



**UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS DE CHAPADINHA
CURSO DE ENGENHARIA AGRÍCOLA
TRABALHO DE CONCLUSÃO DE CURSO**

ENYO FRANCISCO DINIZ SIMÕES

**ANÁLISE ESPAÇO-TEMPORAL DA DINÂMICA DO USO E OCUPAÇÃO DO
SOLO NA REGIÃO SUL DO MUNICÍPIO DE BALSAS, MARANHÃO**

ENYO FRANCISCO DINIZ SIMÕES

**ANÁLISE ESPAÇO-TEMPORAL DA DINÂMICA DO USO E OCUPAÇÃO DO
SOLO NA REGIÃO SUL DO MUNICÍPIO DE BALSAS, MARANHÃO**

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

Orientador: Prof. Dr. Plinio Antonio Guerra
Filho

ENYO FRANCISCO DINIZ SIMÕES

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

TCC defendido e aprovado, em 21 de dezembro de 2023, pela comissão examinadora constituída pelos professores:

Prof. Dr. Plinio Antonio Guerra Filho
Orientador

Prof. Dr. Marcus Willame Lopes Carvalho
Examinador

Ms. Rita de Cássia Freire Carvalho
Examinadora

Chapadinha - MA
2023

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

Simões, Enyo Francisco Diniz.

ANÁLISE ESPAÇO-TEMPORAL DA DINÂMICA DO USO E OCUPAÇÃO
DO SOLO NA REGIÃO SUL DO MUNICÍPIO DE BALSAS, MARANHÃO /
Enyo Francisco Diniz Simões. - 2023.

51 f.

Orientador(a): Plinio Antonio Guerra Filho.

Curso de Engenharia Agrícola, Universidade Federal do
Maranhão, Chapadinha, 2023.

1. Cerrado. 2. Geotecnologias. 3. Mudanças na
Cobertura Vegetal. 4. Sensoriamento Remoto. I. Filho,
Plinio Antonio Guerra. II. Título.

Dedico este trabalho aos meus queridos familiares e amigos, que sempre estiveram ao meu lado durante esta jornada acadêmica. Em especial, dedico esta conquista ao meu pai, que sempre me incentivou e apoiou em todas as minhas decisões, e que é uma verdadeira inspiração em minha vida.

DEDICO

AGRADECIMENTOS

Agradeço em primeiro lugar a Deus por me proporcionar saúde, força e sabedoria para concluir este trabalho. À minha família, que sempre esteve ao meu lado e me apoiou durante toda a trajetória acadêmica, sou profundamente grato. Aos meus amigos, pela companhia e pelo incentivo nos momentos difíceis, meu muito obrigado.

À minha avó que ora por mim todas as noites pedindo saúde e sabedoria para enfrentar os desafios da vida acadêmica e profissional.

Aos meus colegas de faculdade, que me apoiaram nas disciplinas e momentos difíceis, e que se tornaram grandes amigos os quais levarei para fora dos muros na Universidade.

Aos meus colegas de república, que compartilharam momentos inesquecíveis ao longo desses anos e foram minha família enquanto estava longe do meu grupo familiar. Obrigado por me aturar, amigos!

Ao meu orientador, Plinio Antonio Guerra Filho, minha sincera gratidão pela paciência e orientação que foram fundamentais para a realização deste trabalho.

Por fim, não poderia deixar de agradecer à Universidade Federal do Maranhão e aos docentes do curso de Engenharia Agrícola, que me proporcionaram um ambiente acadêmico acolhedor, desafiador e estimulante para minha experiência universitária.

Muito obrigado a todos que contribuíram com minha formação. Que esta conquista seja apenas o início de uma jornada de sucesso e realizações.

SUMÁRIO

LISTA DE FIGURAS	8
LISTA DE TABELAS	9
LISTA DE QUADROS	10
LISTA DE ABREVIATURAS E SIGLAS	11
RESUMO	12
1. INTRODUÇÃO	14
2. OBJETIVOS	16
2.1. Objetivo geral	16
2.2. Objetivos específicos	16
3. REFERENCIAL TEÓRICO	16
3.1. Balsas e o Agronegócio Maranhense	16
3.2. Fragmentação Vegetal	17
3.3. Sensoriamento Remoto	18
3.4. Imagens de Satélite e Sensores	20
3.5. Classificação Supervisionada	21
3.6. Análise do Uso e Ocupação do Solo	22
4. MATERIAIS E MÉTODOS	24
4.1. Caracterização da área de estudo	24
4.2. Seleção e aquisição das imagens do Landsat-8	25
4.3. Base cartográfica	26
4.4. Pré-processamento das imagens	26
4.5. Medidas para mitigar erros no mapa	27
4.5.1. Delimitação com polígonos	28
4.6. Classificação supervisionada das imagens	28
4.7. Pós-processamento e tabulação dos dados	33
5. RESULTADOS E DISCUSSÃO	35
5.1. Uso e cobertura do solo para o ano de 2013	35
5.2. Uso e cobertura do solo para o ano de 2023	38
5.3. Evolução espaço-temporal do uso e cobertura do solo	41
6. CONCLUSÕES	46
7. REFERÊNCIAS	47

LISTA DE FIGURAS

Figura 1. Mapa de localização da área de estudo. Região sul do município de Balsas, Maranhão.	24
Figura 2. Fluxograma metodológico.	25
Figura 3. Composições coloridas utilizadas para coleta de amostras do ano de 2013.	30
Figura 4. Composições coloridas utilizadas para coleta de amostras do ano de 2023.	30
Figura 5. Exemplo de uma área com predominância da classe Floresta Densa visualizada através do Google Satélite e da composição 654.	31
Figura 6. Exemplo de uma área com predominância da classe Floresta Rala visualizada através do Google Satélite e da composição 654.	31
Figura 7. Exemplo de uma área com predominância da classe Área Agrícola visualizada através do Google Satélite e da composição 654.	31
Figura 8. Exemplo de uma área com predominância da classe Área Não Florestal visualizada através do Google Satélite e da composição 654.	32
Figura 9. Mapa de uso e ocupação do solo da região sul do município de Balsas, Maranhão, para o ano de 2013.	35
Figura 10. Mapa de uso e ocupação do solo da região sul do município de Balsas, Maranhão, para o ano de 2023.	38
Figura 11. Gráfico de evolução das classes de uso do solo ao longo dos 10 anos de análise. Área, em ha x Classes de uso e ocupação do solo.	41
Figura 12. Comparação dos mapas de uso e cobertura do solo da região sul do município de Balsas, Maranhão, nos anos de 2013 e 2023.	42
Figura 13. Comparação dos mapas coloridos (Comp654) da região sul do município de Balsas, Maranhão, nos anos de 2013 e 2023.	43

LISTA DE TABELAS

Tabela 1. Classes de uso e ocupação do solo adotadas para área de estudo.....	29
Tabela 2. Área total das classes para a classificação supervisionada do ano de 2013.	36
Tabela 3. Matriz de Erro. Acurácia global, desvio padrão da acurácia global, acurácias do produtor e do usuário, erros de comissão e omissão para a classificação do ano de 2013. .	37
Tabela 4. Área total das classes para a classificação supervisionada do ano de 2023.	39
Tabela 5. Matriz de Erro. Acurácia global, desvio padrão da acurácia global, acurácias do produtor e do usuário, erros de comissão e omissão para a classificação do ano de 2023. .	40
Tabela 6. Áreas das classes nos dois anos de estudo, 2013 e 2023, e suas respectivas variações.....	41

LISTA DE QUADROS

Quadro 1. Cenas brutas adquiridas da USGS.	26
Quadro 2. Composições coloridas de imagens orbitais do sensor OLI do satélite Landsat-8.	29
Quadro 3. Matriz de erro, onde os elementos diagonais em destaque contêm o número de casos onde as classes e os pontos de referência representando a verdade de campo coincidem. As variáveis A, B, C e D correspondem às classes.	34

LISTA DE ABREVIATURAS E SIGLAS

AcATaMa – *Accuracy Assessment of Thematic Maps*

Comp – Composição

DOS1 – *Dark Object Subtraction*

EIA – Estudo de Impacto Ambiental

ha - Hectares

IBGE – Instituto Brasileiro de Geografia e Estatística

Inpe - Instituto Nacional de Pesquisas Espaciais

MATOPIBA – Maranhão, Tocantins, Piauí e Bahia

Maxver – Máxima Verossimilhança

NDVI – Índice de Vegetação por Diferença Normalizada

OLI – *Operational Land Imager*

PIB – Produto Interno Bruto

REM – Radiação Eletromagnética

RGB – *Red, Green e Blue*

SCP – *Semi-Automatic Classification Plugin*

SIG – Sistema de Informações Geográficas

SR – Sensoriamento Remoto

SRC – Sistema de Referência de Coordenadas

SWIR – *Short-Wave Infrared* (Infravermelho de Ondas Curtas)

TIRS – *Thermal InfraRed Sensor*

USGS – *United States Geological Survey* (Serviço Geológico dos Estados Unidos)

UTM – *Universal Transverse Mercator*

WGS84 – *World Geodetic System 84* (Sistema Geodésico Mundial de 1984)

RESUMO

O bioma do Cerrado, essencial para a biodiversidade brasileira e que abrange a maior parte do estado do Maranhão, enfrenta uma preocupante diminuição de sua cobertura vegetal, demandando atenção urgente das autoridades e da sociedade. A preservação de tal riqueza biológica requer análises eficientes acerca das mudanças sofridas na superfície terrestre, em especial, o desmatamento. Nesse contexto, a utilização das geotecnologias se torna fundamental para realização de estudos relacionados às mudanças na cobertura vegetal. Através de técnicas de geoprocessamento, este trabalho avaliou as alterações no uso e ocupação do solo entre os anos de 2013 e 2023 na região sul do município de Balsas, Maranhão, utilizando imagens do satélite Landsat-8 com resolução espacial de 30 metros. Todo o processamento digital foi conduzido no QGIS 3.16.9 Hannover, com o auxílio dos complementos SCP, para pré-processamento e classificação supervisionada, e AcATaMA, para avaliação de acurácia do mapa resultante da classificação. As ferramentas de edição de polígonos e outras funcionalidades nativas do *software* também foram empregadas ao longo do processo. A análise revelou níveis de acurácia global de 93,2 e 88,9% para os anos de 2013 e 2023, respectivamente. No que diz respeito às mudanças na cobertura do solo, as formações florestais densas e ralas aumentaram em 0,24%, enquanto as não florestais reduziram em 37%. Notavelmente, as áreas destinadas à agropecuária apresentaram um incremento significativo de 47,1% ao longo da última década.

Palavras-chave: Cerrado; Geotecnologias; Mudanças na Cobertura Vegetal; Sensoriamento Remoto.

ABSTRACT

The Cerrado biome, essential for Brazilian biodiversity and which covers most of the state of Maranhão, is facing a worrying decrease in its vegetation cover, demanding urgent attention from authorities and society. The preservation of such biological wealth requires efficient analyzes of the changes suffered on the Earth's surface, in particular, deforestation. In this context, the use of geotechnologies becomes essential for carrying out studies related to changes in vegetation cover. Using geoprocessing techniques, this work evaluated changes in land use and occupation between 2013 and 2023 in the southern region of the municipality of Balsas, Maranhão, using images from the Landsat-8 satellite with a spatial resolution of 30 meters. All digital processing was conducted in QGIS 3.16.9 Hannover, with the help of the add-ons SCP, for pre-processing and supervised classification, and AcATaMA, for evaluating the accuracy of the map resulting from the classification. Polygon editing tools and other native features of the software were also used throughout the process. The analysis revealed global accuracy levels of 93.2 and 88.9% for the years 2013 and 2023, respectively. With regard to changes in land cover, dense and thin forest formations increased by 0.24%, while non-forest formations reduced by 37%. Notably, the areas allocated to agriculture showed a significant increase of 47.1% over the last decade.

Keywords: Cerrado; Geotechnologies; Changes in Vegetation Cover; Remote Sensing.

1. INTRODUÇÃO

O território brasileiro é ocupado por diversas formações vegetais as quais ostentam uma grande biodiversidade. Segundo Rocha e Nascimento (2021), o Brasil, país de extensão continental, é abrangido por diferentes biomas, mas todos com igual importância ambiental. Entre estes, o Cerrado é o segundo maior em ocupação, sendo superado somente pela Amazônia. No Brasil, esse bioma possui uma formação savânica e é conhecido por comportar uma das maiores biodiversidades do mundo, além de ocupar cerca de 2 milhões de km² de área, o que corresponde a cerca de 23% do território nacional. O ecossistema do bioma abriga uma grande biodiversidade mundial e possui a mais rica flora comparada às outras savanas do planeta, tornando sua preservação uma tarefa de grande relevância para a sustentabilidade global (COSTA et al., 2020). Embora possua toda essa importância no cenário ambiental mundial, no Brasil, o bioma é o mais ameaçado pela ação antrópica (COSTA et al., 2020).

A fragmentação vegetal é um dos processos resultantes do desmatamento. Esse pode ocorrer por causas naturais, porém, a ação antrópica é responsável pela intensificação da fragmentação, principalmente devido ao crescimento populacional e ao desmatamento ocasionados pela expansão urbana e agrícola. Os impactos ambientais desse fenômeno estão relacionados a perda de habitat e alterações nos padrões de configuração espacial da cobertura vegetal, devido a perda da continuidade da área florestal. O tamanho e forma dos fragmentos gerados, além da distância entre os mesmos, são fatores que influenciam diretamente nos impactos, uma vez que fragmentos menores e mais isolados têm como características redução na biodiversidade (LIMA; FRANCISCO; BOHRER, 2017).

No Cerrado, o desmatamento ocorre de forma acentuada, apresentando índices que superam os da Mata Atlântica e Floresta Amazônica. Dados de 2018 já apontavam grande alteração na cobertura do solo do bioma causados pela ação antrópica ao longo dos anos, o que levou a aproximadamente 41,3% de perda da sua cobertura natural. Esses danos ocorreram principalmente após a década de 1970, quando foram implementados programas para desenvolvimento econômico da região. A estreita relação entre queimadas e atividades agropecuárias antigas, como remoção da vegetação natural com uso do fogo, torna o Cerrado ainda mais propenso à perda da sua vegetação nativa, sendo este o segundo bioma com maior índice de focos de queimadas, atrás somente da Amazônia (ROCHA e NASCIMENTO, 2021). Segundo Roscoe (2023), dados atuais do Inpe indicam que os esforços de conservação do bioma ainda não foram bem-sucedidos. No primeiro trimestre de 2023, o Cerrado

brasileiro registrou um recorde de desmatamento, alcançando uma área desmatada de 1.375,3 km², superando inclusive a Amazônia, que teve 844,6 km² desmatados no mesmo período.

Nos últimos anos, diversos estados do Cerrado passaram por grande expansão da produção agrícola e a consequência foi a redução da sua vegetação nativa para abertura de novas áreas para cultivo. Alguns estados das regiões Norte e Nordeste, como Maranhão, Tocantins, Piauí e Bahia, são exemplos desse desenvolvimento, estes apresentaram aumento acentuado de suas áreas plantadas e juntos formaram uma nova fronteira agrícola do Cerrado, a MATOPIBA, a qual abrange aproximadamente 45 milhões de hectares e 151 municípios desses estados (SANO et al., 2019).

Como todo estudo, a tomada de decisão é precedida por análises, conforme a natureza do mesmo. Segundo Saito (2016), na problemática do desmatamento e a consequente fragmentação vegetal das florestas naturais, é possível realizar estas análises com a utilização de indicadores quantitativos com base nas propriedades espaciais e na organização espacial dos fragmentos de uma paisagem. Nesse sentido, as geotecnologias são um conjunto de técnicas as quais compõem todo o processo de geração de informações com referência geográfica. O avanço dessas tecnologias possibilita a obtenção de dados rápidos e confiáveis acerca de diversos eventos ocorridos na superfície do globo, tornando possíveis as análises propostas neste trabalho (FERREIRA e PASA, 2015).

Ferreira e Pasa (2015) também destacam que as imagens de satélite junto com as ferramentas de geoprocessamento podem ser utilizadas em todas as etapas de um Estudo de Impacto Ambiental (EIA), possibilitando a atualização constante de dados referentes às análises e a elaboração de projeções acerca de impactos futuros em determinada região da Terra. Com isso, é possível realizar o monitoramento da fragmentação da vegetação nativa com o uso do geoprocessamento, permitindo a manipulação de dados de grandes áreas, o que simplifica os EIA e possibilita a criação de mapas digitais em níveis estaduais, municipais e regionais.

O uso das técnicas de geoprocessamento propostas neste estudo irá possibilitar o fornecimento de informações relevantes acerca dos impactos sofridos pela vegetação nativa ao longo do tempo, especialmente no decurso da expansão agrícola, por fatores antropogênicos no município. Com base nesses dados, poderão ser incentivadas medidas que

busquem o desenvolvimento sustentável da agricultura, bem como da sociedade em geral, além de atuações mais conscientes dos produtores rurais.

2. OBJETIVOS

2.1. Objetivo geral

Analisar as mudanças no uso e ocupação do solo na região sul do município de Balsas, Maranhão, entre os anos de 2013 e 2023, utilizando imagens de satélite e técnicas de geoprocessamento.

2.2. Objetivos específicos

- Realizar a classificação supervisionada do uso da terra por meio de técnicas de processamento para segmentar a área de estudo em quatro classes principais: Floresta Densa, Floresta Rala, Área Agrícola e Área Não Florestal;
- Verificar as mudanças no uso da terra durante o período estudado, quantificando os incrementos e desmatamentos de vegetação nativa;
- Destacar a eficiência do uso de dados e ferramentas gratuitas para produção de mapas de análise do uso e ocupação do solo;
- Avaliar a relação entre a fragmentação da floresta e os principais fatores ambientais e antrópicos que atuam na região.

3. REFERENCIAL TEÓRICO

3.1. Balsas e o Agronegócio Maranhense

O município de Balsas - MA é um forte representante maranhense na MATOPIBA, sendo considerado um dos mais importantes na produção de grãos do estado, especialmente de soja, milho e arroz (BRITO et al., 2020). A expansão agrícola na região é evidente devido à alta demanda por *commodities* agrícolas no mercado. O desenvolvimento econômico da cidade se dá, principalmente, pela agricultura, tendo o arroz como seu primeiro ciclo produtivo. As condições de espaço, incluindo clima e pluviosidade, somadas ao baixo custo para a aquisição de terras e as políticas de Estado para o desenvolvimento do Cerrado foram fundamentais para atrair a atenção dos agricultores sulistas para a região na década de 70. A partir disso, com a aplicação de técnicas de correção e calagem do solo, foram criadas áreas propícias para produção de soja, a qual se tornou a principal atividade agrícola da cidade.

Com o avanço na agricultura, a cidade recebeu diversas políticas públicas do Estado, como o Plano Proceder, o que aumentou cada vez mais a produção de soja (VIEIRA, 2019).

A cidade é uma das principais áreas de produção agrícola do estado do Maranhão. Isso se dá a partir de 1990, quando ocorreu a instalação de uma grande cadeia produtiva de soja na região, ocasionada pela liberação da economia, isso atraiu investimentos significativos em vias de escoamento da produção até o Porto de Itaqui, um dos principais do país, localizado em São Luís – MA (BRITO et al., 2020).

A localização geográfica é um dos fatores que contribuíram para o desenvolvimento da agricultura local, pois a cidade é cortada pelas rodovias BR 230, BR 330, BR 324 e ainda pela MA 140, o que favorece a logística de transporte da produção agrícola (RODRIGUES e TERRA, 2018). Além disso, a regularidade das chuvas, o aumento da área plantada e o incentivo do governo são características que favorecem o desenvolvimento da agricultura no município, sendo um dos maiores produtores de grãos do MATOPIBA. A consequência disso é a terceira posição entre os municípios com maior PIB do estado. As principais cadeias produtivas atuantes na região são a soja e o algodão (UNIBALSAS, 2020; IDH, 2021).

Sua vegetação pertence ao bioma Cerrado que possui como características gerais vegetação aberta ou floresta semidecidual com árvores de médio porte com galhos e troncos retorcidos, raízes densas e bem adaptadas as menores pluviosidades. O Cerrado apresenta condições distintas de pequenos períodos de alta precipitação e extensos períodos de estiagem, que, junto com uma alta incidência de radiação solar característica do bioma, acarreta frequentes ocorrência de incêndios florestais (REIS e SCHMIELE, 2019).

3.2. Fragmentação Vegetal

A paisagem é formada por diversos elementos físicos, biológicos e antrópicos, e a combinação dinâmica destes elementos resulta em uma constante evolução da paisagem, gerando transformações e adaptações. Por isso, a paisagem não está restrita apenas ao ambiente natural, já que as ações humanas sobre o meio ambiente têm um impacto significativo sobre ela. Neste contexto, a fragmentação florestal é caracterizada pela remoção de partes de uma floresta contínua, resultando na formação de fragmentos de floresta menores e isolados (ANDRADE et al., 2020). Esse fenômeno ocorre por causas antrópicas ou por eventos naturais, e sua característica principal é a subdivisão de um ecossistema formando

uma paisagem com diversos fragmentos de cobertura vegetal original ocupando um espaço com diferentes propriedades naturais (D'ARROCHELLA e SILVA, 2020).

A relação entre biodiversidade e a heterogeneidade territorial é estreita, visto que as mudanças nos cenários de interações de espécies do planeta influenciam diretamente nos padrões e distribuição dessa biodiversidade. Apesar disso, as ações antrópicas responsáveis pela transformação da terra, carregam danos ambientais como a redução da matriz territorial dos habitats, acarretando consequências indiretas de perda e fragmentação dos habitats naturais, tornando-se uma ameaça à biodiversidade (ENCINA et al., 2018).

A fragmentação da vegetação é um dos principais processos que ameaçam a biodiversidade em escala global. A perda de partes da floresta promove a redução da quantidade de habitats, provocando o aparecimento de um grande número de manchas isoladas e pequenas. As dimensões e o grau de isolamentos são parâmetros relevantes nas oscilações da riqueza de espécies nos fragmentos de floresta (ROSSI, 2016). Segundo Andrade et al. (2020), problemas como alterações nas relações de predação e competição, bem como a perda de micro-habitat e consequente extinção de espécies, são consequências das menores dimensões e isolamento das manchas de floresta promovidas pela fragmentação.

O desmatamento contínuo favorece o aumento de limites artificiais que reduzem o tamanho das zonas habitáveis, gerando o efeito de borda. Esse efeito é um dos principais relacionados com a fragmentação florestal e é responsável por causar impactos negativos na riqueza e composição das espécies. Esse processo, embora sua formação dependa de alguns fatores, possui um papel fundamental na elaboração de estratégias para recuperação florestal, podendo fornecer dados para o desenho de reservas e desenvolvimento de medidas preventivas que detenham a extinção das espécies (SILVA et al., 2019).

3.3. Sensoriamento Remoto

No mundo moderno, os satélites artificiais estão cada vez mais presentes no cotidiano das pessoas, seja no acesso à internet, nas ligações telefônicas, no monitoramento de zonas terrestres ou até mesmo na previsão do tempo, o que torna este dispositivo um importante elemento tecnológico na atualidade. A obtenção de dados da superfície terrestre a distância é realizada, entre outras formas, através desses equipamentos. Por sua vez, o sensoriamento remoto (SR) é uma tecnologia que possibilita a obtenção de informações da superfície da

Terra, por meio da captura e registro da energia refletida ou emitida por ela (GUEDES e SILVA, 2018).

Segundo Zaidan (2017), o geoprocessamento faz parte do rol das geotecnologias e é definido como um conjunto de técnicas envolvendo métodos teóricos e computacionais para coleta, entrada, armazenamento, tratamento e processamento de dados com o objetivo de produzir novas informações espaciais ou dados georreferenciados, sendo o segundo relacionado com uma posição específica do globo terrestre. Os SIGs (Sistema de Informações Geográficas) estão inseridos dentro das práticas de geoprocessamento e seu conceito tem sido tratado com complexidade. Porém, os SIGs são sistemas operacionais de coleta, armazenamento, manipulação e saída de dados cartográficos e envolve uma estrutura que abrange técnicas e métodos programados para o gerenciamento de ferramentas por meio de softwares, os quais são alimentados pelas análises realizadas por diferentes equipamentos e hardwares, com o propósito de disponibilizar dados ou informações geográficas.

O sensoriamento remoto envolve um conjunto de dispositivos que, juntos, atuam nos estudos de fenômenos, eventos e processos que ocorrem na superfície da Terra a partir do registro e análise da resposta resultante das interações da radiação eletromagnética com os corpos presentes na superfície terrestre. Os sensores, equipamentos de processamento e transmissão de dados, os quais realizam a detecção e registro das informações necessárias para os estudos com sensoriamento remoto, são acoplados em aeronaves, espaçonaves ou outras plataformas, ou seja, realizam as etapas do processo à distância, sem contato direto com a superfície analisada. A partir dos dados fornecidos por esses dispositivos, é possível utilizar softwares específicos para seu tratamento, a fim de extrair diferentes tipos de informações sobre as feições terrestres e gerar mapas para diferentes tipos de análises (VALE et al., 2018).

Os dados proporcionados por essa ferramenta são fundamentais nos estudos de grandes áreas ou de regiões de pouco acesso, possibilitando a adaptação das análises para os diferentes tipos de estudos ambientais, como crescimento urbano, fontes poluidoras de rios, desmatamento, reflorestamento, uso e ocupação do solo, entre outros (SCHLEICH; FILHO; LAHM, 2022). Os estudos de fragmentação vegetal, geralmente, envolvem grandes áreas, tornando as análises uma tarefa complexa e cansativa quando executadas por sistemas alternativos. Portanto, a simplicidade e viabilidade econômica da aquisição de dados proporcionadas pelas técnicas de sensoriamento remoto permitem a cobertura de áreas com

dimensões ilimitadas e com quaisquer tipos de uso e ocupação, o que agiliza os resultados das análises e promove uma tomada de decisão eficiente.

3.4. Imagens de Satélite e Sensores

Os resultados das análises da superfície terrestre utilizando técnicas de sensoriamento remoto são obtidos a partir de imagens de satélite, as quais carregam informações acerca do comportamento espectral da porção de superfície estudada. O uso dessas imagens orbitais vem possibilitando estudos relevantes o que proporciona a disponibilidade de dados relacionados às feições da superfície do globo, como: área irrigada, necessidade hídrica, tipos de cultura, identificação de processos de degradação e desmatamento, além de vários outros (ALMEIDA et al., 2018).

Na área do sensoriamento remoto, os sensores são equipamentos que transformam a radiação eletromagnética (REM) em um sinal apto a ser convertido em informações acerca da superfície. Esses dispositivos têm a capacidade de responder à radiação de diferentes faixas do espectro eletromagnético e registrá-la, gerando dados em formato adequado para interpretação dos softwares. Os sensores remotos podem gerar informações na forma de imagens, no caso dos imageadores, ou em valores numéricos ou gráficos, no caso dos não-imageadores. A qualidade das imagens de satélite depende fundamentalmente da capacidade desses sensores remotos imagens e pode ser determinada por meio de quatro tipos de resoluções, são elas: espectral, espacial, radiométrica e temporal (FIORIO, 2020).

Iniciada há mais de 40 anos com o lançamento do satélite Landsat-1, a série Landsat possibilita a obtenção de dados relevantes para realização de mapeamento e monitoramento da superfície terrestre. Em órbita desde 2013, o satélite Landsat-8 aperfeiçoou o potencial das imagens desta série com a inclusão de novas bandas espectrais nas faixas azul e infravermelho de onda curta (SWIR), melhorias na relação sinal/ruído do sensor e na resolução radiométrica das imagens. A bordo do Landsat-8, o sensor *Operational Land Imager* (OLI) possui resolução espectral de nove bandas, resolução espacial de 30 m e 15 m, resolução radiométrica de 16 bits e resolução temporal de 16 dias (SOTHE et al., 2017; FIORIO, 2020). O sensor também possui uma faixa imageada média de 185 km (BEZERRA et al., 2018). Outro instrumento imageador deste satélite é o *Thermal InfraRed Sensor* (TIRS) que possui duas bandas do Infravermelho Termal e resolução espacial de 100 m.

As diversas bandas registradas pelos sensores multiespectrais, ou orbitais, possibilitam a geração de uma imagem composta para diferentes tipos de estudos e análises. As bandas que compõem a imagem bruta podem ser combinadas ou transformadas de forma individual a fim de destacar determinado padrão ou recurso desejado, essa prática é comumente utilizada para geração de novas imagens para retirada de informações específicas. A representação da vegetação para essas análises pode ser aprimorada através dos índices de vegetação, os quais buscam destacar o comportamento espectral da vegetação em relação aos demais alvos da superfície terrestre. O NDVI (Índice de Vegetação por Diferença Normalizada) tem ganhado destaque por ser um dos indicadores mais importantes nos estudos de vegetação, sendo muito aplicado para o mapeamento da cobertura vegetal devido sua alta sensibilidade à vegetação esparsa e densa, possibilitando a realização dessas análises em diversas escalas de uma determinada região (BARROS; FARIAS; MARINHO, 2020).

Embora exista uma alta tecnologia por trás dos processos descritos, atualmente, é possível adquirir essas imagens e outros dados geoespaciais através de diversos bancos de dados gratuitos. A agência USGS (*United States Geological Survey*) possui uma grande coleção de dados orbitais, os quais podem ser adquiridos através da plataforma *Earth Explorer*. Essa ferramenta fornece dados de diversos sensores orbitais, como dados ópticos, de radares, imagens de satélite meteorológicos, mapas digitais e elevação, entre outros, tudo com recursos avançados de pesquisa. Além dessa, há outras plataformas semelhantes, como: *EOSDA LandViewer*, *Sentinel Hub*, *NASA Earthdata Search* e *INPE Image Catalog* (SERGIEIEVA, 2020).

3.5. Classificação Supervisionada

Com o avanço das geotecnologias, surgiram diferentes metodologias para o tratamento dos dados oriundos das técnicas de sensoriamento remoto. Uma das inovações proporcionadas por esse avanço foi a elaboração de mapas, processo que apresentou grande evolução com o desenvolvimento dessas tecnologias, principalmente com o processo de classificação de imagens de satélite. De forma geral, esse processo tem o objetivo de identificar a informação presente em cada pixel que compõe a imagem e, a partir disso, classificar e atribuir categorias para os mesmos. Na classificação supervisionada, a geração das diferentes classes de uso do solo ocorre a partir da identificação dos diferentes tipos de comportamentos espectrais que compõem os pixels da imagem (VALE et al., 2018).

Para realizar esse processo de classificação, existem dois modelos com diferentes abordagens. Na classificação não supervisionada, o algoritmo realiza o processamento com base nas informações presentes na imagem, fazendo a correlação entre elas e separando as classes, sem a necessidade de receber previamente uma classe de saída. No modelo supervisionado, o algoritmo utiliza como referência para determinação das classes as informações de uma classe de saída determinada pelo usuário previamente (LOPEZ et al., 2017).

As informações presentes nas imagens de satélite são medidas e obtidas em diferentes faixas do espectro eletromagnético e, dessa forma, os pixels da imagem recebem valores numéricos os quais descrevem os objetos reais da superfície. Na classificação de imagens, para categorizar e atribuir classes aos pixels, os softwares de geoprocessamento realizam o processamento da imagem a partir desses dados espectrais, os quais possibilitam a visualização de diversas bandas de dentro e fora da faixa do visível do espectro eletromagnético. Isso ocorre devido às propriedades físicas dos materiais que constituem a superfície terrestre, onde cada um apresenta respostas espectrais distintas, possibilitando ao algoritmo realizar sua diferenciação. Para os estudos que envolvem cobertura vegetal, os comprimentos de onda mais utilizados na classificação estão situados nas regiões do vermelho e do infravermelho próximo e médio, visto que nessas faixas possuem maior variação da resposta espectral (FITZ, 2020).

3.6. Análise do Uso e Ocupação do Solo

Um dos eventos responsáveis por gerar impactos ambientais relacionados ao uso e ocupação do solo é a ação humana desenvolvida sem planejamento e incompatível com as características naturais de um local (ASCIUTTI; STANGANINI; MELANDA, 2019). O crescimento das regiões urbanizadas aumenta a demanda por novas áreas, tanto para construção de moradia como para prática de certas atividades, o que resulta em problemas como a ocupação desordenada de áreas vegetadas e uso desregulado dos recursos naturais locais. O uso incorreto do solo acarreta em impactos significativos ao meio ambiente, como perda da biodiversidade, processos de erosão intensa, inundações, assoreamento de reservatórios e cursos d'água (NASCIMENTO e FERNANDES, 2017).

A análise do uso do solo, envolvendo sua identificação e classificação, é fundamental nos estudos do ambiente, da mesma forma que o avanço de técnicas relacionadas com a

aquisição e manutenção dessas informações. As técnicas de sensoriamento remoto geram informações relevantes para o desenvolvimento de um sistema de classificação do uso do solo, o que possibilita tais avanços. Sendo assim, tanto essas técnicas como o geoprocessamento como um todo são ferramentas indispensáveis nos processos de monitoramento do uso e ocupação do solo por proporcionarem uma alta frequência na atualização e rapidez no processamento dos dados, além de apresentar viabilidade econômica acentuada (COSTA, 2019).

As técnicas de sensoriamento remoto possibilitam a obtenção de informações acerca dos corpos presentes na superfície da Terra, como vegetação e solo, por meio da interação eletromagnética. Isso ocorre devido a atividade fotossintética das plantas e varia em função da absorção da radiação eletromagnética e sua reflectância, além disso, a morfologia e as funções físico-químicas das folhas também são fatores que alteram o comportamento espectral da vegetação. A vegetação apresenta baixa reflectância na faixa do visível, região do espectro eletromagnético onde há grande absorção de radiação pela clorofila. No Infravermelho Próximo ocorre grande absorção da radiação e no Infravermelho Médio a reflectância é absorvida pela água presente na estrutura interna das folhas. Já no solo, o comportamento espectral varia em função alguns fatores como material orgânico, minerais, umidade e composição química, contudo, o comprimento de onda em que ocorre maior reflectância é a Faixa do Vermelho (BORGES; RODRIGUES; LEITE, 2019).

4. MATERIAIS E MÉTODOS

4.1. Caracterização da área de estudo

O município de Balsas fica localizado na Mesorregião Sul do Maranhão, nas coordenadas 7° 31' 57" de latitude Sul e 46° 02' 08" de longitude Oeste, com uma altitude média de 243 m. Possui uma área de 13.141,162 km², sendo o maior do estado, e uma população de aproximadamente 96.951 habitantes, resultando em uma densidade demográfica de 6,36 hab.km⁻². O clima da região é classificado como tropical quente e úmido (Aw) com estação seca, segundo a classificação de *Köppen*. O município integra a Microrregião dos Gerais de Balsas, onde é o principal, fazendo fronteira com os municípios: Riachão, São Raimundo das Mangabeiras, Fortaleza dos Nogueiras, Tasso Fragoso, Alto Parnaíba, Novas Colinas, Sambaíba e Recursolândia-TO (PASSOS; ZAMBRZYCKI; PEREIRA, 2017; IBGE, 2023). O perímetro da área de estudo deste trabalho se limita à região sul do município, uma área que abrange pouco mais da metade da sua área total, mais especificamente, 6.642,009 km² (664.200,90 ha), como mostra a Figura 1.

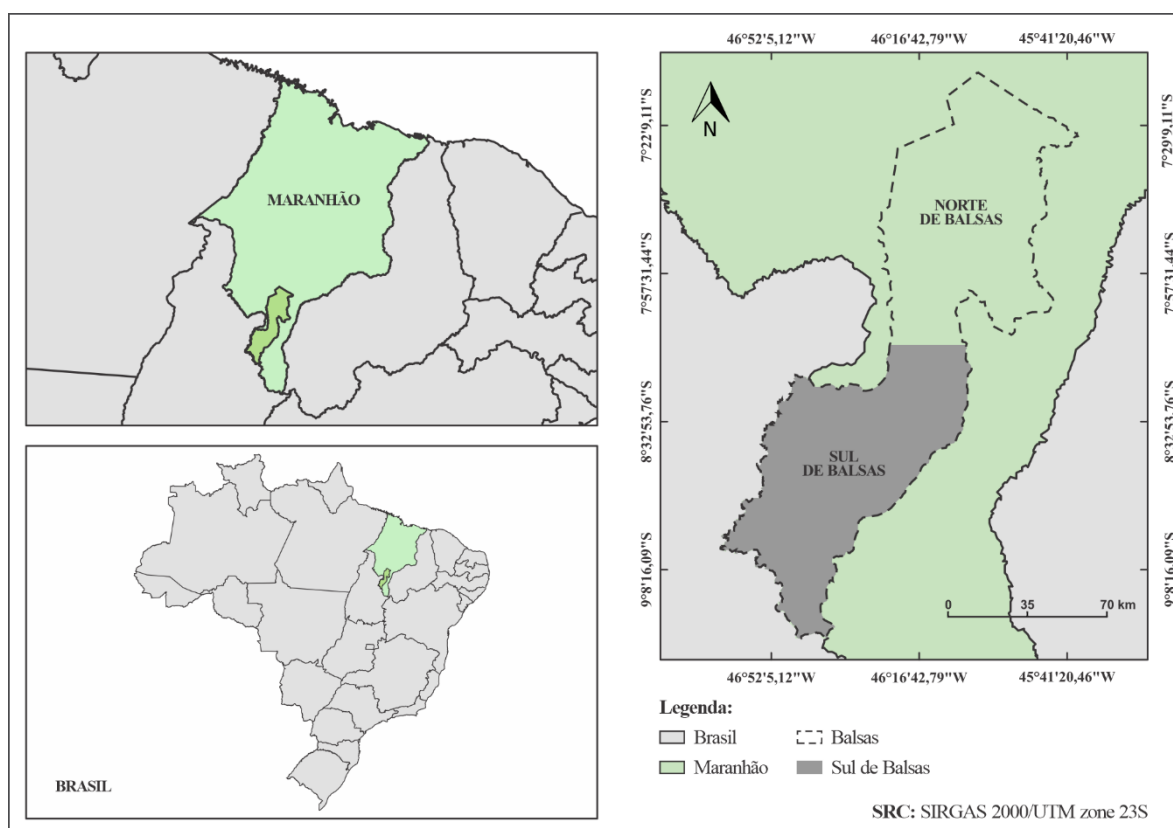


Figura 1. Região sul do município de Balsas, Maranhão, Brasil.

Fonte: Adaptado de IBGE.

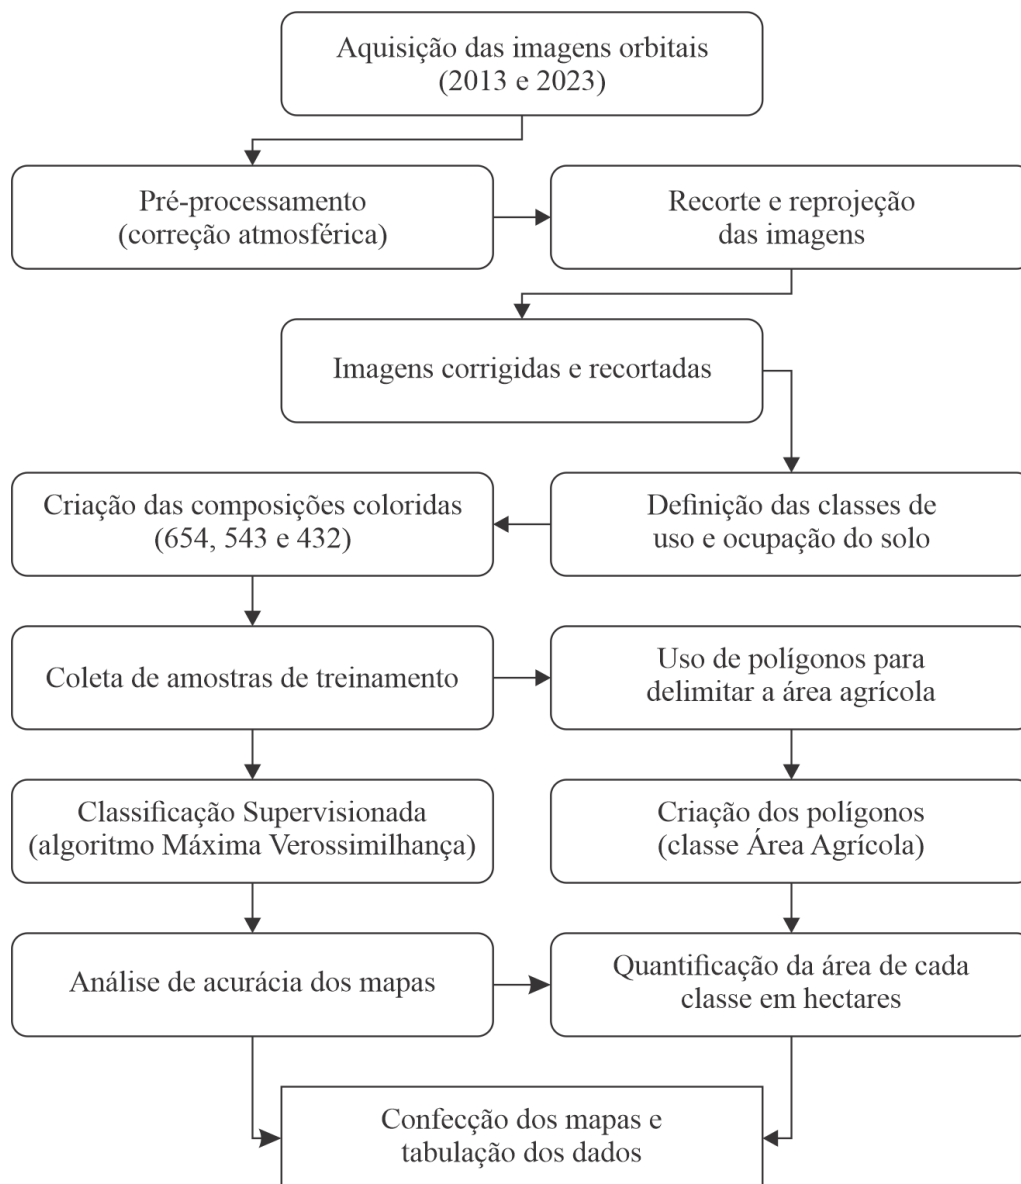


Figura 2. Fluxograma metodológico.

Fonte: O autor.

4.2. Seleção e aquisição das imagens do Landsat-8

As imagens utilizadas foram adquiridas gratuitamente do banco de dados da USGS, através da plataforma *Earth Explorer*. Dentro da plataforma é possível filtrar as informações de busca das imagens, como: região no globo, coordenadas do local, data da captura, percentual de incidência de nuvens, entre outros, o que possibilita a obtenção de resultados pontuais. Também é possível definir o conjunto de dados referente aos diversos serviços disponibilizados pela USGS a fim de obter as cenas registradas especificamente pelo satélite Landsat-8. A partir dos resultados da pesquisa, foram selecionadas as imagens que abrangiam todo o perímetro de interesse e que apresentavam baixa incidência de nuvens, fator que interfere na visualização da superfície e, conseqüentemente, nos resultados da classificação.

Nos anos de 2013 e 2023, foram selecionadas imagens dos dias 27 de junho e 23 de junho, respectivamente. As cenas utilizadas estão localizadas na órbita 221 e no ponto 66 do satélite Landsat-8. O conjunto de dados utilizado foi o *Landsat Collection 2 Level-1*, o mesmo disponibiliza dados de imageamento a partir do Landsat-4 até os atuais no Sistema de Referência de Coordenadas (SRC) WGS84 UTM zona 23N. Os dados referentes às imagens adquiridas estão expressos no Quadro 1.

Quadro 1. Cenas brutas adquiridas da USGS.

ID da Cena	Data da captura	Satélite	Datum/Projeção
LC82210662013178LGN02	27/06/2013	Landsat-8	WGS84/UTM 23N
LC82210662023174LGN00	23/06/2023	Landsat-8	WGS84/UTM 23N

Fonte: O autor.

4.3. Base cartográfica

O arquivo *shapefile* contendo a delimitação do município foi obtido no portal do IBGE Municípios. Posteriormente, esse arquivo passou por um processo de edição, utilizando a barra de ferramentas "Digitalizar". O objetivo desse procedimento foi remodelar a camada vetorial, destacando apenas a região de interesse deste trabalho.

4.4. Pré-processamento das imagens

Esta etapa do processo é essencial para qualquer processamento digital de imagens de satélite, uma vez que tem a função de preparar as imagens para as próximas fases do processamento. O pré-processamento das imagens, assim como todas as etapas da classificação supervisionada, foi realizado no software QGIS 3.16.9 *Hannover*. Para isso, foi utilizado o complemento *Semi-Automatic Classification Plugin* (SCP), este fornece as ferramentas necessárias para esse modelo de classificação, do pré ao pós-processamento das imagens, e pode ser adquirido através do Gerenciador de Complementos do software (CONGEDO, 2021).

De início, através do SCP, foram inseridas as bandas espectrais adquiridas da USGS aplicando o algoritmo de correção atmosférica *DOS1 atmospheric correction*, processo que corrige os valores de reflectância para reduzir o erro em regiões que apresentam sombra completa, assumindo um valor mínimo de 1% de reflectância para qualquer pixel, mesmo que esse apresente tais valores nulos. Isso se faz necessário devido ao fato de que poucos alvos na Terra são completamente pretos. Com isso, a reflectância das imagens brutas de

satélite é convertida para um parâmetro que varia entre valores próximos de 0 e 1, ou seja, entre 1 e 100% (CONGEDO, 2020; SANTOS, 2023).

As imagens corrigidas foram recortadas e reprojctadas para o SRC WGS84 UTM zona 23S, adequado para a região estudada. Com as imagens preparadas, foi criado um *band set*, processo que permitiu a criação de composições coloridas a partir do empilhamento das bandas espectrais, as quais serão utilizadas para identificação das classes de uso e ocupação do solo de interesse neste trabalho.

4.5. Medidas para mitigar erros no mapa

Ferreira et al. (2013) destacam a complexidade na classificação das fitofisionomias no bioma Cerrado, especialmente quando associada às atividades agropecuárias. A presença de áreas em regeneração, pastagens e pastos sujos dificulta a distinção espectral com formações savânicas e campestres, as quais se encaixam nas classes Floresta Rala e Áreas Não Florestais. As práticas de gerenciamento agropecuário, como rotação de culturas e sobrepastejo, resultam em diferentes níveis de degradação e biomassa, complicando a classificação. Essas informações ressaltam a necessidade de considerar influências humanas ao estudar e classificar esse bioma.

Com o objetivo de melhorar o resultado final e reduzir possíveis erros nos mapas, a delimitação da classe Área Agrícola foi realizada por meio da criação de polígonos. A decisão de excluir essa classe do processo de classificação supervisionada foi motivada pela sua geometria mais definida, apresentando poucas variações, o que facilitou a criação manual de um contorno. Durante o processamento, as classes Área Agrícola e Área Não Florestal foram inicialmente agrupadas como uma única classe na coleta de amostras e na geração do mapa preliminar. Posteriormente, foi necessário subtrair a área dos polígonos para distinguir a classe Área Não Florestal e finalizar o mapa.

O uso da ferramenta para caracterização de áreas de interesse através de polígonos, linhas e pontos pode ser uma estratégia eficaz em diversos tipos de estudos, especialmente quando se trata de alvos geometricamente regulares. Em um estudo ambiental, Torchetto et al. (2014) utilizaram essa ferramenta através do QGIS para a delimitação de parâmetros como área, vias de acesso e pontos de interesse em área impactada com a mineração para um Estudo de Impacto Ambiental, onde classificou, não só essa ferramenta, mas também o software

como um todo, como um bom método geotécnico para o planejamento de recuperação de áreas degradadas.

4.5.1. Delimitação com polígonos

Essa foi uma etapa completamente manual e complexa devido à grande quantidade de áreas relacionadas com práticas agrícolas presentes na região. Foi utilizada a barra de ferramentas “Digitalizar” para criação dos polígonos e edição de vértices. O arquivo vetorial correspondente foi criado com os campos “id” e “área em ha”, a fim de armazenar as informações de identificação dos polígonos e as áreas correspondentes a cada um.

Para seleção das áreas agrícolas, foi necessário realizar uma análise visual minuciosa da superfície de estudo, tendo como base as imagens disponíveis de cada período (2013 e 2023), sendo elas as composições coloridas utilizadas na fase de classificação supervisionada, imagens do Google Satélite, além de algumas composições geradas com bandas espectrais de satélites com melhor resolução espacial. Com a identificação desses alvos de interesse, foi possível criar e ajustar dezenas de polígonos ao longo de toda a área de estudo, priorizando o objetivo de abranger todas as regiões que visualmente apresentassem quaisquer atividades agropecuárias, mesmo que, por ora, não houvesse cobertura vegetal.

Finalmente, por meio da tabela de atributos do arquivo vetorial associado aos polígonos criados, realizou-se o cálculo das áreas correspondentes a cada polígono usando a ferramenta calculadora de campo. A função "\$area/10000" foi empregada para preencher o campo "área em ha" com valores de áreas dos polígonos convertidos para hectares. Essa abordagem permitiu a soma das áreas de todos os polígonos criados, proporcionando a determinação do total da área ocupada por atividades agropecuárias na região de interesse.

4.6. Classificação supervisionada das imagens

Considerada a principal fase do processamento das imagens, a classificação supervisionada é responsável por segmentar a área de estudo nas classes de interesse deste trabalho, ou seja, quantificar a área correspondente a cada classe nos diferentes anos (2013 e 2023) para a realização das comparações necessárias, além de gerar os mapas de classes de uso do solo. Para isso, são coletadas amostras ao longo da área de estudo para criação de assinaturas espectrais referentes a cada classe, essas são utilizadas como referência para o

algoritmo realizar a classificação da imagem por inteira, detectando regiões com as mesmas características espectrais das amostras (BARROS e PAMBOUKIAN, 2017).

A descrição seguinte apresenta todo o processo envolvendo a classificação individual de cada ano de análise. As subetapas necessárias para a realização da classificação supervisionada estão descritas a seguir em ordem cronológica:

a) Determinação das classes que serão extraídas da imagem: Floresta Densa, Floresta Rala, Área Agrícola e Área Não Florestal. Os nomes e descrições das classes foram determinados tendo como referência o Projeto MapBiomass (Tabela 1).

Tabela 1. Classes de uso e ocupação do solo adotadas para área de estudo.

Classe	Descrição
Floresta Densa	Formações que apresentam vegetação com predomínio de espécies arbóreas, com formação de dossel contínuo, além de um estrato herbáceo definido, podendo ser visualizadas em tons de verde claro (Figura 5).
Floresta Rala	Formações com estrato arbóreo menos denso, mas com estrato arbustivo-herbáceo definido, acarretando em um solo com boa cobertura superficial, podendo ser visualizada em tons de verde escuro (Figura 6).
Área Agrícola	Regiões que apresentam alguma atividade agropecuária, como agricultura, pastagem, silvicultura, etc., podendo apresentar diferentes cores na sua visualização dependendo da atividade que hospeda (Figura 7).
Área Não Florestal	Regiões de formações onde o solo se apresenta predominantemente exposto, apresentando desde regiões com fisionomia herbácea, com poucos arbustos e nenhuma árvore, até regiões rochosas com presença de ervas e arbustos, podendo ter arvoretas pouco desenvolvidas (Figura 8).

Fonte: O autor.

b) Criação de três composições RGB (*Red, Green e Blue*) utilizando a ferramenta de empilhamento de bandas (*band set*) do SCP, para identificação das classes presentes na superfície e coleta das amostras de treinamento: 654, 543 e 432. Os detalhes do empilhamento estão descritos no Quadro 2 e podem ser visualizados nas figuras 3 e 4.

Quadro 2. Composições coloridas de imagens orbitais do sensor OLI do satélite Landsat-8.

Imagens de entrada (bandas)	Descrição	Identificação
OLI6(R) OLI5(G) OLI4(B)	Análise da vegetação	Comp654
OLI5(R) OLI4(G) OLI3(B)	Avaliação da vegetação	Comp543
OLI4(R) OLI3(G) OLI2(B)	Cor natural	Comp432

Fonte: O autor.

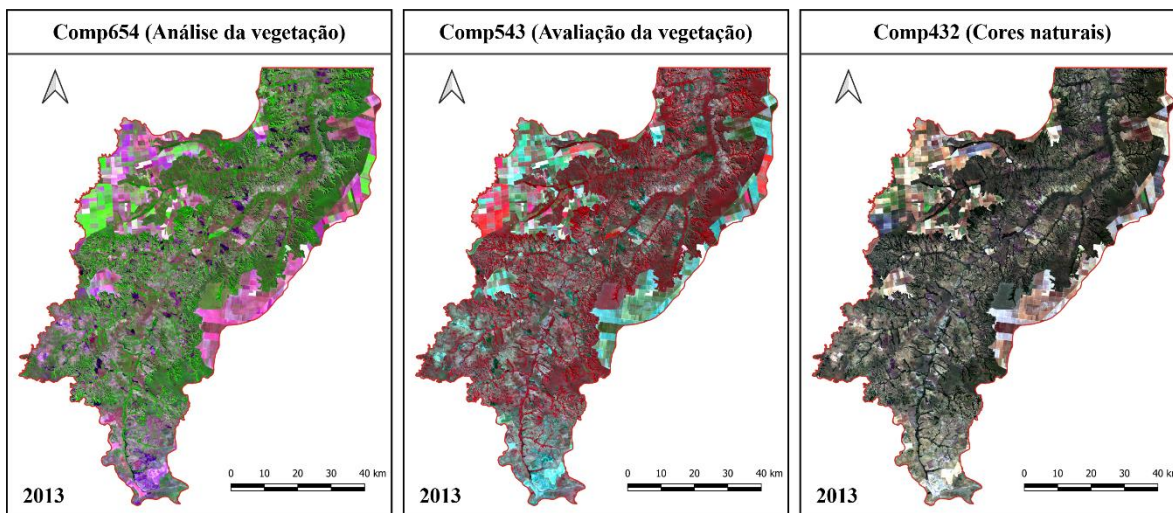


Figura 3. Composições coloridas utilizadas para coleta de amostras do ano de 2013.

Fonte: O autor.

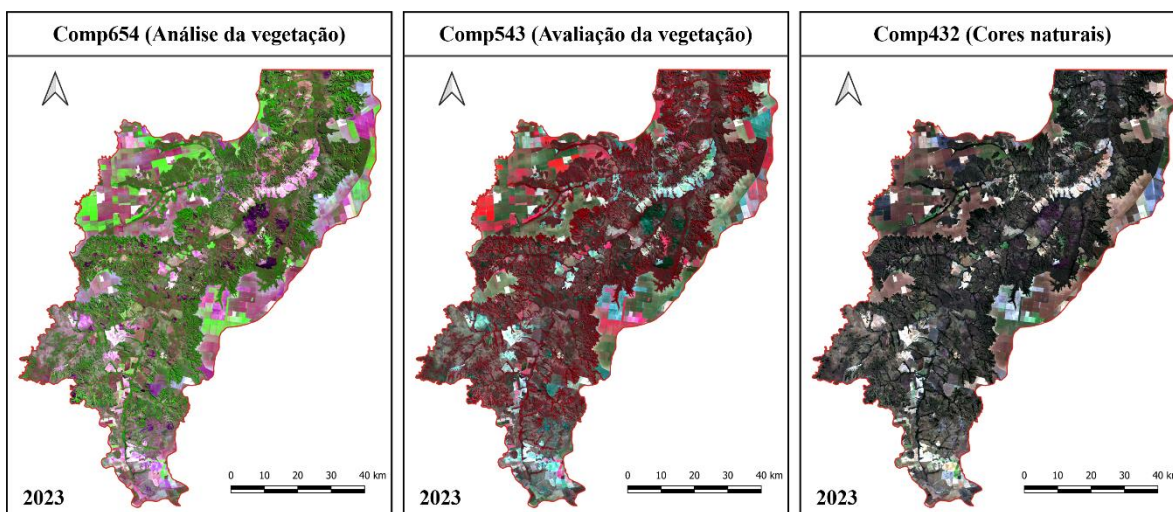


Figura 4. Composições coloridas utilizadas para coleta de amostras do ano de 2023.

Fonte: O autor.

c) Seleção das amostras de treinamento ao longo de toda a extensão da área de estudo utilizando a ferramenta de criação de polígonos do SCP. A coleta manual das amostras foi possível a partir da identificação visual dos alvos utilizando como base as composições coloridas e imagens do Google Satélite, disponibilizadas pelo complemento *Quick Maps Services*. Para cada classificação, foram selecionadas cerca de 500 amostras em proporções diferentes conforme a classe, número relativamente baixo para as dimensões da área de estudo, mas que foram suficientes para atingir boa precisão dos mapas. Abaixo estão alguns exemplos da identificação das classes a partir das imagens utilizadas:

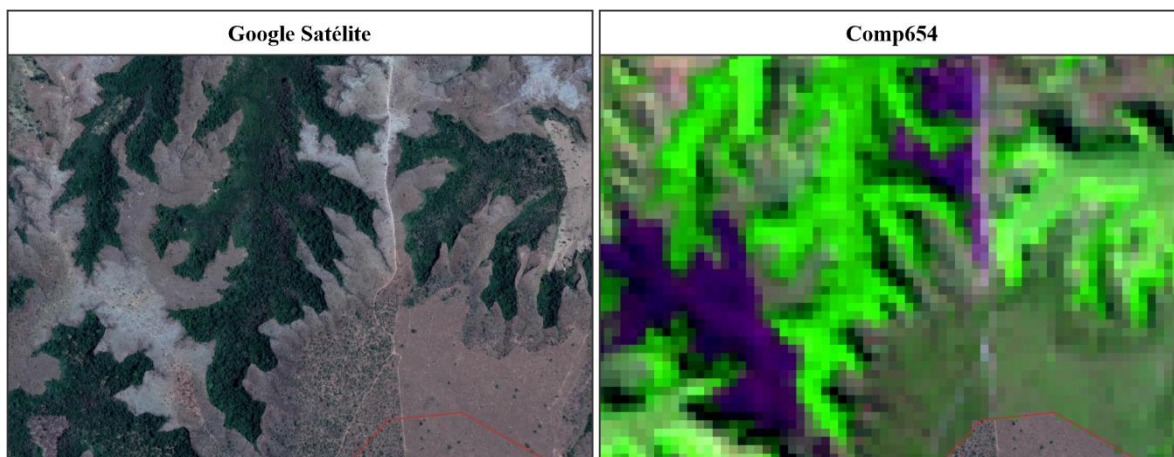


Figura 5. Exemplo de uma área com predominância da classe Floresta Densa visualizada através do Google Satélite e da composição 654.

Fonte: O autor.




Figura 6. Exemplo de uma área com predominância da classe Floresta Rala visualizada através do Google Satélite e da composição 654.

Fonte: O autor.




Figura 7. Exemplo de uma área com predominância da classe Área Agrícola visualizada através do Google Satélite e da composição 654.

Fonte: O autor.




Figura 8. Exemplo de uma área com predominância da classe Área Não Florestal visualizada através do Google Satélite e da composição 654.

Fonte: O autor.

As figuras 7 e 8 correspondem as classes que serão mescladas no processo de classificação. É possível notar uma semelhança quando comparadas as imagens do Google Satélite das duas classes, pois uma região da área de lavoura destacada apresenta solo exposto, característica comum da classe Área Não Florestal.

d) Seleção e aplicação do algoritmo de classificação:

Com todas as amostras de treinamento devidamente criadas, é possível selecionar o algoritmo de classificação que irá atuar no software. É possível optar por diferentes tipos de algoritmos de classificação supervisionada, cabendo ao usuário definir o mais apropriado para os objetivos e peculiaridades do projeto. Dentre os mais utilizados, pode-se citar alguns, como: Máxima Verossimilhança (Maxver), Método do Paralelepípedo e Distância Euclidiana. No SCP, estão disponíveis, além do Maxver, o de Mínima Distância e o de Mapeamento de Ângulo Espectral.

Para este estudo, foi aplicado o algoritmo da Máxima Verossimilhança, um dos métodos de classificação de imagens mais comuns quando se trata da classificação supervisionada. O método Maxver considera parâmetros estatísticos, como média e desvio padrão das assinaturas espectrais, para maximizar a probabilidade de observar os dados. O algoritmo utiliza uma função de probabilidade $P(x)$ para definir se um determinado pixel pertence a uma determinada classe. Basicamente, o pixel é atribuído à classe que maximiza a função $P(x)$, ou seja, à que possui maior probabilidade de pertencer. Ao utilizar parâmetros estatísticos, é necessário um número considerável de pixels para cada classe, a fim de

enriquecer a função $P(x)$ com mais informações e, assim, aprimorar a precisão dos dados nos mapas gerados (FERREIRA, 2020).

4.7. Pós-processamento e tabulação dos dados

Após a conclusão do mapa, é fundamental que este seja devidamente avaliado. O complemento utilizado para a verificação da qualidade dos resultados obtidos no processo de classificação supervisionada foi o AcATaMa (*Accuracy Assessment of Thematic Maps*), esse é um dos mais robustos para a avaliação da qualidade de projetos relacionados com a classificação do uso e cobertura do solo. O AcATaMa é projetado para avaliação da precisão de mapas temáticos gerados através de algoritmos de classificação supervisionada ou não supervisionada, ou seja, o plugin mede o quão próximo as informações do mapa temático estão da realidade (SMBYC, 2023).

Para aplicação do processo de avaliação da acurácia (precisão) do mapa temático, foi utilizado o método de Validação de Amostragem Aleatória Estratificada e a opção “Proporção Baseada em Área”. Com isso, o AcATaMa calculou automaticamente o tamanho total das amostras e o número de pontos para cada classe com base na proporção da área de cada classe no mapa. Foram criadas 396 e 397 amostras para os anos de 2013 e 2023, respectivamente, as quais foram distribuídas aleatoriamente ao longo dos mapas. Cada amostra foi interpretada pelo usuário com base em comparações com imagens do Google Satélite, composições coloridas e mosaicos com melhores resoluções. Com base na interpretação realizada, o complemento verifica esses dados de referência com os apresentados no mapa da classificação, retornando um diagnóstico acerca da qualidade do mesmo.

Os resultados da avaliação de acurácia são expressos em três tipos de variáveis: acurácias do produtor e do usuário, que apresenta resultados individuais para cada classe; e acurácia global, variável única que expressa o resultado geral da avaliação. A acurácia do produtor representa a porcentagem da área X que foi corretamente identificada como área X pelos classificadores, sendo influenciada pelo erro de omissão, onde ocorre a falha em mapear corretamente um pixel de determinada classe. Já a acurácia do usuário refere-se à porcentagem da área mapeada como área X que foi corretamente interpretada como tal pelo usuário, sendo afetada pelo erro de comissão, quando um pixel de uma classe é erroneamente atribuído a outra. A acurácia global é uma estimativa relacionada à proporção da área

classificada corretamente (LUZ et al., 2018). Os dados referentes à classificação supervisionada e os pontos de referência que determinam essas variáveis são relacionados em uma matriz de erro (Quadro 3).

Os dados de interesse disponibilizados nos relatórios desses processos computacionais foram tabulados e organizados no Microsoft Excel 2016. Dentro do software foi possível adaptar e complementar os dados estatísticos adquiridos nos processos já descritos para realizar as discussões desejadas neste trabalho.

Quadro 3. Matriz de erro, onde os elementos diagonais em destaque contêm o número de casos onde as classes e os pontos de referência representando a verdade de campo coincidem. As variáveis A, B, C e D correspondem às classes.

		<i>Referência</i>				
		A	B	C	D	Σ
<i>Classificação</i>	A	<i>n_{AA}</i>	<i>n_{AB}</i>	<i>n_{AC}</i>	<i>n_{AD}</i>	<i>n_{A+}</i>
	B	<i>n_{BA}</i>	<i>n_{BB}</i>	<i>n_{BC}</i>	<i>n_{BD}</i>	<i>n_{B+}</i>
	C	<i>n_{CA}</i>	<i>n_{CB}</i>	<i>n_{CC}</i>	<i>n_{CD}</i>	<i>n_{C+}</i>
	D	<i>n_{DA}</i>	<i>n_{DB}</i>	<i>n_{DC}</i>	<i>n_{DD}</i>	<i>n_{D+}</i>
	Σ	<i>n_{+A}</i>	<i>n_{+B}</i>	<i>n_{+C}</i>	<i>n_{+D}</i>	<i>n</i>

Fonte: Adaptado de Luz et al. (2018).

5. RESULTADOS E DISCUSSÃO

5.1. Uso e cobertura do solo para o ano de 2013

Os dados obtidos para o ano de 2013 apresentam maior proporção para a classe Floresta Rala, com cobertura de 34,8% da área, com distribuição ao longo de todo o mapa. A classe que mais se aproximou foi a Área Não Florestal, com 29,7% de cobertura, que se distribui nas partes mais centrais e predomina na região sul do mapa. Em seguida aparecem as classes Área Agrícola e Floresta Densa, com 23,1 e 12,4%, respectivamente (Tabela 2).

Totalizando as regiões de Floresta Densa e Rala, a área de estudo contava com 313.372,4 ha de florestas em sua cobertura no ano de 2013, tendo cerca de 47,2% de sua área ocupada com essas formações florestais no período. A menor abrangência da classe Floresta Densa se destaca tanto no mapa de classificação como nas composições coloridas e está relacionada com a maior especificidade das características dessa classe dentro da área de estudo (Tabela 2).

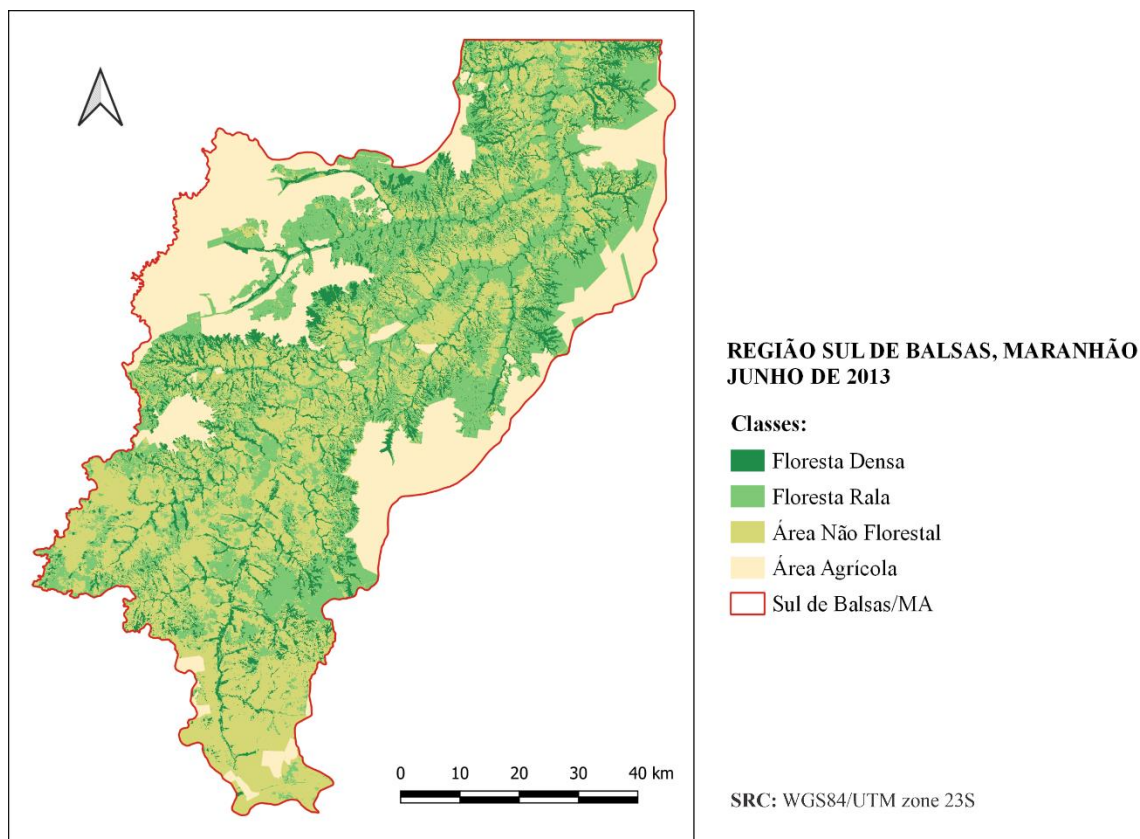


Figura 9. Mapa de uso e ocupação do solo da região sul do município de Balsas, Maranhão, para o ano de 2013.

Fonte: O autor.

As áreas de atividades agropecuárias já mostravam uma boa abrangência na região sul de Balsas, com 153.554 ha ocupados, representando cerca de 23,1% de ocupação, ao mesmo tempo em que a região já passava por uma revolução do agronegócio da região que se intensificou especialmente a partir dos anos 1990 com a produção de soja em grande escala (BRITO et al., 2020). Segundo o MapBiomas, as regiões do mapa ocupadas pela classe Área Agrícola apresentam como principal atividade a agricultura de lavouras temporárias e uma pequena ocupação de pastagens (Figura 9).

Vale destacar a alta cobertura da classe Área Não Florestal no mapa (Figura 9). Esse resultado pode estar relacionado com a grande abundância das formações naturais não florestais na região, principalmente a formação campestre e área pantanosa que ocorrem na região mais central do mapa, essas possuem características que coincidem com a descrição dessa classe. Tais formações são caracterizadas pela predominância de alguns estratos herbáceos, como campo limpo, campo sujo e campo rupestre (rochoso), e algumas formações savânicas, como o Cerrado rupestre. De forma geral, as formações savânicas predominam na região (MAPBIOMAS, 2023). Como descrito, essa classe abrange não apenas áreas com total ausência de cobertura vegetal, mas também áreas com características de campos.

Os dados quantitativos gerados para as áreas das classes estão expressos na Tabela 2, onde a mesma apresenta a classe Área Agrícola, extraída da área de estudo através dos polígonos, desanexada da classe Área Não Florestal, conforme foi especificado na metodologia. No processo de classificação supervisionada, essas duas classes foram agrupadas sob uma única categoria denominada "Área Não Flor./Agrícola", como pode ser evidenciado na Matriz de Erro (Tabela 3). Sendo assim, as variáveis Erro, Limite Inferior e Limite Superior referem-se à soma das áreas das duas classes, totalizando 350.828,4 ha.

Tabela 2. Área total das classes para a classificação supervisionada do ano de 2013.

Classe	Área (ha)	Área (%)	Erro	Limite Inferior	Limite Superior
Floresta Densa	82.051,5	12,4%	4.082,4	74.050,0	90.052,9
Floresta Rala	231.321,0	34,8%	8.107,5	215.430,3	247.211,6
Área Agrícola	153.554,0	23,1%	7.715,6	335.705,8	365.951,0
Área Não Florestal	197.274,4	29,7%			
Total	664.200,9				

Fonte: O autor.

Os resultados da análise do complemento AcATaMa para o ano de 2013 atingiram um bom resultado geral com 93,2% de acurácia global e um intervalo de confiança entre 91,9 e 94,5% com base no desvio padrão de 1,3%. Foi observado que das 396 amostras, 369 apresentaram concordantes com a classificação (Tabela 3).

O nível de acurácia relativamente alto é fundamental na confiabilidade do mapa, porém, vale destacar que imagens de alta resolução possibilitam uma melhor análise de acurácia no AcATaMa, visto a importância da identificação visual requerida nesse processo, algo que não foi possível para o ano de 2013 devido à escassez de mosaicos em alta qualidade para esse período, problema que foi contornado com o uso de outras composições coloridas (Tabela 3).

A classe Floresta Rala apresentou o menor erro de comissão, com 3,3%, e o maior erro de omissão, com 15,2%. Seguindo a mesma linha, a classe Área Não Flor./Agrícola obteve o menor erro de omissão, com apenas 1%, e o maior erro de comissão, com 9,2%. Os erros de comissão e omissão para a classe Floresta Densa foram satisfatórios, atingindo os valores, respectivamente, de 4,3 e 8,2% (Tabela 3).

Tabela 3. Matriz de Erro. Acurácia global, desvio padrão da acurácia global, acurácias do produtor e do usuário, erros de comissão e omissão para a classificação do ano de 2013.

Classes	Floresta Densa	Floresta Rala	Área Não Flor./Agrícola	Total	Acurácia do usuário (%)	Erro de comissão (%)
Floresta Densa	45	2	0	47	95,7%	4,3%
Floresta Rala	2	117	2	121	96,7%	3,3%
Área Não Flor./Agrícola	2	19	207	228	90,8%	9,2%
Total	49	138	209	396		
Acurácia do produtor (%)	91,8%	84,8%	99,0%	Acurácia global (%)	93,2%	
Erro de omissão (%)	8,2%	15,2%	1,0%	Desvio padrão	1,3%	

Fonte: O autor.

De acordo com Bochow et al. (2012), uma característica que eleva os erros na classificação são os corpos escuros presentes na superfície, como água, sombras de relevo, sombras de nuvens ou de rochas. A ocorrência desses alvos é comum na área, o que causa uma confusão espectral, podendo ocasionar em resultados distantes da realidade em áreas que apresentem esses tipos.

5.2. Uso e cobertura do solo para o ano de 2023

O mapa de classificação para o ano de 2023 apontou mudanças consideráveis no uso e cobertura do solo em relação a 2013, demonstrando, inclusive, uma nova classe predominante. Dessa vez, a classe que predomina em cobertura é a Área Agrícola, perfazendo 34% da área de estudo, pouco acima dos 33,8% da classe Floresta Rala, que antes liderava no quesito. A classe Área Não Florestal, que dessa vez é a terceira mais abrangente, ocupa cerca de 18,7% da área, à frente dos 13,5% ocupados pela Floresta Densa (Tabela 4). Na região sul do mapa, que antes era dominada pela classe Área Não Florestal, agora já apresenta diversos pontos de cultivos agrícolas, bem como as regiões centrais do mapa (Figura 10).

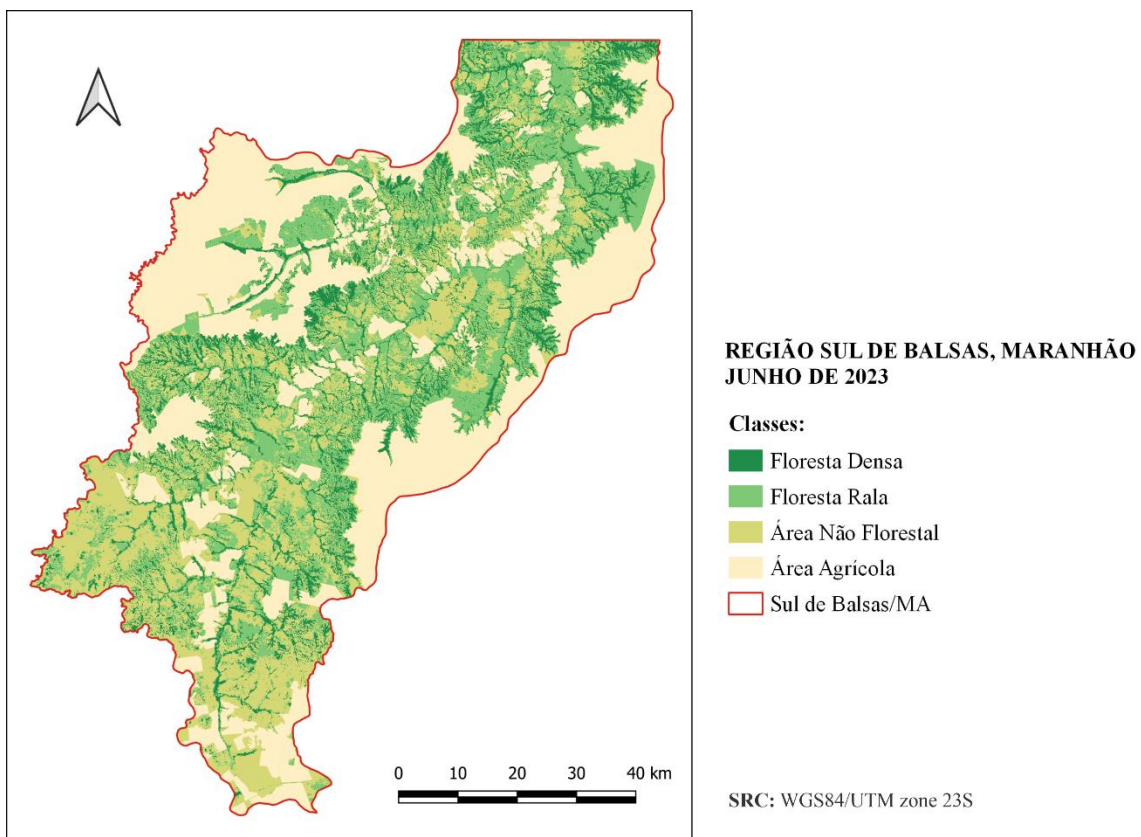


Figura 10. Mapa de uso e ocupação do solo da região sul do município de Balsas, Maranhão, para o ano de 2023.

Fonte: O autor.

As formações florestais naturais apresentaram um pequeno aumento nos 10 anos, com incremento para a classe Floresta Densa e redução para a Floresta Rala. Essa variação pode estar relacionada ao erro admitido para a classificação, que, se considerado, a torna estatisticamente nula, mas também à conservação e restauração natural das formações florestais da região (Figura 10).

A predominância da classe Área Agrícola ostenta os resultados do acentuado desenvolvimento agrícola do município, característica que o torna referência do agronegócio maranhense. Segundo o MapBiomas, a agricultura de lavouras temporárias permanece como a principal dentro dessa classe, porém, dessa vez é possível destacar a ocorrência de diversas áreas de pastagens, principalmente plantadas. Uma característica dessa atividade é a semelhança espectral com áreas de formação campestre, que corresponde à classe Área Não Florestal, isso resulta em uma eminente confusão na distinção e separação dessas classes.

Assim como os resultados do ano de 2013, em 2023 também há o agrupamento das classes Área Agrícola e Área Não Florestal na classificação, significando que as variáveis Erro, Limite Inferior e Limite Superior estão ligadas à soma das áreas das duas classes, totalizando 350.071,90 ha (Tabela 4).

Tabela 4. Área total das classes para a classificação supervisionada do ano de 2023.

Classe	Área (ha)	Área (%)	Erro	Limite Inferior	Limite Superior
Floresta Densa	89.862,5	13,5%	4.055,6	81.913,6	97.811,4
Floresta Rala	224.266,5	33,8%	10.275,1	204.127,2	244.405,7
Área Agrícola	225.824,0	34,0%	9.724,9	331.011,2	369.132,6
Área Não Florestal	124.247,9	18,7%			
Total	664.200,9				

Fonte: O autor.

Os resultados da análise do complemento AcATaMa para o mapa temático do ano de 2023 apresentou acurácia global de 88,9%, com um intervalo de confiança de 87,3 e 90,5%, baseando-se no desvio padrão de 1,6%. Observou-se que das 397 amostras aleatórias, 353 se apresentaram em concordância com a classificação (Tabela 5).

Tabela 5. Matriz de Erro. Acurácia global, desvio padrão da acurácia global, acurácias do produtor e do usuário, erros de comissão e omissão para a classificação do ano de 2023.

Classes	Floresta Densa	Floresta Rala	Área Não Flor./Agrícola	Total	Acurácia do usuário (%)	Erro de comissão (%)
Floresta Densa	49	1	0	50	98,0%	2,0%
Floresta Rala	4	98	3	105	93,3%	6,7%
Área Não Flor./Agrícola	1	35	206	242	85,1%	14,9%
Total	54	134	209	397		
Acurácia do produtor (%)	90,7%	73,1%	98,6%	Acurácia global (%)	88,9%	
Erro de omissão (%)	9,3%	26,9%	1,4%	Desvio padrão	1,6%	

Fonte: O autor.

Assim como na análise do ano de 2013, a classe Área Não Flor./Agrícola obteve o menor erro de omissão, com 1,4%, e o maior erro de comissão, com 14,9%. A classe Floresta Rala ainda manteve o maior erro de omissão, com 26,9%, porém, obteve um erro de comissão mais elevado, de 6,7%. O menor erro de comissão ficou para a classe Floresta Densa com 2%, e um de erro de omissão de 9,3%. Os resultados seguiram linhas parecidas de proximidade nas duas análises de acurácia, o que eleva a confiabilidade em relação ao critério adotado na coleta de amostras para a Classificação Supervisionada (Tabela 5).

Os resultados evidenciaram que os principais percentuais de erros em ambas as análises, associados à diminuição das acurácias do usuário e do produtor, concentram-se na omissão de amostras. Em outras palavras, pixels que não foram adequadamente capturados e atribuídos às suas respectivas classes, resultaram na redução da eficácia do algoritmo classificador.

Para uma área extensa como a abordada neste estudo, foram obtidos resultados que ressaltam a qualidade da classificação, possivelmente associada ao emprego de polígonos para mitigar questões relacionadas à precisão dos mapas quando diferentes classes apresentam semelhanças espectrais significativas. Embora a técnica seja trabalhosa, ela pode ser aplicada eficientemente na delimitação de áreas com geometrias regulares, como em

zonas agrícolas, porém, apresenta dificuldades consideráveis em áreas com geometria irregular ou indefinida.

5.3. Evolução espaço-temporal do uso e cobertura do solo

Através da análise dos dados mapeados nos anos de 2013 e 2023, foi possível quantificar e examinar a progressão das mudanças significativas no uso e cobertura do solo na região sul do município de Balsas - MA no período de análise de 10 anos. Os resumos dos dados obtidos com as classificações, assim como os cálculos de variações das áreas das classes ao longo dos anos, estão expressos na Tabela 6.

Tabela 6. Áreas das classes nos dois anos de estudo, 2013 e 2023, e suas respectivas variações.

Classe	2013		2023		Aumento/ Redução (%)
	Área (ha)	Área (%)	Área (ha)	Área (%)	
Floresta Densa	82.051,5	12,4%	89.862,5	13,5%	+ 9,5%
Floresta Rala	231.321,0	34,8%	224.266,5	33,8%	- 3,0%
Área Agrícola	153.554,0	23,1%	225.824,0	34,0%	+ 47,1%
Área Não Florestal	197.274,4	29,7%	124.247,9	18,7%	- 37,0%
Total	664200,9	100%	664200,9	100%	

Fonte: O autor.

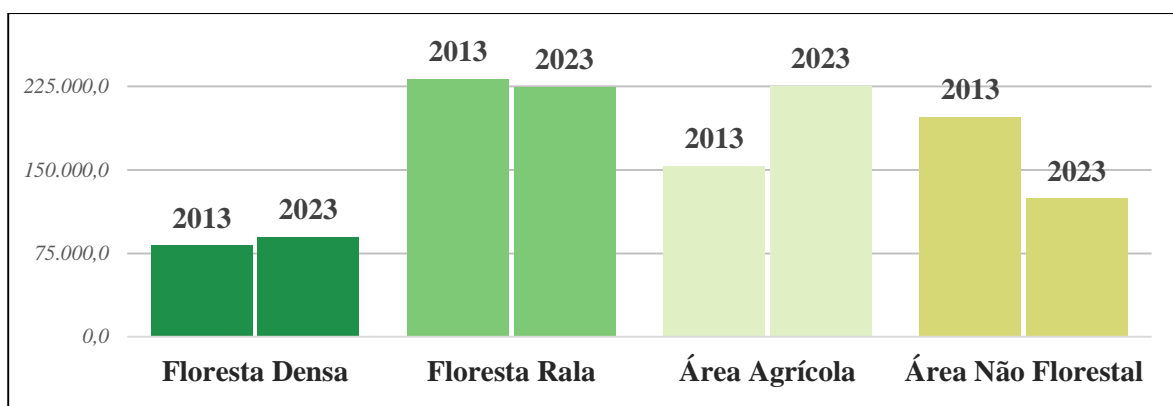


Figura 11. Gráfico de evolução das classes de uso do solo ao longo dos 10 anos de análise. Área, em ha x Classes de uso e ocupação do solo.

Fonte: O autor.

No gráfico da Figura 11 pode-se visualizar de forma mais intuitiva as variações ocorridas em uma mesma classe nos dois anos de análise. A princípio, é possível observar as pequenas variações que ocorreram nas classes Floresta Densa e Rala. Já com as demais classes, a mudança é evidente, principalmente o aumento e redução que ocorreram nas classes Área Agrícola e Área Não Florestal, respectivamente.

Com os resultados, observou-se uma perda substancial de área na classe Área Não Florestal, com uma redução significativa de 73.026,5 ha, valor expressivo que corresponde a 37% de redução de sua ocupação no intervalo de 10 anos. Por outro lado, as atividades agropecuárias expandiram-se, ocupando uma área adicional de 72.270 ha, representando um aumento de 47,1%.

A classe Floresta Rala registrou uma redução de 7.054,5 ha (3%), enquanto a classe Floresta Densa apresentou um aumento de 7.811 ha (9,5%) durante o mesmo período (Tabela 6). É notável que esses eventos dificilmente estão relacionados, uma vez que diversas regiões de floresta ralam foram substituídas por áreas agrícolas. Ambas as classes representam as formações florestais naturais, áreas onde a vegetação possui as melhores condições de cobertura do solo e densidade de árvores e plantas. Considerando ambas as classes, houve um acréscimo de 0,24% nas formações florestais, correspondendo a 756,5 ha.

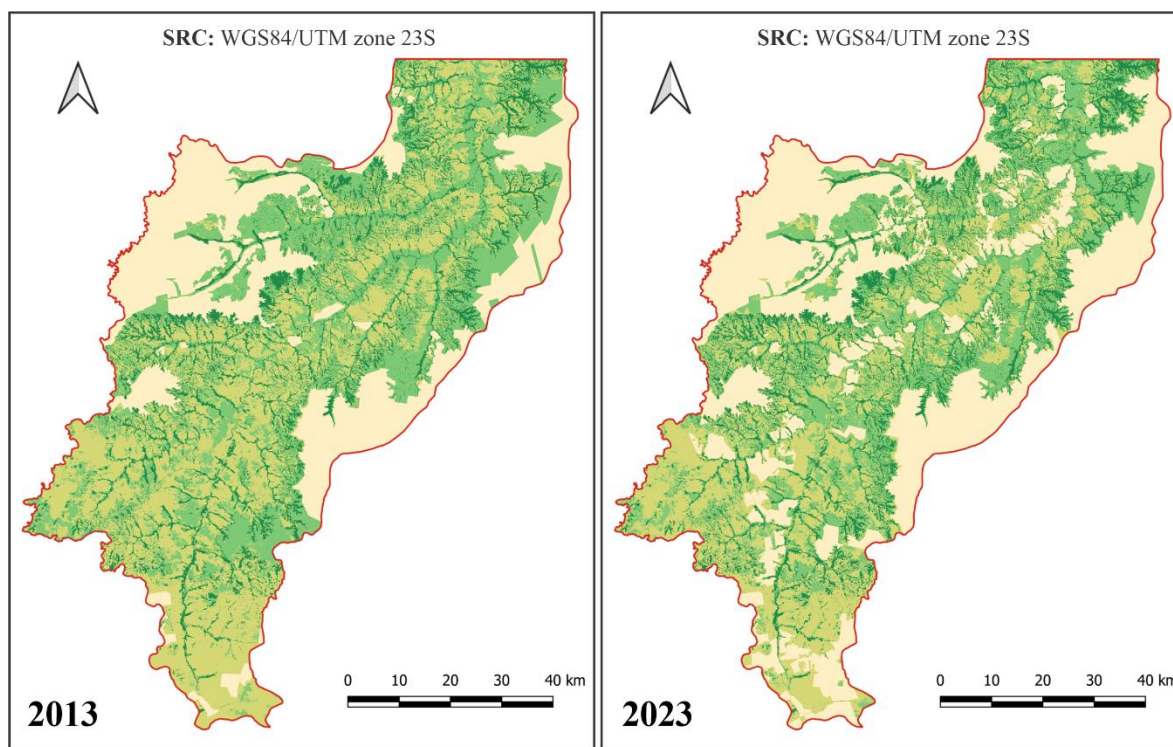


Figura 12. Comparação dos mapas de uso e cobertura do solo da região sul do município de Balsas, Maranhão, nos anos de 2013 e 2023.

Fonte: O autor.

A Figura 12 demonstra a distribuição das classes de forma comparativa e as transformações que ocorreram ao longo dos anos. É possível observar a distribuição mais periférica das áreas de atividade agrícola no ano de 2013, algo que se mantém no ano de 2023, mas com diversos incrementos ocorridos nas regiões mais centrais e sul do mapa. As

demais classes podem ser facilmente visualizadas com destaque para a grande abrangência da classe Área Não Florestal no ano de 2013, que sofreu acentuada redução comparada com o ano de 2023.

A cobertura expressiva da classe Área Não Florestal no ano de 2013 também pode ser visualizada na comparação entre as composições coloridas na Figura 13. As regiões em tons esbranquiçados, correspondem às áreas com pouca ou nenhuma vegetação que apresentam solo predominantemente descoberto, características definidas para essa classe, além de algumas atividades agropecuárias. Essas regiões estão evidentes especialmente na parte sul do mapa, diferente do ano de 2023 onde há uma maior presença de regiões verdes, representando formações florestais. Na comparação com os mapas de uso e ocupação do solo (Figura 12), é possível observar nas regiões centrais a substituição de áreas da classe Área Não Florestal pela classe Área Agrícola.

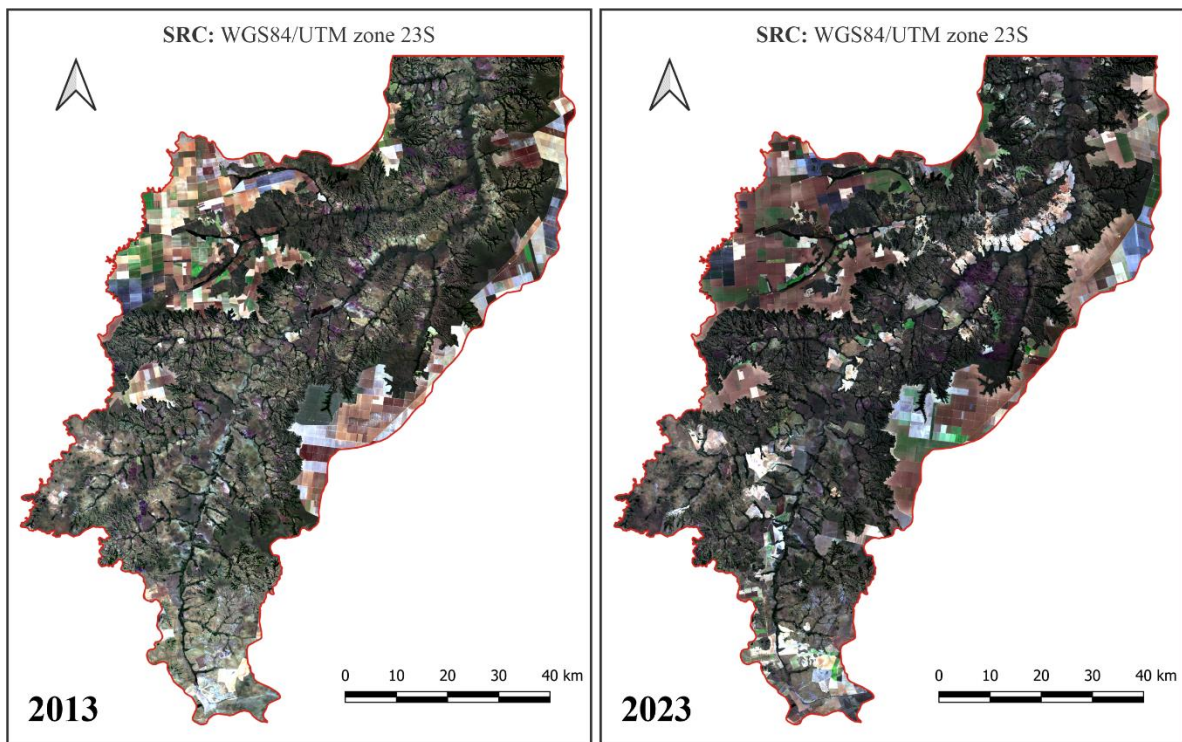


Figura 13. Comparação dos mapas coloridos (Comp432) da região sul do município de Balsas, Maranhão, nos anos de 2013 e 2023.

Fonte: O autor.

A partir dessas comparações qualitativas e quantitativas, é possível determinar que houveram alterações em todas as classes, umas mais significativas do que outras. A priori, é preciso destacar o aumento expressivo da classe Área Agrícola que está relacionado com o avanço na agricultura local. A Mesorregião Sul Maranhense é conhecida tradicionalmente

pela produção de soja no estado, tendo o município de Balsas como seu grande destaque. A produção da região foi consolidada na década de 1990 e vem apresentando um crescimento expressivo desde então (ALMEIDA e JÚNIOR, 2016).

As lavouras temporárias predominam na área de estudo e em todo o município de Balsas desde o primeiro ano de análise até os dias atuais (MAPBIOMAS, 2022), algo que foge do padrão do bioma Cerrado que, como descrito por Scaramuzza et al. (2017), tem a pastagem cultivada como a à principal atividade antrópica.

Segundo o IBGE (2022), a área plantada de lavouras temporárias em Balsas aumentou 57,5% entre 2013 e 2022, com destaque para as culturas de milho e soja, que cresceram 100,8 e 46,1%, respectivamente. Todo esse crescimento acarretou em uma disparada no valor da produção agrícola da cidade que evoluiu 430,9% no período.

Ainda de acordo com o MapBiomias (2022), é possível determinar que as pastagens foram destaque no aumento expressivo da classe Área Agrícola, uma vez que essa atividade não tinha grande representação no primeiro ano da análise. Atualmente, há diversos incrementos das regiões mais centrais ao sul do mapa do ano de 2023 (Figura 12). O incremento da área de pastagens durante o período analisado, embora não detalhado nesta pesquisa, está vinculado ao aumento do rebanho bovino no município de Balsas, que registrou um crescimento de 54,3% entre 2013 e 2022.

A expansão da agropecuária no município resultou na abertura de novas áreas, tanto nas regiões norte quanto sul, conforme analisado. Ao comparar visualmente os dois mapas, observa-se que os acréscimos nas regiões de atividades agropecuárias ocorrem principalmente em áreas que anteriormente eram classificadas como Área Não Florestal, além de pequenas extensões de Floresta Rala. Além disso, é válido mencionar que não houve uma substituição significativa quando se considera a classe Floresta Densa (Figura 12).

De acordo com os dados do MapBiomias, Balsas experimentou uma redução de 13,3% nas formações florestais entre 2013 e 2022. Contudo, é importante notar que este estudo se concentrou em uma área correspondente à metade da extensão da cidade, sendo apenas a região sul, o qual demonstrou um crescimento de 0,24% nessas formações, conforme já mencionado. Vale salientar também que as definições das classes no MapBiomias e neste trabalho não correspondem exatamente às mesmas características. Com base nessas

informações, pode-se sugerir que a maior parte da redução ocorreu na região norte do município, onde se encontra a zona urbana e as áreas periféricas associadas a ela.

No entanto, não é conclusivo afirmar que a região sul de Balsas experimentou incrementos simultâneos à redução na região norte. Isso se deve à existência de uma margem de erro a ser considerada para cada classe analisada. Neste caso, é possível que tenha ocorrido uma diminuição mínima das formações florestais na região sul, não detectada nas análises, mas que esteja dentro da margem de confiança da classificação. Mas também, é possível que essas áreas tenham se mantido preservadas ou mesmo passado por leves restaurações naturais.

A paridade entre os índices de incremento e redução das classes Floresta Densa e Rala é evidente. Ao comparar os mapas, nota-se um leve aumento nas áreas de atividades agropecuárias sobre regiões anteriormente classificadas como Floresta Rala (Figura 12). Isso descarta a hipótese de que as áreas da Floresta Rala foram restauradas para adquirir características de Floresta Densa, indicando, em vez disso, um modesto crescimento da Floresta Densa. O verificado foi que a maior parte da perda de área na classe Floresta Rala está atribuída ao avanço da agricultura local.

A problemática da fragmentação está intimamente ligada à perda de porções da vegetação, resultando na quebra da continuidade das florestas. No contexto deste estudo, as formações florestais mencionadas sofreram alterações mínimas, apesar do notável desenvolvimento da agricultura aqui discutido. Por outro lado, a classe Área Não Florestal apresentou uma redução significativa, cedendo espaço para a expansão de lavouras e, principalmente, pastagens. Esse fenômeno não apenas reflete a ampliação das atividades agrícolas, mas também aponta para uma transformação substancial do ambiente, com impactos ambientais consideráveis concentrados em regiões originalmente não florestais, as quais apresentam flora e fauna menos expressivas em comparação às formações florestais.

A análise da última década oferece uma perspectiva valiosa ao permitir a avaliação do impacto ao longo de um período temporal significativo. Contudo, uma abordagem temporal mais ampliada não apenas contribui para uma análise mais precisa, mas também fornece entendimentos cruciais para o desenvolvimento de estratégias de conservação e gestão sustentável, considerando o histórico de alterações e o potencial impacto futuro nas florestas da região.

Em muitos estudos relacionados à temática do desmatamento, é comum a adoção de uma categoria dedicada às regiões de solo exposto. Entretanto, neste trabalho, essa abordagem foi realizada de maneira distinta, pois as áreas de solo exposto foram enquadradas nas características adotadas para a classe Área Não Florestal. A localização da área de estudo na região rural do município elimina a presença de zonas urbanizadas significativas, que normalmente constituem a maior parte dessa categoria. Na área em questão, foram registradas apenas pequenas propriedades e estruturas com pouca influência espacial.

6. CONCLUSÕES

Em todos os anos analisados, as classificações demonstraram-se satisfatórias, atingindo níveis de acurácias global próximos a 90%, algo que aumenta a confiança nos dados obtidos com os procedimentos computacionais. Ainda, as acurácias individuais das classes se apresentaram acima dos 73% em todas as verificações, o que mostra a eficácia da metodologia empregada para estudos ambientais como este. Ressalta-se a importância de um conhecimento detalhado acerca da área de estudo para facilitar a identificação de alvos, seja por meio de análise visual ou imagens de satélite de alta resolução.

A classe Área Agrícola foi o destaque das transformações ocorridas na região sul do município de Balsas, estado do Maranhão. Isso evidencia o acentuado desenvolvimento da agricultura e pecuária do município, resultado de grandes investimentos em inovações tecnológicas voltadas a esse setor da economia.

Com base nisso, é possível afirmar que houve conservação das formações florestais nativas na região estudada. Apesar de pequenas variações e incrementos em algumas áreas, não se percebe uma alteração expressiva nas características das formações florestais ao longo do período analisado. Essa estabilidade sugere que, em grande parte, as formações florestais nativas foram preservadas na região sul do município, no que se refere à última década, mesmo diante de pressões antrópicas, como o avanço da agricultura.

Conseqüentemente, os registros apontam que as reduções significativas na cobertura vegetal ocorreram de maneira proeminente na classe Área Não Florestal. Essa constatação ressalta a concentração das alterações ambientais e da diminuição da vegetação em áreas originalmente classificadas como não pertencentes ao contexto florestal.

As ferramentas geoespaciais utilizadas demonstraram eficácia, destacando-se positivamente na avaliação de acurácia dos mapas pelo complemento AcATaMa. O uso do complemento SCP permitiu a segmentação de uma área com notáveis variações espectrais em sua cobertura, mesmo com uma amostragem relativamente reduzida. Verificou-se que em situações de desempenho inferior da classificação, como as observadas neste estudo, é possível compensar adotando técnicas paralelas, como o uso de polígonos.

7. REFERÊNCIAS

AcATaMa. **SMBYC**, 2023. Disponível em: <<https://smbyc.github.io/AcATaMa/>>. Acesso em: 08 nov. 2023.

ALMEIDA, D. N. O. et al. Uso e cobertura do solo utilizando geoprocessamento em municípios do Agreste de Pernambuco. **Revista Brasileira de Meio Ambiente**, v. 4, n. 1, P. 58-68, 2018.

ALMEIDA, J. G.; JÚNIOR, J. S. A dinâmica da produção de soja no município de Brejo (MA) e seus reflexos na produção agrícola camponesa. **Campo-Território: revista de geografia agrária**, Uberlândia, v. 11, n. 24, p. 374-399, 2016.

ANDRADE, Á. S. et al. Fragmentação da vegetação da bacia hidrográfica do Rio Marapanim, nordeste do Pará. **Ciência Florestal**, Santa Maria, v. 30, n. 2, p. 406-420, 2020.

ASCIUTTI, G. A. M.; STANGANINI, F. N.; MELANDA, E. A. Identificação dos diferentes usos e ocupação do solo na Bacia Hidrográfica do Rio do Quilombo, São Carlos/SP utilizando imagem do Satélite Sentinel 2 e o complemento SCP do Qgis. **Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto**, 2019.

BARROS, A. S.; FARIAS, L. M.; MARINHO, J. L. A. Aplicação do Índice de Vegetação por Diferença Normalizada (NDVI) na Caracterização da Cobertura Vegetativa de Juazeiro do Norte – CE. **Revista Brasileira de Geografia Física**, v. 13, n. 06, p. 2885-2895, 2020.

BARROS, E. O.; PAMBOUKIAN, S. V. D. Análise do desastre em Mariana através da classificação supervisionada de imagens de sensoriamento remoto. **Revista Mackenzie de Engenharia e Computação**, São Paulo, v. 17, n. 1, p. 8-26, 2017.

BEZERRA, U. A. et al. Comparativo do Índice de Vegetação de Diferença Normalizada (NDVI) entre os Sensores OLI - Satélite Landsat-8 e MSI – Satélite Sentinel-2 em Região Semiárida. **Anuário do Instituto de Geociências – UFRJ**, v. 41, n. 3, p. 167-177, 2018.

BOCHOW, M. et al. On the use of airborne imaging spectroscopy data for the automatic detection and delineation of surface water bodies. In: **Remote sensing of planet earth**. InTech, 2012. p. 1-22.

BORGES, M. G.; RODRIGUES, H. L. A.; LEITE, M. E. Sensoriamento remoto aplicado ao mapeamento do Cerrado no Norte de Minas Gerais e suas fitofisionomias. **Caderno de Geografia**, v. 29, n. 58, p. 819-835, 2019.

BRITO, M. S.; BERALDO, K. A.; SOUSA, D. N.; GONÇALVES, L. M. Políticas Públicas para a Agricultura Familiar: Análise do PRONAF nas Comunidades Rurais de Balsas/MA. **Revista Humanidades e Inovação**, v.8, n. 56, p. 41-57, 2020.

CONGEDO, L. Semi-Automatic Classification Plugin Documentation. **Release**, v. 6, n. 4.0.2, p. 243, 2020.

CONGEDO, L. Semi-Automatic Classification Plugin: A Python tool for the download and processing of remote sensing images in QGIS. **Journal of Open Source Software**, v. 6, n. 64, p. 6, 2021.

COSTA, A. L. **Dinâmica do uso e ocupação do solo no município de Arcoverde – PE usando sensoriamento remoto**. 2019. 110 f. Tese (Doutorado em Engenharia Agrícola) – Programa de Pós-Graduação em Engenharia Agrícola, Universidade Federal de Pernambuco, Recife, 2019.

COSTA, F. G. et al. Conhecendo o Cerrado: aulas de campo e sua importância para o conhecimento e preservação ambiental. **Research, Society and Development**, v. 9, n. 10, 2020.

D'ARROCHELLA, M. L. G.; SILVA, I. B. Observações iniciais sobre o padrão de fragmentação da floresta amazônica na fronteira de expansão agrícola ao redor da Reserva Kayapó, Sudeste do Pará. **Revista Mutirão (Folhetim de Geografias Agrárias do Sul)**, v. 1, n. 3, p. 241-266, 2020.

ENCINA, C. C. C. et al. Análise da Estrutura Vegetal de Fragmentos do Bioma Cerrado Através de Sensoriamento Remoto. **Anuário do Instituto de Geociências**, v. 41, n. 2, p. 585-597, 2018.

FERREIRA, A. L. S.; PASA, M. C. O uso de geotecnologia aplicada ao monitoramento de desmatamento do Pantanal Mato-grossense. **Advances in Forestry Science**, Cuiabá, v. 2, n. 2, p. 41-47, 2015.

FERREIRA, D. M. **Mudanças de uso e cobertura da terra na bacia do rio Lajeado, estado do Maranhão**. 2020. 69 f. Dissertação (Mestrado em Agricultura e Ambiente) - Programa de Pós-Graduação em Agricultura e Ambiente, Universidade Estadual do Maranhão, Balsas, 2020.

FERREIRA, L. G.; SANO, E. E.; FERNANDEZ, L. E.; ARAÚJO, F. M. Biophysical characteristics and fire occurrence of cultivated pastures in the Brazilian savanna observed by moderate resolution satellite data. **International Journal of Remote Sensing**, v. 34, n. 1, p. 154-167, 2013.

FIORIO, P. R. **Sistemas Sensores**. 2020. Apresentação em Slide Share. 132 slides. color. Aula do Dep. Eng. de Biossistemas - ESALQ/USP. Disponível em: https://edisciplinas.usp.br/pluginfile.php/5821773/mod_resource/content/0/AULA_SISTEMAS_SENSORES_2020.pdf. Acesso em: 10 mai. 2023.

FITZ, P. R. Classificação de imagens de satélite e índices espectrais de vegetação: uma análise comparativa. **Geosul**, Florianópolis, v. 35, n. 76, p. 171-188, 2020.

GUEDES, J. C. F.; SILVA, S. M. P. Sensoriamento remoto no estudo da vegetação: princípios físicos, sensores e métodos. **ACTA Geográfica**, Boa Vista, v.12, n.29, p. 127-144, 2018.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Pesquisa da Pecuária Municipal, 2022**. Disponível em: <<https://sidra.ibge.gov.br/tabela/3939>>. Acesso em: 07 dez. 2023.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Produção Agrícola – Lavouras Temporárias – Balsas, 2022**. Disponível em: <<https://cidades.ibge.gov.br/brasil/ma/balsas/pesquisa/14/10193>>. Acesso em: 06 dez. 2023.

JÚNIOR, J. J. F.; DANTAS, M. J. F. Análise do albedo da superfície e índices de vegetação por sensoriamento remoto na bacia hidrográfica do rio Pacoti/CE. **Revista Tecnologia**, v. 39, n. 2, p. 1-18, 2018.

LIMA, B. C.; FRANCISCO, C. N.; BOHRER, C. B. A. Deslizamentos e fragmentação florestal na região serrana do estado do Rio de Janeiro. **Ciência Florestal**, Santa Maria, v. 27, n. 4, p. 1283-1295, 2017.

LOPEZ, M. A. et al. **Um algoritmo não supervisionado e rápido para seleção de características em classificação de tráfego**. 2017.

LUZ, N. B. et al. **Manual de análise de paisagem: volume 2: procedimentos para a execução do controle de qualidade do mapeamento de uso e cobertura da terra**. v. 2. Colombo: Embrapa Florestas, 2018.

NASCIMENTO, T. V.; FERNANDES, L. L. Mapeamento de uso e ocupação do solo em uma pequena bacia hidrográfica da Amazônia. **Ciência e Natura**, v. 39, n. 1, p. 169-177, 2017.

No setor do Agronegócio, Balsas é destaque no PIB do Maranhão. **UNIBALSAS**, 2020. Disponível: <<https://www.unibalsas.edu.br/no-setor-do-agronegocio-balsas-e-destaque-no-pib-do-maranhao/>>. Acesso em: 25 mai. 2023.

Pacto Regional PCI Região de Balsas, Maranhão, Brasil. **IDH Transforming Markets**, 2021. Disponível em: <<https://idhlatam.com/onde-estamos/pactos-regionais-pci/regiao-de-balsas-ma/>>. Acesso em: 25 mai. 2023.

Panorama de Balsas. **IBGE Cidades**, 2023. Disponível em: <<https://cidades.ibge.gov.br/brasil/ma/balsas/panorama>>. Acesso em: 17 mai. 2023.

PASSOS, M. L. V.; ZAMBRZYCKI, G. C.; PEREIRA, R. S. Balanço hídrico climatológico e classificação climática para o município de Balsas-MA. **Scientia Agraria**, v. 18, n. 1, p. 83-89, 2017.

Projeto MapBiomias – Coleção 8.0 da Série Anual de Mapas de Cobertura e Uso da Terra do Brasil. Disponível em: <<https://plataforma.brasil.mapbiomas.org/cobertura>>. Acesso em: 01 dez. 2023.

REIS, A. F.; SCHMIELE, M. Características e potencialidades dos frutos do Cerrado na indústria de alimentos. **Brazilian Journal of Food Technology**, Campinas, v. 22, 2019.

ROCHA, M. I. S.; NASCIMENTO, D. T. F. Distribuição espaço-temporal das queimadas no bioma Cerrado (1999/2018) e sua ocorrência conforme os diferentes tipos de cobertura e uso do solo. **Revista Brasileira de Geografia Física**, v. 14, n. 03, p. 1220-1235, 2021.

RODRIGUES, V. V.; TERRA, A. Conflitos socioespaciais entre os agricultores tradicionais e sojicultores no município de Balsas Maranhão. **Brazilian Journal of Development**, Curitiba, v. 4, n. 4, p. 1196-1216, 2018.

ROSCOE, B. Desmatamento no primeiro trimestre de 2023 bate recorde no Cerrado, segundo dados do Inpe. **CBN – Globo Rádio**, Brasília, 07 de abr. 2023. Disponível em: <<https://cbn.globoradio.globo.com/media/audio/405240/desmatamento-no-primeiro-trimestre-de-2023-bate-re.htm>>. Acesso em: 13 abr. 2023.

ROSSI, R. F. **Respostas de comunidade de aves à fragmentação florestal no Cerrado**. 2016. 88 f. Dissertação de Mestrado (Mestrado em Zoologia) – Instituto de Ciências Biológicas, Universidade de Brasília, Brasília, 2016.

SAITO, N. S.; MOREIRA, M. A.; SANTOS, A. R.; EUGENIO, F. C.; FIGUEIREDO, Á. C. Geotecnologia e Ecologia da Paisagem no Monitoramento da Fragmentação Florestal. **Floresta e Ambiente**, v. 23, n. 2, p. 201-210, 2016.

SANO, E. E. et al. Land use dynamics in the Brazilian Cerrado in the period from 2002 to 2013. **Pesquisa Agropecuária Brasileira**, Brasília, v. 54, 2019.

SANTOS, A. R. Vídeo (13:03 min). **Aula 36 - SCP - Parte 02 - Correção Atmosférica no QGIS**. Publicado pelo canal Mundo da Geomática, 2023. Disponível em: <<https://www.youtube.com/watch?v=bv1fevCWYzw>>. Acesso em: 16 nov. 2023.

SCARAMUZZA, C. A. M. et al. Mapeamento de Uso e Cobertura de Terras do Cerrado com Base Principalmente em Imagens do Satélite Landsat-8. **Revista Brasileira de Cartografia**, Rio de Janeiro, n. 69/6, p. 1041-1051, 2017.

SCHLEICH, A. P.; FILHO, J. B. R.; LAHM, R. A. Aplicações do sensoriamento remoto em estudos ambientais. **Educação Ambiental em Ação**, v. 20, n. 78, 2022.

SERGIEIEVA, K. Imagens de Satélite Gratuitas: As Principais Fontes. **EOS Data Analytics**, 2020. Disponível em: <<https://eos.com/pt/blog/imagens-de-satelite-gratuitas/>>. Acesso em: 10 mai. 2023.

SILVA, C. O. et al. Efeito de borda sobre o componente arbóreo de um fragmento do Morro da Harmonia, município de Teutônia, Rio Grande do Sul, Brasil. **Revista Geoaraguaia**, v. 9, n. 1, p. 6-17, 2019.

SOTHE, C. et al. Evaluating Sentinel-2 and Landsat-8 data to map sucessional forest stages in a subtropical forest in Southern Brazil. **Remote Sensing**, v. 9, n. 8, p. 838, 2017.

TURCHETTO, N. L. et al. O uso do Quantum Gis (QGIS) para caracterização e delimitação de área degradada por atividade de mineração de basalto no município de Tentente Portela (RS). **Revista Eletrônica em Gestão, Educação e Tecnologia Ambiental**, Santa Maria, v. 18 n. 2, p. 719-726, 2014.

VALE, J. R. B. et al. Análise comparativa de métodos de classificação supervisionada aplicada ao mapeamento da cobertura do solo no município de Medicilândia, Pará. **InterEspaço**, Grajaú, v. 4, n. 13, p. 26-44, 2018.

VIEIRA, L. F. F. **O agronegócio no Brasil, uma visão geo-econômica do avanço da Commodite Soja na região do Matopiba: o caso Balsas-MA, a cidade do agronegócio**. 2019. 27 f. Trabalho de Conclusão do Curso (Bacharelado em Geografia) – Centro de Ciências Exatas e da Natureza, Universidade Federal da Paraíba, João Pessoa-PB, 2019.

ZAIDAN, R. T. Geoprocessamento conceitos e definições. **Revista de Geografia-PPGEO-UFJF**, Juiz de Fora, v. 7, n. 2, p. 195-201, 2017.