusão é amplamente utilizada para avaliar a precisão de classificações, permitindo calcular a precisão global, bem como as precisões do produtor e do usuário (Comber et al., 2012). O Índice Kappa complementa essas avaliações ao ajustar a precisão para ajustes aleatórios, oferecendo uma avaliação mais robusta da acurácia de mapas temáticos em Sensoriamento Remoto.

Diferentes estudos demonstram a aplicabilidade do Índice Kappa em análises espaciais. Hakim e Tsai (2025) aplicaram aprendizado profundo em imagens de satélite de altíssima resolução para a classificação de cobertura do solo, contribuindo para a produção de mapas topográficos em larga escala. De forma semelhante, Porath et al. (2024)

desenvolveu uma ferramenta de aprendizado de máquina para a classificação automatizada de uso e cobertura da terra em linhas de distribuição da CELESC, resultando em um aumento de 6,8% na precisão dos mapas gerados.

Dessa forma, o Índice Kappa se apresenta como uma métrica essencial para garantir a confiabilidade dos mapas temáticos, contribuindo para a tomada de decisão em aplicações ambientais, urbanas e agrícolas. De acordo com Foody (2002), esse índice é amplamente utilizado na validação da precisão de classificações de uso e cobertura do solo, permitindo a detecção de discrepâncias entre mapas gerados e dados de campo. Além disso, Landis e Koch (1977) estabeleceram uma escala de interpretação dos valores do Índice Kappa, auxiliando na avaliação da concordância entre diferentes classificações. Estudos mais recentes, como os de Comber et al. (2012) e Vale et al. (2021), reforçam sua importância para análises espaciais, destacando sua eficácia na localização de modelos de aprendizado de máquina aplicados ao Sensoriamento Remoto.

1.7 Cadastro Ambiental Rural: Conceito e Legislação

O CAR é um instrumento fundamental para a regularização ambiental no Brasil, instituído pela Lei Federal nº 12.651/2012, também conhecido como Código Florestal. O CAR é uma inscrição eletrônica obrigatória para todos os imóveis rurais, integrada ao Sistema de Cadastro Ambiental Rural Federal (SICAR), que permite o cadastro, a consulta e o acompanhamento da situação e a regularização ambiental dos imóveis rurais em todo o país (Brasil, 2012). Este registro público desempenha um papel crucial no controle, monitoramento, planejamento e combate ao desmatamento, ao incluir informações ambientais em um banco de dados centralizado (Brasil, 2012).

Do ponto de vista ambiental, o objetivo principal do CAR é integrar as informações relativas à situação das APP, RL, AVN, áreas de uso restrito e AC, das propriedades rurais em todo o território nacional (Júnior, 2022).

Conforme ilustrado na Figura 1, o CAR delimita e apresenta graficamente essas áreas, facilitando a visualização da relação entre os imóveis rurais e os requisitos ambientais previstos no Novo Código Florestal.

Figura 3. O imóvel rural e o Código Florestal: Informações para o CAR.



Fonte: Ministério da Agricultura (Brasil, 2022)

A inscrição no CAR é o primeiro passo para a regularização ambiental das propriedades, registrando informações planejadas sobre o proprietário, a posse e as características geoespaciais do imóvel, incluindo áreas de vegetação nativa, APPs, RLs e áreas consolidadas (Brasil, 2023).

As análises do CAR têm como objetivo principal verificar a veracidade das informações declaradas pelos proprietários rurais, avaliando se há passivos ambientais e se os dados estão em conformidade com a legislação vigente, especialmente o Código Florestal (Lei nº 12.651 /2012). Essas análises podem ser realizadas de duas maneiras: por meio da análise manual ou da análise dinamizada.

Na análise manual, uma equipe técnica realiza a inspeção detalhada dos dados, identificando inconsistências, como sobreposições de áreas e erros de vetorização. Já uma análise dinamizada, recentemente implementada em alguns estados, utiliza sistemas automatizados para verificar as informações declaradas. Nessa modalidade, o sistema identifica automaticamente as inconsistências e propõe a retificação e o cumprimento das pendências por parte do proprietário. Após a correção dos dados, o cadastro segue para a aprovação final (Lopes; Machado; Chiavari, 2023).

Esse processo automatizado tem o potencial de acelerar a análise dos cadastros, garantindo maior eficiência e precisão na identificação de inconformidades. No entanto, ainda enfrenta dificuldades relacionados à implantação e funcionamento eficaz da tecnologia, além da capacitação dos usuários envolvidos (Junior, 2022).

Dessa forma, o CAR é uma ferramenta essencial para a gestão e regularização ambiental no Brasil, especialmente em áreas rurais com passivos ambientais, como no

estado de Mato Grosso. Tecnologias de Sensoriamento Remoto e geoprocessamento são fundamentais para identificar inconformidades e corrigir dados, aumentando a eficiência na regularização. Contudo, desafios como a lentidão no processo de validação e o uso inadequado das tecnologias ainda persistem. O futuro do CAR depende de avanços tecnológicos e de maior integração entre órgãos ambientais e rurais, garantindo a preservação dos recursos naturais e o cumprimento das legislações (Brasil, 2012; Lopes et al., 2023; Junir, 2022; Mma, 2020).

1.7.1 A Evolução e Implementação do CAR em Mato Grosso

O estado de Mato Grosso foi pioneiro na implementação do CAR com a Lei Complementar Estadual 343/2008, que instituiu o programa MT Legal. Esse programa exigiu a adesão dos proprietários ao CAR e o desenvolvimento de Projetos de Recuperação de Áreas Degradadas (PRAD), promovendo avanços no licenciamento ambiental rural. Integrado ao Sistema de Monitoramento e Licenciamento Ambiental (SIMLAM), o MT Legal melhorou a gestão ambiental, facilitando o diálogo entre técnicos e órgãos governamentais (The Nature Conservancy, 2015; De Oliveira et al., 2018).

O Decreto nº 2.238, de 13 de novembro de 2009, regulamenta o Programa Mato-Grossense de Regularização Ambiental Rural, tornando o CAR obrigatório como ferramenta de registro de propriedades junto à Secretaria de Estado de Meio Ambiente (SEMA). A implementação do CAR visava não apenas o controle e monitoramento das atividades agropecuárias, mas também a preservação das Áreas de APP e ARL (Mato Grossoa, 2009).

Com a promulgação do novo Código Florestal Brasileiro em 2012, a inscrição no CAR tornou-se obrigatória em todo o território nacional, integrando informações ambientais das propriedades rurais de todo território brasileiro (Brasilb, 2012).

Em 2014, a Instrução Normativa MMA nº 2 instituiu o Sistema Nacional de Cadastro Ambiental Rural (SICAR), unificou as informações ambientais das propriedades rurais em uma base de dados centralizada, promovendo um monitoramento e controle ambiental mais eficaz (BrasiLa, 2014).

Em 2016, a criação do Sistema Mato-Grossense de Cadastro Ambiental Rural (SIMCAR), regulamentada pelo Decreto Nº 420, desenvolveu uma plataforma estadual integrada ao SICAR. O SIMCAR visa aprimorar a gestão dos dados ambientais no estado, fornecendo uma interface mais eficiente para o controle e monitoramento das propriedades

rurais. O sistema permite uma análise mais detalhada de APPs e ARL, facilitando a conformidade com o Novo Código Florestal e promovendo a sustentabilidade ambiental em Mato Grosso (Mato Grossob, 2016).

A Lei Complementar nº 592, de 26 de maio de 2017, aprimorou a estrutura regulatória para a conservação e uso sustentável dos recursos naturais no estado. A lei consolidou as normas ambientais, melhorou os mecanismos de supervisão e fiscalização, e fortaleceu as políticas de proteção ambiental em Mato Grosso (Mato Grossoc, 2017).

A Portaria MAPA nº 121, de 2021, distribuiu metodologias complementares para a análise dos dados do CAR em Mato Grosso. Essa portaria foi essencial para a integração entre o SIMCAR e o SICAR, permitindo a formalização da análise automatizada dos cadastros e garantindo maiores resultados na regularização ambiental das propriedades rurais (Brasilc, 2021).

O Decreto nº 780, de 27 de março de 2024, regulamenta o procedimento de análise automatizada do CAR no âmbito do Sistema SIMCAR, com o objetivo de avançar na validação dos dados e aumentar a eficiência e precisão na regularização das propriedades rurais (Mato Grosso 2024). Implementado inicialmente no município de Nova Ubiratã, o CAR Digital já contempla 18 municípios: Lucas do Rio Verde, Sorriso, Nova Mutum, Diamantino, Ipiranga do Norte, São José do Rio Claro, Campo Novo do Parecis, Nova Maringá, Sapezal, Vera, Brasnorte, Campos de Júlio, Cláudia, Tangará da Serra, União do Sul, Sinop e Feliz Natal (SEMA-MT, 2024). As bases de referência utilizadas pelo CAR Digital estão disponíveis no Geoportal, (<https://geoportal.sema.mt.gov.br>) uma plataforma digital desenvolvida pela SEMA-MT que disponibiliza informações geográficas relacionadas ao CAR e outras ferramentas de gestão ambiental (Sema, 2024).

1.7.2 O Papel do CAR na Fiscalização e Monitoramento Ambiental

A inscrição do CAR é declaratória e permanente, sendo fundamental para que os proprietários rurais acessem programas de fiscalização, regularização e incentivos econômicos (Brasilb, 2012).

Entre os principais programas que exigem a inscrição no CAR estão o Programa de Regularização Ambiental (PRA), que visa a recomposição de áreas desmatadas, o Pagamentos por Serviços Ambientais (PSA), que recompensam práticas de conservação, e as Cotas de Reserva Ambiental (CRA), que permitem compensar déficits de Reserva Legal.

Além disso, o CAR é pré-requisito para o acesso a créditos rurais, seguro agrícola e descontos tributários vinculados à preservação ambiental e ao uso sustentável da terra.

A inscrição no CAR, além de cumprir as exigências legais, facilita a fiscalização das Áreas de Preservação Permanente (APPs) e das Reservas Legais (ARL), permitindo uma análise detalhada das condições ambientais das propriedades. Isso possibilita que os proprietários rurais participem de políticas públicas voltadas à sustentabilidade, promovendo um desenvolvimento econômico alinhado à conservação ambiental (Agroanalysis, 2022).

As informações no CAR são inseridas pelo proprietário ou possuidor rural, que é integralmente responsável pelos dados declarados. Esses dados são posteriormente analisados pelo órgão ambiental competente estadual, distrital ou municipal, que pode realizar vistorias para verificar a veracidade das informações (Machado; Saleme, 2017). Conforme expresso pela The Nature Conservancy (2015), o CAR possibilita a regularização e obtenção do licenciamento ambiental, além de promover o comprometimento com o PRA. Isso pode isentar o produtor de autuações ou multas relacionadas ao desmatamento consolidado até julho de 2008.

1.7.3 Resultados e Impactos do CAR em Mato Grosso


O estado de Mato Grosso se destaca na implementação do Cadastro Ambiental Rural (CAR), trazendo avanços inovadores na regularização ambiental. Em 2022, houve um aumento de quase 60% na assinatura de termos de compromissos vinculados ao Programa de Regularização Ambiental (PRA), demonstrando a eficácia das políticas voltadas para a regularização de imóveis rurais. No entanto, desafios ainda persistem, como o grande número de propriedades aguardando análise e as extensas áreas com passivos ambientais a serem restauradas. Esses obstáculos evidenciam a necessidade de intensificar os esforços para garantir a recuperação ambiental e o cumprimento das metas previstas pelo Código Florestal (Climate Policy Initiative, 2023).

Os cadastros do SIMCAR são representados espacialmente em mapas que refletem o cenário atual do monitoramento ambiental no estado de Mato Grosso. Conforme dados do Geoportal da SEMA-MT, de um total de 99.093 cadastros registrados no CAR, apenas 4.437 foram validados, representando 4,48% do total. Além disso, 99.093 cadastros ainda aguardam análise, enquanto 20.634 cadastros (ou 20,83%) estão em fase de complementação de informações (Sema, 2024).

No contexto do Programa de Regularização Ambiental (PRA), com dados atualizados até 10 de abril de 2024, 3.583 cadastros (ou 3,62%) aguardam envio de documentação, enquanto 986 cadastros (ou 0,99%) aguardam análise. Além disso, 1.757 cadastros (ou 1,77%) foram validados, mas ainda estão em fase de regularização. Por outro lado, 4.182 cadastros (ou 4,22%) foram indeferidos e 10.681 cadastros (ou 10,78%) foram cancelados. Esses números reforçam a importância de uma análise contínua e detalhada para garantir um monitoramento e uma gestão ambiental eficaz no estado de Mato Grosso (Brasil, 2024).

A Figura 4 abaixo ilustra a distribuição espacial dos cadastros no SIMCAR, destacando as diferentes categorias de status dos cadastros, como os validados, os que aguardam análise e os que estão em complementação.

Figura 4. Distribuição Espacial Cadastros SIMCAR 2024



Fonte: Geoportal, (Sema,2024)

4.Considerações Finais

Dessa forma, o CAR em Mato Grosso tem se consolidado como um instrumento fundamental para a gestão ambiental e regularização fundiária no estado, promovendo avanços significativos na identificação de passivos ambientais e no planejamento da recuperação de áreas degradadas (Lopes; Machado; Chiavari, 2023). No entanto, persistem desafios, como a demora na análise dos cadastros e a necessidade de maior integração entre os órgãos ambientais para acelerar a validação das informações (Brasil, 2024). Assim a implementação de tecnologias de Sensoriamento Remoto e inteligência artificial pode otimizar esse processo, proporcionando maior precisão na detecção de inconformidades e eficiência na gestão de dados territoriais (Sema, 2024). Além disso, a ampliação de incentivos para a adesão ao Programa de Regularização Ambiental (PRA) pode contribuir para a conformidade das propriedades rurais, garantindo maior sustentabilidade no uso dos recursos naturais e o cumprimento da legislação ambiental vigente (Serviço Florestal Brasileiro, 2023).

REFERÊNCIAS:

AGROANALYSIS. Avanços na Análise do Cadastro Ambiental Rural. **Revista de Pesquisa em Políticas Públicas**, p. 24-25, fev. 2022.

ALAM, A.; BHAT, M. S.; MAHEEN, M. Using Landsat satellite data for assessing the land use and land cover change in Kashmir valley. **GeoJournal**. 85, 1529–1543 (2020). <https://doi.org/10.1007/s10708-019-10037-x>

ALENCAR, A.; SHIMBO, J. Z.; LENTI, F.; BALZANI MARQUES, C.; ZIMBRES, B.; ROSA, M.; ARRUDA, V.; CASTRO, I.; RIBEIRO, J. P. F. M.; VARELA, V.; PIONTEKOWSKI, V.; RIBEIRO, V.; BUSTAMANTE, M. M. C.; SANO, E. E.; BARROSO, M. Mapping Three Decades of Changes in the Brazilian Savanna Native Vegetation Using Landsat Data Processed in the Google Earth Engine Platform. **Remote Sens**. 2020, 12 (6) , 924. <https://doi.org/10.3390/rs12060924>

ANDREATTA, D.; GIANELLE, D.; SCOTTON, M.; DALPONTE, M. Estimating grassland vegetation cover with remote sensing: a comparison between landsat-8, sentinel-2 and planetscope imagery. *Ecological Indicators*, [S.L.], v. 141, p. 1-11, ago. 2022. **Elsevier BV**. <http://dx.doi.org/10.1016/j.ecolind.2022.109102>.

ANJINHO, P. S.; BARBOSA, M. A. G. A.; NEVES, G. L.; SANTOS, A. R. dos; MAUAD, F. Integrated empirical models to assess nutrient concentration in water resources: case study of a small basin in southeastern brazil. **Environmental Science And Pollution Research**, [S.L.], v. 28, n. 18, p. 23349-23367, 14 jan. 2021. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11356-020-12125-9>.

BELGIU, M.; DRĂGUŢ, L. Random forest in remote sensing: a review of applications and future directions. **Isprs Journal Of Photogrammetry And Remote Sensing**, [S.L.], v. 114, p. 24-31, abr. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.isprsjprs.2016.01.011>.

BORGES, R.; COSTA, V.C. Identificação de classes de uso e ocupação do solo nas APAs que compõem a zona de amortecimento da Rebio Tinguá/Rio de Janeiro com classificação supervisionada semiautomática. **Revista Brasileira de Sensoriamento Remoto**, Rio de Janeiro, v. 4, n. 1, p. 18-29, 2023.

BRASILa. Instrução Normativa MMA nº 2, de 5 de maio de 2014. Dispõe sobre os procedimentos para a integração, execução e compatibilização do Sistema de Cadastro Ambiental Rural – SICAR e dos Cadastros Estaduais de Imóveis Rurais. Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis – IBAMA. **Diário Oficial da União**: seção 1, Brasília, DF, 7 maio 2014. Disponível em: <https://www.ibama.gov.br/>

BRASILb. Lei nº 12.651, de 25 de maio de 2012. Dispõe sobre a proteção da vegetação nativa e dá outras providências. **Diário Oficial da União**, Brasília, DF, 28 maio 2012. Disponível em: http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/12651.htm

BRASILc. Portaria MAPA nº 121, de 12 de maio de 2021. Estabelece, no âmbito do Ministério da Agricultura, Pecuária e Abastecimento, procedimentos gerais complementares para a análise dos dados do Cadastro Ambiental Rural (CAR) e para integração dos resultados da análise ao Sistema de Cadastro Ambiental Rural (SICAR) e dá outras providências. **Diário Oficial da União**: seção 1, Brasília, DF, 12 maio 2021. Disponível em: <https://www.in.gov.br/en/web/dou/-/portaria-mapa-n-121-de-12-de-maio-de-2021-319796627>

BREIMAN, L. Random Forests: random forests. **Machine Learning**, [S.L.], v. 45, n. 1, p. 5-32, 2001. Springer Science and Business Media LLC. <http://dx.doi.org/10.1023/a:1010933404324>.

BRENNAN, R. L.; PREDIGER, D. J.. Coefficient Kappa: some uses, misuses, and alternatives. **Educational And Psychological Measurement**, [S.L.], v. 41, n. 3, p. 687-699, out. 1981. SAGE Publications. <http://dx.doi.org/10.1177/001316448104100307>.

CARDONA-MESA, A.A.; VÁSQUEZ-SALAZAR, R.D.; PARRA, J. C.; OLMOS-SEVERICHE, C.; TRAVIESO-GONZÁLEZ, C. M.; GÓMEZ, L. A Methodology for the Multitemporal Analysis of Land Cover Changes and Urban Expansion Using Synthetic Aperture Radar (SAR) Imagery: a case study of the aburrá valley in colombia. **Remote Sensing**, [S.L.], v. 17, n. 3, p. 554, 6 fev. 2025. MDPI AG. <http://dx.doi.org/10.3390/rs17030554>

CHANDA, M.; HOSSAIN, A. K. M. Azad. Application of PlanetScope Imagery for Flood Mapping: a case study in south chickamauga creek, chattanooga, tennessee. **Remote Sensing**, [S.L.], v. 16, n. 23, p. 4437, 27 nov. 2024. MDPI AG. <http://dx.doi.org/10.3390/rs16234437>

COHEN, J. A Coefficient of Agreement for Nominal Scales. **Educational And Psychological Measurement**, [S.L.], v. 20, n. 1, p. 37-46, abr. 1960. SAGE Publications. <http://dx.doi.org/10.1177/001316446002000104>.

COMBER, A.; FISHER, P.; BRUNSDON, C.; KHMAG, Abdulhakim. Spatial analysis of remote sensing image classification accuracy. **Remote Sensing Of Environment**, [S.L.], v. 127, p. 237-246, dez. 2012. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2012.09.005>.

DELANCEY, E. R.; SIMMS, J. F.; MAHDIANPARI, M.; BRISCO, B.; MAHONEY, C.; KARIYEVA, J.. Comparing Deep Learning and Shallow Learning for Large-Scale Wetland Classification in Alberta, Canada. **Remote Sensing**, [S.L.], v. 12, n. 1, p. 2, 18 dez. 2019. MDPI AG. <http://dx.doi.org/10.3390/rs12010002>.

DELANEY, B.; TANSEY, K.; WHELAN, M.. Satellite Remote Sensing Techniques and Limitations for Identifying Bare Soil. **Remote Sensing**, [S.L.], v. 17, n. 4, p. 630, 12 fev. 2025. MDPI AG. <http://dx.doi.org/10.3390/rs17040630>.

FEIZIZADEH, B.. A Novel Approach of Fuzzy Dempster–Shafer Theory for Spatial Uncertainty Analysis and Accuracy Assessment of Object-Based Image Classification. **Ieee Geoscience And Remote Sensing Letters**, [S.L.], v. 15, n. 1, p. 18-

22, jan. 2018. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/lgrs.2017.2763979>. **FOODY, GM Status da avaliação da precisão da classificação da cobertura do solo.** *Remote Sens. Environ.* 2002, 80, 185–201

GISLASON, P. O.; BENEDIKTSSON, J. A.; SVEINSSON, J. R. Random Forests for land cover classification. *Pattern Recognition Letters*, [S.L.], v. 27, n. 4, p. 294-300, mar. 2006. Elsevier BV. <http://dx.doi.org/10.1016/j.patrec.2005.08.011>.

GONG, X.; LI, T.; WANG, R.; HU, S.; YUAN, S.. Beyond the Remote Sensing Ecological Index: a comprehensive ecological quality evaluation using a deep-learning-based remote sensing ecological index. *Remote Sensing*, [S.L.], v. 17, n. 3, p. 558, 6 fev. 2025. MDPI AG. <http://dx.doi.org/10.3390/rs17030558>.

HAKIM, Y. F.; TSAI, F.. Deep Learning-Based Land Cover Extraction from Very-High-Resolution Satellite Imagery for Assisting Large-Scale Topographic Map Production. *Remote Sensing*, [S.L.], v. 17, n. 3, p. 473, 30 jan. 2025. MDPI AG. <http://dx.doi.org/10.3390/rs17030473>

INPE, Instituto Nacional de Pesquisas Espaciais. **Projeto PRODES: Monitoramento da Floresta Amazônica Brasileira por Satélite.** São José dos Campos: projeto prodes: monitoramento da floresta amazônica brasileira por satélite. são josé dos campos. Projeto PRODES: Monitoramento da Floresta Amazônica Brasileira por Satélite. São José dos Campos. 2023. Disponível em: <http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes>.

LANDIS, J. R.; KOCH, G. G.. An Application of Hierarchical Kappa-type Statistics in the Assessment of Majority Agreement among Multiple Observers. *Biometrics*, [S.L.], v. 33, n. 2, p. 363, jun. 1977. JSTOR. <http://dx.doi.org/10.2307/2529786>.

LIU, M.; QU, Y.; WANG, J.; LIAO, Y.; ZHENG, G.; GUO, Y.; LIU, L. A 30-m annual grassland dataset from 1991 to 2020 for Inner Mongolia, China. *Scientific Data*, [S.L.], v. 11, n. 1, p. 1-12, 17 out. 2024. **Springer Science and Business Media LLC**. <http://dx.doi.org/10.1038/s41597-024-03990-x>.

LOPES, CRISTINA L; MARIA.E S.; JOANA C. Onde Estamos na Implementação do Código Florestal? Radiografia do CAR e do PRA nos Estados Brasileiros — Edição 2023. Rio de Janeiro: **Climate Policy Initiative**, 2023.

LUCA, G; SILVA, J. M. N.; FAZIO, S.; MODICA, G. Integrated use of Sentinel-1 and Sentinel-2 data and open-source machine learning algorithms for land cover mapping in a Mediterranean region. *European Journal Of Remote Sensing*, [S.L.], v. 55, n. 1, p. 52-70, 12 jan. 2022. Informa UK Limited. <http://dx.doi.org/10.1080/22797254.2021.2018667>.

MARIANO, J.; BUTTURI, W.; VALDIONES, A. P.; SILGUEIRO, V. F.. Considerações sobre os módulos de análise automatizada do Cadastro Ambiental Rural. Nota Técnica, junho de 2024. Disponível em: <https://www.icv.org.br/publicacao/consideracoes-sobre-os-modulos-de-analise-automatizada-do-cadastro-ambiental-rural/>. Acesso em: 12 fev. 2025.

MATO GROSSOa. Decreto nº 2.238, de 13 de novembro de 2009. Dispõe sobre o Programa Mato-grossense de Regularização Ambiental Rural - MT Legal e o Sistema de Licenciamento de Propriedades Rurais - SLAPR. **Diário Oficial do Estado de Mato Grosso**, Cuiabá, 13 nov. 2009.

MATO GROSSOb. Decreto nº 420, de 05 de fevereiro de 2016. Dispõe sobre a regulamentação do Sistema Estadual de Meio Ambiente e dá outras providências. **Diário Oficial do Estado de Mato Grosso**, Cuiabá, 05 Set. 2016.

MATO GROSSOc. Lei Complementar nº 592, de 26 de maio de 2017. Dispõe sobre a gestão ambiental e dá outras providências. **Diário Oficial do Estado de Mato Grosso**, Cuiabá, 26 maio 2017.

MATO GROSSOd. Portaria SEMA nº 360, de 9 de maio de 2023. Regulamenta a análise dinamizada do Cadastro Ambiental Rural no Estado de Mato Grosso. **Diário Oficial do Estado de Mato Grosso**, Cuiabá, MT, 10 maio 2023. Disponível em: <https://www.sema.mt.gov.br>. Acesso em: 16 set. 2024.

MENDES J., Cezar Augusto. O Cadastro Ambiental Rural (CAR) como instrumento de regularização fundiária no Matopiba, Amazônia Legal e Estado de Goiás. 2022. 469 f. Dissertação (Mestrado) - Curso de Direito, **Faculdade de Direito Programa de Pós-Graduação em Direito Agrário**, Universidade Federal de Goiás, Universidade Federal de Goiás, 2022.

MENESES, Paulo Roberto; ALMEIDA, Tati de (org.). INTRODUÇÃO AO PROCESSAMENTO DE IMAGENS DE SENSORIAMENTO REMOTO. Brasília: **CNPQ**, 2012. 277 p.

MOAYEDI, Hossein; JAMALI, Ali; GIBRIL, Mohamed Barakat A.; FOONG, Loke Kok; BAHIRAEI, Mehdi. Evaluation of tree-base data mining algorithms in land used/land cover mapping in a semi-arid environment through Landsat 8 OLI image; Shiraz, Iran. **Geomatics, Natural Hazards And Risk**, [S.L.], v. 11, n. 1, p. 724-741, 1 jan. 2020. Informa UK Limited. <http://dx.doi.org/10.1080/19475705.2020.1745902>.

MOHAMMADPOUR, P.; VIEGAS, D. X.; VIEGAS, C. Vegetation Mapping with Random Forest Using Sentinel 2 and GLCM Texture Feature—A Case Study for Lousã Region, Portugal. **Remote Sensing**, [S.L.], v. 14, n. 18, p. 4585, 14 set. 2022. MDPI AG. <http://dx.doi.org/10.3390/rs14184585>.

MOHANRAJAN, S. N.; LOGANATHAN, A.; MANOHARAN, P. Survey on Land Use/Land Cover (LU/LC) change analysis in remote sensing and GIS environment: techniques and challenges. **Environmental Science And Pollution Research**, [S.L.], v. 27, n. 24, p. 29900-29926, 5 jun. 2020. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11356-020-09091-7>.

MOURA, B. B.; BRESSAN, L. M.; WOJAHN, V. de S.; BOEIRA, L. dos S.; TERRA, V. S. S. Análise da Fragilidade Ambiental em uma Sub-Bacia Hidrográfica na Metade Sul do Rio Grande do Sul com o uso de geoprocessamento. **Revista Brasileira de**

Geografia Física, [S.L.], v. 16, n. 5, p. 2375-2389, 1 out. 2023. Revista Brasileira de Geografia Física. <http://dx.doi.org/10.26848/rbgf.v16.5.p2375-2389>.

NOBRE, B. A.; LEITE, M. E.; MARQUES, Samuel Carlos Santos. Análise da Estrutura Fundiária do Município de Montes Claros-MG por Meio dos Dados do Cadastro Ambiental Rural (CAR). **Espaço Aberto**, Rio de Janeiro, Brasil, v. 11, n. 1, p. 119–133, 2021. DOI: 10.36403/espacoaberto.2021.35367. Disponível em: <https://revistas.ufrj.br/index.php/EspacoAberto/article/view/35367>.

OLIVEIRA, A. L. A. de; SILGUEIRO, V. F.; BUTTURI, W. Análise temporal da implementação do cadastro ambiental rural nos assentamentos rurais do estado de Mato Grosso. **Retratos de Assentamentos**, [S.L.], v. 21, n. 2, p. 128-144, 1 ago. 2018. Retratos de Assentamentos. <http://dx.doi.org/10.25059/2527-2594/retratosdeassentamentos/2018.v21i2.320>.

PAIXÃO, G. M. M.; SANTOS, B. C.; ARAUJO, R. M.; RIBEIRO, M. H.; MORAES, J. L.; RIBEIRO, A. L. Machine Learning na Medicina: revisão e aplicabilidade. **Arquivos Brasileiros de Cardiologia**, [S.L.], v. 118, n. 1, p. 95-102, jan. 2022. Sociedade Brasileira de Cardiologia. <http://dx.doi.org/10.36660/abc.20200596>.

PANIGRAHI, S.; VERMA, K.; TRIPATHI, P.. Data mining algorithms for land cover change detection: a review. **Sādhanā**, [S.L.], v. 42, n. 12, p. 2081-2097, 24 nov. 2017. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s12046-017-0751-4>

PINHEIRO, É. C. C.; RAMOS, A. P. M.; MARCATO, J.. Remote Sensing Applied to the Environmental Regularization of Rural Properties in Mato Grosso do Sul. Anuário do Instituto de Geociências - Ufrj, [S.L.], v. 42, n. 3, p. 145-153, 30 set. 2019. **Instituto de Geociências - UFRJ**. http://dx.doi.org/10.11137/2019_3_145_153.

PORATH, P H. M.; SILVA, F. O.; CARUSO JUNIOR, F.; FINCO, J.; PAULO, B. T.; SCHERER, Dionatan Oster. Desenvolvimento de ferramenta de Machine Learning para classificação automatizada de uso e cobertura da terra em linhas de distribuição da CELESC. **Revista Brasileira de Sensoriamento Remoto**, Brasil, v. 5, n. 2, p. 31-42, 27 mar. 2024.

RIBEIRO, J.; W., BMT Fitofisionomias do bioma Cerrado. No Cerrado: Ambiente e Flora ; Sano, SM, Almeida, SP, Eds.; **Embrapa-CPAC**: Planaltina, DF, Brasil, 1998; Boné. 3; pp. 87–166.

RODRIGUEZ G., V.F.; GHIMIRE, B.; ROGAN, J.; CHICA-OLMO, M.; RIGOL-SANCHEZ, J.P. An assessment of the effectiveness of a random forest classifier for land-cover classification. **Isprs Journal Of Photogrammetry And Remote Sensing**, [S.L.], v. 67, p. 93-104, jan. 2012. Elsevier BV. <http://dx.doi.org/10.1016/j.isprsjprs.2011.11.002>.

SANO, E. E.; ROSA, R.; BRITO, Jorge L. S.; FERREIRA, Laerte G. Land cover mapping of the tropical savanna region in Brazil. **Environmental Monitoring And Assessment**, [S.L.], v. 166, n. 1-4, p. 113-124, 6 jun. 2009. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s10661-009-0988-4>.

SEMA-MT – Secretaria de Estado de Meio Ambiente de Mato Grosso. CAR Digital já foi implementado em 18 municípios do estado. Cuiabá: **SEMA-MT, 2024**. Disponível em: <https://www.secom.mt.gov.br/w/sema-apresenta-car-digital-ao-juizado-volante-e-vara-especializada-de-meio-ambiente>. Acesso em: 31 jan. 2025.

SEMA-MT. Geoportal da Secretaria de Estado de Meio Ambiente de Mato Grosso. **Secretaria de Estado de Meio Ambiente, 2024**. Disponível em: <https://geoportal.sema.mt.gov.br>. Acesso em: 31 jan. 2025.

SERVIÇO FLORESTAL BRASILEIRO. **Relatório de monitoramento ambiental no Brasil: desafios e avanços do CAR**. Brasília: Serviço Florestal Brasileiro, [s.d.]. Disponível em: <https://www.florestal.gov.br/publicacoes/relatorio-monitoramento-ambiental-CAR.pdf>. Acesso em: 10 fev. 2025.

SHARIFI, A.; MAHDIPOUR, H. Utilizing geospatial artificial intelligence for remote sensing applications. **Environmental Earth Sciences**, [S.L.], v. 83, n. 9, p. 1-2, 29 abr. 2024. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s12665-024-11584-4>.

SOUZA, C. M.; SHIMBO, J. Z.; ROSA, M. R.; PARENTE, L. L.; ALENCAR, A. A.; RUDORFF, B. F. T.; HASENACK, H.; MATSUMOTO, M.; FERREIRA, L. G.; SOUZA-F., P. W. M. Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. **Remote Sensing**, [S.L.], v. 12, n. 17, p. 2735, 25 ago. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12172735>.

SOUZA, C. M.; SHIMBO, J. Z.; ROSA, M. R.; PARENTE, L. L.; ALENCAR, A. A.; RUDORFF, B. F. T.; HASENACK, H.; MATSUMOTO, M.; FERREIRA, L. G.; SOUZA-FILHO, P. W. M. Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. **Remote Sensing**, [S.L.], v. 12, n. 17, p. 2735, 25 ago. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12172735>.

TAN, Y.; GU, J.; LU, L.; ZHANG, L.; HUANG, J.; PAN, L.; LV, Y.; WANG, Y.; CHEN, Y. Hyperspectral Band Selection for Crop Identification and Mapping of Agriculture. **Remote Sensing**, [S.L.], v. 17, n. 4, p. 663, 15 fev. 2025. MDPI AG. <http://dx.doi.org/10.3390/rs17040663>

THE NATURE CONSERVANCY. Cadastro Ambiental Rural - CAR: nasce a identidade do imóvel rural. 1ª ed. Curitiba, Paraná: **The Nature Conservancy, 2015**. ISBN 978-85-60797-15-8.

VEIGA, A. J. P.; MATTA, J. M. B. ; VEIGA, D. A. M.; BOMFIM, C. S. S. ANÁLISE DO USO E COBERTURA DA TERRA EM ITAPETINGA NO ESTADO DA BAHIA, BRASIL, COM USO DE SENSORIAMENTO REMOTO E SIG / ANALYSIS OF THE USE AND LAND COVER IN ITAPETINGA IN THE STATE OF BAHIA, BRAZIL, USING REMOTE SENSING AND GIS. **Brazilian Journal Of Development**, [S.L.], v. 6, n. 9, p. 73928-73947, 2020. Brazilian Journal of Development. <http://dx.doi.org/10.34117/bjdv6n9-741>.

YIN, H.; PFLUGMAC., Dirk; LI, A.; LI, Z.; HOSTERT, P.. Land use and land cover change in Inner Mongolia - understanding the effects of China's re-vegetation programs. **Remote Sensing Of Environment**, [S.L.], v. 204, p. 918-930, jan. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2017.08.030>.

ZHANG, L.; ZHANG, L.. Artificial Intelligence for Remote Sensing Data Analysis: a review of challenges and opportunities. **Ieee Geoscience And Remote Sensing Magazine**, [S.L.], v. 10, n. 2, p. 270-294, jun. 2022. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/mgrs.2022.3145854>.

ZHANG, X.; QIN, C.; MA, S.; LIU, J.; WANG, Y.; LIU, H.; AN, Z.; MA, Y.. Study on the Extraction of Topsoil-Loss Areas of Cultivated Land Based on Multi-Source Remote Sensing Data. **Remote Sensing**, [S.L.], v. 17, n. 3, p. 547, 6 fev. 2025. MDPI AG. <http://dx.doi.org/10.3390/rs17030547>.

1. CAPÍTULO II - ARTIGO I: CLASSIFICAÇÃO DA COBERTURA DO SOLO DO MUNICÍPIO DE CHAPADA DOS GUIMARÃES/MT COM O USO DE DADOS PLANET E ALGORITMO DE APRENDIZADO DE MÁQUINA

RESUMO

O objetivo deste estudo foi avaliar o uso de imagens do satélite Planet SuperDove (PSB.SD) e o algoritmo de aprendizado da máquina Random Forest para mapear o uso e a cobertura do solo no município de Chapada dos Guimarães (MT) Brasil. A classificação obteve acurácia global de 91% e coeficiente Kappa de 0,89, garantindo alta precisão na distinção de formações florestais, savânicas, agrícolas e campos. Os resultados demonstram a eficácia das geotecnologias na análise espacial, permitindo um monitoramento detalhado das mudanças na paisagem e fornecendo subsídios para a gestão ambiental e o ordenamento territorial. A base temática gerada pode auxiliar na tomada de decisões estratégicas, no planejamento sustentável e no cumprimento da legislação ambiental, reforçando a importância do Sensoriamento Remoto e do aprendizado de máquina na conservação dos recursos naturais.

PALAVRA CHAVE: Classificação Supervisionada; Random Forest; base temática

CLASSIFICATION OF LAND COVER IN THE MUNICIPALITY OF CHAPADA DOS GUIMARÃES/MT USING PLANET DATA AND MACHINE LEARNING ALGORITHM

ABSTRACT

The objective of this study was to evaluate the use of Planet SuperDove (PSB.SD) satellite images and the Random Forest machine learning algorithm to map land use and land cover in the municipality of Chapada dos Guimarães (MT) Brazil. The classification achieved an overall accuracy of 91% and a Kappa coefficient of 0.89, ensuring high precision in distinguishing forest formations, savannas, agricultural areas, and grasslands. The results demonstrate the effectiveness of geotechnologies in spatial analysis, enabling detailed monitoring of landscape changes and providing support for environmental management and territorial planning. The generated thematic database can assist in strategic decision-making, sustainable planning, and compliance with environmental legislation, reinforcing the importance of Remote Sensing and machine learning in natural resource conservation

KEYWORDS: Supervised Classification; Random Forest; thematic basis

CLASIFICACIÓN DE LA COBERTURA DEL SUELO EN EL MUNICIPIO DE CHAPADA DOS GUIMARÃES/MT UTILIZANDO DATOS PLANETAS Y ALGORITMO DE APRENDIZAJE AUTOMÁTICO

RESUMEN

El objetivo de este estudio fue evaluar el uso de imágenes del satélite Planet SuperDove (PSB.SD) y del algoritmo de aprendizaje automático Random Forest para mapear el uso y cobertura del suelo en el municipio de Chapada dos Guimarães (MT). La clasificación logró una precisión general del 91 % y un coeficiente Kappa de 0,89, lo que garantiza una alta precisión a la hora de diferenciar formaciones forestales, de sabana, agrícolas y de campo. Los resultados demuestran la eficacia de las geotecnologías en el análisis espacial, permitiendo un seguimiento detallado de los cambios paisajísticos y dando apoyo a la gestión ambiental y la planificación territorial. La base temática generada puede contribuir a la toma de decisiones estratégicas, la planificación sostenible y el cumplimiento de la legislación ambiental, reforzando la importancia de la teledetección y el aprendizaje automático en la conservación de los recursos naturales.

PALABRAS CLAVE: Clasificación Supervisada Random Forest; base temática.

2.1 INTRODUÇÃO

O Cerrado brasileiro é um dos biomas mais biodiversos e ameaçados da América do Sul (Silva; Bates, 2002). A intensificação do uso da terra para a expansão agrícola tem levado à perda de biodiversidade, erosão do solo e poluição dos mananciais, comprometendo diversos serviços ecossistêmicos essenciais (Alencar et al., 2020). Estima-se que aproximadamente 45% da vegetação nativa do Cerrado já tenha sido convertida para usos antrópicos, com o desmatamento avançando continuamente sobre o bioma (Souza et al., 2020).

Diante dessas transformações, o mapeamento e o monitoramento preciso das fitofisionomias do Cerrado, assim como a identificação de áreas já convertidas, são fundamentais para subsidiar estratégias de conservação e desenvolvimento sustentável (Lewis et al., 2022). Tecnologias de geoprocessamento, como Sensoriamento Remoto e Sistemas de Informação Geográfica (SIG), possibilitam análises espaciais planejadas das alterações na paisagem, forneceram uma visão contínua das transformações ambientais ao longo do tempo (Veiga et al., 2020). Essas ferramentas podem ser aplicadas tanto em

levantamentos de larga escala quanto em estudos detalhados de áreas específicas, sendo cruciais para planejamentos ambientais em escalas municipais, regionais e continentais (Hakim; Tsai, 2025).

As geotecnologias são compostas por quatro elementos principais: hardware, software, peopleware (recursos humanos) e dataware. Esses componentes, aliados aos procedimentos de coleta, armazenamento, processamento e análise de dados, tornam-se ferramentas estratégicas para análises espaciais e suporte à tomada de decisão em projetos ambientais (Rosa, 2005; Zaidam, 2017). Nesse contexto, o mapeamento de uso e cobertura do solo desempenha um papel central, pois permite diagnosticar a distribuição da vegetação, identificar áreas de desmatamento e avaliar mudanças na densidade florestal (The Nature Conservancy, 2015). Além disso, essa abordagem tem sido amplamente utilizada na identificação de propriedades do solo, auxiliando no monitoramento da umidade, matéria orgânica, mineralogia e textura dos solos expostos (Delaney; Tansey; Whelan, 2025).

A classificação de imagens de Sensoriamento Remoto é um método essencial no processamento digital de imagens, permitindo extrair e categorizar informações com base nas assinaturas espectrais da cobertura do solo (Panigrahi; Verma; Tripathi, 2017). Os mapas temáticos gerados por essas técnicas oferecem representações confiáveis da superfície terrestre, sendo fundamentais para análises espaciais em diferentes escalas temporais e geográficas (Mohanrajan; Loganathan; Manoharan, 2020). O uso de imagens de alta resolução e técnicas de aprendizado de máquina como Random Forest (RF), possibilita uma classificação mais precisa e detalhada das classes de uso e cobertura do terreno. Dados do satélite PlanetScope, combinados com técnicas avançadas de aprendizado de máquina, demonstram grande potencial para discriminar diferentes padrões de uso do solo com alta precisão (Rodrigues et al., 2025).

2.2 MATERIAL E MÉTODOS

2.2.1 Área de Estudo


O município de Chapada dos Guimarães, localizado na região centro-sul do Estado de Mato Grosso, possui uma extensão territorial de 6.603,252 km² (Ibge, 2024).

Com uma rica diversidade de fitofisionomias, como mata semidecídua, mata ciliar, cerradão, cerrado sensu stricto, campo sujo, campo cerrado e campo cerrado rupestre. A mata semidecídua, encontrada em encostas e interflúvios, destaca-se por árvores altas e espécies amazônicas, como copaíba (*Copaifera langsdorffii*) e jatobá (*Hymenaea spp.*). A mata ciliar ocorre em áreas de definição bem definidas, com presença de buritis (*Mauritia flexuosa*) e ingás (*Inga uruguensis*). Já o cerradão apresenta vegetação densa com múltiplos estratos e espécies como carvão-de-ferreiro (*Sclerolobium paniculatum*). O cerrado sensu stricto e o campo sujo predominam em áreas abertas, com gramíneas e arbustos esparsos, enquanto o campo rupestre, em altitudes acima de 800 metros, é caracterizado por florestas de pequeno porte, como bromélias e orquídeas (Icmbio, 2009).

O clima da região é classificado como tropical de altitude, com influências subtropicais, e se destaca pela definição clara entre as estações chuvosa e seca. Segundo a classificação de Köppen, o clima é do tipo Aw, típico de savana tropical, com estações chuvosas ocorre entre outubro e março, abrangendo as estações da primavera e verão, enquanto a estação seca se estende de abril a setembro, correspondendo ao outono e inverno. as temperaturas médias variam em torno de 21,5°C nas áreas mais elevadas. As temperaturas mínimas podem cair abaixo de 5°C (Ibama, 1995; Icmbio, 2009).

A Figura 1 apresenta a localização e os limites geográficos do município de Chapada dos Guimarães, destacando sua extensão territorial e as características ambientais.

Figura 1. Mapa de Localização Município de Chapada dos Guimarães.



Fonte: Elaborado pela autora (2025)

2.2.2 Base de dados utilizada no processamento

Para a análise foram utilizadas imagens do satélite Super Dove, de terceira geração do Planet (sensor PSB.SD). Esses dados foram acessados por meio do portal Planet, utilizando a licença do Programa Padrão de Educação e Pesquisa, que facilita o acesso a informações adicionais de pesquisas científicas. As imagens obtidas estão associadas ao produto Planetscope Analytic que é radiometricamente corrigido para reflectância de superfície e possuem correção geométrica e resolução espacial de 3 metros, o que garante uma alta precisão na identificação de características geográficas e na análise do uso do solo e da cobertura vegetal.

As imagens obtidas possuem oito bandas espectrais, essenciais para diversos tipos de análises ambientais, como o monitoramento de mudanças no ecossistema e no uso do solo, identificação de corpos d'água, e acompanhamento de processos de gestão ambiental. Essas

bandas abrangem diferentes regiões do espectro eletromagnético, permitindo que se capturem informações além do visível, o que enriquece as possibilidades de análise e interpretação dos dados.

A tabela 1. apresenta as especificações projetadas da missão Super Dove, incluindo as principais características técnicas do sensor PSB.SD utilizado para a coleta de dados no município de Chapada dos Guimarães.

Tabela 1. Especificações das bandas do satélite Planet Super Dove (PSB.SD).

	Banda Espectral	(nm)	FWHM
1	Azul costal	443	20
2	Azul	490	50
3	Verde I	531	36
4	Verde	565	36
5	Amarelo	610	20
6	Vermelho	665	31
7	Borda do Vermelho	705	15
8	Nir	865	40

Fonte: Elaborado pela autora com dados Planet Labs (2023) e Vanhellemont, (2023).

A partir do portal planet Explorer foram selecionadas Cinco diferentes faixas/orbitas do município de Chapada dos Guimarães nas datas de 05/05/2023,15/05/2023 e 17/05/2023.

As imagens utilizadas foram adquiridas ao longo do mês de maio de 2023, período estrategicamente selecionado devido ao menor recobrimento de nuvens. Esse intervalo marca a transição entre o final da estação chuvosa e o início da estação seca, quando ocorre maior contraste entre as formações vegetais e o solo exposto. Essa característica favorece a distinção entre as classes de uso e cobertura do solo, fornecendo informações espectrais essenciais para identificar e diferenciar as categorias de interesse, o que contribui para maior precisão nos resultados da classificação (Rodrigues et al., 2025).

A correção radiométrica, já realizada pela Planet Labs, garantiu que os dados refletissem condições homogêneas de iluminação e de distorções atmosféricas, além das calibrações radiométricas, a cena vem ortoretificada a partir de dados de diversas fontes. As imagens foram ajustadas para a projeção cartográfica UTM (Universal Transverse Mercator), zona 21S, com o sistema de referência SIRGAS 2000, O SIRGAS2000 (Sistema

de Referência Geocêntrico para as Américas) é o datum de referência oficial do Brasil , definido pelo IBGE por meio da Resolução nº 1/2005 (Ibge,2024).

2.2.3 Distribuição de Amostras

Para a distribuição das amostras de treinamento, foi necessário definir os polígonos representando as classes de cobertura do solo. Nesta etapa, foram estabelecidas as seguintes classes: água, área agrícola, área úmida, campo, solos, formação florestal, formação savânica e área urbana. Essas categorias foram selecionadas com base na relevância ecológica e no uso do solo da região, garantindo que o modelo de classificação abranja as principais características ambientais e de ocupação do território.

Tabela 2. Classes Classificação Supervisionada Random Forest

Classes	Descrição
Água	Corpos d'água como rios, lagos e açudes, represas naturais, artificiais.
Área Agrícola	Áreas destinadas à agricultura, com cultivos de diferentes tipos.
Área Úmida	Áreas específicas com presença predominante de buritis, em solos sujeitos a alagamentos sazonais.
Formação Campestre	Áreas de campo limpo, capo sujo e pastagens
Solo Exposto	Áreas onde o solo está diretamente exposto, sem cobertura vegetal.
Formação Florestal	Áreas cobertas por vegetação densa e alta, característica de florestas.
Formação Savânica	Áreas de transição entre cerrado e outros tipos de vegetação, com características de savana.
Área Urbana	Áreas compostas por edificações, ruas, rodovias, áreas residenciais, comerciais, industriais e de serviços.

Fonte: Elaborado pela autora (2025)

A distribuição das amostras de treinamento foi dividida por classe, com o número de pixels selecionados para cada categoria, totalizando 400.000 pixels. Essa distribuição

balanceada garante uma representação adequada de todas as categorias de uso e cobertura do solo, permitindo uma classificação precisa dos dados coletados.

2.2.4 Classificação Supervisionada Random Forest

O processo de classificação das imagens foi conduzido utilizando o algoritmo Random Forest (RF), amplamente reconhecido por sua robustez e elevada precisão na classificação de imagens multiespectrais. A operação foi realizada no software ENVI 5.6, onde foram definidas as Regiões de Interesse (ROIs) para coletar as amostras de treinamento de cada classe. No total, foram identificados 400.000 pixels de amostras envolvendo as faixas de aquisição dos satélites SuperDove que recobriram o município, selecionados com base em uma análise visual detalhada das imagens de satélite, considerando o comportamento espectral característico de cada classe.

Após a etapa de classificação realizada com o algoritmo RF, os softwares QGIS e ArcGIS foram utilizados para o processamento e validação dos resultados. Entre as principais tarefas realizadas nesses softwares, destaca-se a correção de geometrias inválidas, garantindo que as feições geográficas, como áreas e linhas, estejam topologicamente corretas e livres de sobreposições.

O ArcGIS foi utilizado em etapas avançadas de processamento, desempenhando um papel crucial no refinamento dos dados. O software forneceu ferramentas robustas para a correção de geometrias e foi essencial na realização de análises espaciais, espaciais, como a geração de mapas temáticos e a integração dos resultados da classificação supervisionada.

Para a avaliação da acurácia das classificações, foram coletadas 520 amostras pelas áreas das oito classes, obedecendo ao número mínimo de 50 amostras, previsto por Congalton e Green (2001). A classificação foi realizada utilizando o software ArcGIS, e as amostras foram estratificadas por meio da ferramenta Create Accuracy Assessment Points, na qual foram subtraídas aleatoriamente da classificação gerada.

Após essa etapa, foram construídas as matrizes de erro, em que as colunas representam as amostras de referência, identificadas a partir de imagens do Google Earth de maio de 2023, e as linhas específicas às classes geradas na classificação. Essas matrizes permitem a análise dos erros de omissão, que ocorrem quando uma amostra não é corretamente incluída em sua classe de referência, e dos erros de comissão, quando uma amostra é erroneamente atribuída a uma classe diferente de sua real.

É importante destacar que a matriz de confusão não inclui a classe Veredas, pois essa categoria passou por um refinamento posterior com interpretação visual, devido à sua alta similaridade espectral com outras classes e às limitações na diferenciação automática pelo modelo de classificação.

Com base nesses dados, foram calculados três principais índices de acurácia. O primeiro, denominado exatidão global, expressa a relação entre o número total de amostras corretamente e o número total de amostras de referência. O segundo índice, a exatidão do produtor, está associado ao erro de omissão e representa a proporção de amostras corretamente incluídas em relação ao total de amostras de referência de cada classe. Por fim, a exatidão do usuário refere-se ao erro de comissão e indica a relação entre as amostras corretamente incluídas dentro de uma classe e o total de amostras transferidas para essa mesma classe (Congalton e Green, 2001).

Ao analisar as Áreas Úmidas e Veredas no município de Chapada dos Guimarães, constatou-se que a classificação automática apresentou limitações na identificação precisa das veredas. Essa imprecisão decorreu da subestimação das áreas de campo, o que levou à incorporação indevida de pixels dessa categoria nas veredas.


Para corrigir essa inconsistência, foi realizado um refinamento na classificação por meio de uma análise visual detalhada. Para isso foram utilizadas imagens de alta resolução do Google Earth, datadas de abril de 2023, que possibilitaram ajustes precisos na delimitação das veredas e a correção das falhas observadas na classificação inicial.

2.3 RESULTADOS

A classificação supervisionada aplicada ao município de Chapada dos Guimarães resultou em um mapa temático com categorias de uso do solo. As classes foram definidas com base em características ecológicas e espaciais específicas, como formações florestais, formações savânicas, áreas agrícolas, solos expostos, campo, área úmidas, e áreas urbanas e corpos hídricos (Lewis et al, 2022).

A definição dessas classes foi fundamental para garantir que o algoritmo de classificação Random Forest distinguisse corretamente entre as diferentes categorias de uso do solo. Conforme o resultado demonstrado na Figura 2.

Figura 2. Mapa do Resultado da Classificação Supervisionada.




Fonte: Elaborado pela autora (2025).

A aplicação da classificação supervisionada utilizando o algoritmo Random Forest segmentou a área de estudo de Chapada dos Guimarães em diversas classes de uso e cobertura do solo, abrangendo uma área total de 785.153,05 hectares. Cada classe foi cuidadosamente definida com base em suas características espectrais e ecológicas, permitindo a elaboração de uma análise detalhada da distribuição territorial.

Os percentuais relativos à área total de cada classe foram calculados, facilitando a compreensão da distribuição espacial das diferentes categorias de uso do solo na região.

A Figura 3, a seguir, apresenta o resultado final da classificação, mostrando a distribuição espacial das classes de uso e cobertura do solo identificadas na área de estudo.


Figura 3. Mapa do Resultado da Classificação por Classes.

ÁGUA		Os Corpos Hídricos, representados pela classe Água, cobriram 4,6% da área total, o que corresponde a 36.221,68 hectares, sendo essa classe composta por rios, lagos e reservatórios.	AGRÍCOLA		Área Agrícola foi responsável por 9,1% da área total, correspondendo a 71.592,62 hectares, refletindo áreas dedicadas ao cultivo agrícola.
SOLO EXPOSTO		O Solo Exposto ocupa 0,34% da área total, correspondendo a 2.690,09 hectares, e apresenta áreas onde o solo está diretamente exposto, sem cobertura vegetal significativa, como construção, mineração, ou áreas degradadas por práticas agrícolas inadequadas.	ÁREAS ÚMIDAS		As Áreas Úmidas, compostas por brejos e várzeas, representaram a menor porção da área total, com 0,02% ou 188,58 hectares destacando-se pela presença de água no solo e vegetação específica.
CAMPO		A classe Campo, que representa vegetação campestre ou pastagens naturais, ocupou 25,2% do território, totalizando 197.592,87 hectares.	F. SAVÂNICA		A classe Formação Savânica foi a mais representativa, abrangendo 33,8% da área total, o que corresponde a 265.423,54 hectares. Essa classe inclui as formações típicas do Cerrado, com vegetação rala e dispersa.
URBANO		Áreas Urbanas representaram 0,13%, cobrindo 1.000,95 hectares, principalmente com áreas construídas e urbanizadas.	F. FLORESTAL		A Formação Florestal ocupou 25,4% da área total, cobrindo 199.404,13 hectares, sendo caracterizada por florestas nativas com vegetação densa.

Fonte: Elaborado pela autora (2025)

Após o processo inicial de classificação automática, a classe "Veredas" passou por um refinamento manual por meio de interpretação visual detalhada, visando aprimorar a acurácia da sua delimitação, devido à alta similaridade espectral com outras formações vegetais, como campos e savanas. Esse procedimento foi necessário para corrigir omissões e comissões identificadas na etapa automatizada, principalmente em áreas de transição ecológica. Como resultado desse refinamento, foi possível identificar 3.366 fragmentos classificados como veredas na área de estudo, com tamanhos variando entre 0,014 ha e 227 ha, totalizando 6.681,67 hectares. Esses valores evidenciam a alta fragmentação dessa fitofisionomia e reforçam a importância do mapeamento criterioso para a representação adequada de ambientes ecologicamente sensíveis. (Figura 4).

Figura 4. Mapa de Refinamento das Áreas Úmidas e Veredas na Chapada dos Guimarães.



Fonte: Elaborado pela autora (2025)

A classificação supervisionada utilizando o algoritmo Random Forest apresentou desempenho satisfatório, com Acurácia Global de 91% e coeficiente Kappa de 0,89, indicando elevado grau de concordância entre os dados classificados e as amostras de referência. A Tabela 4 apresenta os resultados detalhados da avaliação de acurácia. As classes “Formação Florestal” (97%) e “Formação Savânica” (92%) destacaram-se pelo alto desempenho, enquanto a classe “Área Urbana” obteve 100% de precisão. Por outro lado, as classes “Água” (84%) e “Campo” (87%) apresentaram maiores índices de confusão, sendo comumente classificadas equivocadamente como “Formação Florestal” e “Formação Savânica”, respectivamente. A classe “Área Úmida” (90%) apresentou erro de omissão pontual, refletindo as dificuldades associadas à sua distinção automática, especialmente em razão da similaridade espectral com outras formações e da influência fenológica. Esses resultados confirmam a confiabilidade da base temática gerada, validando sua aplicação nas análises comparativas com a base SIMCAR.

Tabela 4: Matriz de Confusão e Índice Kappa

CLASSES	ÁGUA	AGR.	CAMPO	F. FLOR.	SAVANA	SOLOS	URBANA	AU	TOT.
ÁGUA	21	0	0	2	0	0	0	0	23
AGR.	0	40	5	0	0	0	0	0	45
CAMPO	1	2	116	1	10	1	0	1	132
F. FLOR.	0	1	2	110	0	0	0	0	116
SAVANA	3	1	8	0	158	0	0	0	167
SOLOS	0	0	1	0	0	13	0	0	14
URBANA	0	0	0	0	0	0	10	0	10
AU	0	0	0	0	0	0	0	10	10
TOTAL	25	44	132	113	171	14	10	11	10
A. G.	0,84%	0,90%	0,87%	0,97%	0,92%	0,92%	100,00%	0,90%	520

Fonte: Elaborado pela autora (2025)

A análise da cobertura do solo nas áreas protegidas do município de Chapada dos Guimarães considerou as Unidades de Conservação (UCs) que se encontram total ou parcialmente dentro dos limites do município, somando uma área total avaliada de 171.507,81 hectares. A delimitação da análise apenas às UCs inseridas no município justifica-se pelo escopo do estudo, que busca compreender a efetividade das diferentes categorias de conservação presentes na área de estudo, com base na realidade territorial local e na influência de atividades antrópicas.

Dentre as unidades avaliadas, a APA Cabeceiras do Rio Cuiabá (A) possui área total de 462.364,87 ha, dos quais apenas 8.446,53 ha (1,83%) estão inseridos nos limites do município. A APA Rio da Casca (B) totaliza 39.863,57 ha, com 26.286,39 ha (65,94%) dentro da Chapada. Já a APA Chapada dos Guimarães (C) possui área de 218.029,20 ha, sendo 117.481,67 ha (53,89%) inseridos no município. O Parque Municipal da Cabeceira do Rio Coxipó (D) apresenta área de 91,37 ha, completamente localizada no município. O Parque Nacional da Chapada dos Guimarães (E) possui 32.647,27 ha, dos quais 12.672,43 ha (38,82%) estão dentro da área municipal. A Estação Ecológica do Rio da Casca (F) tem 3.492,66 ha no total, sendo 2.439,78 ha (69,87%) em Chapada dos Guimarães.

Além disso, estão inteiramente dentro do município a RPPN Hotel Mirante (19,88 ha), o Parque Municipal da Quineira (46,31 ha) e o Monumento Natural Centro Geodésico da América Latina (43,65 ha), todos com 100% de suas áreas inseridas nos limites de Chapada dos Guimarães.


Em relação à cobertura do solo, a APA Cabeceiras do Rio Cuiabá (A) apresenta 2.996,77 ha de campos e 2.864,5 ha de florestas. A APA Rio da Casca (B) contém 7.651,39

ha de áreas campestres e 6.741,49 ha de formação florestal. A APA Chapada dos Guimarães (C) possui 37.121,75 ha de vegetação campestre, 30.254,45 ha de formação florestal e 39.005,08 ha de formações savânicas. O Parque Municipal da Cabeceira do Rio Coxipó (D), embora pequeno, conserva 85,78 ha de formação florestal e 1,44 ha de áreas savânicas. O Parque Nacional da Chapada dos Guimarães (E) protege 10.580,51 ha de áreas savânicas e 1.250,35 ha de florestas. Já a Estação Ecológica do Rio da Casca (F) conserva 1.043,69 ha de formações savânicas e 542,79 ha de formação florestal.

Foi identificada influência antrópica significativa, com destaque para áreas agrícolas: 9.089,17 ha na APA Rio da Casca (B) e 9.022,85 ha na APA Chapada dos Guimarães (C), além de 672,94 ha de área urbana nesta última. A Figura 4 apresenta a distribuição dessas classes de uso, conforme as letras identificadoras das unidades: (A) APA Cabeceiras do Rio Cuiabá, (B) APA Rio da Casca, (C) APA Chapada dos Guimarães, (D) Parque Municipal Cabeceira do Rio Coxipó, (E) Parque Nacional da Chapada dos Guimarães e (F) Estação Ecológica do Rio da Casca. A Figura 5 detalha a classificação temática de uso do solo no interior dessas áreas protegidas, dentro dos limites do município de Chapada dos Guimarães.

A Figura 5 apresenta a classificação do uso do solo, no interior das áreas protegidas no município de Chapada dos Guimarães.

Figura 5. Áreas protegidas do Município de Chapada dos Guimarães



Fonte: Elaborado pela autora (2025)

2.4 DISCUSSÃO

Este estudo evidenciou o uso das imagens do Planet SuperDove para o mapeamento do uso e cobertura do solo, destacando sua alta precisão, que pode ser atribuída à sua resolução espacial superior (LIU et al., 2022). O algoritmo Random Forest apresentou um desempenho satisfatório, com acurácia global de 91% e coeficiente Kappa de 0,89%, sendo a Formação Florestal (97%) e Formação Savânica (92%) as classes com melhor exatidão. Esses resultados corroboram os achados de Haddad et al. (2022), que demonstraram ganhos de 19,3% (EVI), 13,1% (NDVI) e 5,4% (GRND) na análise fenológica de florestas do

Cerrado utilizando imagens do PlanetScope. Da mesma forma, Acharki (2022) obteve acurácia geral superior a 97% ao utilizar dados do PlanetScope para mapeamento do uso da terra, reforçando que sensores de alta resolução espacial aprimoram significativamente a precisão da classificação.

As classes de Formação Florestal (97%) e Formação Savânica (92%) apresentaram os melhores desempenhos na classificação, o que pode ser atribuído à sua assinatura espectral bem definida e maior contraste em relação às demais classes. Esses resultados são consistentes com o estudo de Rodrigues et al. (2025), que também obteve elevada acurácia na classificação dessas formações utilizando imagens do PlanetScope, alcançando precisão geral de 97,51% e coeficiente Kappa de 0,96%.

As áreas com presença de veredas apresentaram divergências significativas entre as classes temáticas Formações Florestais, Formações Savânicas, Campo e Solos. Essa inconsistência decorre da similaridade das assinaturas espectrais entre essas coberturas vegetais, dificultando a distinção precisa por meio de classificação automática especialmente em áreas de transição ecológica, onde variações no espectro podem ser influenciadas por fatores como a composição das espécies e o estágio do ciclo de vida (Nascente, Ferreira e Nunes, 2024). A análise espacial revelou a ocorrência de 3.366 fragmentos classificados como veredas na área de estudo, totalizando 6.681,67 hectares, com um tamanho médio de 1,98 hectares, o que evidencia a alta fragmentação dessa fitofisionomia e reforça a necessidade de critérios técnicos mais refinados para sua delimitação.

As veredas desempenham um papel fundamental na manutenção dos serviços ecossistêmicos do Cerrado, sendo cruciais para a regulação hídrica, a biodiversidade e o suporte às comunidades locais. Essas formações estão associadas a nascentes e solos hidromórficos, contribuindo diretamente para a recarga dos aquíferos e a manutenção do fluxo hídrico ao longo do ano (Ribeiro & Walter, 2008; Peixoto, Luz & Brito, 2016). Diante dessa relevância, o mapeamento preciso dessas áreas torna-se indispensável não apenas do ponto de vista científico, mas também para subsidiar ações concretas de conservação, fiscalização e planejamento ambiental. O presente estudo contribui nesse sentido ao utilizar imagens de alta resolução e técnicas de aprendizado de máquina para detectar essas fitofisionomias com maior detalhamento e acurácia.

As áreas agrícolas e de uso antrópico são específicas em regiões de menor altitude e relevo plano, predominantemente nas porções central e oeste do município, voltadas ao cultivo de grãos e pastagens para pecuária. Segundo Victoria et al. (2021), cerca de 99%

das áreas agrícolas do Cerrado encontram-se em terrenos com declividades entre 0% e 13%, sendo que 64,3% possuem inclinações de 0% a 3% e 31,1% entre 4% e 8%. Essas condições favorecem a mecanização e tornam essas regiões mais propícias à agricultura intensiva.

A análise em áreas protegidas revelou padrões distintos de uso e conservação, evidenciando o papel dessas áreas na manutenção dos ecossistemas naturais e na regulação dos impactos antrópicos, resultado semelhante ao verificado por Roque, Paga e Renaud (2020). O Parque Nacional da Chapada dos Guimarães e a Estação Ecológica do Rio da Casca apresentam grande extensão de fitofisionomias savânicas e formações florestais, reforçando que essas unidades cumprem um papel essencial na conservação da vegetação nativa.

Conforme Francoso et al. (2015), apenas 8,3% da vegetação original do Cerrado permanece protegida em unidades de conservação, o que ressalta a importância de estratégias de manejo e fiscalização para evitar perdas adicionais de habitats naturais. Além disso, Sonoda et al. (2021) destacam que as Unidades de Conservação (UCs) são fundamentais para a conservação *in situ*, funcionando como uma estratégia eficaz para reduzir os impactos da gestão ambiental e proteger espécies vulneráveis.

A presença de extensas áreas agrícolas na APA Rio da Casca (9.089,17 ha) e na APA Chapada dos Guimarães (9.022,85 ha), aliada aos 672,94 ha de área urbana nesta última, reflete a maior permissividade de uso em Áreas de Proteção Ambiental (APAs) em comparação a Unidades de Conservação de Proteção Integral. (Carvalho, Silva E Salvio 2022). Diante desse cenário, o presente mapeamento torna-se uma ferramenta valiosa para a avaliação da integridade e da gestão dos espaços protegidos ao oferecer uma base temática de alta resolução, capaz de identificar com maior precisão as classes de uso e cobertura do solo. Isso permite detectar pressões antrópicas mesmo dentro de unidades de conservação, como nas Áreas de Proteção Ambiental (APAs), onde a permissividade legal de uso é maior. Ao revelar, por exemplo, a ocupação agrícola expressiva nas APAs Rio da Casca e Chapada dos Guimarães, o estudo fornece subsídios técnicos para que gestores ambientais possam reavaliar zonas de amortecimento, fortalecer mecanismos de fiscalização e propor ajustes nos planos de manejo. As Unidades de Conservação de Proteção Integral, como o Parque Nacional e a Estação Ecológica, mantêm maior integridade ecológica conforme demonstrado pela predominância de fitofisionomias nativas, reforçando seu papel na conservação do Cerrado. Nesse sentido, o mapeamento detalhado com imagens Planet SuperDove e técnicas de aprendizado de máquina representa

uma ferramenta estratégica para o monitoramento contínuo e a tomada de decisão em políticas públicas voltadas à proteção dos ecossistemas naturais.

2.5 CONSIDERAÇÕES FINAIS

Os resultados deste estudo demonstraram a eficácia das técnicas de aprendizado de máquina aplicada às imagens do satélite Planet SuperDove PSB.SD, por meio do algoritmo Random Forest, alcançou acurácia global de 91% e Kappa de 89% na distinção das classes de uso e cobertura do solo em Chapada dos Guimarães. A identificação bem-sucedida de formações florestais e savânicas, bem como a delimitação refinada das veredas, reforçam o papel fundamental dessas formações na regulação hídrica e na preservação da biodiversidade do Cerrado (Rodrigues Et al., 2025).

As áreas protegidas, em especial o Parque Nacional da Chapada dos Guimarães e a Estação Ecológica do Rio da Casca, apresentaram maior conservação das fitofisionomias naturais, evidenciando a importância de estratégias de manejo efetivas nessas unidades. Esse resultado está em consonância com os achados de Francoso et al. (2015), que ressaltam a necessidade de ampliar a proteção do Cerrado. Por outro lado, as Áreas de Proteção Ambiental (APAs) demonstraram maior influência antrópica, o que indica que sua categoria de uso sustentável, embora importante, pode comprometer os objetivos de conservação quando não acompanhada de controle efetivo. Conclui-se que a efetividade das UCs depende não apenas de sua existência legal, mas também da compatibilidade entre os usos permitidos e a implementação de ações concretas de manejo e fiscalização.

A base temática desenvolvida neste estudo constitui uma ferramenta estratégica para subsidiar análises futuras e apoiar a formulação de políticas públicas que promovam a conservação ambiental e o uso sustentável dos recursos naturais. Além disso, este trabalho contribui diretamente para o cumprimento das metas estabelecidas pelo Código Florestal (Lei nº 12.651/2012), ao fornecer uma base espacial detalhada que permite a identificação mais precisa de Áreas de Preservação Permanente (APPs), Reserva Legal e áreas consolidadas, subsidiando o processo de regularização ambiental dos imóveis rurais. A utilização de imagens de alta resolução associadas ao aprendizado de máquina representa uma ferramenta poderosa para os órgãos ambientais, tornando possível aprimorar a fiscalização, identificar passivos ambientais e orientar ações de recuperação. Como recomendação, destaca-se a importância de ampliar o mapeamento para outras áreas do Cerrado e atualizar periodicamente as bases temáticas utilizando novas imagens e

algoritmos. Também é recomendável integrar bases oficiais, como o CAR, com dados produzidos por instituições de pesquisa, a fim de reduzir inconsistências declaratórias. As maiores dificuldades enfrentadas no processo de mapeamento incluíram a sobreposição de classes ambientais, a confusão espectral entre áreas antropizadas e vegetação secundária e a ausência de dados oficiais atualizados, o que exigiu um esforço adicional de refinamento e validação manual para garantir a qualidade dos resultados.

2.6 REFERÊNCIAS:

ALENCAR, A.; SHIMBO, J. Z.; LENTI, F.; MARQUES, C. Balzani; ZIMBRES, B.; ROSA, M.; ARRUDA, V.; CASTRO, I.; RIBEIRO, J. F. M.; VARELA, V.. Mapping Three Decades of Changes in the Brazilian Savanna Native Vegetation Using Landsat Data Processed in the Google Earth Engine Platform. **Remote Sensing**, [S.L.], v. 12, n. 6, p. 924, 13 mar. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12060924>.

ACHARKI, S.. PlanetScope contributions compared to Sentinel-2, and Landsat-8 for LULC mapping. **Remote Sensing Applications: Society and Environment**, [S.L.], v. 27, p. 100774, ago. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.rsase.2022.100774>.

NASCENTE, J. Cristina; MANZON N., G.; FERREIRA, M. E. CLASSIFICAÇÃO ORIENTADA A OBJETO APLICADA EM DADOS PLANET PARA O MAPEAMENTO DE ÁREAS-CHAVE PARA A BIODIVERSIDADE NO CERRADO BRASILEIRO. **Geoambiente On-line**, Goiânia, n. 50, 2024. Disponível em: <https://revistas.ufj.edu.br/geoambiente/article/view/768>

CARVALHO, G. O. T.; SILVA, N. C.; SALVIO, Geraldo M. M. Vulnerabilidade ambiental em Áreas de Proteção Ambiental (APA) do Bioma Mata Atlântica na região sudeste brasileira. **Ciência Florestal**, [S.L.], v. 32, n. 3, p. 1575-1593, 22 set. 2022. Universidade Federal de Santa Maria. <http://dx.doi.org/10.5902/1980509867261>.

CONGALTON, R.G. Accuracy assessment and validation of remotely sensed and other spatial information. **International Journal Of Wildland Fire**, [S.L.], v. 10, n. 4, p. 321, 2001. CSIRO Publishing. <http://dx.doi.org/10.1071/wf01031>.

DELANEY, B.; TANSEY, K.; WHELAN, M. Satellite Remote Sensing Techniques and Limitations for Identifying Bare Soil. **Remote Sensing**, [S.L.], v. 17, n. 4, p. 630, 12 fev. 2025. MDPI AG. <http://dx.doi.org/10.3390/rs17040630>.

FRANÇO, R. D.; BRANDÃO, R.; NOGUEIRA, C. C.; SALMONA, Y. B.; MACHADO, R. B.; COLLI, Guarino R. Habitat loss and the effectiveness of protected areas in the Cerrado Biodiversity Hotspot. **Natureza & Conservação**, [S.L.], v. 13, n. 1, p. 35-40, jan. 2015. Elsevier BV. <http://dx.doi.org/10.1016/j.ncon.2015.04.001>.

HADDAD, I.; GALVÃO, L. S.; BREUNIG, F. M.; DALAGNOL, R.; BOURSCHEIDT, V.; JACON, A. D. On the combined use of phenological metrics derived from different PlanetScope vegetation indices for classifying savannas in Brazil. **REMOTE SENSING APPLICATIONS: Society and Environment**, [S.L.], v. 26, p. 100764, abr. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.rsase.2022.100764>.

IBAMA. Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis. **Diagnóstico Ambiental do Parque Nacional da Chapada dos Guimarães**. Brasília: IBAMA, 1995.

IBGE. Instituto Brasileiro de Geografia e Estatística. Relatório de **Caracterização Territorial do Município de Chapada dos Guimarães**. 2ª ed. Rio de Janeiro: IBGE, 2024.

IBGE. Instituto Brasileiro de Geografia e Estatística. Resolução nº 1, de 25 de fevereiro de 2005: **adoção do sistema de referência geocêntrico para as Américas (SIRGAS2000)**. Rio de Janeiro: IBGE, 2005. Disponível em: <https://www.ibge.gov.br/home/geociencias/geodesia>. Acesso em: 8 fev. 2025.

ICMBio. Instituto Chico Mendes de Conservação da Biodiversidade. **Plano de Manejo do Parque Nacional da Chapada dos Guimarães**. Brasília: ICMBio, 2009.

HAKIM, Y. F.; TSAI, F. Deep Learning-Based Land Cover Extraction from Very-High-Resolution Satellite Imagery for Assisting Large-Scale Topographic Map Production. **Remote Sensing**, [S.L.], v. 17, n. 3, p. 473, 30 jan. 2025. MDPI AG. <http://dx.doi.org/10.3390/rs17030473>.

RAO, P.; ZHOU, W.; BHATTARAI, N.; SRIVASTAVA, A. K.; SINGH, B.; POONIA, S.; LOBELL, D. B.; J., Meha. Using Sentinel-1, Sentinel-2, and Planet Imagery to Map Crop Type of Smallholder Farms. **Remote Sensing**, [S.L.], v. 13, n. 10, p. 1870, 11 maio 2021. MDPI AG. <http://dx.doi.org/10.3390/rs13101870>

MOHANRAJAN, S. N.; LOGANATHAN, A.; MANOHARAN, P. Survey on Land Use/Land Cover (LU/LC) change analysis in remote sensing and GIS environment: techniques and challenges. **Environmental Science And Pollution Research**, [S.L.], v. 27, n. 24, p. 29900-29926, 5 jun. 2020. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11356-020-09091-7>.

PANIGRAHI, S.; VERMA, K.; TRIPATHI, P. Data mining algorithms for land cover change detection: a review. **Sādhanā**, [S.L.], v. 42, n. 12, p. 2081-2097, 24 nov. 2017.

SILVA, J. Maria C.; BATES, J. M. Biogeographic Patterns and Conservation in the South American Cerrado: a tropical savanna hotspot. **Bioscience**, [S.L.], v. 52, n. 3, p. 225, 2002. Oxford University Press (OUP). [http://dx.doi.org/10.1641/0006-3568\(2002\)052\[0225:bpacit\]2.0.co;2](http://dx.doi.org/10.1641/0006-3568(2002)052[0225:bpacit]2.0.co;2).

SPRINGER Science and Business Media LLC. <http://dx.doi.org/10.1007/s12046-017-0751-4>.

THE NATURE CONSERVANCY. Cadastro Ambiental Rural - CAR: nasce a identidade do imóvel rural. 1ª ed. Curitiba, Paraná: **The Nature Conservancy**, 2015. ISBN 978-85-60797-15-8.

PEIXOTO, Ariane Luna; LUZ, José Roberto Pujol; BRITO, Márcia Aparecida de (Org.). **Conhecendo a biodiversidade**. Brasília: MCTIC, CNPq, PPBio, 2016. 196 p. ISBN 978-85-63100-08-5.

RIBEIRO, J. F.; WALTER, B. M. Teles. As principais fitofisionomias do bioma Cerrado. In: PEIXOTO, Ariane Luna; LUZ, José Roberto Pujol; BRITO, Márcia Aparecida de (Org.). **Conhecendo a biodiversidade**. Brasília: MCTIC, CNPq, PPBio, 2016. p. 153-212

RODRIGUES, T.; TAKAHASHI, F.; DIAS, A.; LIMA, T.; ALCÂNTARA, E.. Machine Learning-Based Cerrado Land Cover Classification Using PlanetScope Imagery. **Remote Sensing**, [S.L.], v. 17, n. 3, p. 480, 30 jan. 2025. MDPI AG. <http://dx.doi.org/10.3390/rs17030480>.

RODRIGUEZ G., V.F.; GHIMIRE, B.; ROGAN, J.; CHICA-OLMO, M.; RIGOL-SANCHEZ, J.P. An assessment of the effectiveness of a random forest classifier for land-cover classification. **Isprs Journal Of Photogrammetry And Remote Sensing**, [S.L.], v. 67, p. 93-104, jan. 2012. Elsevier BV. <http://dx.doi.org/10.1016/j.isprsjprs.2011.11.002>.

BELLÓN, B.; BLANCO, J.; VOS, A.; ROQUE, F. O.; PAYS, O.; RENAUD, P. C. Integrated Landscape Change Analysis of Protected Areas and their Surrounding Landscapes: application in the brazilian cerrado. **Remote Sensing**, [S.L.], v. 12, n. 9, p. 1413, 30 abr. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12091413>.

ROSA, Roberto. Geotecnologias na Geografia aplicada. **Revista do Departamento de Geografia**, São Paulo, Brasil, v. 16, p. 81–90, 2011. DOI: 10.7154/RDG.2005.0016.0009. Disponível em: <https://revistas.usp.br/rdg/article/view/47288>.. Acesso em: 11 fev. 2025.

SONODA, F. A.; SILVA, P. B. A.; RIBEIRO, L. R.; TOCANTINS, Nely; TORRECILHA, Sylvia. A efetividade das áreas protegidas na conservação das espécies de mamíferos do bioma Pantanal. *Boletim do Museu Paraense Emílio Goeldi - Ciências Naturais*, [S.L.], v. 16, n. 3, p. 371-440, 31 jan. 2022. *Boletim do Museu Paraense Emílio Goeldi*. <http://dx.doi.org/10.46357/bcnaturais.v16i3.815>.

SOUZA, C. M.; SHIMBO, J. Z.; ROSA, M. R.; PARENTE, L. L.; ALENCAR, A.; RUDORFF, B. F. T.; HASENACK, H.; MATSUMOTO, M.; FERREIRA, L. G.; SOUZA-FILHO, P. W. M. Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. **Remote Sensing**, [S.L.], v. 12, n. 17, p. 2735, 25 ago. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12172735>.

VEIGA, A. J. P.; MATTA, J. M. B. da; VEIGA, D. A. M.; BOMFIM, C. S. S. Análise do uso e cobertura da terra em Itapetinga no estado da Bahia, Brasil, com uso de SENSORIAMENTO Remoto e SIG / Analysis of the use and land cover in Itapetinga in the state of Bahia, Brazil, using Remote Sensing and GIS. **Brazilian Journal of Development**, [S. l.], v. 6, n. 9, p. 73928–73947, 2020. DOI: 10.34117/bjdv6n9-741.

VICTORIA, D. C., BOLFE, E., S., EE, A., ED, A., RG, G., DP, & Landau, EC (2020). Potencialidades para expansão e diversificação agrícola sustentável do Cerrado. Em É. L. Bolfe, EE Sano, & SK Campos (Eds.), *Dinâmica Agrícola no Cerrado: análises e projeções* (Vol. 1, Cap. 8, pp. 229-258). Brasília, DF: Embrapa.

WANG, Z.; WU, W.; LIU, H.. Comparing Soil pH Mapping from Multi-Temporal PlanetScope and Sentinel-2 Data Across Land Use Types. **Remote Sensing**, [S.L.], v. 17, n. 2, p. 189, 7 jan. 2025. MDPI AG. <http://dx.doi.org/10.3390/rs17020189>.

ZAIDAN, R. T. GEOPROCESSAMENTO CONCEITOS E DEFINIÇÕES. **Revista de Geografia - Ppgeo - Ufjf**, [S.L.], v. 7, n. 2, p. 196-201, 28 set. 2017. Universidade Federal de Juiz de Fora. <http://dx.doi.org/10.34019/2236-837x.2017.v7.18073>.

VANHELLEMONT, Quinten. Evaluation of eight band SuperDove imagery for aquatic applications. **Optics Express**, [S.L.], v. 31, n. 9, p. 13851, 12 abr. 2023. Optica Publishing Group. <http://dx.doi.org/10.1364/oe.483418>.

LEWIS, K.; BARROS, F. de V.; CURE, M. B.; DAVIES, C. A.; FURTADO, M. N.; HILL, T. C.; HIROTA, M.; MARTINS, D. L.; MAZZOCHINI, G. G.; MITCHARD, E. T. A.. Mapping native and non-native vegetation in the Brazilian Cerrado using freely available satellite products. **Scientific Reports**, [S.L.], v. 12, n. 1, p. 11-26, 28 jan. 2022. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/s41598-022-05332-6>.

3. CAPITULO III - PROPOSTA METODOLÓGICA PARA GERAÇÃO DE BASE CARTOGRÁFICA DO CADASTRO AMBIENTAL RURAL/MT UTILIZANDO APRENDIZADO DE MAQUINA RANDOM FOREST

RESUMO

Este estudo teve como objetivo avaliar a precisão na identificação de classes ambientais a partir da comparação entre as bases do Sistema Mato-Grossense de Cadastro Ambiental Rural (SIMCAR) e do Laboratório de Sensoriamento Remoto da UFMT (LabSensor), no município de Chapada dos Guimarães. Para a análise, foram utilizadas imagens do satélite Planet SuperDove e técnicas de aprendizado de máquina, com a aplicação do algoritmo Random Forest (RF). Os resultados apresentados que a base LabSensor apresentou maior nível de detalhamento, evidenciando diferenças em relação ao SIMCAR. O estudo destaca a importância de tecnologias avançadas no monitoramento territorial para aprimorar a regularização ambiental e subsidiar políticas públicas voltadas à gestão sustentável dos recursos naturais

PALVRAS CHAVE: SIMCAR, Planet Superdove, Chapada dos Guimarães, Classificação supervisionada.

ABSTRACT

This study aimed to evaluate the accuracy in identifying environmental classes based on a comparison between the databases of the Mato Grosso Rural Environmental Registry System (SIMCAR) and the UFMT Remote Sensing Laboratory (LabSensor), in the municipality of Chapada dos Guimarães. For the analysis, images from the Planet SuperDove satellite and machine learning techniques were used, with the application of the Random Forest (RF) algorithm. The results showed that the LabSensor database presented a greater level of detail, highlighting differences in relation to SIMCAR. The study highlights the importance of advanced technologies in territorial monitoring to improve environmental regularization and support public policies aimed at the sustainable management of natural resources.

KEYWORDS: Simcar, Planet Superdove, Chapada dos Guimarães, Supervised classification.

RESUMEN

Este estudio tuvo como objetivo evaluar la precisión en la identificación de clases ambientales a partir de una comparación entre las bases de datos del Sistema de Registro Ambiental Rural de Mato Grosso (SIMCAR) y del Laboratorio de Teledetección de la UFMT (LabSensor), en el municipio de Chapada dos Guimarães. Para el análisis se utilizaron imágenes del satélite Planet SuperDove y técnicas de aprendizaje automático, con la aplicación del algoritmo Random Forest (RF). Los resultados mostraron que la base de datos LabSensor presentó un mayor nivel de detalle, destacando diferencias con relación a SIMCAR. El estudio destaca la importancia de las tecnologías avanzadas en el

seguimiento territorial para mejorar la regularización ambiental y apoyar las políticas públicas orientadas a la gestión sostenible de los recursos naturales

PALABRAS CLAVE: Simcar, Planet Superdove, Chapada dos Guimarães, Clasificación supervisada.

3.1 INTRODUÇÃO

O Cadastro Ambiental Rural (CAR) é um registro público eletrônico de abrangência nacional, instituído pela Lei nº 12.651/2012, conhecida como “Novo Código Florestal” (BRASIL, 2012). Sua implementação ocorreu no contexto do Sistema Nacional de Informação sobre Meio Ambiente (SINIMA) e foi regulamentada pelos Decretos nº 7.830/2012 e nº 8.235/2014, além da Instrução Normativa MMA nº 2/2014 (MMA, 2014). O CAR é obrigatório para todos os imóveis rurais e tem como principal objetivo integrar informações ambientais, abrangendo Áreas de Preservação Permanente (APPs), áreas de uso restrito, Reservas Legais (ARL), remanescentes de florestas nativas e áreas rurais consolidadas. Sua base de dados é utilizada para controle, monitoramento, planejamento ambiental e econômico, além de servir como ferramenta no combate ao desmatamento.

Para reforçar esse sistema, alguns estados desenvolveram suas próprias plataformas integradas ao Sistema Nacional de Cadastro Ambiental Rural (SICAR). No estado de Mato Grosso, foi desenvolvido o Sistema Mato-Grossense de Cadastro Ambiental Rural (SIMCAR), regulamentado pelo Decreto nº 420/2016 (Mato Grosso, 2016). O SIMCAR tem como função registrar, monitorar e fiscalizar propriedades rurais, auxiliando no cumprimento do Código Florestal. Essa ferramenta digital permite o armazenamento, gestão e análise de informações geográficas e ambientais, desempenhando um papel essencial na regularização fundiária e na gestão ambiental do estado (Mato Grosso, 2024).

No entanto, apesar da sua importância, o CAR e as suas plataformas estaduais, como o SIMCAR, enfrentam desafios significativos. De acordo com Lopes, Machado e Chiavari (2023) há um grande número de propriedades aguardando análise além de uma vasta extensão de áreas com passivos ambientais pendentes de restauração. Outro problema crítico diz respeito à confiabilidade dos dados uma vez que o CAR é um sistema declaratório, ou seja, as informações são inseridas pelos próprios proprietários, além disso, há uma falta de precisão no mapeamento e um déficit de mão de obra especializada para validar os registros e monitorar a regularização ambiental (Scolforo et al., 2014; Oliveira et al., 2019).

Nesse contexto, o mapeamento de uso e cobertura do solo tem um papel fundamental para a regularização ambiental dos imóveis rurais, pois permite a identificação e caracterização de áreas protegidas, passivas ambientais e atividades produtivas, dessa forma a precisão dos dados espaciais é essencial para garantir que as propriedades rurais estejam em conformidade com o Código Florestal, possibilitando uma avaliação criteriosa dos impactos ambientais e auxiliando na tomada de decisão para a regularização e recuperação de áreas degradadas (Soares et al., 2019). O avanço de tecnologias como Sensoriamento Remoto e aprendizado de máquina tem melhorado a qualidade e confiabilidade das bases cartográficas, reduzindo erros e aumentando a eficiência na fiscalização ambiental (Galvão; Breunig; Jacon, 2022).

Apesar dos avanços do Sensoriamento Remoto e dos Sistemas de Informação Geográfica (SIG), ainda existem desafios relacionados à precisão e confiabilidade dos mapas de uso e cobertura do solo. A grande variação fitofisionômica do Cerrado, aliada às mudanças constantes no uso da terra, torna necessária a aplicação de técnicas mais aprimoradas para a identificação das classes ambientais (Hakim; Tsai, 2025). A disponibilidade de imagens de alta resolução, como as fornecidas pelo satélite PlanetScope (Planet, 2024), aliadas ao uso de algoritmos de aprendizado de máquina, tem abordagens mais robustas permitidas para essa classificação (Dritsas; Trigka, 2025).

O problema central desta pesquisa está relacionado à baixa precisão e inconsistências cartográficas nas informações declaradas no SIMCAR. Isso porque as inconsistências nos dados declaratórios dos imóveis cadastrados comprometem a eficácia do sistema de gestão ambiental. Além disso, as metodologias utilizadas para mapeamento da vegetação e uso da terra nem sempre garantem níveis altos de precisão, gerando dificuldades no licenciamento ambiental e na recuperação de áreas degradadas.

Diante desse cenário, esta pesquisa tem como objetivo criar uma base cartográfica mais precisa e cartograficamente consistente, utilizando imagens de satélite de alta resolução e aprendizado de máquina. Posteriormente, será realizada uma análise espacial detalhada dos imóveis cadastrados no CAR no município de Chapada dos Guimarães no estado de Mato Grosso, com foco na identificação de divergências cartográficas e na avaliação da conformidade das áreas mapeadas com as normativas ambientais.

A pesquisa compara a base temática gerada com as informações declaradas no CAR, analisando se a base temática oferece dados mais detalhados e precisos. O objetivo final é contribuir para o aprimoramento do controle ambiental e do planejamento territorial,

fornecendo subsídios técnicos para a melhoria das políticas públicas de regularização ambiental.


3.2 MATERIAL E MÉTODOS

3.2.1 Área de Estudo

Este estudo foi realizado no município de Chapada dos Guimarães (Figura 1), situado no Estado de Mato Grosso, com uma área territorial de aproximadamente 6.603.252 km² (IBGE, 2024). O município está totalmente inserido no bioma Cerrado, um dos mais biodiversos do mundo, abrigando uma rica diversidade biológica, estimada em cerca de 160 mil espécies.

O clima predominante na região é tropical de savana (Aw) segundo a classificação de Köppen, caracterizando-se por uma alternância entre períodos úmidos e secos. A apresenta altitudes que variam entre 600 e 800 metros, influenciando a distribuição das formações vegetacionais. A Chapada dos Guimarães inclui diversas fitofisionomias do Cerrado, como mata ciliar, mata de galeria, cerradão, cerrado sensu stricto, campo sujo, campo limpo, veredas e palmeirais, essenciais para a biodiversidade e regulação hídrica. (IcmBio, 2009).

Figura 1. Mapa de Localização do Município de Chapada dos Guimarães.



Fonte: Elaborado pela autora (2025).

3.2.2 Aquisição e pré-processamento de dados de Sensoriamento Remoto

A aquisição de dados para a realização das análises comparativas envolveu a utilização de duas fontes principais: a base temática elaborada pelo Laboratório de Sensoriamento Remoto e Geotecnologias da Faculdade de Engenharia Florestal - UFMT LabSensor e os dados validados do Cadastro Ambiental Rural (CAR), disponíveis no Geoportal da Secretaria de Estado de Meio Ambiente de Mato Grosso (SEMA-MT). A base do LabSensor foi gerada a partir de imagens de satélite de alta resolução, Planet Super Dove (sensor PSB.SD). processadas e classificadas utilizando técnicas de aprendizado de máquina, como o algoritmo Random Forest (RF), para identificar diferentes categorias de uso e ocupação do solo.

As Imagens utilizadas no processamento Planet Super Dove- PSB.SD, foram adquiridas através portal Planet, utilizando a licença do Programa Padrão de Educação e Pesquisa. Para a cobertura do Município foram selecionados 5 faixas/órbitas com datas de 05/05/2023.15/05/2023 e 17/05/2023, A escolha dessas datas foi estratégica, pois correspondem ao período de transição entre o final da estação chuvosa e o início da seca, favorecendo condições atmosféricas mais estáveis e com menor presença de nuvens — aspecto crucial para melhorar a acurácia na classificação das diferentes categorias temáticas de uso e cobertura da terra (Rodrigues et al., 2025). As imagens possuem oito bandas espectrais conforme representado na tabela.

Tabela1. Especificação das bandas espectrais Satélite Planet Super Dove PSB.SD

	Banda Espectral	(nm)	FWHM
1	Azul costal	443	20
2	Azul	490	50
3	Verde I	531	36
4	Verde	565	36
5	Amarelo	610	20
6	Vermelho	665	31
7	Borda do Vermelho	705	15
8	Nir	865	40

Fonte: Elaborado pela autora com dados Planet Labs (2023) e Vanhellemont, (2023).

O próximo passo foi fazer a distribuição das amostras de treinamento, que foi realizado utilizando o software Envi 5.6, para isso foram definidas as classes: água, área agrícola, área úmida, campo, solos, formação florestal, formação savânica e área urbana conforme a tabela 2.

Tabela 2. Classes Classificação Supervisionada Random Forest

Classes	Descrição
Água	Corpos d'água como rios, lagos e açudes.
Área Agrícola	Áreas destinadas à agricultura, com cultivos de diferentes tipos.
Área Úmida	Áreas específicas com presença predominante de buritis, em solos sujeitos a alagamentos sazonais.
Campo	Áreas de campo limpo, capoeira suja e pastagens
Solo Exposto	Áreas onde o solo está diretamente exposto, sem cobertura vegetal.
Formação Florestal	Áreas cobertas por vegetação densa e alta, característica de florestas.
Formação Savânica	Áreas de transição entre cerrado e outros tipos de vegetação, com características de savana.
Área Urbana	Áreas compostas por edificações, ruas, rodovias, áreas residenciais, comerciais, industriais e de serviços.

Fonte: Elaborado pela autora (2025).

A distribuição das amostras de treinamento foi dividida por classe, totalizando em 400.000 pixels. Para a classificação das imagens foi utilizado o algoritmo Random Forest (RF), também no software ENVI 5.6, o resultado foi uma base temática no formato raster. O refinamento dos resultados foi realizado utilizando o software ArcGIS e QGIS, para correção de geometrias, recortes, análises espaciais e geração de mapas.

Os itens presentes na base temática LabSensuR compreendem categorias de uso e ocupação do solo mapeadas com o objetivo de atender às especificidades ambientais e territoriais da região de estudo.

3.2.3 Base LabSensoR e Base SIMCAR

Para realizar a análise comparativa, foi necessário ajustar as classes da base LabSensoR gerada no capítulo I, de modo a alinhá-las com as categorias apresentadas no SIMCAR. foi necessário gerar as feições correspondentes às classes compatíveis, de forma a permitir a comparação entre as duas bases., conforme figura a seguir.

Ressalta-se que nem todas as classes previstas no SIMCAR foram mapeadas neste estudo. Foram consideradas apenas aquelas efetivamente identificadas nas imagens, conforme a realidade de cada imóvel rural analisado.

Tabela 3. Classes SIMCAR

Classes SIMCAR	Descrição
ATP - Área Total da Propriedade	Representa o limite total da propriedade rural.
AVN - Área de Vegetação Nativa	Refere-se às áreas de vegetação nativa dentro da propriedade.
Veredas	Áreas caracterizadas por solos hidro mórficos, frequentemente com a presença da palmeira buriti. São protegidas e consideradas de importância ambiental.
Área consolidada	Áreas que foram antropizadas antes de 22 de julho de 2008 e continuam sendo usadas, exceto em regime de pousio.
Cursos d'água	Representação de cursos d'água na propriedade, que deve ser vetorizada como polígono, independentemente da largura do curso d'água.
Nascente	Representa nascentes localizadas dentro da propriedade, devendo ser representadas por um ponto.
Lagoas naturais	Representação de lagos e lagoas naturais dentro do imóvel ou em sua divisa, vetorizados como polígonos.
Reservatórios artificiais	Representação de reservatórios artificiais de água, resultantes de barramentos ou represamentos dentro da propriedade.

Área de declividade	Áreas com declividade superior a 45°, consideradas Áreas de Preservação Permanente (APP).
APP - Área de Preservação Permanente	Inclui diversas áreas como bordas de chapadas, topos de morro, áreas acima de 1.800 metros de altitude, entre outras, que têm proteção legal especial.
AUAS - Áreas de Uso Antropizado do Solo	São caracterizadas por áreas alteradas, degradadas ou de uso antropizado, com ou sem autorização do órgão ambiental até 22 de julho de 2008.

Fonte: Elaborado pela autora (2025).

As classes de água, identificadas na base LabSensor, foram integradas às categorias de hidrografia, nas quais estão incluídas (Rio até 10 metros, Rio de 10 até 50 metros, Rio de 50 até 200 metros, Rio de 200 até 600 metros, Rio maior que 600 metros, Lagoa natural, Reservatório artificial). Já as classes de área agrícola, campo, solo exposto e área urbana foram atribuídas à Área Consolidada (AC) ou Área de Uso Antropizado do Solo (AUAS) dependendo do período que ocorreu a antropização da área. As formações florestais e savânicas foram denominadas Área de Vegetação Nativa (AVN), garantindo a compatibilidade com as diretrizes do Cadastro Ambiental Rural.

Com objetivo de complementar as análises, foram geradas classes de uso restrito e áreas com declividade superior a 45°, utilizando as ferramentas do software ArcGIS. A classe de uso restrito foi gerada com o objetivo de identificar e classificar as áreas que apresentam restrições quanto ao uso ou exploração devido a características ambientais. É importante destacar que as bases de uso restrito e declividade superior a 45° não estão disponíveis no Geoportal.

Para elaboração dos dados de declividade e uso restrito no ArcGIS, primeiramente, foi utilizado um Modelo Digital de Elevação (MDE) de alta resolução, obtido a partir de do ALOS PALSAR. A declividade foi calculada por meio da ferramenta Slope, /Spatial Analyst Tools, gerando um raster com valores de orientação em graus. Em seguida, aplicou-se a reclassificação dos valores de declividade conforme os critérios da Lei 12.651/2012, delimitando áreas com proteção entre 25° e 45° como uso restrito e acima de 45° como áreas de preservação permanente. Para validar as informações, as áreas

delimitadas foram cruzadas com a base cartográfica oficial e imagens de satélite, utilizando a ferramenta Estatística Zonal, para comparar os resultados com dados de referência. Por fim, os polígonos gerados foram convertidos para shapefile e integrados ao banco de dados geoespaciais para posterior análise e sobreposição com outras camadas vetoriais.

As Áreas de APP e as Áreas de Preservação Permanente Degradadas (APPD) também foram geradas pelo LabSensor, seguindo a legislação vigente. Para a delimitação das APPs, foram consideradas as hidrografias do SFB, abrangendo cursos d'água com largura de até 10 metros, rios de margem dupla (aqueles com largura superior a 10 metros) e massas d'água, que incluem lagos, lagoas e represas naturais e artificiais da base temática utilizada. Além disso, as veredas, ajustadas especificamente para esta pesquisa, foram embutidas ao mapeamento, bem como as nascentes, também geradas pelo LabSensor.

A delimitação das Áreas de Preservação Permanente (APPs) foi realizada no ArcGIS a partir dos dados hidrográficos mencionados anteriormente. Para isso, utilizou-se a ferramenta Buffer para gerar as faixas de proteção ao redor das hidrografias, conforme os critérios estabelecidos na legislação vigente. Já as Áreas de Preservação Permanente Degradadas (APPD) foram extraídas por meio de uma análise espacial, na qual foram cruzadas as APPs com as Áreas Consolidadas (AC) e as Áreas de Uso Alternativo do Solo (AUAS) dessa forma, todo APP que estava sobreposta a essas áreas foi automaticamente ajustada como APPD.

Os dados do SIMCAR foram obtidos diretamente do Geoportal (<https://geoportal.sema.mt.gov.br>).

Para a análise das propriedades, foram utilizadas as hidrografias (cursos d'água) com Largura de até 200 metros, produzidas pelo Serviço Florestal Brasileiro (SFB) em escala de 1:25.000, geradas a partir de imagens da Planet, com dados de 09/2021 (Brasil, 2022), e disponibilizadas no Geoportal. Contudo, as áreas de APP fornecidas apresentaram erros de geometria, o que inviabilizou o seu uso direto, em resposta a essas limitações, o LabSensor gerou uma base de APP utilizando as hidrografias do Geoportal como referência. Além disso, as nascentes não estavam disponíveis no Geoportal, o que levou o LabSensor a gerar essas informações a partir das hidrografias também fornecidas pelo Geoportal.

Na análise das hidrografias com largura superior a 200 metros e das veredas, foram utilizadas as informações provenientes da base temática de uso do solo elaborada pelo LabSensor que permitiu identificar com maior precisão e detalhamento essas categorias.

As bases SIMCAR e LabSensoR foram comparadas para avaliar a precisão e o detalhamento das informações relativas ao uso e ocupação do solo. A análise foi realizada com foco em classes como APP, APPD, Uso Restrito (UR), Declividade 45°, AC, AU, Veredas, AVN, AUAS.


A fim de atender a uma exigência metodológica estabelecida pelo orientador da pesquisa, foi adotado um procedimento de reorganização espacial das classes temáticas, com a exclusão das sobreposições entre as classes. Embora tais sobreposições sejam previstas na legislação ambiental vigente e façam parte da complexidade dos territórios rurais, optou-se pela exclusividade espacial entre as classes com o objetivo de possibilitar a comparação direta entre a base SIMCAR e os dados gerados pelo LabSensoR. Essa abordagem, embora facilite o cruzamento de dados quantitativos e a padronização cartográfica entre bases distintas, implicou na supressão de porções significativas de informações ambientais que coexistem no território, conforme previsto pela legislação. Áreas de Vegetação Nativa (AVN), por exemplo, muitas vezes se sobrepõem legalmente a Áreas de Preservação Permanente (APP) ou Veredas, compondo uma realidade complexa que o presente recorte metodológico simplificou.

Tal decisão técnica não reflete, portanto, a totalidade das funções ecológicas e normativas que incidem sobre essas áreas. Deve ser considerada uma limitação metodológica que impacta a análise dos resultados e a interpretação dos dados gerados a partir desta reorganização espacial.

3.3 RESULTADOS

Os ajustes realizados na base temática LabSensoR para alinhar as classes às categorias do SIMCAR resultaram em uma base temática aprimorada, composta por classes padronizadas e adaptadas às exigências do sistema. SIMCAR.

Figura 2. Mapa Classes do SIMCAR.



Fonte: Elaborado pela autora (2025).

O mapa apresentado ilustra a distribuição espacial das classes de uso e cobertura do solo no município de Chapada dos Guimarães, conforme as categorias temáticas utilizadas no Cadastro Ambiental Rural (CAR). A análise das classes evidenciadas oferece uma visão ampla sobre a ocupação do solo e a relação dessas áreas com a legislação ambiental vigente. A seguir, descrevem-se as principais classes observadas:

A Área Consolidada, representando a maior parte da região mapeada, abrange aproximadamente 255.551,72 hectares. Este tipo de área corresponde a zonas já ocupadas por atividades agropecuárias e pastagem, sendo indicadores claros de intervenções humanas prolongadas no solo. A grande extensão dessas áreas sugere o avanço de atividades produtivas na região, o que pode estar relacionado tanto ao desenvolvimento econômico quanto à pressão sobre os recursos naturais.

As áreas de vegetação nativa, destacadas em verde, ocupam uma extensão de 284.574,82 hectares, sendo a classe com maior cobertura. Essas áreas preservam a vegetação original da região, possivelmente consistindo em Áreas de Preservação Permanente (APPs) e Reservas Legais (RLs), conforme exigido pela legislação ambiental. A presença significativa de vegetação nativa é essencial para a manutenção da biodiversidade local e para a sustentabilidade dos ecossistemas.

As áreas úmidas, representadas em azul claro, abrangem 146,31 hectares. Essas zonas estão associadas a regiões que podem estar sujeitas a inundações periódicas ou permanentes, impactando a fauna e flora local. A gestão dessas áreas é de extrema importância, pois desempenham um papel crucial no ciclo hidrológico, funcionando como zonas de amortecimento para enchentes e como habitats para várias espécies.

As massas de água, em azul escuro, somam 30.507,11 hectares e representam corpos hídricos maiores, como lagos e reservatórios, que são de fundamental importância para o abastecimento hídrico e a manutenção de ecossistemas aquáticos. Essas áreas também são relevantes para atividades econômicas, como a pesca e o turismo.

Representados em azul claro, os rios somam 850,95 hectares e correspondem aos cursos d'água que atravessam a região. Esses rios desempenham um papel vital na drenagem e no abastecimento de água da região, além de serem essenciais para a agricultura e outras atividades dependentes de recursos hídricos.

As Áreas de Uso Antropizado do Solo (AUAS) totalizaram 44.936,94 hectares, representando as áreas que foram abertas ou alteradas após o marco legal previsto pelo Código Florestal, em 22 de julho de 2008. Essas áreas refletem atividades humanas recentes que impactaram o uso e a cobertura do solo, destacando-se como um indicador das transformações ambientais ocorridas no período posterior à implementação da legislação ambiental vigente.


3.3.1 Análise das Propriedades Validadas no Município de Chapada dos Guimarães

Na análise dos cruzamentos de informações, foram selecionadas 48 propriedades com status de CAR VALIDADO, conforme disponibilizadas no Geoportal da SEMA-MT. Esse número corresponde ao total de imóveis com validação concluída disponíveis na plataforma na data da coleta dos dados, o que justifica sua utilização como universo da amostra analisada. Essas propriedades, aprovadas no sistema conforme os critérios técnicos aplicados pelo órgão ambiental, foram escolhidas por sua consistência cadastral e por representarem uma base relevante para a avaliação comparativa com os dados produzidos na pesquisa.

Contudo, para viabilizar a análise espacial e eliminar sobreposições entre classes, foram realizados recortes e ajustes nas feições, os quais implicam simplificações das categorias originais do SIMCAR. Esses ajustes foram feitos conforme diretrizes

metodológicas definidas nesta etapa do estudo, podendo descaracterizar parcialmente os critérios legais originalmente aplicados no processo de validação.

Figura 3. Mapa Propriedades Validadas disponibilizadas no site Geoportal SEMA.



Fonte: Elaborado pela autora (2025).

A análise foi realizada de forma individual a partir do recorte dos 48 perímetros da base SIMCAR, com a Base LabSensor, utilizando o software ArcGIS.

Nos dados extraídos da base SIMCAR, da pasta CAR VALIDADO, disponibilizadas no Geoportal, observou-se ausência de algumas classes, como as de hidrografias e áreas consolidadas.

Diante da ausência de algumas classes nos dados do SIMCAR, foi necessário analisar as informações e os dados disponibilizados no Geoportal, especificamente na pasta de Autorização, que se trata permissão para a realização de determinadas atividades que envolvem o uso ou alteração do meio ambiente. Essas autorizações são permitidas para garantir que qualquer intervenção, como exploração de recursos naturais, desmatamento, queima controlada ou restauração ambiental, esteja em conformidade com as leis ambientais e as políticas de preservação (BRASIL, 2019).


Dessa forma, as propriedades que apresentavam ausência de classes foram verificadas para identificar se nessas áreas havia alguma autorização que não estivessem presentes na pasta de arquivos do CAR Validado.

De acordo com o Decreto nº 262, de 16 de outubro de 2019, que institui a Autorização Provisória de Funcionamento de Atividade Rural (APF), considera-se:

"Art. 3º A Autorização Provisória de Funcionamento de Atividade - APF será emitida automaticamente considerando o polígono que incide sobre a base de Referência de Uso Consolidado, na escala 1:25.000, homologada pela SEMA nos termos da Lei nº 12.651/2012, fornecendo a massa d'água, a APP - Área de Preservação Permanente e a AVN - Área de Vegetação Nativa declaradas no Cadastro Ambiental Bem Rural; como o polígono desmatado após 22 de julho de 2008, com autorização do órgão ambiental competente" (BRASILc, 2019)."

Desse modo, as classes ausentes, quando identificadas como áreas vinculadas à APF Rural, foram contabilizadas como Áreas Consolidadas. Já os espaços não identificados, conforme verificado no Geoportal, foram considerados como dados não disponíveis. A Figura 4 apresenta o layout de uma propriedade validada, destacando a atribuição das áreas da APF Rural com base nas informações disponibilizadas. Após a verificação da presença de APF, foi realizada uma análise adicional para conferir se a área coincidia com a Base de Uso Consolidado disponibilizada pela SEMA, a fim de garantir consistência na caracterização da classe.

Figura 4. Mapa comparativo com ausência de classes SIMCAR.



Fonte: Elaborado pela autora (2024)

A Tabela 4 mostram os valores totais das diferentes classes de uso e cobertura do solo mapeadas nas 48 propriedades validadas, conforme registradas nas bases SIMCAR e LabSensor. A Área Total da Propriedade (ATP) manteve-se idêntica entre ambas (33.957,42 ha), o que reforça a consistência na delimitação dos perímetros. No entanto, observa-se uma série de variações expressivas nas demais categorias.

A Área de Uso Antropizado do Solo (AUAS) apresentou aumento de 1.576,18 ha na base LabSensor (+132,67%), enquanto a Área de Vegetação Nativa (AVN) foi reduzida em 1.414,01 ha (-10,11%), refletindo diferenças nos critérios de classificação dessas áreas. As Áreas de Preservação Permanente (APP) saltaram de 2.368,53 ha para 3.532,22 ha, um acréscimo de 1.163,69 ha (+49,13%). A APP Degradada (APPD), por sua vez, apresentou crescimento ainda mais acentuado, passando de 151,22 ha para 561,20 ha — um aumento de mais de 270%.

Tabela 4. Comparativo entre a base declarada no SIMCAR e a classificação gerada pelo LabSensor quanto ao uso e cobertura do solo no município de Chapada dos Guimarães.

Classe	SIMCAR (ha)	LabSensor (ha)	Diferença (ha)	% Diferença
AUAS	1188,04	2764,22	1576,18	132,67
AVN	13983,34	12569,33	-1414,01	-10,11
APP	2368,53	3532,22	1163,69	49,13
APPD	151,22	561,2	409,98	271,11
VEREDA	-	323,74	323,74	-
AU	30,76	13,36	-17,4	-56,57
AC	12675,12	14018,05	1342,93	10,6
Uso Restrito (UR)	-	100,43	100,43	-
Declividade > 45º	-	8,06	8,06	-
Massa d'água	-	17,02	-	-
Hidrografia	-	49,82	-	-
Total	33957,42	33957,42		

Fonte: Elaborado pela autora (2025).


A classe Vereda, ausente no SIMCAR, foi mapeada separadamente pela base LabSensor, totalizando 323,74 ha, evidenciando a maior capacidade de detecção de feições ambientais específicas com base em imagens de alta resolução. O mesmo se aplica às classes de Uso Restrito (100,43 ha), Declividade superior a 45º (8,06 ha), Hidrografia

(49,82 ha) e Massa d'água (17,02 ha), também não identificadas no SIMCAR. Por outro lado, a Área Úmida (AU) foi reduzida de 30,76 ha para 13,36 ha.

A Área Consolidada (AC) passou de 12.675,12 ha na base SIMCAR para 14.018,05 ha na base LabSensor, um crescimento de 1.342,93 ha (+10,6%), refletindo a reinterpretação de áreas com indícios de uso consolidado conforme critérios técnicos mais refinados.

Essas discrepâncias revelam que, embora ambas as bases estejam sobre o mesmo espaço geográfico, a escolha da metodologia influencia significativamente a identificação e quantificação das classes ambientais. A base LabSensor, ao empregar técnicas de Sensoriamento Remoto e imagens de maior resolução espacial, mostrou-se mais sensível à detecção de feições específicas, revelando aspectos que podem ser subestimados em bases auto declaratórias.

Gráfico 1. Comparação Base SIMCAR E LabSensor.



Fonte: Elaborado pela autora (2025).

3.4 DISCUSSÕES

Os resultados deste estudo demonstram que a aplicação de técnicas de aprendizado de máquina e o uso de imagens de alta resolução, como as fornecidas pelo satélite PlanetScope, contribuíram significativamente para o aprimoramento do mapeamento ambiental. Esses achados estão em consonância com os resultados de Rodrigues et al. (2025), que utilizaram o algoritmo SVM com imagens Planet para classificar formações vegetacionais do Cerrado, alcançando uma acurácia de 97,51%. De forma semelhante, neste trabalho, a comparação entre as bases SIMCAR e LabSensor evidenciou divergências significativas na quantificação de diversas classes ambientais, indicando que bases auto declaratórias como o SIMCAR tendem a subestimar áreas ecologicamente relevantes (Lopes et al., 2022; Lewis et al., 2022).

Com base na análise consolidada das 48 propriedades rurais, observou-se que a Área Total da Propriedade (ATP) se manteve constante (33.957,42 ha), porém ocorreram variações expressivas nas proporções internas das classes temáticas. A classe de Área de Uso Antropizado do Solo (AUAS) foi a que apresentou o maior aumento absoluto, com 1.576,18 ha (+132,67%). A Área Consolidada (AC) cresceu 1.342,93 ha (+10,6%), totalizando 14.018,05 ha na base LabSensor. As Áreas de Preservação Permanente (APP) tiveram incremento de 1.163,69 ha (+49,13%), e a Área de Preservação Permanente Degradada (APPD) aumentou 409,98 ha, representando um crescimento de 271,11%.

A classe Vereda, inexistente na base SIMCAR, foi mapeada com 323,74 ha no LabSensor, evidenciando a capacidade da abordagem em identificar formações vegetacionais específicas. Estudos como o de Nascente et al. (2024) reforçam a complexidade na detecção dessas áreas, principalmente em regiões de transição ecológica, sendo necessário o uso de técnicas como classificação orientada a objeto (OBIA), lógica booleana e critérios hidromorfológicos para sua delimitação. Na mesma linha, os dados de APPs derivados da hidrografia SFB (com cursos até 10 metros) também foram refinados com apoio das imagens Planet, melhorando a precisão na delimitação dessas áreas protegidas.

As classes de Uso Restrito (100,43 ha), Declividade superior a 45° (8,06 ha), Hidrografia (49,82 ha) e Massa d'água (17,02 ha) também foram identificadas exclusivamente na base LabSensor, demonstrando o detalhamento técnico ampliado da metodologia. Em contrapartida, observou-se redução em algumas categorias, como Área

de Vegetação Nativa (AVN), que diminuiu 1.414,01 ha (-10,11%), e Área Úmida (AU), com decréscimo de 17,4 ha (-56,57%).

Essas diferenças reforçam os achados de Pinheiro et al. (2019), que validaram a eficiência das imagens Planet associadas ao algoritmo Random Forest para mapeamento ambiental no CAR, atingindo exatidão global de 99,98% e índice Kappa de 86,16%. Em conjunto, os resultados deste estudo comprovam que o uso de SR de alta resolução, aliado a algoritmos robustos, aprimora significativamente a identificação e a quantificação das classes ambientais. Tal abordagem é fundamental para subsidiar políticas públicas, promover maior acurácia em processos de regularização ambiental e reduzir incertezas decorrentes de bases declaratórias incompletas.

Essas diferenças refletem desafios semelhantes às observações no Cadastro Ambiental Rural (CAR) em Goiás, onde divergências entre dados declaratórios e Sensoriamento Remoto foram evidenciadas (Souza et al., 2023). O mapeamento inadequado de áreas de uso restrito e APPs, especialmente em regiões com relevância accidental, pode comprometer a efetividade das políticas ambientais.

Os resultados demonstram que a integração de diferentes bases de dados, como SIMCAR e LabSensoR, possibilitou uma análise mais precisa da ocupação do solo (Kappa de 0,89), comparando-se com os estudos realizados por Chelotti e Sano (2024), que utilizou classificação supervisionada no Cerrado a partir de imagens do satélite PlanetScope com resolução de 4,77 m, obtendo um índice Kappa de 0,83 e um índice de similaridade de 0,90, reforçando assim a eficiência do uso de sensores de alta resolução espacial na caracterização detalhada da cobertura e uso do solo.

3.5 CONSIDERAÇÕES FINAIS

Não há uma metodologia única capaz de representar com fidelidade a realidade ambiental dos imóveis rurais do estado de Mato Grosso. Este estudo demonstrou que a integração de imagens de alta resolução do satélite Planet SuperDove com algoritmos de aprendizado de máquina, como o Random Forest, aprimorou significativamente a precisão no mapeamento da base temática de uso e cobertura da terra. A análise integrada das 48 propriedades validou a eficácia da abordagem, evidenciando divergências marcantes entre os dados auto declaratórios do SIMCAR e os dados extraídos da base LabSensoR.

Entre os principais avanços, destacam-se os aumentos de 49,13% em Áreas de Preservação Permanente (APP), 271,11% em Áreas de Preservação Permanente Degradada (APPD), 10,6% em Áreas Consolidadas (AC), e a inclusão de 323,74 ha de Veredas, ausentes na base SIMCAR. Além disso, novas classes como Uso Restrito, declividades superiores a 45°, hidrografia e massas d'água, não contempladas pelo SIMCAR, foram corretamente individualizadas pela classificação supervisionada. Isso revela não apenas o aprimoramento técnico da base, mas a capacidade de reconhecer elementos ambientais sensíveis que passam despercebidos em cadastros convencionais.

Tais diferenças ressaltam a limitação das bases declaratórias no cumprimento das diretrizes do Código Florestal, especialmente no que se refere à identificação precisa de Áreas de Preservação Permanente e vegetação nativa. A ausência ou subestimação dessas áreas pode comprometer diretamente a regularização ambiental, a fiscalização e o planejamento do uso da terra.

A implementação de tecnologias avançadas de SR, associadas ao aprendizado de máquina, demonstrou ser um caminho eficaz para a melhoria dos sistemas de cadastro ambiental. Este estudo contribui tecnicamente ao propor uma metodologia replicável, transparente e baseada em evidências, que pode ser incorporada por órgãos gestores na validação do CAR, no monitoramento ambiental e na definição de políticas públicas mais eficientes.

Recomenda-se, portanto, a atualização contínua dos cadastros ambientais rurais com o suporte de dados orbitais de alta resolução e modelos automatizados, garantindo maior confiabilidade às bases oficiais e promovendo uma gestão territorial mais sustentável e alinhada às exigências legais.

3.6 REFERÊNCIAS:

BRASIL. **Cadastro Ambiental Rural. Boletim.** Disponível em: [https://www.car.gov.br/#/central\(Conteudo/boletim](https://www.car.gov.br/#/central(Conteudo/boletim) . Acesso em: 13 ago. 2024

BRASIL. **Decreto nº 262, de 16 de outubro de 2019.** Regulamento do art. 31 da Lei Complementar nº 592, de 26 de maio de 2017, que institui a Autorização Provisória de Funcionamento da Atividade Rural - APF, no âmbito do procedimento da Licença Ambiental Única e dá outras providências. Diário Oficial do Estado de Mato Grosso, Cuiabá, 16 out. 2019. Disponível em : <https://www.legislacao.mt.gov.br>

BRASIL. Decreto nº 7.830, de 17 de outubro de 2012. Dispõe sobre o Sistema de Cadastro Ambiental Rural, o Cadastro Ambiental Rural, estabelece normas de caráter geral aos Programas de Regularização Ambiental, de que trata a Lei nº 12.651, de 25 de maio de 2012, e dá outras providências. Diário Oficial da União: seção 1, Brasília, DF, p. 5, 18 out. 2012.

BRASIL. **Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio).** Plano de Manejo do Parque Nacional da Chapada dos Guimarães. Chapada dos Guimarães, MT: ICMBio, 2009

BRASIL. Instrução Normativa MMA nº 2, de 6 de maio de 2014. **Dispõe sobre os procedimentos para a integração, execução e compatibilização do Sistema de Cadastro Ambiental Rural - SICAR e dos Cadastros Estaduais de Imóveis Rurais.** Diário Oficial da União: seção 1, Brasília, DF, p. 54, 7 maio 2014.

BRASIL. Lei n.º 12.651, de 25 de maio de 2012. **Dispõe sobre a proteção da vegetação nativa e dá outras providências. Diário Oficial da União, Brasília, DF, 28 maio 2012.** Disponível em: http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/l12651.htm. Acesso em: 16 set. 2024

BRASIL. Lei nº 12.651 **Dispõe sobre a proteção da vegetação nativa, alterada pelas Leis nº 6.938, de 31 de agosto de 1981, nº 9.393, de 19 de dezembro de 1996, e nº 11.428, de 22 de dezembro de 2006, revogada como Leis nº 4.771, de 15 de setembro de 1965, e nº 7.754, de 14 de abril de 1989, e dá outras providências.** Diário Oficial da União: seção 1, Brasília, DF, 28 maio 2012. Disponível em: http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/l12651.htm

BRASIL. **Ministério do Meio Ambiente. Instituto Chico Mendes de Conservação da Biodiversidade.** Plano de manejo do Parque Nacional da Chapada dos Guimarães. Chapada dos Guimarães, MT: ICMBio, 2009.

BRASIL. Portaria MAPA nº 121, de 12 de maio de 2021. **Estabelece metodologias complementares para a análise dos dados do CAR e sua integração ao SICAR.** Diário Oficial da União, Brasília, DF, 13 maio 2021. Disponível em: <https://www.in.gov.br/en/web/dou/-/portaria-n-121-de-12-de-maio-de-2021-319962645>. Acesso em: 16 set. 2024

CHANDA, M.; HOSSAIN, A. K. M. Azad. Application of PlanetScope Imagery for Flood Mapping: a case study in south chickamauga creek, chattanooga, tennessee. *Remote Sensing*, [S.L.], v. 16, n. 23, p. 4437, 27 nov. 2024. MDPI AG. <http://dx.doi.org/10.3390/rs16234437>.

CHELOTTI, G.; SANO, E. E. Identificação de Diferentes Tipos de Coberturas Vegetais no Distrito Federal a partir de Dados do Satélite PlanetScope. *Geosul*, [S.L.], v. 39, n. 89, p. 274-297, 13 ago. 2024. Universidade Federal de Santa Catarina (UFSC). <http://dx.doi.org/10.5007/2177-5230.2024.e94854>.

DRITSAS, E.S; TRIGKA, M. Remote Sensing and Geospatial Analysis in the Big Data Era: a survey. *Remote Sensing*, [S.L.], v. 17, n. 3, p. 550, 6 fev. 2025. MDPI AG. <http://dx.doi.org/10.3390/rs17030550>.

GAO, Wande; ZHENG, Ce; LIU, Xiuhua; LU, Yudong; CHEN, Yunfei; WEI, Yan; MA, Yandong. NDVI-based vegetation dynamics and their responses to climate change and human activities from 1982 to 2020: a case study in the mu us sandy land, China. *Ecological Indicators*, [S.L.], v. 137, p. 108745, abr. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.ecolind.2022.108745>.

HAKIM, Y. F.; TSAI, F. Deep Learning-Based Land Cover Extraction from Very-High-Resolution Satellite Imagery for Assisting Large-Scale Topographic Map Production. *Remote Sensing*, [S.L.], v. 17, n. 3, p. 473, 30 jan. 2025. MDPI AG. <http://dx.doi.org/10.3390/rs17030473>.

IBGE. Instituto Brasileiro de Geografia e Estatística. Relatório de **Caracterização Territorial do Município de Chapada dos Guimarães**. 2ª ed. Rio de Janeiro: IBGE, 2024

LEWIS, K. et al. Mapeamento da vegetação nativa e não nativa do Cerrado brasileiro usando produtos de satélite disponíveis gratuitamente. *Relatórios Científicos*, v. 12, n. 1588, 2022. Disponível em: <https://www.nature.com/articles/s41598-022-1588>

LOPES, Cristina L.; MACHADO, Lourdes; CHIAVARI, Joana. **Onde Estamos na Implementação do Código Florestal? Radiografia do CAR e do PRA nos Estados Brasileiros** - Edição 2022. Rio de Janeiro: Climate Policy Initiative, 2023.

MAPA. Portaria nº 121, de 12 de maio de 2021. Dispõe sobre os procedimentos complementares de análise dos dados do CAR. Ministério da Agricultura, Pecuária e Abastecimento, Brasília, DF, 12 maio 2021

MATO GROSSO. Decreto nº 420, de 05 de fevereiro de 2016. **Dispõe sobre a regulamentação do Sistema Estadual de Meio Ambiente e dá outras providências**. Diário Oficial do Estado de Mato Grosso, Cuiabá, 05 Set. 2016. MATO GROSSO. Secretaria de Estado de Meio Ambiente. **Geoportal SEMA MT**. Disponível em: <https://geoportal.sema.mt.gov.br/>. Acesso em: 12 set. 2024.

MMA. Instrução Normativa nº 2, de 5 de maio de 2014. Estabelece critérios para inscrição no CAR e procedimentos correlatos. Ministério do Meio Ambiente, Brasília, DF, 5 maio 2014.

NASCENTE, J. C.; FERREIRA, M. E.; Nunes, Gustavo Manzon. Classificação Orientada a Objeto Aplicada em Dados Planet para o Mapeamento de Áreas-Chave para a Biodiversidade no Cerrado Brasileiro. **Geoambiente On-Line**. v.50, p.1 - 26, 2024.

NJOMABA, E.; OFORI, J. N.; GUUROH, Reginald T.; AIKINS, B. E.; NAGBIJA, R. K.; SUROVÝ, Peter. Assessing Forest Species Diversity in Ghana's Tropical Forest Using PlanetScope Data. **Remote Sensing**, [S.L.], v. 16, n. 3, p. 463, 25 jan. 2024. MDPI AG. <http://dx.doi.org/10.3390/rs16030463>.

PINHEIRO, É. C. C.; RAMOS, A. P. M.; MARCATO, J. Remote Sensing Applied to the Environmental Regularization of Rural Properties in Mato Grosso do Sul. **Anuário do Instituto de Geociências - UFRJ**, [S.L.], v. 42, n. 3, p. 145-153, 30 set. 2019. Instituto de Geociências - UFRJ. http://dx.doi.org/10.11137/2019_3_145_153.Referencias

Planet. Imagens de satélite e arquivo. 2021. Disponível online: <https://planet.com/products/planet-imagery/> (acessado em 01 de junho de 2024).

RODRIGUES, T.; TAKAHASHI, F.; DIAS, A.; LIMA, T.; ALCÂNTARA, E. Machine Learning-Based Cerrado Land Cover Classification Using PlanetScope Imagery. **Remote Sensing**, [S.L.], v. 17, n. 3, p. 480, 30 jan. 2025. MDPI AG. <http://dx.doi.org/10.3390/rs17030480>

SECRETARIA DE ESTADO DO MEIO AMBIENTE DE MATO GROSSO. **Manual do usuário do SIMLAM - Sistema Integrado de Monitoramento e Licenciamento Ambiental**. Mato Grosso: SEMA, 2020. Disponível em: https://monitoramento.sema.mt.gov.br/simlam/EtramiteIMS/Manual_Public_SIMLAM.pdf. Acesso em: 13 ago. 2024.

SERVIÇO FLORESTAL BRASILEIRO. **Relatório de monitoramento ambiental no Brasil: desafios e avanços do CAR. Brasília: Serviço Florestal Brasileiro, 2023**. Disponível em: <https://www.florestal.gov.br>. Acesso em: 10 set. 2024

SOUZA, L. D. de; OLIVEIRA, R. L.; MOURA, J. R. de; et al. **Contribuições do Cadastro Ambiental Rural (CAR) para a análise de imóveis rurais no Cerrado goiano**. In: Anais do 20º Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 2023

LOPES, CRISTINA L; MARIA.E S.; JOANA C. Onde Estamos na Implementação do Código Florestal? Radiografia do CAR e do PRA nos Estados Brasileiros — Edição 2023. Rio de Janeiro: **Climate Policy Initiative**, 2023.

SCOLFORO, J. R., CAMPOS, S., B., L. A. C., MORAES F., L. O., SANTOS, P. A., ABREU, E. C. R., COUTO J., A. C. S., NASCIMENTO, R. C., OLIVEIRA, A. L., BARRO, D. A., LAUDARES, S. S., PEREIRA, C. M. (2014). **Noções de Geotecnologias. Curso de Capacitação para o Cadastro Ambiental Rural (CAPLAR)**. UFLA – Universidade Federal de Lavras.

OLIVEIRA, L. de; OLIVEIRA, F. H. **Verificação da integração entre o Cadastro Ambiental Rural (CAR) e o Cadastro Nacional de Imóveis Rurais (CNIR) sob a ótica do cadastro territorial multifinalitário.** *Geosul*, [S.L.], v. 34, n. 70, p. 339-357, 25 mar. 2019. Universidade Federal de Santa Catarina (UFSC). <http://dx.doi.org/10.5007/2177-5230.2019v34n70p339>

SOARES, V. P. et al. Mapeamento e licenciamento ambiental: desafios e perspectivas no Brasil. *Revista Brasileira de Geociências*, v. 49, n. 3, p. 275-289, 2019.

3.7. CONCLUSÕES GERAIS

A presente pesquisa demonstrou a importância da aplicação de tecnologias avançadas no mapeamento ambiental, evidenciando que o uso de Sensoriamento Remoto e aprendizado de máquina pode melhorar significativamente a precisão cartográfica e a gestão territorial. As bases existentes no SIMCAR/SEMA revelaram inconsistências nos dados cadastrais em uma análise comparativa com a base gerada pelo LabSensor, demonstrando que métodos convencionais podem subestimar áreas ambientalmente protegidas. Nesse contexto, a metodologia apresentada neste estudo com a modernização das bases cartográficas, por meio da utilização de imagens de alta resolução e algoritmos de classificação mais avançados, mostrou-se essencial para o monitoramento eficaz da ocupação do solo.

O avanço na integração de dados geoespaciais reforça a necessidade de estratégias mais robustas para a fiscalização ambiental e a regularização fundiária. O refinamento dos modelos de classificação e a incorporação de técnicas automatizadas podem reduzir erros e garantir maior precisão na delimitação de Áreas de Preservação Permanente (APPs), Veredas e Áreas Consolidadas (ACs). Além disso, a identificação de áreas de uso restritas e declividades superiores a 45° destacou lacunas nos sistemas declaratórios, apontando a urgência de aprimoramentos técnicos nas plataformas governamentais.

Os resultados obtidos neste estudo reforçam a importância da ciência geoespacial para o planejamento e a gestão sustentável dos territórios. A combinação de imagens de satélite de alta resolução e aprendizado de máquina não apenas amplia a capacidade de detecção e monitoramento de mudanças ambientais, mas também fornece subsídios

técnicos essenciais para a formulação de políticas públicas. Dessa forma, este trabalho contribui para o avanço das metodologias de mapeamento ambiental, fornecendo uma base mais confiável para a tomada de decisões estratégicas na conservação do Cerrado e na implementação do Código Florestal.

Para estudos futuros, recomenda-se o aperfeiçoamento dos modelos de classificação, integrando múltiplas fontes de dados, como sensores LiDAR e imagens SAR, que podem aumentar a precisão na identificação das classes ambientais, principalmente nas que possuem assinaturas espectrais semelhantes. Além disso, a ampliação das validações em campo poderá fortalecer ainda mais a confiabilidade das bases geradas. Assim, espera-se que os avanços tecnológicos e metodológicos contribuam para o aprimoramento contínuo da gestão ambiental e territorial, garantindo um equilíbrio entre o desenvolvimento econômico e a conservação dos recursos naturais.

PROP.26	681,35	7,59	37,24	513,44	38,39	0	0	0	84,69	0	0	681,35
PROP.27	5282,29	110,57	0	2393,26	445,64	49,85	0	0	2.282,97	0	0	5.282,29
PROP.28	1909,00	5,94	3,93	479,20	135,60	0,07	0	6,03	1.278,22	0	0	1.909,00
PROP.29	3198,12	47,60	0	809,87	248,83	2,13	0	0	2.089,70	0	0	3.198,12
PROP.30	3,13	0,24	0	2,89	0	0	0	0	0	0	0	3,13
PROP.31	24,40	0,72	0	13,53	10,15	0	0	0	0	0	0	24,40
PROP.32	20,92	0	0,33	8,48	12,06	0,06	0	0	0	0	0	20,92
PROP.33	25,05	0	0	2,93	0	0	0	0	22,13	0	0	25,05
PROP.34	954,13	3,40	0	476,56	59,75	7,88	0	0	406,54	0	0	954,13
PROP.35	993,93	3,14	262,13	550,27	125,79	19,15	0	0	33,46	0	0	993,93
PROP.36	1001,72	1,34	617,66	367,74	13,44		0	1,54	0	0	0	1.001,72
PROP.37	984,09	6,12	54,53	82,33	30,20	16,81	0	0	794,10	0	0	984,09
PROP.38	2564,70	14,57	59,56	1436,24	300,63	26,60	0	0	727,11	0	0	2.564,70
PROP.39	403,46	1,16	0	189,01	29,61	0	0	0	183,68	0	0	403,46
PROP.40	1,70	0	0		1,70	0	0	0	0	0	0	1,70
PROP.41	1412,73	1,90	0	42,41	11,05	0	0	0	1.357,36	0	0	1.412,73
PROP.42	1933,21	7,48	1,08	576,34	46,00	0	0	0	1.302,31	0	0	1.933,21
PROP.43	15,03	12,29	0	1,75	0,99	0	0	0	0	0	0	15,03
PROP.44	990,99	0	0	66,14	7,16	0	0	0	917,69	0	0	990,99
PROP.45	140	107,67	0,09	18,92	13,11	0,20	0	0	0	0	0	140
PROP.46	204,46	1,26	1,76	65,65	7,23	0	0	0	128,56	0	0	204,46
PROP.47	0,25	0,01	0	0,19	0,05	0	0	0	0	0	0	0,25
PROP.48	920,98	0,75	0	593,82	40,09	0	0	0	286,32	0	0	920,98
TOTAL	33957,42	3560,40	1188,04	13983,34	2368,53	151,22	0	30,76	12675,12	0	0	33957,42

Apêndice II – Planilha de cálculos LabSensorR

LABSENSOR													
48 PROP.	ATP	AUAS	AVN	APP	APPD	VER.	AU	AC	U.R	DEC.45	HID	M.AGUA	TOTAL
PROP.01	91,63	0,04	10,10	13,87	1,16	8,80	0	57,53	0,03	0	0,10	0	91,63
PROP.02	934,99	80,88	338,89	234,71	87,12	23,10	0	147,59	19,65	1,54	1,51	0	934,99
PROP.03	37,09	0,000	0,51	1,43	0,91	0,81	0	33,41	0	0	0,02	0	37,09
PROP.04	94,72	1,64	13,57	17,96	0,31	3,47	0	57,53	0	0	0,24	0	94,72
PROP.05	8,7	1,05	1,48	0	0	0	0	6,2	0	0	0	0	8,78
PROP.06	659,52	17,78	482,47	147,81	2,73	0	0	3	0	0	2,30	0	659,52
PROP.07	116,75	20,35	66,36	16,64	4,06	9,27	0	0	0	0	0,07	0	116,75
PROP.08	306,49	3,69	221,44	23,70	0	0	0	57,27	0	0	0,40	0	306,49
PROP.09	1315,07	14,09	76,01	60,33	49,81	41,79	0	1.070,26	2,09	0	0,69	0	1315,07
PROP.10	79,77	4,62	1,51	5,82	1,68	1,51	0	64,24	0,13	0	0,26	0	79,77
PROP.11	4038,32	789,30	2152,49	744,11	89,94	0	0	243,31	0	0	12,72	6,46	408,32
PROP.12	276,19	1,00	45,01	17,10	0,19	0,05	1,18	211,60	0,02	0	0,28	0	276,19
PROP.13	799,99	0,10	385,87	61,66	18,95	1,90	0	10,29	0,11	0	1,11	0	799,99
PROP.14	63,68	0,25	37,08	2,54	0,62	1,00	0	22,19	0	0	0,007	0	63,68
PROP.15	41,02	1,00	17,77	7,81	0,82	0	0	13,45	0,05	0	0,12	0	41,02
PROP.16	6,20	0	5,96	0,24	0	0	0	0	0	0	0	0	6,20
PROP.17	750,46	408,01	292,00	44,20	4,81	0	0	0,22	0	0,49	0,74	0	750,46
PROP.18	13,53	0	0,10	0	0	0	0	13,43	0	0	0	0	13,53
PROP.19	10,79	0,02	9,91	0,84	0	0	0	0	0	0	0,01	0	10,79
PROP.20	23,04	0,51	18,70	3,22	0	0,24	0	0	0,32	0	0,04	0	23,04

PROP.21	96,89	0,27	17,38	12,18	1,27	10,05	0	55,70	0	0	0,04	0	96,89
PROP.22	31,76	0	22,55	9,08	0	0	0	0	0	0	0,14	0	31,76
PROP.23	267,18	0,71	210,50	38,40	0,14	0	0	16,67	0,11	0	0,65	0	267,18
PROP.24	120,82	1,30	11,56	9,41	2,47	0	0	95,88	0	0	0,20	0	120,82
PROP.25	107,09	0,34	36,68	0	0	0	0	70,07	0	0	0,01	0	107,09
PROP.26	681,35	109,72	398,50	77,38	4,71	13,37	0	76,51	0	0	1,16	0,03	681,35
PROP.27	5282,29	123,10	2240,54	516,29	135,84	0	0	2255,15	0	0	11,37	0	5282,29
PROP.28	1909,00	20,50	455,81	109,66	5,15	39,89	0	1276,02	1,12	0	0,85	0	1909,00
PROP.29	3198,12	71,63	750,04	221,10	18,04	26,39	0	2055,30	46,90	6,03	2,06	0,62	3198,12
PROP.30	3,13	0,34	2,52	0,19	0	0	0	0,08	0	0	0	0	3,13
PROP.31	24,40	0	17,14	7,09	0	0	0	0	0	0	0,16	0	24,40
PROP.32	20,92	0,10	9,34	11,16	0	0	0	0	0,14	0	0,19	0	20,92
PROP.33	25,05	0	0,34	0,42	0,77	0,27	0	23,25	0	0	0	0	25,05
PROP.34	954,13	119,41	267,91	129,50	11,90	63,80	0	358,64	0,48	0	1,00	1,50	954,13
PROP.35	993,93	265,57	539,20	112,52	29,50	0	0	32,42	12,51	0	2,21	0	993,93
PROP.36	1001,72	9,36	357,57	22,07	0	3,38	0	609,19	0	0	0,16	0	1001,72
PROP.37	984,09	59,40	87,74	33,95	1,87	0,27	0	798,72	0	0	0,41	1,72	984,09
PROP.38	2564,70	251,17	1625,34	331,36	48,69	0	0	293,56	2,40	0	5,53	6,65	2564,70
PROP.39	403,46	2,09	283,03	65,56	2,65	0	0	49,06	0,02	0	1,05	0	403,46
PROP.40	1,70	0	1,70	0	0	0	0	0	0	0	0	0	1,70
PROP.41	1412,73	1,61	50,44	15,30	0,03	0,79	0	1336,10	8,29	0	0,16	0	1412,72
PROP.42	1933,21	10,85	573,55	34,75	0,76	1,18	0	1307,66	3,94	0	0,53	0	1933,21
PROP.43	15,03	0,19	0,77	0,20	1,27	2,70	0	9,87	0	0	0,03	0	15,03
PROP.44	990,99	7,88	25,23	22,98	14,07	37,77	0	882,43	0,36	0	0,27	0	990,99
PROP.45	140	2,61	24,57	12,88	1,55	0	0	97,93	0,23	0	0,24	0	140
PROP.46	204,46	38,88	30,98	9,18	0,88	0,84	0	122,75	0,79	0	0,12	0,04	204,46

PROP.47	0,25	0	0,17	0,08	0	0	0	0	0	0	0	0	0,25
PROP.48	920,98	2,87	351,00	325,54	16,73	31,17	12,18	180,09	0,73	0	0,67	0	920,98
TOTAL	33957,4	2764,22	12569,33	3532,22	561,20	323,74	13,36	14018,05	100,43	8,06	49,82	17,02	33957,42