



UNIVERSIDADE FEDERAL DO MARANHÃO – UFMA
CAMPUS DE CHAPADINHA/MA
CENTRO DE CIENCIAS DE CHAPADINHA-CCCh
CURSO DE ENGENHARIA AGRÍCOLA

PEDRO DO CARMO BARBOSA NETO

**ANÁLISE DA ACURÁCIA DE DADOS ORIUNDOS DE
MAPEAMENTOS AUTOMÁTICOS, ESTUDO DE CASO**

CHAPADINHA-MA

2025

PEDRO DO CARMO BARBOSA NETO

**ANÁLISE DA ACURÁCIA DE DADOS ORIUNDOS DE
MAPEAMENTOS AUTOMÁTICOS, ESTUDO DE CASO**

Trabalho de Conclusão de Curso apresentado a coordenação do curso de Engenharia Agrícola da Universidade Federal do Maranhão, como requisito para obtenção do título de Bacharel em Engenharia Agrícola.

Orientadora: Dr. Kamilla Andrade de Oliveira Emiliano

Coorientador: Marcus Willame Lopes Carvalho

CHAPADINHA-MA

2025

PEDRO DO CARMO BARBOSA NETO

Trabalho de Conclusão de Curso apresentado á coordenação de Engenharia Agrícola da Universidade Federal do Maranhão, como requisito para obtenção do título de Bacharel em Engenharia Agrícola.

Trabalho de Conclusão de Curso defendido e aprovado, em 15 de Feveiro de 2025, pela Comissão Examinadora constituída pelos professores:

Prof. Dr. Kamilla Andrade de Oliveira Emiliano
Orientador (a)

Prof. Dr. Eduardo Silva dos Santos
Examinador

Prof. Dr. Carlos Augusto Alves Cardoso Silva
Examinador

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Diretoria Integrada de Bibliotecas/UFMA

do Carmo Barbosa Neto, Pedro.

Análise da acurácia de dados oriundos de mapeamentos automáticos, estudo de caso / Pedro do Carmo Barbosa Neto.
- 2025.

44 p.

Coorientador(a) 1: Marcus Willame Lopes Carvalho.

Orientador(a): Kamilla Andrade de Oliveira Emiliano.

Curso de Engenharia Agrícola, Universidade Federal do Maranhão, Chapadinha, Maranhão, 2025.

1. Mapbiomas. 2. Índice Nbr. 3. Cicatrizes de Fogo.
I. Andrade de Oliveira Emiliano, Kamilla. II. Willame Lopes Carvalho, Marcus. III. Título.

DEDICATÓRIA

À minha mãe, Ivanilza Maria da Costa Nascimento Barbosa, por ser um admirável exemplo de vida e a quem devo tudo.

Ao meu pai, Pedro do Carmo Barbosa Junior, por todo o suporte na realização dos meus sonhos.

À minha irmã, Rafaella de Nazareth Nascimento Barbosa, pelo amor e carinho incondicionais.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por me permitir estar aqui e possibilitar viver este momento com todos que ajudaram a estar aqui.

Agradeço a meus pais, Ivanilza e Pedro Barbosa, e a meus avós, Ivan e Nilza Nascimento, por todo o apoio, principalmente financeiro, que foi fundamental para minha permanência no curso e na cidade. Aos meus tios Evandro e Ivana Sobreiro também, minha gratidão.

Agradeço imensamente à professora doutora Kamilla Andrade, por toda a paciência durante esses meses e pelo desenvolvimento que tivemos em busca de eu me tornar um grande profissional.

Aos professores Dr. Eduardo Silva, Dr. Marcus Willame e Dr. Khalil de Menezes, por terem me proporcionado as primeiras vivências em campo e possibilitar uma visão mais ampla e profunda da área, meu muito obrigado.

Agradeço também à professora Dra. Raissa Silva, por ter sido a primeira a me acolher em um grupo de pesquisa dentro do campus, proporcionando contatos importantes e valiosos.

Aos professores Dr. Nítalo André e Ismênia Ribeiro, sou grato por me proporcionarem a primeira experiência como pesquisador da FAPEMA.

Agradeço às famílias Matos, Lisboa e Araújo, por terem cuidado de mim no Maranhão em diversas situações, permitindo que eu chegasse até aqui.

Aos meus amigos do grupo de pesquisa, Gerson Freitas, Ronaldy Sousa e Gabriele Lobo, por todos os momentos de interação e pela forte amizade que desenvolvemos durante as atividades dentro e fora do campus.

Aos meus amigos Andreza Maciel e André Mamedio, por me ajudarem com uma disciplina que muitas vezes achei que não conseguiria superar. Graças a vocês, estou aqui hoje.

Às minhas amigas do grupo de pesquisa FRUTIMA, Maria, Roberta e Karelly, por todo o desenvolvimento que pude ter no grupo e pelo apoio dentro do campus, minha imensa gratidão.

Agradeço também à minha dupla nas disciplinas mais difíceis, Samara Sousa e Jakelynnne Gomes, pelos momentos compartilhados dentro e fora do campus nesses cinco anos.

Às minhas amigas da Casa 11, Ruth, Débora e Larissa, que muitas vezes me acolheram durante vários períodos na UFMA. Agradeço muito pela nossa amizade.

Às minhas amigas Maura e Francisca Larissa, que foram cruciais nas minhas atividades e desenvolvimento na parte escrita, me salvando muitas vezes. Agradeço demais.

Às minhas amigas do mutirão, Layara Sousa, Andressa Kethlen e Maria Pires, por estarem presentes em todos os momentos de dificuldades e novas experiências. Obrigado por tudo.

Agradeço à Emanuele, Samira, Sheyla, Daniela e muitos outros amigos que me ajudaram e apoiaram dentro da Agropec. Agradeço muito.

À minha dupla de irrigação, Felipe Sales e Joice Lopes, que me ajudaram muito a passar em uma disciplina difícil, enfrentando madrugadas de estudo.

Ao meu grupo de Libras, Ana, Iara, Jayrla e Raissa, por uma ótima experiência com inclusão, sendo uma disciplina extremamente diferente para mim, que levarei sempre comigo.

Por fim, mas não menos importante, algumas pessoas que gostaria de citar em particular:

À minha amiga e mestranda Alayne Sousa, com quem vivi muitas boas situações em Chapadinha e no grupo de pesquisa, além do estágio na Secretaria do Meio Ambiente.

Agradeço imensamente à Lourdiana Costa, pois graças a você pude concluir meu estágio e ter muitas experiências como profissional.

À Erica Lisboa, minha companheira, apoiadora e incentivadora nesta etapa final do meu curso, mesmo com todas as dificuldades, minha eterna gratidão.

À Revena Vieira, por estar presente em momentos importantes, levando-me a ter uma nova experiência nos cultos de Chapadinha, algo que mexeu comigo e ajudou minha religiosidade e visão de mundo.

Ao Lucas Costa e Robson Lopes, que fizeram parte do meu primeiro grupo em uma disciplina que nos deu medo no primeiro período inteiro.

Aos meus amigos e irmãos, Gleicy Matos e Daniel Lobo, que foram cruciais para que eu estivesse aqui hoje. Se estou me formando, é graças a vocês.

O mérito é nosso, gratidão sempre com vocês.

"Confie no Senhor de todo o seu coração e não se apoie em seu próprio entendimento; reconheça-o em todos os seus caminhos, e ele endireitará as suas veredas."

PROVÉRBIOS 3:5-6

RESUMO

Este trabalho de conclusão de curso avalia a precisão dos mapeamentos automáticos de 2021 e 2022 em comparação com imagens de referência de 2023, utilizando ferramentas de geoprocessamento como QGIS e PEC Avalia, e programas nacionais como INPE, Prodes e MapBiomias. O objetivo é determinar a acurácia dos mapeamentos automáticos e identificar suas limitações para aplicações de alta precisão. A metodologia incluiu a coleta e processamento de imagens de satélite, análise de pontos de dados e comparação de resultados. Os resultados revelam que, embora o mapeamento de 2022 tenha mostrado uma cobertura mais ampla, ainda existem discrepâncias significativas que comprometem a confiabilidade dos dados para aplicações detalhadas. Recomenda-se a implementação de controles de qualidade mais rigorosos e a utilização de sensores de maior resolução para melhorar a precisão dos mapeamentos automáticos.

Palavras-chave: mapeamento automático; precisão espacial; geoprocessamento; MapBiomias; PEC Avalia.

ABSTRACT

This thesis evaluates the accuracy of automatic mappings from 2021 and 2022 in comparison with reference images from 2023, using geoprocessing tools such as QGIS and PEC Avalia, as well as national programs like INPE, Prodes, and MapBiomas. The aim is to determine the accuracy of automatic mappings and identify their limitations for high-precision applications. The methodology included the collection and processing of satellite images, data point analysis, and result comparison. The findings reveal that, while the 2022 mapping showed broader coverage, significant discrepancies still compromise the reliability of the data for detailed applications. It is recommended to implement more rigorous quality controls and utilize higher-resolution sensors to enhance the accuracy of automatic mappings.

Keywords: automatic mapping; spatial accuracy; geoprocessing; MapBiomas; PEC Avalia.

LISTAS DE FIGURAS

Figura 1. Mapa de Localização da Terra Indígena Governador, no município de Amarante do Maranhão Brasil.....	27
Figura 2: Mapa de localização da área de estudo.....	29
Figura 3: mapa de Área terra Indígena Governador – MA.....	30
Figura4: Nuvem de pontos área Cerrado com mesclagem da ferramenta PEC avalia.....	31
Figura 5: Nuvem de pontos área Formação Savânica com mesclagem da ferramenta PEC avalia.....	37
Figura 6 : Nuvem de pontos área Degradada com mesclagem da ferramenta PEC avalia.....	38
Figura 7: Nuvem de pontos área Floresta com mesclagem da ferramenta PEC avalia.....	38
Figura 8: Nuvem de Pontos Floresta (Referência, 2022 e 2021)	39

LISTA DE TABELAS

Tabela 1: Resumo das Camadas de Teste 2021.....	33
Tabela 2: Resumo das Camadas de Teste 2022.....	33
Tabela 3: Estatísticas das Camadas 2021.....	34
Tabela 4: Estatísticas das Camadas 2022.....	35
Tabela 5: Tolerâncias PEC-PCD e Classificação ET-CQDG 2021.....	36
Tabela 6: Tolerâncias PEC-PCD e Classificação ET-CQDG 2022.....	36

LISTA DE SIGLAS

SIGS – Sistema de Informações Geográficas SR – Sensoriamento Remoto

TI – Terra Indígena

INPE – Instituto Nacional de Pesquisas Espaciais

Prodes - Projeto de Monitoramento do Desmatamento na Amazônia Legal por Satélite.

QGIS - *Quantum Geographic Information System*

SUMÁRIO

1. INTRODUÇÃO	12
2. OBJETIVOS	13
2.1. Objetivo Geral	13
2.2. Objetivos Específicos	13
3. REVISÃO DA LITERATURA	14
3.1. Mapeamentos Automáticos e Manuais: Conceitos e Técnicas	14
3.2. Ferramentas de Geoprocessamento: QGIS e PEC Avalia	16
3.3. Programas Nacionais de Mapeamento	17
3.3.1. INPE e Prodes	17
3.3.2. MapBiomias	18
3.4. Comparação e Abordagens complementares	19
3.5. Acurácia em Mapeamentos Automáticos	20
3.5.1. Definição de Acurácia	20
3.5.2. Níveis de Acurácia e Erro	20
3.6. Classificação de Imagens de Satélite	22
3.7. Impactos Ambientais e Degradação da Terra Indígena Governador	24
4. Metodologia	27
4.1. Caracterização da Área de Estudo	27
4.2. Base de Dados	28
4.2.1. Processamento das Imagens	28
4.3. Reclassificação e Análise das Imagens de Satélite	30
4.4. Comparação e Análise	32
4.5. Análise dos Dados de 2021 e 2022	32
4.5.1. Coleta e Quantidade de Pontos Utilizados	32
4.5.2. Estatísticas de Planimétrica (dx, dy)	34
4.5.3. Tolerâncias	35
4.5.4. Discrepâncias e Variações nos Valores Máximo e Mínimo	36
5. RESULTADOS E DISCURSÕES	36
5.1. Nuvem de Pontos e Ferramenta PEC Avalia	36
5.2. Relatórios de Acurácia	39
6. CONCLUSÃO	40
7. REFERENCIAS	44

1. INTRODUÇÃO

No Brasil, a regulamentação da qualidade dos produtos cartográficos é estabelecida pelo Decreto-Lei nº 89.817, de 1984 (Santos, 2010), que define padrões e procedimentos para avaliação dos mapas como produtos finais. Com o avanço das tecnologias de mapeamento automático, que utiliza algoritmos de processamento de linguagem natural, aprendizado de máquina e visão computacional, entre outras técnicas avançadas, a análise de acurácia tornou-se essencial para garantir que os resultados gerados por esses sistemas atendam aos critérios de precisão e confiabilidade exigidos.

Nos últimos anos, as Terras Indígenas no Brasil têm enfrentado uma crescente devastação ambiental, mudanças no uso da terra e uma alta incidência de focos de calor decorrentes de incêndios florestais, especialmente nas regiões Norte e Centro-Oeste. Esses incêndios têm causado a destruição de aldeias, plantações e, em muitos casos, resultam na hospitalização de povos nativos devido a problemas respiratórios. Nesse contexto, mapear e avaliar a qualidade dos mapeamentos das áreas afetadas por incêndios pode ajudar a compreender os fatores espaciais que impactam a qualidade de vida dessas populações, além de orientar estratégias de desenvolvimento sustentável em seus territórios (Paiva, 2019).

A queima de vegetação é um fenômeno global que interfere na distribuição dos principais ciclos biogeoquímicos e no sistema climático (Bowman et al., 2009). As mudanças no uso e na cobertura do solo têm causado inúmeros impactos ambientais, como a perda e fragmentação de habitats naturais, aumentando o risco de extinção de espécies e alterando o ciclo hidrológico, os processos biogeoquímicos e o funcionamento dos ecossistemas (Strassburg et al., 2017).

Os eventos de fogo, comuns no Cerrado, desempenham um papel determinante na vegetação e contribuem para a evolução da flora local (Simon et al., 2009). No entanto, as alterações recentes nos regimes de incêndio têm elevado a frequência e intensidade dessas ocorrências, impactando diretamente a resiliência dos ecossistemas da região.

O mapeamento espaço-temporal das áreas afetadas por incêndios florestais oferece suporte crucial para entender a frequência e a distribuição desses eventos e seus impactos sobre a vegetação. Além disso, fornece dados valiosos para formuladores de políticas públicas e brigadas de incêndio, facilitando a implementação de ações de prevenção e controle de incêndios de maneira mais eficiente e organizada (Piromal et al., 2008).

Com o objetivo de determinar a acurácia dos dados automatizados sobre o uso do solo e as cicatrizes de fogo disponibilizados pelo projeto MapBiomias para o ano de 2022, esta pesquisa propõe a utilização de ferramentas de Sistemas de Informações Geográficas (SIG). Com isso, busca-se fornecer informações relevantes para a sociedade e apoiar a gestão ambiental e espacial de maneira mais eficaz.

2. OBJETIVOS

2.1. Objetivo Geral

O objetivo principal deste estudo é avaliar a precisão dos dados gerados por mapeamentos automáticos de incêndios florestais na Terra Indígena Governador, utilizando o software QGIS e o complemento PEC Avalia.

2.2. Objetivos Específicos

- **Comparar mapeamentos automáticos e manuais:** Examinar a precisão e confiabilidade dos mapeamentos automáticos em relação aos manuais, identificando as divergências e coincidências entre os dois métodos.
- **Empregar ferramentas avançadas de geoprocessamento:** Utilizar o software QGIS e o complemento PEC Avalia para processar e classificar imagens de satélite, visando uma análise detalhada das classes de cobertura do solo.
- **Classificar imagens em categorias específicas:** Reclassificar as imagens em quatro categorias principais — Cerrado, floresta degradada e vegetação savânica — com base na tabela de classes fornecida pelo MapBiomias.
- **Analisar dados das coleções do MapBiomias:** Integrar e examinar as imagens das coleções 7 e 8 do MapBiomias, referentes aos anos de 2021 e 2022, com foco na Terra Indígena Governador.
- **Gerar e interpretar relatórios de acurácia:** Aplicar o complemento PEC Avalia para criar relatórios de acurácia de cada classe de cobertura do solo e interpretar esses relatórios para entender a precisão dos mapeamentos automáticos.
- **Contribuir para o aperfeiçoamento das técnicas de mapeamento:** Oferecer recomendações que possam aprimorar os métodos de mapeamento, contribuindo para uma gestão ambiental mais eficiente em áreas degradadas.
- **Validar dados geoespaciais:** Ressaltar a importância da validação de dados geoespaciais, enfatizando a relevância de programas nacionais como o INPE, Prodes e MapBiomias na avaliação e monitoramento de áreas de interesse ambiental.

3. REVISÃO DE LITERATURA

3.1. Mapeamentos Automáticos e Manuais: Conceitos e Técnicas

Os mapeamentos automáticos e manuais representam abordagens distintas para a classificação e análise de dados geoespaciais, cada qual com suas características e aplicações específicas. O mapeamento manual envolve a interpretação de imagens de satélite ou fotografias aéreas por especialistas, que utilizam seu conhecimento para identificar diferentes tipos de cobertura do solo. Este método é frequentemente visto como mais preciso, pois os profissionais conseguem detectar detalhes que os algoritmos automáticos podem não captar. No entanto, sua principal desvantagem reside no fato de ser extremamente demorado e oneroso, especialmente quando aplicado a áreas extensas ou de alta complexidade (Souza, 2020).

Por outro lado, o mapeamento automático faz uso de algoritmos e técnicas de aprendizado de máquina para processar e classificar imagens geoespaciais de forma automatizada. A Inteligência Artificial, especificamente o aprendizado de máquina, permite que os algoritmos analisem e classifiquem os dados de maneira independente, aprendendo e aprimorando suas previsões à medida que são alimentados com mais informações (Fávero *et al.*, 2024). Esse método se destaca pela capacidade de lidar com grandes volumes de dados em um tempo relativamente curto e com custos reduzidos, tornando-o uma solução atrativa para projetos de grande escala.

Entretanto, a precisão do mapeamento automático pode ser comprometida por fatores como a qualidade das imagens, a complexidade do terreno e a eficácia dos algoritmos empregados. Em áreas com vegetação densa ou relevo acidentado, por exemplo, os algoritmos podem ter dificuldades em distinguir diferentes tipos de cobertura do solo. Além disso, a eficácia dos algoritmos depende fortemente dos dados de treinamento, e eles podem não generalizar bem para áreas diferentes das usadas no treinamento, resultando em classificações incorretas. O aumento das interações entre variáveis e a busca por maior eficiência nas práticas agrícolas têm tornado o mapeamento automático cada vez mais complexo (Silva, 2021).

As técnicas de classificação em mapeamentos automáticos variam, mas incluem métodos como a classificação supervisionada, não supervisionada e aprendizado profundo. Na classificação supervisionada, o algoritmo é treinado com dados de referência, permitindo que aprenda a identificar diferentes classes de cobertura do solo. Já na classificação não

supervisionada, os dados são agrupados com base em suas características intrínsecas, sem o uso de dados de referência pré-existentes. O aprendizado profundo, através de redes neurais convolucionais, tem se destacado pela capacidade de lidar com grandes volumes de dados e na identificação dos padrões complexos (Brito & Moraes, 2016).

3.2. Ferramentas de Geoprocessamento: QGIS e PEC Avalia

O QGIS é um software de geoprocessamento de código aberto amplamente utilizado para manipulação, análise e visualização de dados geoespaciais, como shapefiles, geojson e kml. Sua interface flexível e o suporte a diversos formatos permitem a criação de mapas interativos, análises espaciais complexas e a integração de plugins que ampliam suas funcionalidades (Ferreira & Silva, 2018).

Além de integrar dados de diferentes fontes, como serviços web e bancos de dados espaciais, o QGIS oferece operações como buffer, intersecção e análise de raster, sendo uma ferramenta versátil para estudos geoespaciais (Oliveira Junior et al., 2023).

O plugin PEC Avalia auxilia na análise de acurácia de classificações geoespaciais, comparando dados de mapeamentos automáticos com referências confiáveis. Ele gera relatórios detalhados, incluindo matrizes de confusão e coeficientes de Kappa, sendo essencial para validar classificações de uso e cobertura da terra (Costa, 2021).

Um estudo de Espindola et al. (2023) demonstrou que a combinação de diferentes fontes de dados melhora a qualidade do georreferenciamento de imagens orbitais, reduzindo custos e aumentando a precisão. Esses exemplos destacam a importância do QGIS e do PEC Avalia na gestão ambiental, planejamento urbano e conservação, garantindo análises mais confiáveis para tomadas de decisão baseadas em dados geoespaciais.

3.3. Programas Nacionais de Mapeamento

3.3.1. INPE e PRODES

O Instituto Nacional de Pesquisas Espaciais (INPE) coordena o Projeto de Monitoramento do Desmatamento na Amazônia Legal por Satélite (Prodes), uma das mais importantes e reconhecidas iniciativas globais no monitoramento ambiental. Desde sua criação, em 1988, o Prodes tem como objetivo mapear e quantificar as áreas desmatadas na Amazônia

Legal brasileira. Para isso, utiliza imagens de satélite de alta resolução, principalmente do satélite Landsat, realizando análises anuais das mudanças na cobertura florestal. A metodologia consiste na comparação de imagens de anos consecutivos, detectando novas áreas de desmatamento, que são então classificadas e quantificadas. Os dados gerados pelo Prodes desempenham um papel crucial na formulação de políticas públicas, fiscalização ambiental e implementação de medidas de conservação. Sua precisão e confiabilidade fizeram do Prodes uma referência internacional no monitoramento de desmatamento (INPE, 2024).

Ao longo do tempo, o projeto evoluiu tecnicamente, incorporando novas tecnologias de processamento de imagens, o que aumentou tanto a precisão quanto a frequência das análises. Anualmente, o Prodes divulga dados detalhados sobre o desmatamento, que são amplamente utilizados por órgãos governamentais e organizações não governamentais para planejar e executar ações de conservação e fiscalização ambiental (Martins, 2019). A abordagem metodológica envolve a comparação de imagens de satélite para detectar mudanças na cobertura florestal, e as áreas desmatadas são quantificadas e classificadas. Os dados resultantes são fundamentais para o governo brasileiro no estabelecimento de políticas públicas relacionadas ao meio ambiente (Gomes et al., 2024).

3.3.2. MapBiomias

Iniciado em 2015, o Projeto MapBiomias tem como objetivo monitorar o uso e as mudanças no uso da terra em todos os biomas brasileiros, utilizando séries temporais de imagens de satélite desde 1985 (Moura, 2024). Diferentemente do Prodes, que foca exclusivamente no desmatamento da Amazônia, o MapBiomias abrange todo o território nacional, monitorando diversos tipos de cobertura e uso do solo, como florestas, áreas agrícolas, corpos d'água, áreas urbanas e pastagens.

A metodologia do MapBiomias combina imagens de satélite com técnicas de aprendizado de máquina para classificar diferentes classes de uso do solo. Os dados gerados são amplamente utilizados para pesquisa científica, planejamento ambiental, monitoramento de políticas públicas e educação (MapBiomias, 2024). O projeto conta com a colaboração de diversas instituições de pesquisa e ONGs, que contribuem com dados e conhecimento especializado, aprimorando a acurácia e abrangência dos mapas gerados (Rodrigues, 2020).

O MapBiomias adota uma abordagem baseada em aprendizado de máquina para a classificação das imagens, permitindo a análise de grandes volumes de dados e a identificação

de padrões complexos de uso do solo. A cada ano, novas coleções de dados são incorporadas, possibilitando uma análise temporal detalhada das mudanças na cobertura e uso do solo no Brasil. Desde 1985, o MapBiomas produz mapas anuais com resolução de 30 metros, abrangendo cobertura e uso da terra, monitoramento de corpos d'água, cicatrizes de fogo e relatórios sobre desmatamento (Lueders et al., 2023). Além disso, o projeto integra dados de diversas fontes, como imagens de satélite de diferentes resoluções e dados de campo, para aumentar a precisão das classificações.

3.4. Acurácia em Mapeamentos Automáticos

3.4.1. Definição de Acurácia

A acurácia em mapeamentos automáticos é um conceito crucial que se refere à precisão com que os dados geoespaciais representam a realidade. Em termos simples, acurácia mede a proximidade entre as medições ou classificações realizadas por um sistema de mapeamento e os valores reais ou aceitos como verdadeiros. Assim, quanto maior a acurácia, mais fielmente o mapa refletirá a realidade no terreno, tornando-se uma ferramenta confiável para diversas aplicações, desde a gestão ambiental até o planejamento urbano (QGIS Development Team, 2024). Garantir uma alta acurácia é essencial, pois os dados são frequentemente utilizados para decisões importantes em áreas como planejamento urbano, conservação ambiental, gestão de recursos naturais e resposta a desastres (Silva & Oliveira, 2017).

3.4.2. Níveis de Acurácia e Erro

A acurácia pode ser avaliada em diferentes níveis, cada um oferecendo uma perspectiva distinta sobre a precisão dos mapeamentos. Esses níveis são fundamentais para uma análise detalhada e compreensiva da qualidade dos dados gerados:

1. **Acurácia Global:** Representa a proporção total de classificações corretas em relação ao número total de classificações realizadas. Segundo Santos (2024), a Acurácia Global é calculada dividindo o total de pixels corretamente classificados pelo número total de pixels na Matriz de Confusão. Embora forneça uma visão geral do desempenho do sistema de mapeamento, a acurácia global pode não revelar problemas específicos em certas classes de cobertura do solo.

2. **Acurácia do Usuário:** Refere-se à probabilidade de que uma área classificada como pertencente a uma determinada classe corresponda efetivamente a essa classe na realidade. Em outras palavras, indica a confiabilidade das classificações do ponto de vista do

usuário final que utiliza os dados para tomadas de decisão. De acordo com De Conto et al. (2024), a acurácia do usuário é calculada dividindo o número total de amostras corretas em uma classe pelo número total de amostras classificadas nessa classe, refletindo o erro de inclusão.

3. **Acurácia do Produtor:** Representa a probabilidade de que todas as áreas de uma determinada classe, na realidade, sejam corretamente identificadas pelo classificador. Este nível de acurácia é crucial para avaliar a capacidade do sistema de mapeamento de detectar todas as ocorrências de uma classe específica, evitando subestimações. Sartorio et al. (2023, p. 13) afirmam que “a acurácia do produtor representa a qualidade do mapeamento de cada classe para quem elaborou o mapa, podendo ser uma informação útil pensando em melhorias.”

Erros em programas de mapeamento, como os utilizados pelo INPE, Prodes e MapBiomas, podem impactar significativamente a acurácia dos dados. Esses erros são geralmente classificados em dois tipos principais:

- **Erro de Omissão:** Ocorre quando áreas que deveriam ter sido classificadas como uma determinada classe não são identificadas corretamente. Jensen (1996, apud De Souza e Rodrigues, 2020) descreve a omissão como a situação em que um pixel pertencente a uma classe específica é erroneamente classificado como pertencente a outra classe. Isso leva à subestimação da presença dessa classe no mapa, o que pode resultar em decisões inadequadas de gestão e conservação.

- **Erro de Comissão:** Acontece quando áreas são classificadas como pertencentes a uma determinada classe, mas na realidade pertencem a outra. Esse tipo de erro pode levar a uma superestimação da presença de uma classe, causando alocação inadequada de recursos e esforços de gestão. Vieira et al. (2009) explicam que erros de comissão ocorrem quando áreas são incorretamente incluídas em uma classe, e erros de omissão quando áreas que deveriam estar na classe são excluídas. A acurácia do usuário e do produtor são diretamente afetadas por esses erros.

Minimizar esses erros é crucial, pois erros de omissão e comissão não apenas reduzem a acurácia dos mapeamentos, mas também podem ter consequências práticas significativas. Decisões baseadas em dados geoespaciais imprecisos podem levar a falhas na implementação de políticas públicas, erros na gestão de recursos e respostas inadequadas a emergências ambientais. Portanto, a validação rigorosa e a melhoria contínua dos métodos de mapeamento são essenciais para garantir que os dados sejam confiáveis e úteis. De acordo com De Paula et al. (n.d.), a precisão e acurácia na extração de informações estão diretamente ligadas às

tecnologias empregadas, e dados com resoluções mais elevadas proporcionam melhores resultados.

Para garantir alta acurácia, é comum usar validação cruzada, comparando dados mapeados com referências confiáveis. Santos (2021) aplica essa técnica para dividir os dados em subconjuntos, melhorando a avaliação dos modelos. Isso permite corrigir erros e aumentar a precisão dos mapeamentos, que tendem a evoluir com os avanços tecnológicos

3.5. Classificação de Imagens de Satélite

A classificação de imagens de satélite é um processo complexo que envolve a aplicação de diversas técnicas e algoritmos para identificar e categorizar diferentes tipos de cobertura e uso do solo. A escolha entre classificação supervisionada e não supervisionada depende das informações disponíveis e dos objetivos do estudo. A reclassificação utilizando tabelas de classes, como as do MapBiomas, é uma etapa crucial para refinar os dados e assegurar sua precisão e utilidade. Com o avanço das tecnologias de aprendizado de máquina e processamento de imagens, as técnicas de classificação continuam a evoluir, oferecendo novas possibilidades para a análise de dados geoespaciais.

A classificação de imagens de satélite é essencial para analisar dados geoespaciais, identificando diferentes coberturas e usos do solo. Existem duas principais abordagens: supervisionada e não supervisionada.

Na classificação supervisionada, o analista seleciona amostras representativas da área, conhecidas como assinaturas espectrais, para treinar um algoritmo, como Máxima Verossimilhança, KNN ou SVM. Esse método é preciso, mas exige conhecimento prévio da área.

Já a classificação não supervisionada agrupa pixels automaticamente com base em suas características espectrais, utilizando algoritmos como K-Means e PCA. Embora útil quando há pouca informação prévia, sua precisão tende a ser menor, exigindo interpretação posterior pelo analista.

Após a classificação inicial, a reclassificação pode ser necessária para alinhar as categorias com padrões como os do MapBiomas, refinando os resultados.

Com os avanços tecnológicos, métodos mais sofisticados, como redes neurais e aprendizado profundo, estão sendo cada vez mais utilizados para melhorar a precisão das classificações. Além dos algoritmos, a qualidade das imagens e a validação com dados de campo são fundamentais para garantir resultados confiáveis.

3.6. Degradação da Terra Indígena Governador

A Terra Indígena Governador, no Maranhão, enfrenta grave degradação ambiental, impulsionada pelo desmatamento ilegal, exploração madeireira e expansão agropecuária. O desmatamento aumentou de 3.975 hectares (2000) para 5.582 hectares (2023), agravado pela falta de fiscalização e invasões ilegais.

Incêndios florestais são uma das principais causas da degradação, muitas vezes provocados para limpeza de terras. Isso leva à perda de biodiversidade, degradação do solo e impactos no ciclo hidrológico, tornando o ecossistema mais vulnerável.

Para mitigar esses danos, medidas como restauração ecológica e sistemas agroflorestais vêm sendo aplicadas, aliadas ao monitoramento ambiental via sensoriamento remoto. Além disso, o fortalecimento de políticas públicas, fiscalização eficaz e incentivos à conservação são essenciais para a recuperação sustentável da área.

4. Metodologia

4.1. Caracterização da Área de Estudo

O estudo foi conduzido nas Terras Indígenas de Governador, localizadas no município de Amarante, no estado do Maranhão, com coordenadas geográficas de 05°47'59" S e 45°58'10" W, situando-se na Mesorregião Oeste Maranhense, Microrregião de Imperatriz (Figura 1). De acordo com a classificação climática de Köppen, a região possui um clima tropical (AW') subúmido, caracterizado por dois períodos bem distintos: um período chuvoso, que vai de dezembro a maio, com precipitação mensal média superior a 191,9 mm, e um período seco, que abrange os meses de junho a novembro. Durante a estação seca, a precipitação varia entre 6,9 e 133,2 mm, enquanto no período chuvoso, os valores vão de 85,9 a 273,4 mm, resultando em uma média anual aproximada de 1.426 mm (Correa Filho, 2011).

A Terra Indígena Governador foi oficialmente homologada pelo Decreto nº 88.001, datado de 1982, e possui uma área total de 42.000 hectares. Os habitantes indígenas da região pertencem às etnias Gavião Pykopjê, Guajajara e Tabajara (FUNAI), e falam a língua Timbira, que pertence à família Jê (Dias et al., 2017).

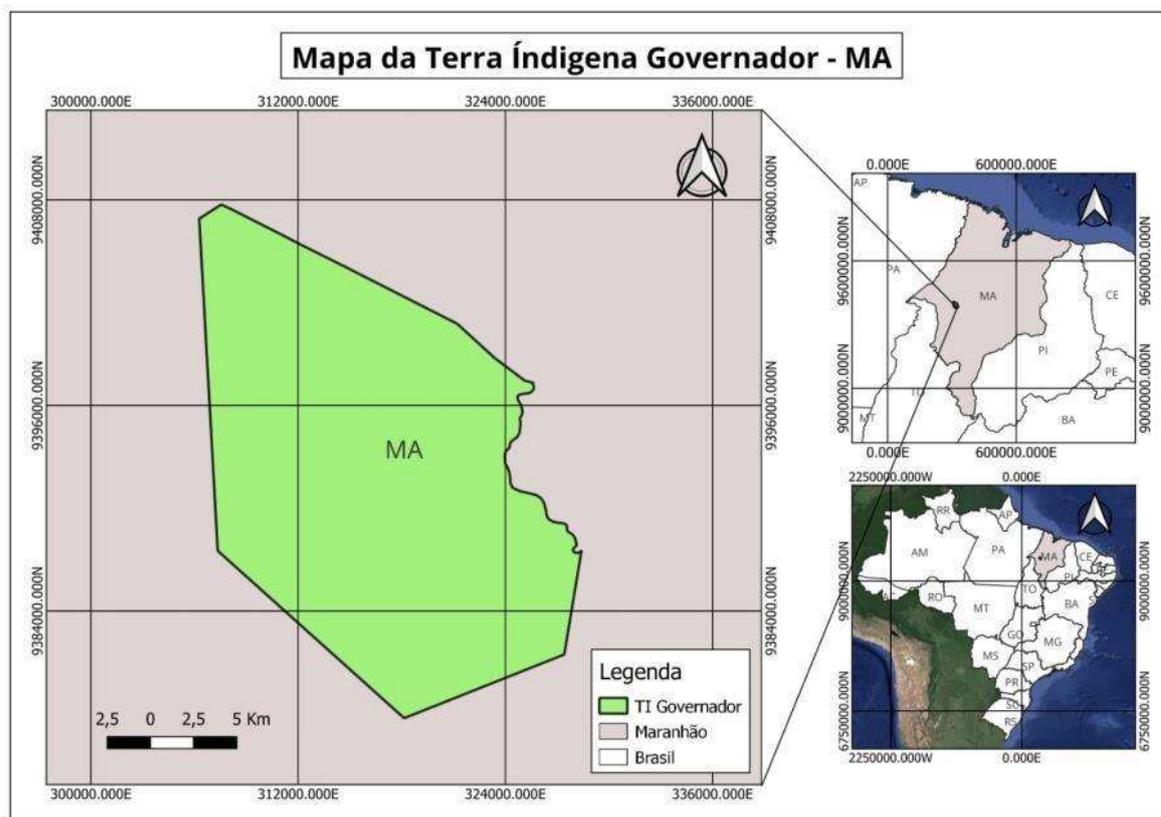


Figura 1: Área delimitada da terra indígena Governador

Fonte: Autor

De acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE), o município possui uma população estimada em 41.729 habitantes (IBGE, 2021). A principal fonte de renda dos indígenas da Terra Indígena Governador provém de benefícios do governo federal, como Bolsa Família, aposentadoria e auxílio-doença. Além disso, esses povos mantêm práticas tradicionais de agricultura, comuns na região do Maranhão. Essa prática agrícola tradicional envolve a derrubada da vegetação, poda, queima, plantio e colheita, sendo realizada manualmente (Santos Filho, 2022).

4.2. Base de Dados

4.2.1. Processamento das Imagens

Os dados utilizados neste estudo foram adquiridos por meio do Google Earth Engine, uma plataforma que proporciona acesso a uma ampla gama de dados de satélite e processamento geoespacial em larga escala. Utilizando esta ferramenta, foram acessadas imagens de satélite processadas que possibilitaram a criação de um mapa de composição RGB (Figura 2). Esse mapa combina diferentes bandas espectrais para gerar uma representação visual das características da superfície terrestre. Além disso, foram incorporados dados do Instituto Brasileiro de Geografia e Estatística (IBGE), que incluíam informações geográficas e cartográficas detalhadas, fundamentais para delimitar com precisão a área de estudo. Esses dados do IBGE foram cruciais para garantir que a área analisada correspondia exatamente ao território de interesse. Com base nessas informações, o software QGIS® 3.28.11 Firenze foi utilizado para aplicar técnicas avançadas de análise espacial e criar representações cartográficas detalhadas, facilitando a visualização e interpretação das áreas afetadas (Figura 3).

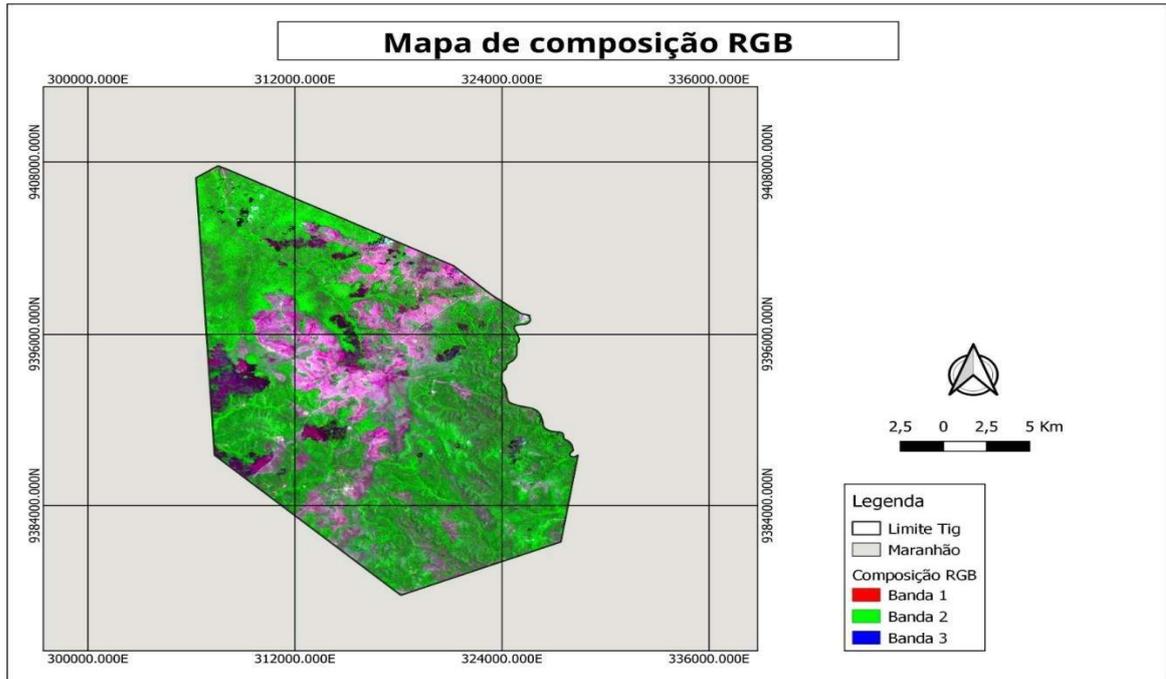


Figura 2: Mapa de composição RGB elaborado com GEE
Fonte: Autor (2024)

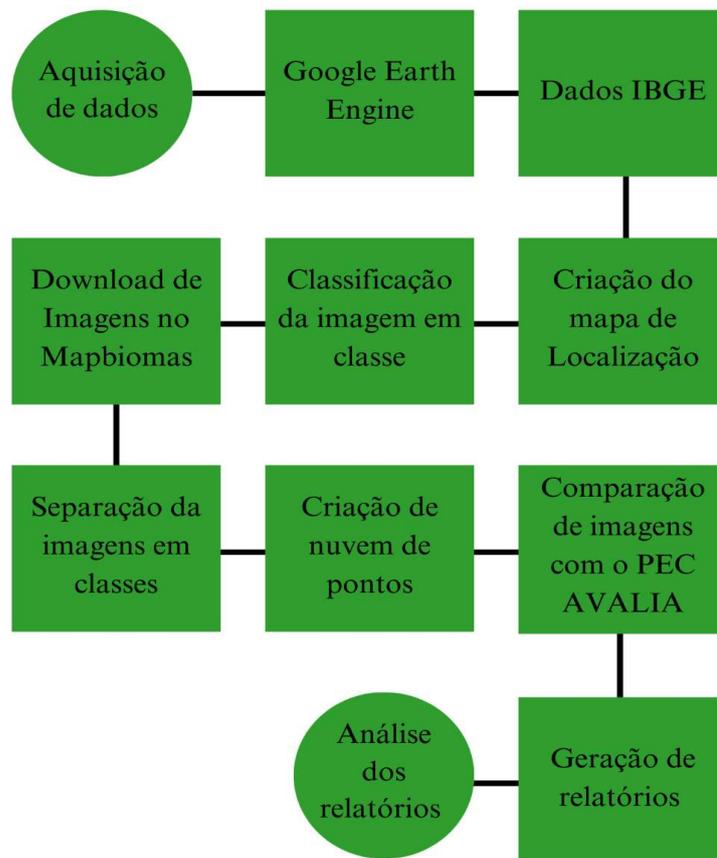


Figura 3. Fluxograma de etapas dos processos de uso da ferramenta PEC avalia
Fonte: Autor (2024)

4.3. Reclassificação e Análise das Imagens de Satélite

Após a classificação inicial, as imagens foram reclassificadas utilizando a tabela de classes elaborada para identificação dos dados fornecidos pelo MapBiomias (Tabela 1) e a tabela de classes fornecidas pelo MapBiomias (Tabelas 2 e 3). Esta tabela foi escolhida devido à sua alta confiabilidade e ampla aceitação na comunidade científica, garantindo que as categorias de cobertura do solo fossem alinhadas com definições padronizadas, como Cerrado, áreas degradadas, florestas e vegetação de formação savânica. A reclassificação foi realizada com o auxílio da extensão PEC Avalia do software QGIS, empregando técnicas avançadas de processamento de imagem e algoritmos de classificação para assegurar uma categorização precisa e consistente.

Classes	Código	Cor
Cerrado	3	#1f8d49
Áreas degradadas	21	#ffefc3
Formação Florestal	3	#006400
Formação savânica	15	#edde8e

Tabela 1. Tabela de Classes da coleção 7 e 8 do MapBiomias

Além disso, foram adquiridas imagens adicionais das coleções 7 e 8 do MapBiomias, correspondentes aos anos de 2021 e 2022 (ver Figuras 4B e 4C). Essas coleções fornecem imagens de alta resolução e detalhamento, cobrindo a mesma área da Terra Indígena Governador. A análise dessas imagens permitiu uma comparação temporal detalhada, facilitando a identificação e análise das mudanças na cobertura do solo ao longo dos dois anos. Esta abordagem oferece uma perspectiva mais abrangente sobre a dinâmica da degradação ambiental, permitindo uma compreensão mais profunda dos processos em curso e fornecendo informações valiosas para a gestão e conservação da área estudada.

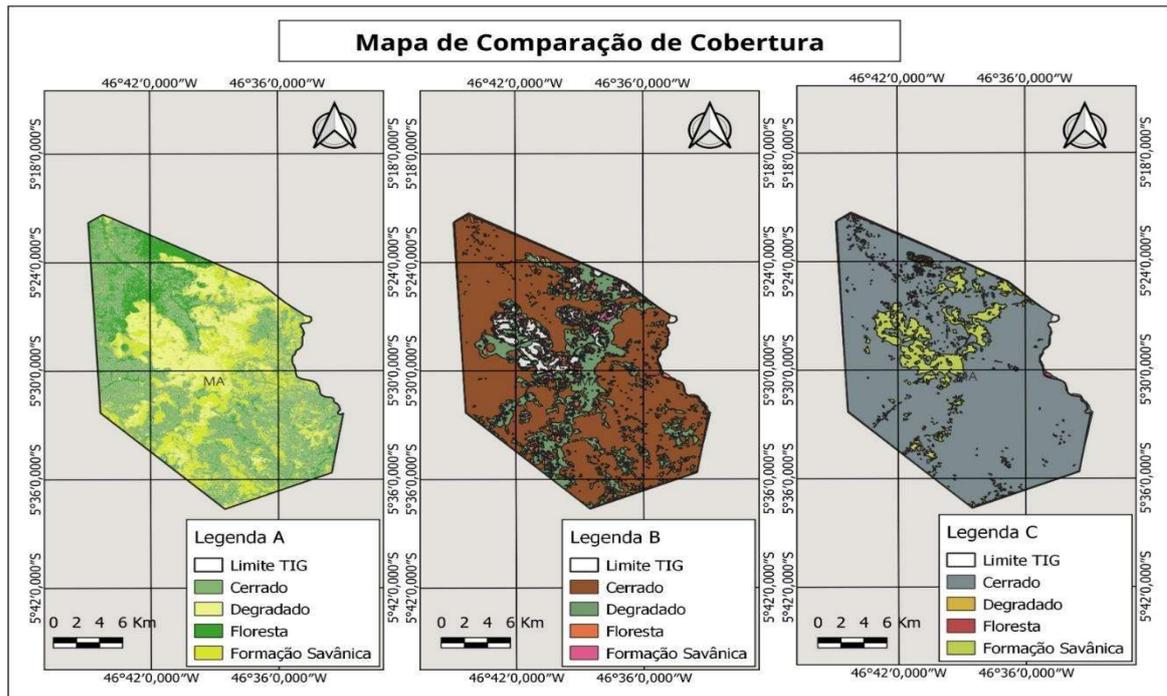


Figura 4: Mapa de Comparação de Cobertura

Fonte: Autor

As imagens foram segmentadas em quatro classes distintas, conforme previamente mencionado. Este processo de separação foi realizado utilizando a função de tabela de atributos do software QGIS, o que permitiu isolar cada classe com base em suas assinaturas espectrais específicas. As assinaturas espectrais são essenciais para distinguir entre diferentes tipos de cobertura do solo, possibilitando a identificação precisa das classes.

A precisão na segmentação das imagens é um passo crucial, pois garante a consistência dos dados e a integridade das análises subsequentes. Para assegurar a qualidade da segmentação, foram realizadas validações cruzadas e verificações de qualidade, confirmando que as classes foram corretamente identificadas. Uma segmentação precisa é fundamental para uma análise robusta da acurácia dos mapeamentos automáticos, permitindo uma avaliação mais confiável da qualidade dos dados gerados e a identificação de possíveis discrepâncias entre as classificações automáticas e as referências de campo.

4.4. Comparação e Análise

Para avaliar a precisão dos mapeamentos automáticos, foram geradas nuvens de pontos para cada uma das 12 classes identificadas, divididas igualmente entre quatro classes para cada um dos três conjuntos de dados: referência, 2021 e 2022. Essas nuvens de pontos foram criadas

a partir da amostragem espacial das áreas classificadas, possibilitando uma análise detalhada da distribuição espacial das classes e sua evolução ao longo do tempo. Esse método proporciona uma visualização clara das áreas com discrepâncias ou consistências nas classificações.

A ferramenta PEC Avalia foi utilizada para comparar as imagens de referência com as imagens dos anos de 2021 e 2022, realizando a análise para cada classe individualmente (por exemplo, comparando o Cerrado da referência com o Cerrado de 2021 e, em seguida, com o Cerrado de 2022). A PEC Avalia oferece uma plataforma robusta para essa comparação, permitindo uma análise minuciosa das mudanças e das consistências nas classificações. Os relatórios gerados pela ferramenta incluíram métricas detalhadas, como matrizes de confusão, que indicam a quantidade de acertos e erros nas classificações, e coeficientes de Kappa, que medem o nível de concordância entre as classificações automáticas e as referências. A análise dessas métricas forneceu informações valiosas sobre os pontos fortes e fracos dos mapeamentos automáticos, ajudando a identificar áreas para aprimoramento nas técnicas de mapeamento e oferecendo recomendações para a gestão ambiental da Terra Indígena Governador.

4.5. Análise dos Dados de 2021 e 2022

4.5.1. Coleta e Quantidade de Pontos Utilizados

Este estudo analisou dados dos anos de 2021 e 2022, obtidos através das plataformas Google Earth Engine e MapBiomas, respectivamente. A análise concentrou-se em quatro classes principais: Cerrado, vegetação transicional, floresta e áreas degradadas. Para validar a precisão das classificações, foram geradas nuvens de pontos aleatórios distribuídos de forma proporcional entre as classes, garantindo uma amostra representativa para a avaliação.

As nuvens de pontos foram então importadas para as imagens dos anos de 2021 e 2022, possibilitando a comparação entre as classes mapeadas e as de referência. Para cada comparação, foi elaborada uma matriz de confusão que detalha a correspondência entre as classes de referência e as identificadas nas imagens analisadas. Essa matriz possibilita a identificação de taxas de acerto e erro nas classificações. Além disso, foram geradas tabelas que contabilizam os pontos por classe, permitindo uma análise quantitativa precisa da exatidão das classificações. As informações são apresentadas nas Tabelas 2 e 3, que trazem uma visão clara da precisão e consistência dos mapeamentos automáticos.

Tabela 2: Resumo das Camadas de Teste 2021.

Fonte: Autor

Código no mapbiomas	Camada de Referência	Escala Planimétrica	Equidistância Curvas Verticais	Número de Pontos Utilizados
3	Pontos cerrado	1/10000.0	1.0m	45.600
21	Pontos degradado	1/10000.0	1.0m	145.800
3	Pontos floresta	1/10000.0	1.0m	45.600
15	Pontos savanico	1/10000.0	1.0m	154.200

Tabela 3: Resumo das Camadas de Teste 2022.

Fonte: Autor

Código no mapbiomas	Camada de Referência	Escala Planimétrica	Equidistância Curvas Verticais	Número de Pontos Utilizados
3	Pontos cerrado	1/10000.0	1.0m	76.800
21	Pontos degradado	1/10000.0	1.0m	293.400
3	Pontos floresta	1/10000.0	1.0m	76.800
15	Pontos savanico	1/10000.0	1.0m	252.600

A quantidade de pontos utilizados por classe variou significativamente entre os anos de 2021 e 2022. Para o bioma Cerrado, foram contabilizados 45.600 pontos em 2021 e 76.800 pontos em 2022, evidenciando um aumento na quantidade de dados coletados no segundo ano. A vegetação transicional também registrou um crescimento expressivo, com 154.200 pontos em 2021 e 308.400 em 2022. A classe floresta apresentou 76.800 pontos em 2022, mas os dados de 2021 não foram disponibilizados, o que impede uma comparação direta entre os dois anos. Para a classe de área degradada, foram coletados 145.800 pontos em 2021 e 293.400 em 2022.

Esse aumento significativo no número de pontos em 2022 reflete um esforço ampliado na coleta de dados, o que resulta em uma cobertura mais detalhada da área de estudo. O incremento na quantidade de pontos deve melhorar a precisão da análise e proporcionar uma visão mais abrangente das mudanças na cobertura do solo ao longo do tempo. O aumento expressivo de pontos nas classes de vegetação transicional e áreas degradadas é especialmente relevante, pois essas categorias são fundamentais para compreender a dinâmica da degradação ambiental e os impactos das alterações na cobertura do solo.

4.5.2. Estatísticas Planimétrica

As estatísticas de deslocamento nas direções x (dx) e y (dy) foram analisadas para avaliar a precisão do posicionamento dos pontos nos dois anos de estudo. Em 2021, os valores médios de deslocamento variaram entre aproximadamente -3.155.291.829 e -3.167.587.588 em

dx, e entre -93.905.652.718 e -93.999.201.292 em dy, com desvios padrão notáveis (por exemplo, 35.626.142 para dx e 63.011.393 para dy).

A metodologia adotada para a análise dos dados de deslocamento em 2022 envolveu a comparação das médias de deslocamento, dos desvios padrão e do erro quadrático médio (RMS) em relação aos dados de 2021. Observou-se uma leve redução nos valores dessas variáveis, fornecendo uma possível melhoria na precisão do posicionamento. Essa melhoria foi atribuída a ajustes na metodologia de coleta e validação dos dados, os quais resultaram em uma menor dispersão dos pontos em relação ao ponto de referência. Os resultados obtidos foram apresentados nas Tabelas 4 e 5.º dos pontos em relação ao ponto de referência (tabela 4 e 5).

Tabela 4: Estatísticas das Camadas 2021.

Fonte: Autor.

dx Média	dy Média	d2d Média	dx Desvio Padrão	dy Desvio Padrão
-3.155.291.829	-93.947.470.229	94.000.448.646	35.626.142	63.011.393
-3.167.587.588	-93.905.652.718	93.959.071.131	42.890.128	62.908.577
-3.151.995.404	-93.946.772.565	93.999.640.431	34.863.447	62.341.292
-3.137.376.251	-93.999.201.292	94.051.559.028	51.318.020	54.025.378

d2d Desvio Padrão	dx RMS	dy RMS	d2d RMS
62.634.125	3.155.492.944	93.947.491.360	94.000.469.512
63.029.369	3.167.877.945	93.905.673.789	93.959.092.271
62.058.794	3.152.188.202	93.946.793.249	93.999.660.916
52.630.975	3.137.795.924	93.999.216.818	94.051.573.754

Tabela 5: Estatísticas das Camadas 2022.

Fonte: Autor.

dx Média	dy Média	d2d Média	dx Desvio Padrão	dy Desvio Padrão
-3.171.425.169	-93.902.010.474	93.955.558.808	38.863.606	69.996.556
-3.162.114.400	-93.919.921.691	93.973.146.872	40.914.089	57.403.080
-3.169.778.895	-93.902.699.860	93.956.191.956	38.140.169	69.733.248
-3.156.295.422	-93.945.043.660	93.998.061.991	46.283.269	67.493.984

d2d Desvio Padrão	dx RMS	dy RMS	d2d RMS
69.911.748	3.171.663.280	93.902.036.562	93.955.584.818
57.393.750	3.162.379.078	93.919.939.233	93.973.164.398
69.638.939	3.170.008.343	93.902.725.752	93.956.217.764
66.848.598	3.156.634.746	93.945.067.906	93.998.085.761

4.5.3. Tolerâncias

As tolerâncias para planimétricas e altimetria mantiveram-se consistentes durante os dois anos de estudo, indicando que os critérios de qualidade e precisão na coleta de dados foram preservados. Conforme demonstrado nas tabelas 6 e 7, os valores das tolerâncias para o PEC-PCD nas quatro categorias analisadas (Classe A, Classe B, Classe C, Classe D) permaneceram inalterados entre 2021 e 2022, sendo: 2.80 para Classe A, 5.00 para Classe B, 8.00 para Classe C e 10.00 para Classe D.

Para garantir a comparabilidade dos dados entre os dois anos, foram estabelecidas tolerâncias padronizadas para a avaliação dos deslocamentos nas direções x (dx) e y (dy). A manutenção desses critérios assegurou que as variações observadas não fossem influenciadas por diferenças nos métodos de coleta, permitindo uma análise precisa da consistência planimétrica. As tolerâncias adotadas seguiram os padrões estabelecidos para a análise, garantindo que os dados fossem avaliados sob condições uniformes e comparáveis ao longo do estudo.

Essas tolerâncias desempenharam um papel vital no controle da qualidade dos dados, garantindo a manutenção da precisão do estudo e evitando comprometer a integridade dos resultados ao longo do tempo (Planilhas 6 e 7).

Tabela 6: Tolerâncias PEC-PCD e Classificação ET-CQDG 2021.

Fonte: Autor

Tolerância	PEC-PCD Plan A	PEC-PCD Plan B	PEC-PCD Plan C	PEC-PCD Plan D
Valores	2.80	5.00	8.00	10.00

Tabela 7: Tolerâncias PEC-PCD e Classificação ET-CQDG 2022.

Fonte: Autor

Tolerância	PEC-PCD Plan A	PEC-PCD Plan B	PEC-PCD Plan C	PEC-PCD Plan D
Valores	2.80	5.00	8.00	10.00

4.5.4. Discrepâncias e Variações nos Valores Máximo e Mínimo

Para avaliação da precisão dos dados de 2021 e 2022 consiste na análise das coordenadas planimétricas e tridimensionais, com ênfase nas posições nas direções x (dx) e y (dy). Para identificar variações nos dados entre os dois anos, foram calculados os valores máximos e mínimos de deslocamento. Além disso, foram estabelecidos critérios de qualidade para monitorar flutuações, levando em consideração fatores como a resolução das imagens e as variações no processo de coleta de dados.

As análises foram realizadas conforme parâmetros definidos para tolerâncias de deslocamento, de forma a garantir que eventuais variações observadas ocorram dentro de limites aceitáveis. Esse procedimento garantiu a consistência dos dados e a confiabilidade na comparação entre os anos analisados.

5. RESULTADOS E DISCURSÕES

5.1. Nuvem de Pontos e Ferramenta PEC Avalia

Os resultados da análise de acurácia dos mapeamentos automáticos de 2021 e 2022 em relação à imagem de referência de 2023 mostraram variações nas classificações das quatro principais classes analisadas: Cerrado, Área Degradada, Floresta e Vegetação Savânica. A comparação entre três conjuntos de dados distintos (referência, 2021 e 2022) resultou em um total de 12 classificações. A ferramenta PEC Avalia, especializada na avaliação de acurácia de mapeamentos geoespaciais, permitiu quantificar a confiabilidade das classificações e identificar inconsistências nos mapeamentos de 2021 e 2022.

Com essa plataforma, foi possível medir a correspondência entre as classes mapeadas nos diferentes anos e a imagem de referência, facilitando a análise da precisão das classificações automáticas.

As Figuras 5, 6, 7 e 8 ilustram as nuvens de pontos e as comparações entre as imagens de referência para as classes Cerrado, Área Degradada, Floresta e Vegetação Savânica, utilizando os dados do MapBiomas 2021 e MapBiomas 2022. Essas comparações forneceram uma visão clara das variações observadas entre os anos e da consistência das classificações automáticas em relação aos dados de referência.

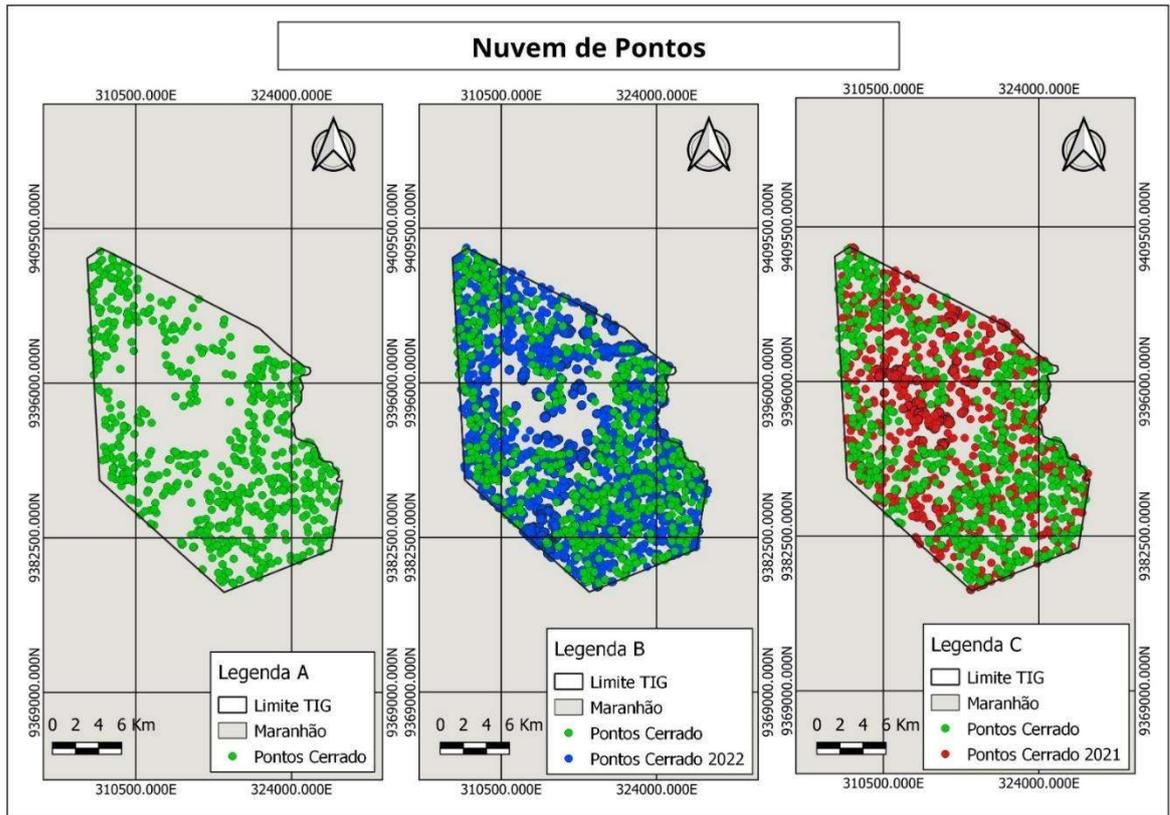


Figura 5: Nuvem de Pontos Cerrado (Referência, 2022 e 2021)

Fonte: Autor

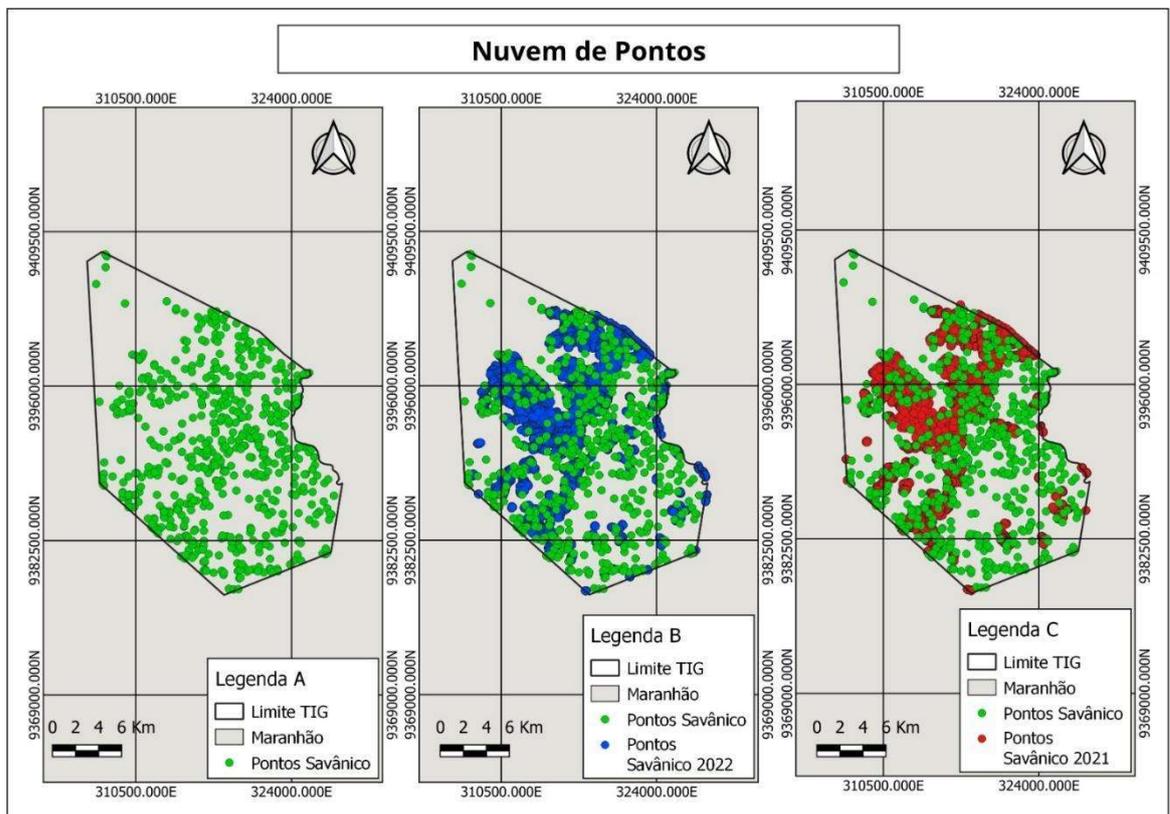


Figura 6: Nuvem de Pontos Mata Savânico (Referência, 2022 e 2021)

Fonte: Autor

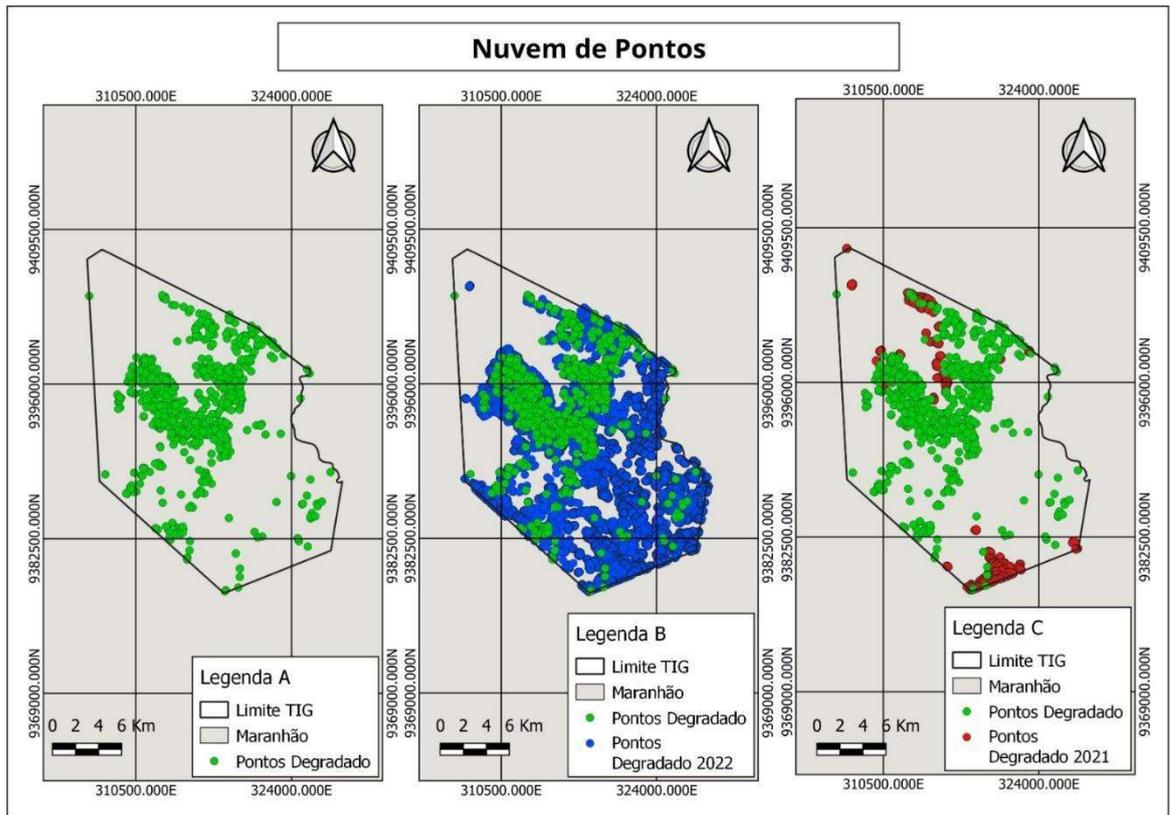


Figura 7: Nuvem de Pontos Degradado (Referência, 2022 e 2021)

Fonte: Autor

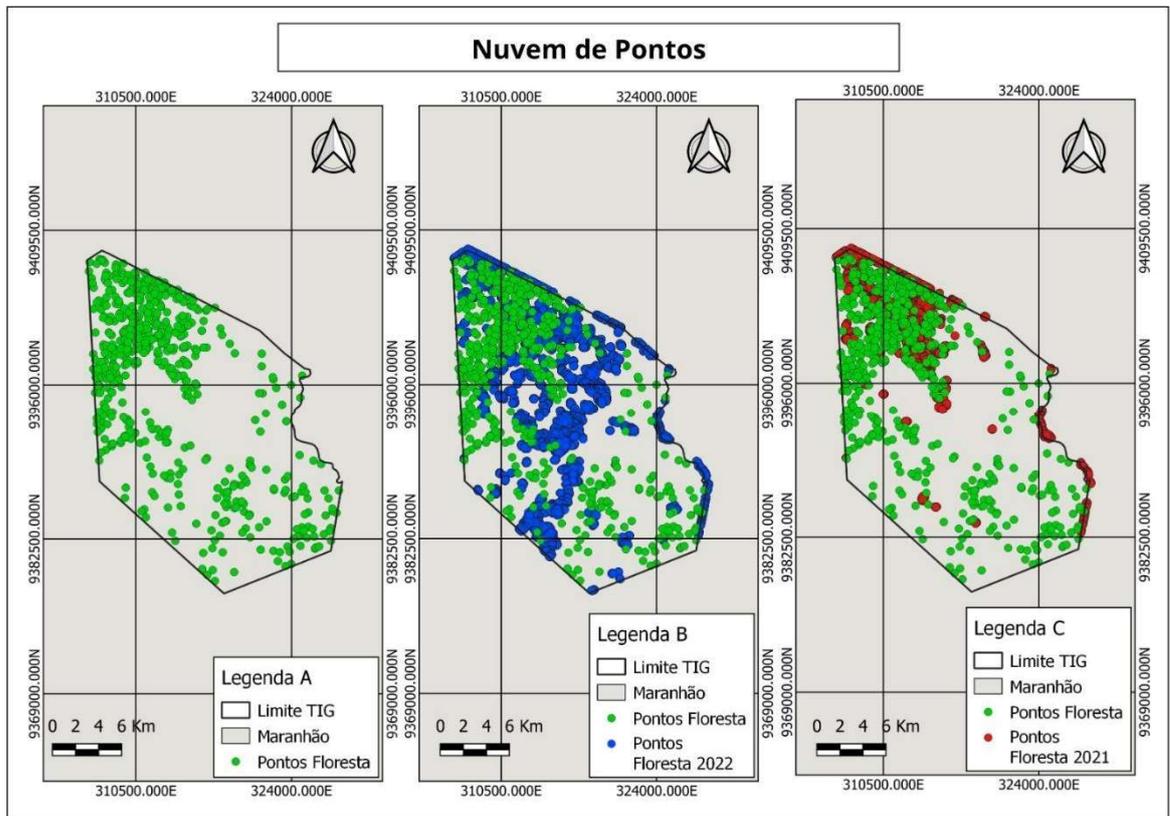


Figura 8: Nuvem de Pontos Floresta (Referência, 2022 e 2021)

Fonte: Autor

5.2. Relatórios de Acurácia

A ferramenta PEC Avalia gerou relatórios detalhados de acurácia para cada classe analisada, fornecendo matrizes de confusão e coeficientes de Kappa, essenciais para destacar os pontos fortes e fracos das classificações automáticas. Embora os dados de 2022 tenham abrangido uma área maior e exibido variações nas estatísticas de precisão, as tolerâncias e discrepâncias seguiram padrões semelhantes aos observados em 2021.

Os resultados demonstram que, apesar da expansão na cobertura de 2022, a confiabilidade desse tipo de mapeamento ainda apresenta limitações significativas. A análise identificou grandes discrepâncias nos deslocamentos planimétricos (dx e dy) e uma alta variabilidade nos dados, evidenciada pelos elevados valores de desvio padrão e do erro quadrático médio (RMS). Esses desvios são significativos e não podem ser desconsiderados, especialmente em contextos que demandam elevada precisão espacial.

Os valores obtidos para os deslocamentos planimétricos e os erros associados estão apresentados nas Tabelas 4 e 5, que sintetizam as principais métricas estatísticas empregadas na avaliação da precisão espacial. A partir desses resultados, verifica-se a necessidade de aprimoramento nas metodologias de processamento e validação dos dados para garantir maior confiabilidade nos produtos gerados.

Os resultados demonstram que, apesar da expansão na cobertura de 2022, a confiabilidade desse tipo de mapeamento ainda apresenta limitações significativas. A análise identificou grandes discrepâncias nos deslocamentos planimétricos (dx e dy) e uma alta variabilidade nos dados, evidenciada pelos elevados valores de desvio padrão e do erro quadrático médio (RMS). Esses desvios são significativos e não podem ser desconsiderados, especialmente em contextos que demandam elevada precisão espacial.

Essas inconsistências são particularmente problemáticas em aplicações que exigem alta acurácia, como o planejamento urbano, projetos de engenharia e o monitoramento ambiental detalhado. A falta de conformidade com os padrões estabelecidos pelo Decreto 89.817/ET-CQDG evidencia que os dados não atingiram os requisitos mínimos de acurácia posicional, tanto em termos planimétricos quanto altimétricos, para as escalas e equidistâncias analisadas.

Isso sugere que, embora o mapeamento automático tenha valor em análises de larga escala, ele pode não ser suficientemente confiável para projetos que exigem alta precisão. Em

situações como a construção de infraestruturas, onde erros de poucos metros podem gerar impactos significativos, ou no monitoramento ambiental detalhado, onde decisões críticas dependem de precisão espacial, o uso desses dados deve ser feito com extrema cautela. A alta variabilidade nos deslocamentos compromete a utilidade desses mapeamentos automáticos em aplicações que demandam exatidão rigorosa.

6. CONCLUSÃO

Com base nos resultados obtidos, conclui-se que o mapeamento automático realizado não possui confiabilidade suficiente para aplicações que exigem alta precisão espacial, como o planejamento urbano ou o monitoramento ambiental detalhado. Para essas finalidades, são necessárias resoluções abaixo de 1 metro. Fatores como deslocamentos planimétricos significativos, altos valores de desvio padrão e elevado erro RMS revelam inconsistências nos dados.

Apesar dessas limitações, o mapeamento pode ser útil para análises mais amplas ou preliminares, especialmente em contextos que não demandam precisão milimétrica, como o monitoramento de grandes áreas ou estudos exploratórios.

Recomenda-se a revisão dos métodos de aquisição e processamento de dados, com a implementação de controles de qualidade mais rigorosos, incluindo validação em campo e o uso de sensores de maior resolução.

7. REFERENCIAS

ALMEIDA, F. S.; CARVALHO, D. R. Ferramentas de geoprocessamento no monitoramento ambiental. In: **CONGRESSO NACIONAL DE GEOTECNOLOGIAS**, 15., 2022, Recife. Anais... Recife: UFPE, p. 210-220, 2022.

BRASIL. MapBiomias. Análise de acurácia. Disponível em: <https://brasil.mapbiomas.org/analise-de-acuracia/>. Acesso em: 28 ago. 2024.

BRITO, L. A. de; MORAES, J. P. Introdução ao sensoriamento remoto. 2. ed. Rio de Janeiro: Ciência Moderna, 2016.

COSTA, K. G. Monitoramento de áreas degradadas utilizando MapBiomias. **Journal of Geospatial Analysis**, v. 15, n. 1, p. 78-92, 2021.

DE CONTO, Danrlei et al. Comparação entre abordagens orientada a objetos geográficos e pixel a pixel para classificação supervisionada de imagens MSI/Sentinel-2: Comparison between approaches to geographic objects and per pixel for supervised classification of MSI/Sentinel-2 imagery. **Revista de Geociências do Nordeste**, v. 10, n. 1, p. 426-440, 2024.

DE FRANÇA, Josimar Fernandes et al. Previsão da produção de soja utilizando imagens de satélite e lógica fuzzy. **Ensaio e Ciência C Biológicas Agrárias e da Saúde**, v. 25, n. 2, p. 232-238, 2021.

DE PAULA, César Francisco et al. Combinação de dados LiDAR e imagens multiespectrais na separação da média e alta cobertura vegetal em ambiente urbano.

DE SOUZA BALIEIRO, Bruna Taynara; VELOSO, Gabriel Alves. Análise multitemporal da cobertura do solo da Terra Indígena Ituna-Itatá através da classificação supervisionada de imagens de satélites. **Cerrados**, v. 20, n. 2, p. 261-282, 2022.

DE SOUZA, Simmon Viegas; RODRIGUES, Suzan Waleska Pequeno. Dados multi-sensores para reconhecimento e mapeamento de ambientes sedimentares na planície do Rio Amazonas: Multi-sensor data to recognize and map sedimentary environments in the Amazonas River lowland. **Geosciences = Geociências**, v. 39, n. 2, p. 425-436, 2020.

DIAS, L. O. et al. Pyhcop cati jijõ pjii - território gavião do Maranhão. **Articulação na Construção do Saber**, v. 2, n. 1, p. 184-202, 2017. DOI: <http://doi.org/10.5216/racs.v2i1.49012>.

ESPINDOLA, Wesley Jordan da Silva et al. Proposta de metodologia simplificada para avaliação da qualidade posicional de imagens orbitais de alta resolução: um estudo de caso em uma região da Amazônia Oriental. 2023. Trabalho de Conclusão de Curso (Graduação em Engenharia Ambiental) – Universidade Federal do Pará, Campus Universitário de Tucuruí, Faculdade de Engenharia Sanitária e Ambiental, Tucuruí, 2023.

FAVERO, Isabella et al. Aprendizado de máquina aplicado no mapeamento do uso e cobertura do solo de assentamentos de reforma agrária no Acre. **Revista Tamoios**, v. 20, n. 2, p. 248-265, 2024.

FERREIRA, A. P.; SILVA, J. R. Análise da acurácia em mapeamentos automáticos. **Revista Brasileira de Cartografia**, v. 70, n. 2, p. 123-136, 2018.

GOMES, José Maria da Silveira et al. Construindo um futuro verde para a Amazônia: uma abordagem sistêmica ao desenvolvimento. 2024. Tese (Doutorado em Engenharia Ambiental) – Universidade Federal Rural da Amazônia, Campus Belém.

INPE (Instituto Nacional de Pesquisas Espaciais). Projeto Prodes. Disponível em: <http://www.inpe.br/prodes>. Acesso em: 15 jul. 2024.

INSTITUTO SOCIOAMBIENTAL. Terra Indígena Governador. Disponível em: <https://terrasindigenas.org.br/pt-br/terras-indigenas/3672>. Acesso em: 27 ago. 2024.

LUEDERS, Alice Ensfeld et al. Análise histórica do uso da terra e previsão futura utilizando o MOLUSCE, no distrito da Lagoa da Conceição, Florianópolis-SC. 2023.

LESSA, Laura Regueira Navarro. Efeitos da agricultura de corte e queima nas transformações do nitrogênio no solo da Caatinga. 2023. Trabalho de Conclusão de Curso.

MARTINS, F. G. Acurácia em mapeamentos automáticos utilizando QGIS e PEC Avalia. 2019. Dissertação (Mestrado em Geoprocessamento) – Universidade Federal do Paraná, Curitiba.

MAPBIOMAS. Coleções de Mapas. Disponível em: <http://mapbiomas.org>. Acesso em: 15 jul. 2024.

MOURA, Adriana Maria Magalhães de. Integração entre as políticas ambiental e agrícola no Brasil: conflitos, convergências e desafios. 2024.

QGIS DEVELOPMENT TEAM. QGIS Geographic Information System. Open Source Geospatial Foundation Project. Disponível em: <http://qgis.osgeo.org>. Acesso em: 15 jul. 2024.

RAMOS, Nilza Patrícia; LUCHIARI JUNIOR, Ariovaldo. Monitoramento ambiental. Embrapa. Disponível em: <https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/cana/pre-producao/meio-ambiente/monitoramento-ambiental>. Acesso em: 27 ago. 2024.

RODRIGUES, E. A. Avaliação de metodologias de mapeamento em áreas de desmatamento. 2020. Tese (Doutorado em Engenharia Ambiental) – Universidade de São Paulo, São Paulo.

SANTOS, Amanda Butura dos et al. Curso pós-técnico em restauração ecossistêmica do Instituto Terra: perfil do ingressante e reflexos na carreira dos egressos. 2023. 45 p. Monografia (Curso de Pós-técnico em Restauração Ecossistêmica) – Instituto Federal do Espírito Santo, Espírito Santo. Disponível em: <https://repositorio.ifes.edu.br/handle/123456789/4385>. Acesso em: 27 ago. 2024.

SANTOS FILHO, O. O. Gestão territorial entre povos indígenas como reação às mudanças ambientais na região da Amazônia-Cerrado. 2022. 94 f. Dissertação (Mestrado em Meio Ambiente) – Universidade CEUMA, 2022.

SANTOS, Matheus Vinicius Giglio Brisolla dos. Mapeamento da vegetação para análise de faltas no sistema de distribuição do município de Presidente Prudente-SP. 2024.

SANTOS, Pedro Thiago Cutrim dos. Aprimoramento da detecção de áreas de garimpo na Região dos Tapajós através de Redes adversárias de super-resolução. 2021.

SARTORIO, Leticia Figueiredo et al. Análise comparativa entre o uso de bandas espectrais e o uso da análise de componentes principais (ACP) na classificação de uso e cobertura da terra. **Revista Brasileira de Cartografia**, v. 75, p. 13, 2023.

SILVA, T. R.; OLIVEIRA, M. A. Uso do QGIS em mapeamentos automáticos. In: **SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO**, 18., 2017, Santos. Anais... São José dos Campos: INPE, p. 345-350, 2017.

VARELA, Victória. Mapbiomas Alerta: uma nova oportunidade de monitoramento do desmatamento brasileiro a curto prazo: uma visão sobre o Cerrado do MATOPIBA. 2020.

VIEIRA, Tatiana Grossi Chquiloff et al. Avaliação de classificadores automáticos no mapeamento de áreas cafeeiras da região de Guaxupé, Minas Gerais. 2009