

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
INSTITUTO DE GEOGRAFIA, GEOCIÊNCIAS E SAÚDE COLETIVA

RAYSSA SANTOS BARBOSA

**AVALIAÇÃO DA ACURÁCIA DO MAPEAMENTO TEMÁTICO CONSIDERANDO
IMAGENS MULTIRESOLUÇÃO**

Monte Carmelo

2025

RAYSSA SANTOS BARBOSA

**AVALIAÇÃO DA ACURÁCIA DO MAPEAMENTO TEMÁTICO CONSIDERANDO
IMAGENS MULTIRESOLUÇÃO**

Trabalho de Conclusão de Curso apresentado à
Universidade Federal de Uberlândia como
requisito parcial para obtenção do título de
bacharel em Engenharia de Agrimensura e
Cartográfica.

Área de concentração: Sensoriamento remoto

Orientador: Prof.º Dr. George Deroco Martins

Monte Carmelo

2025

RAYSSA SANTOS BARBOSA

**AVALIAÇÃO DA ACURÁCIA DO MAPEAMENTO TEMÁTICO CONSIDERANDO
IMAGENS MULTIRESOLUÇÃO**

Trabalho de Conclusão de Curso apresentado à
Universidade Federal de Uberlândia como
requisito parcial para obtenção do título de
bacharel em Engenharia de Agrimensura e
Cartográfica.

Área de concentração: Sensoriamento remoto.

Monte Carmelo, 11 de julho de 2025.

Banca Examinadora:

Prof.º Dr. George Deroco Martins

Prof.º Dr. Sérgio da Conceição Alves

Eng. Lucas Henrique Vicentini Viana de Carvalho

*Dedico este trabalho aos meus pais, que sob
muita luta fizeram-me chegar até aqui.*

AGRADECIMENTOS

Em primeiro lugar, agradeço a Deus, cuja luz e força me guiaram em cada etapa desta jornada, inspirando-me a superar desafios e a seguir em frente com fé e determinação.

À minha família, meu eterno reconhecimento: aos meus pais, pelo amor incondicional, pelo apoio inabalável e por acreditarem em mim mesmo nos momentos mais desafiadores. Suas palavras de incentivo foram o alicerce que me sustentou. Ao meu irmão caçula, que mesmo distante, sempre soube transmitir seu carinho e admiração, fortalecendo-me com seu afeto.

Aos meus amigos, que caminharam ao meu lado ao longo destes anos, compartilhando risadas, conselhos e momentos inesquecíveis – vocês foram minha rede de apoio e alegria, e cada um de vocês deixou uma marca fundamental nesta trajetória.

Por fim, mas não menos importante, ao meu orientador Prof.º George Deroco Martins, pela paciência, sabedoria e dedicação ao longo deste processo. Sua orientação não apenas enriqueceu meu conhecimento acadêmico, mas também me ensinou lições valiosas que levarei para toda a vida. Muito obrigado por compartilhar seu conhecimento e por acreditar no meu potencial.

Esta conquista não seria possível sem cada um de vocês.

RESUMO

A constante evolução da humanidade tem provocado alterações significativas na paisagem, demandando de métodos eficientes para o monitoramento das mudanças de uso e cobertura do solo. Nesse contexto, o Sensoriamento Remoto destaca-se como uma ferramenta crucial para o acompanhamento e mitigação dessas alterações, além de servir como suporte para o planejamento de futuras intervenções. Desse modo, o presente trabalho avaliou a acurácia do mapeamento temático de uso e ocupação do solo, utilizando imagens dos satélites CBERS 04A (China–Brazil Earth Resources Satellite), Sentinel-2 e PRISMA (PRecursore IperSpettrale della Missione Applicativa), visando identificar o satélite mais eficiente. Para condução deste estudo, as imagens provenientes dos satélites citados foram processadas a partir dos softwares QGIS e ENVI *Classic*, utilizando o método de classificação supervisionada, a fim de gerar mapas de uso e ocupação do solo. No processo de classificação, foram testados os algoritmos Paralelepípedo, Distância Mínima, Distância de Mahalanobis, Máxima Verossimilhança, Redes Neurais e *Support Vector Machine*, para analisar a eficácia dos classificadores na discriminação dos alvos. A validação dos resultados foi realizada mediante matrizes de confusão, cálculo do Índice Kappa e Exatidão Global. Os resultados demonstraram que o satélite PRISMA com o algoritmo Distância de Mahalanobis obteve o melhor desempenho dentre todas as classificações, com Índice Kappa de 0,9516 e Exatidão Global de 95,85%. O satélite Sentinel-2 mostrou resultados consistentes em diversos classificadores, destacando-se como a opção mais equilibrada, devido aos valores excelentes na maioria dos algoritmos testados. O CBERS 04A obteve resultados inferiores, mas ainda robustos. Ao final, foram gerados mapas de uso e ocupação do solo dos melhores modelos de classificação para cada satélite.

Palavras-chave: mapas de uso e ocupação do solo; satélites; classificação supervisionada; resoluções da imagem.

ABSTRACT

The constant evolution of humanity has caused significant changes in the landscape, demanding efficient methods for monitoring land use and land cover changes. In this context, Remote Sensing stands out as a crucial tool for tracking and mitigating these changes, as well as supporting the planning of future interventions. Thus, this study evaluated the accuracy of thematic mapping of land use and land cover using images from the CBERS 04A (China–Brazil Earth Resources Satellite), Sentinel-2, and PRISMA (Hyperspectral Precursor of the Application Mission) satellites, aiming to identify the most efficient satellite. To conduct this study, images from the aforementioned satellites were processed using QGIS and ENVI Classic software, employing the supervised classification method to generate land use and land cover maps. During the classification process, the following algorithms were tested: Parallelepiped, Minimum Distance, Mahalanobis Distance, Maximum Likelihood, Neural Networks, and Support Vector Machine, to analyse the effectiveness of the classifiers in discriminating targets. The results were validated using confusion matrices, Kappa Index, and Overall Accuracy calculations. The results showed that the PRISMA satellite with the Mahalanobis Distance algorithm achieved the best performance among all classifications, with a Kappa Index of 0.9516 and an Overall Accuracy of 95.85%. The Sentinel-2 satellite showed consistent results across multiple classifiers, standing out as the most balanced option due to its excellent performance in most tested algorithms. The CBERS 04A yielded inferior but still robust results. Finally, land use and land cover maps were generated for the best classification models of each satellite.

Keywords: land use and occupation maps; satellites; supervised classification; image resolutions.

LISTA DE ILUSTRAÇÕES

Figura 1 – Resoluções espaciais dos satélites CBERS 04A e PRISMA, respectivamente.	16
Figura 2 – Exemplos de resolução radiométrica.	17
Figura 3 – Análise de mudanças em Araçuaí-MG nos anos de 2000 (primeira) e 2019 (segunda).	19
Figura 4 – Processo de classificação.	23
Figura 5 – Exemplo de Matriz de Confusão. Em que: VN = Vegetação Nativa, EU = Eucalipto, SE = Seringueira, AG = Água, SO = Solo Exposto, FR = Fruticultura, CA= Cana-de-açúcar, RC = Restos Culturais e PA = Pastagem.	25
Figura 6 – Mapa de Localização.	27
Figura 7 – Fluxograma do projeto.	29
Quadro 1 – Características das imagens adquiridas.	30
Figura 8 – Classificação não supervisionada a partir do algoritmo ISODATA.	33
Figura 9 – Classificação não supervisionada a partir do algoritmo <i>K-means</i>	34
Quadro 2 – Descrição das Classes.	35
Figura 10 – Classes de Uso e Cobertura da Terra para 2022, segundo MapBiomass.	37
Quadro 3 – Classes definidas para o estudo.	37
Figura 11 – Mapa de uso e cobertura do solo a partir de classificação supervisionada pelo algoritmo SVM utilizando imagens do satélite CBERS 04A.	42
Figura 12 – Mapa de uso e cobertura do solo a partir de classificação supervisionada pelo algoritmo SVM utilizando imagens do satélite Sentinel-2.	43
Figura 13 – Mapa de uso e cobertura do solo a partir de classificação supervisionada pelo algoritmo MahaDist utilizando imagens do satélite PRISMA.	44
Figura 14 – Mapa comparativo entre as melhores classificações.	45
Figura 15 – Fragmento da classe Hidrografia e sua área classificada.	49
Figura 16 – Fragmentos das classes de Pastagem e Vegetação Herbácea e Arbustiva, respectivamente.	50
Figura 17 – Curva espectral para a classe de Silvicultura.	51
Figura 18 – Curva espectral para a classe de Lavoura Perene.	51
Figura 19 – Curva espectral para a classe de Floresta.	51

LISTA DE TABELAS

Tabela 1 – Características das câmeras do CBERS 04A.....	20
Tabela 2 – Características do satélite Sentinel-2.....	21
Tabela 3 – Características do satélite PRISMA.	22
Tabela 4 – Parâmetros do Índice Kappa.....	25
Tabela 5 – Quantidade de pixels extraídos por satélite referente cada classe temática.....	38
Tabela 6 – Panorama geral dos classificadores por satélite, considerando Exatidão Global (%) e Índice Kappa.	40
Tabela 7 – Desempenho comparativo dos classificadores Distância de Mahalanobis e Support Vector Machine (SVM) nos satélites CBERS 04A, Sentinel-2 e PRISMA, apresentando os valores de Exatidão Global (%) e Índice Kappa.....	41
Tabela 8 – Matriz de Confusão (%) com Erros de Omissão (EO) e Comissão (EC) para o satélite CBERS 04A.....	45
Tabela 9 – Matriz de Confusão (%) com Erros de Omissão (EO) e Comissão (EC) para o satélite Sentinel-2.....	46
Tabela 10 – Matriz de Confusão (%) com Erros de Omissão (EO) e Comissão (EC) para o satélite PRISMA.....	46

LISTA DE ABREVIATURAS E SIGLAS

ASI	Agência Espacial Italiana
ESA	European Space Agency
INPE	Instituto Nacional de Pesquisas Espaciais
REM	Radiação Eletromagnética
SWIR	Short-Wave Infrared
VNIR	Visible and Near-Infrared
MahaDist	Distância de Mahalanobis
MaxVer	Máxima Verossimilhança
MinDist	Distância Mínima
PPD	Paralelepípedo
SVM	Support Vector Machine
RN	Redes Neurais
WPM	Wide and Panchromatic Multispectral Camera
MUX	Multispectral Camera
WFI	Wide Field Imager
ISODATA	Iterative Self-Organizing Data Analysis Techniques

SUMÁRIO

1	INTRODUÇÃO.....	12
2	OBJETIVOS	14
2.1	Objetivo Geral.....	14
2.2	Objetivos específicos	14
3	REVISÃO BIBLIOGRÁFICA	15
3.1	Mapeamento Temático	15
3.2	Sensoriamento Remoto: Princípios e Métodos de Classificação de Imagens	15
3.3	Satélites	20
3.3.1	<i>CBERS 04A</i>	20
3.3.2	<i>Sentinel-2</i>	21
3.3.3	<i>PRISMA</i>	22
3.4	Técnicas de Classificação	22
3.4.1	<i>Classificação Não Supervisionada</i>	23
3.4.2	<i>Classificação Supervisionada</i>	24
4	MATERIAL E MÉTODOS	27
4.1	Área de Estudo	27
4.2	Material	28
4.3	Métodos.....	28
4.3.1	<i>Pré-processamento</i>	29
4.3.2	<i>Definição de Classes</i>	32
4.3.3	<i>Processamento</i>	38
4.3.4	<i>Pós- processamento</i>	39
4.3.5	<i>Geração de produtos</i>	39
5	RESULTADOS	40
6	DISCUSSÃO	47
6.1	Comparativo entre classificadores	47
6.2	Avaliação dos melhores modelos	48
7	CONCLUSÃO	53
	REFERÊNCIAS.....	54
	APÊNDICE A – RESULTADOS PARA CLASSIFICAÇÃO SUPERVISIONADA COM BASE NO ALGORITMO MAHADIST UTILIZANDO IMAGENS DO SATÉLITE CBERS 04A	58

APÊNDICE B – RESULTADOS PARA CLASSIFICAÇÃO SUPERVISIONADA COM BASE NO ALGORITMO MAHADIST UTILIZANDO IMAGENS DO SATÉLITE SENTINEL	59
APÊNDICE C – RESULTADOS PARA CLASSIFICAÇÃO SUPERVISIONADA COM BASE NO ALGORITMO SVM UTILIZANDO IMAGENS DO SATÉLITE PRISMA.....	60

1 INTRODUÇÃO

A paisagem tem sido fortemente influenciada pela ação humana e pelas mudanças climáticas, ocasionando em transformações no uso e ocupação do solo, resultantes de atividades como urbanização, agricultura e desmatamento (Fensterseifer; Silva, 2019). Com o avanço científico e tecnológico, o Sensoriamento Remoto tornou-se essencial para a análise do ambiente, promovendo um grande progresso na realização de mapeamentos em diversas áreas do conhecimento, permitindo que tarefas antes manuais sejam agora digitais, realizadas com precisão e um detalhamento superior. Além disso, essas tecnologias reduzem o tempo e os custos de produção dos mapas, otimizando o trabalho em campo e o mapeamento em geral (Almeida; Santos; Chaves, 2011).

Os mapas de uso do solo têm grande relevância, pois permitem através da interpretação de imagens de satélite, identificar áreas ocupadas por pastagens, atividades agrícolas, vegetação natural, cursos d'água e outras feições da paisagem. Estes mapas também possibilitam a identificação de áreas de risco ou regiões degradadas, além de distinguir mudanças resultantes da evolução natural da paisagem e daquelas provocadas por atividades humanas (Santos; Petronzio, 2011).

Estes mapeamentos são produzidos por meio de métodos de classificação de imagens, que consistem em reconhecer classes ou grupos que compartilham das mesmas características. Na classificação de imagens, parte-se do princípio de que diferentes alvos possuem informações espectrais distintas e que cada ponto da imagem corresponde a uma única classe. Existem dois tipos de classificação, supervisionada, onde é necessário o conhecimento prévio referente aos alvos que serão estudados, e não supervisionada, quando não há informações sobre os alvos de interesse e assim as classes são geradas de forma automática, conforme suas características espectrais (Solari, 2017).

Contudo, os métodos de classificação enfrentam desafios significativos, como a dificuldade em distinguir classes com assinaturas espectrais semelhantes ou a resolução espacial e espectral limitada de alguns sensores, que dificulta a discriminação de feições heterogêneas. Avanços recentes buscam superar essas limitações por meio de técnicas de aprendizado de máquina, integração de dados multitemporais e uso de plataformas de processamento em nuvem (Chaves; Picoli; Sanches, 2020).

Para este estudo, foram utilizadas imagens dos satélites CBERS 04A, Sentinel-2 e PRISMA no processo de classificação supervisionada, com o objetivo de mapear o uso e ocupação do solo em municípios do Triângulo Mineiro e Alto Paranaíba. A pesquisa buscou

avaliar o desempenho desses satélites em termos de acurácia na classificação, considerando a combinação de diferentes algoritmos de classificação de imagens, bem como as respectivas resoluções espaciais e espectrais de cada satélite. Parte-se da hipótese de que o satélite PRISMA, devido à sua alta resolução espectral, proporcionará classificações mais precisas em comparação ao Sentinel-2 e ao CBERS 04A, especialmente em áreas com cobertura vegetal complexa, onde a riqueza de bandas espectrais pode oferecer maior discriminação entre classes.

2 OBJETIVOS

2.1 Objetivo Geral

Este trabalho teve como objetivo avaliar a acurácia do mapeamento temático de uso e ocupação do solo, com a utilização de imagens dos satélites CBERS 04A, Sentinel-2 e PRISMA.

2.2 Objetivos específicos

Como objetivos específicos, o presente trabalho buscou:

- Avaliar a influência das resoluções espacial e espectral no produto final;
- Avaliar o desempenho dos algoritmos que foram utilizados no processo de classificação.

3 REVISÃO BIBLIOGRÁFICA

3.1 Mapeamento Temático

Com o decorrer da evolução do homem, é possível notar as grandes mudanças provocadas na paisagem, impulsionadas principalmente pelas atividades humanas realizadas com o passar dos anos. Dessa forma, o mapeamento temático de uso e ocupação do solo apresenta-se como uma ferramenta eficaz para o acompanhamento das mudanças ocorridas (Coelho; Montenegro; Almeida, 2014).

Fensterseifer e Silva (2019) citam que o uso de mapas temáticos com informações sobre áreas urbanas, vegetação, agricultura e solo exposto tem ganhado destaque, pois essa ferramenta facilita a compreensão dos impactos ambientais decorrentes da falta de gestão no uso e ocupação do solo nos últimos tempos.

Segundo Vaeza *et al.* (2010) o uso de técnicas de sensoriamento remoto e geoprocessamento são essenciais no monitoramento da dinâmica do uso e ocupação do solo, proporcionando uma atualização frequente de dados, agilidade no processamento das informações e viabilidade econômica. Essas ferramentas permitem acompanhar as transformações na paisagem de forma eficiente e precisa, contribuindo para a gestão ambiental e o planejamento territorial.

3.2 Sensoriamento Remoto: Princípios e Métodos de Classificação de Imagens

Segundo Meneses e Almeida (2012), o Sensoriamento Remoto é uma ciência baseada na obtenção de imagens da superfície terrestre, a partir da detecção e medição quantitativa das respostas das interações entre a radiação eletromagnética (REM) e os materiais presentes na paisagem terrestre.


Já Novo (2010) traz o Sensoriamento Remoto de uma forma mais abrangente, sendo o uso integrado de sensores, equipamentos para processamento e transmissão de dados, embarcados em aeronaves, espaçonaves ou outros meios, a fim de estudar as mudanças que acontecem na superfície terrestre, através do registro e análise das interações entre a REM e os diversos componentes encontrados na superfície do planeta em suas diferentes ocorrências. Dessa forma, a radiação eletromagnética atua como um veículo que transporta a informação do objeto para o sensor e pode ser definida como uma forma dinâmica de energia que se manifesta através de suas interações com a matéria.

As resoluções da imagem refletem características captadas pelos sensores, cada uma destacando um aspecto particular dos alvos de interesse. Normalmente, um único sensor não possui uma combinação das resoluções ideais em todos os aspectos, cada tipo é projetado para priorizar aspectos que atendam em aplicações específicas (Zanotta; Zortea; Ferreira, 2019).

Existem quatro tipos de resoluções que descrevem uma imagem, conhecidas como resolução espacial, espectral, radiométrica e temporal. Tais variáveis operam de forma conjunta e interativa (Meneses; Almeida, 2012), sendo de suma importância para o processo de diferenciação dos alvos.

De acordo com Florenzano (2011, p.17) a resolução espacial enquadra-se como “a capacidade que o sensor tem de discriminar objetos em função do tamanho”, ou seja, está diretamente ligada ao tamanho do pixel na imagem. Meneses e Almeida (2012) consideram a resolução espacial como um parâmetro essencial do sensor, pois determina o tamanho do menor objeto que pode ser identificado em uma imagem. No estudo de Inacio (2022) é apresentado o mapeamento de uso e ocupação do solo do município de Seropédica (RJ), o qual nota-se que as imagens dos satélites CBERS 04A e Sentinel-2, ofereceram maior nível de detalhamento dos alvos mapeados em comparação ao satélite Landsat 8, pois apresentam maior resolução espacial, dessa maneira um menor tamanho dos pixels. Abaixo, é possível observar imagens do satélite CBERS 04A com resolução de 8 metros e o satélite PRISMA, com resolução de 30 metros, para exemplificar diferentes resoluções espaciais (Figura 1).

Figura 1 – Resoluções espaciais dos satélites CBERS 04A e PRISMA, respectivamente.




Fonte: Adaptado de INPE; ASI (2022).

A resolução espectral para Zanotta, Zortea e Ferreira (2019) define-se como “a capacidade do sensor em descrever o comportamento espectral dos alvos na imagem”, ou seja, quanto maior a quantidade de bandas, maior será a quantidade de informações espectrais e por consequência, a imagem terá uma maior resolução espectral.

Já a resolução radiométrica de um sensor, indica sua aptidão em distinguir variações nos níveis de energia refletida, emitida ou retroespalhada a partir da superfície de um alvo. Essa energia apresenta variações contínuas de intensidade, que o sensor deve ser capaz de detectar. Dessa maneira, quanto maior a capacidade do sensor em diferenciar essas variações de intensidade do sinal, maior será sua resolução radiométrica. Essa capacidade está diretamente ligada à quantidade de níveis de cinza que o sensor pode representar, os quais são determinados pela profundidade de bits utilizada (Novo, 2010). Por exemplo, conforme ilustrado na Figura 2, um sensor com 1 bit de resolução radiométrica distingue apenas 2 níveis de cinza (preto e branco), enquanto um sensor de 4 bits pode discriminar até 16 tons distintos.

Figura 2 – Exemplos de resolução radiométrica.

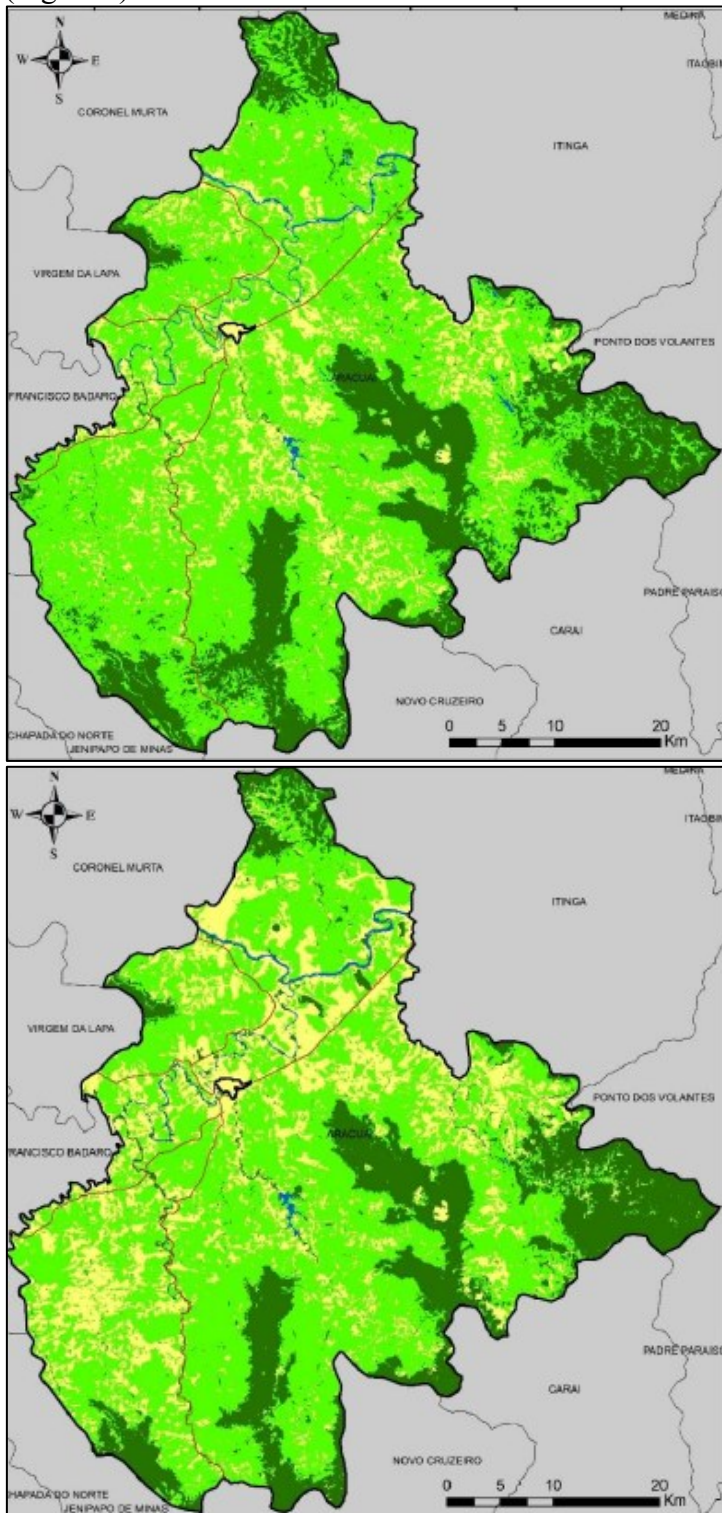


Fonte: USP (2021).

Por fim, a periodicidade de revisita do sensor em um determinado local, para obtenção de imagens, demonstra sua resolução temporal (Zanotta; Zortea; Ferreira, 2019). Logo, este tipo de resolução é essencial para observar e analisar mudanças que ocorrem na Terra, sendo especialmente importante para alvos dinâmicos, como o ciclo fenológico de culturas, desmatamentos e desastres ambientais, trazendo um impacto significativo no monitoramento ambiental (Meneses; Almeida, 2012).

Pacheco (2021) realizou a detecção de mudanças no município de Araçuaí-MG, por meio do mapeamento de uso e ocupação do solo com imagens Landsat datadas nos anos de 2000 e 2019. O estudo apresenta um crescimento das áreas urbanizadas e do solo exposto, no passo que áreas de vegetação houve redução, dessa forma exemplificando a importância de imagens obtidas em épocas diferentes no mesmo lugar, para o monitoramento de mudanças na paisagem (Figura 3).

Figura 3 – Análise de mudanças em Araçuaí-MG nos anos de 2000 (primeira) e 2019 (segunda).



Fonte: Pacheco (2021).

3.3 Satélites

O sensoriamento remoto orbital revolucionou o monitoramento terrestre ao permitir a aquisição sistemática de imagens em diferentes regiões do espectro eletromagnético. Os satélites multiespectrais, como o CBERS-04A e Sentinel-2, capturam dados em um número limitado de bandas espectrais, oferecendo informações essenciais para aplicações em agricultura, uso do solo e monitoramento ambiental. Em contraste, satélites hiperespectrais como o PRISMA, registram centenas de bandas espectrais contíguas e estreitas, possibilitando uma análise química e mineralógica detalhada da superfície terrestre (Furlanetto, 2017).

3.3.1 CBERS 04A

O satélite CBERS 04A é proveniente da parceria entre Brasil e China, com objetivo de fomentar desenvolvimento técnico-científico para o setor, trazendo uma ferramenta para o controle do desmatamento, queimadas, monitoramento de recursos hídricos, áreas agrícolas, entre outros. Este satélite, assim como seus antecessores, está equipado com câmeras para observação óptica global, além de contar com um sistema de coleta e monitoramento de dados ambientais (INPE, 202-?). A seguir, as principais características sobre as câmeras embarcadas neste satélite (Tabela 1):

Tabela 1 – Características das câmeras do CBERS 04A.

SENSOR	BANDAS	FAIXA ESPECTRAL	RESOLUÇÃO ESPACIAL	RESOLUÇÃO RADIOMÉTRICA
WPM	Blue	0,45-0,52μm	8m	10 bits
	Green	0,52-0,59μm		
	Red	0,63-0,69μm		
	NIR	0,77-0,89μm		
	PAN	0,45-0,90μm	2m	
MUX	Blue	0,45-0,52μm	16,5m	8 bits
	Green	0,52-0,59μm		
	Red	0,63-0,69μm		
	NIR	0,77-0,89μm		
WFI	Blue	0,45-0,52μm	55m	10 bits
	Green	0,52-0,59μm		
	Red	0,63-0,69μm		
	NIR	0,77-0,89μm		

Fonte: INPE (2024).

De acordo com a Tabela 1, observa-se que o satélite CBERS 04A é equipado com três câmeras imageadoras: **WPM** (*Wide and Panchromatic Multispectral Camera*), **MUX** (*Multispectral Camera*) e **WFI** (*Wide Field Imager*). A WPM destaca-se por sua alta resolução espacial, oferecendo 8 metros para as bandas multiespectrais (azul, verde, vermelho e infravermelho próximo) e 2 metros para a banda pancromática, além de uma resolução radiométrica de 10 bits. A MUX por sua vez, possui uma resolução espacial de 16,5 metros em todas as suas bandas multiespectrais e uma resolução radiométrica de 8 bits. Já a WFI cobre uma área mais extensa, com resolução espacial de 55 metros e resolução radiométrica de 10 bits, sendo ideal para monitoramento em larga escala. Esses sensores permitem aplicações diversificadas, como observação de desmatamento, agricultura, planejamento urbano e gestão de recursos naturais (INPE, 2024).

3.3.2 Sentinel-2

A missão Sentinel-2 é composta por satélites gêmeos (2A e 2B), os quais trabalham simultaneamente para garantir uma alta frequência de revisita e geração de imagens multiespectrais de alta resolução, assim oferecendo ao usuário 13 bandas espectrais, com diferentes resoluções espaciais entre elas (Tabela 2). Os satélites possuem um tempo de revisita de 10 dias (ESA, 202?).

Tabela 2 – Características do satélite Sentinel-2.

BANDAS	RESOLUÇÃO ESPECTRAL	RESOLUÇÃO ESPACIAL	RESOLUÇÃO RADIOMÉTRICA
Band 2 (<i>Blue</i>)	490 nm	10m	12 bits
Band 3 (<i>Green</i>)	560 nm		
Band 4 (<i>Red</i>)	665 nm		
Band 8 (NIR)	842 nm		
Band 5 (<i>Red Edge</i> 1)	705 nm	20m	
Band 6 (<i>Red Edge</i> 2)	740 nm		
Band 7 (<i>Red Edge</i> 3)	783 nm		
Band 8a (<i>Red Edge</i> 4)	865 nm		
Band 11 (SWIR 1)	1610 nm		
Band 12 (SWIR 2)	2190 nm		
Band 1 (<i>Aerossol</i>)	443 nm	60m	
Band 9 (<i>Water Vapor</i>)	940 nm		
Band 10 (<i>Cirrus</i>)	1375 nm		

Fonte: ESA (202?).

3.3.3 PRISMA

Os sensores espectrais de alta resolução transformaram a maneira como enxergamos o meio ambiente e os fenômenos ambientais. Dessa maneira, o satélite PRISMA sob domínio da Agência Espacial Italiana (ASI), contribui de forma expressiva para a detecção de mudanças e oferece ferramentas para gestão dos recursos naturais (ASI, 2017). As imagens de alta resolução adquiridas por meio do satélite hiperespectral PRISMA apresentam as características listadas abaixo, com bandas do *Visible and Near-Infrared* (VNIR), *Short-Wave Infrared* (SWIR) e pancromática (PAN) (Tabela 3).

Tabela 3 – Características do satélite PRISMA.


BANDAS	FAIXA ESPECTRAL	QTD. DE BANDAS	RESOLUÇÃO ESPACIAL	RESOLUÇÃO RADIMÉTRICA
VNIR	400 – 1010 nm	66	30m	12 bits
SWIR	920 – 2505 nm	173		
PAN	400 – 700 nm	1	5m	

Fonte: eoPortal (2023).

3.4 Técnicas de Classificação

De acordo com Florenzano (2011), os métodos de classificação de imagens digitais têm como objetivo o reconhecimento automático de objetos com base em critérios de decisão, organizando em classes de acordo com a similaridade de suas respostas espectrais. O resultado deste processo é um mapa temático, no qual cada pixel ou grupo de pixels, é alocado em uma classe ou tema estabelecido (Figura 4).

Figura 4 – Processo de classificação.



Fonte: Novo (2010).

As técnicas de classificação de imagens podem ser divididas em dois tipos: classificação não supervisionada e classificação supervisionada, ambas serão descritas abaixo.

3.4.1 Classificação Não Supervisionada

Este tipo de classificação consiste na junção de pixels em determinada classe, sem o conhecimento prévio por parte do usuário de tal classe, dessa forma o procedimento permite ao analista observar a distribuição dos pixels entre as classes espectrais. Essas distribuições são avaliadas e comparadas com dados de campo, mapas ou informações teóricas referente ao comportamento espectral dos alvos. A classificação não supervisionada é uma etapa fundamental a ser realizada antes da classificação supervisionada, pois permite ao analista identificar a quantidade de classes espectrais presentes na imagem. (Novo, 2010).

Os algoritmos de classificação não supervisionada mais utilizados são o ISODATA (*Iterative Self-Organizing Data Analysis Techniques*) e o *K-means*, estes métodos agrupam pixels com atributos semelhantes, baseando-se em técnicas de distância mínima. Desse modo, a classificação não supervisionada também é conhecida como *clustering*. Normalmente, um algoritmo deste tipo utiliza todos os pixels da imagem de entrada como ponto de partida para a análise (Meneses; Almeida, 2012).

3.4.2 Classificação Supervisionada

O processo de classificação supervisionada exige conhecimento anterior referente as classes de interesse, de modo que o analista consiga pré-definir as categorias nas quais a imagem será classificada. Esse método requer que o algoritmo seja treinado anteriormente para diferenciar uma classe da outra, um processo que é acompanhado de perto pelo analista. Nesse treinamento, o analista seleciona pequenas áreas amostrais na imagem, contendo algumas centenas de pixels que representem, de forma consistente, os padrões ou características dos alvos reconhecidos. Esses alvos podem ser identificados com o auxílio de outras fontes, como dados de campo ou mapas (Meneses; Almeida, 2012).

As características estatísticas das classes estimadas a partir das amostras de treinamento, variam com base no método de classificação aplicado (Meneses; Almeida, 2012). Entre os métodos de classificação supervisionada, pode-se citar: Paralelepípedo (PPD), Distância Mínima (MiniDist), Distância de Mahalanobis (MahaDist), Máxima Verossimilhança (MaxVer), Redes Neurais (RN) e *Support Vector Machine* (SVM).

Segundo Novo (2010), para geração de bons produtos algumas ações devem ser tomadas, independente do algoritmo escolhido no processo de classificação supervisionada. Estas ações consistem em:

- 1) Seleção do conjunto de bandas espectrais que melhor representa os alvos de interesse;
- 2) Localização de classes de treinamento bem definidas;
- 3) Analisar a precisão da classificação gerada.

A última etapa citada, busca validar os resultados obtidos durante o processo de classificação. A precisão geralmente é expressa por meio de índices calculados através de matriz de confusão, que mostra a concordância entre a imagem classificada e o conjunto de amostras de referência. A matriz de confusão realiza uma comparação, classe por classe, entre os dados reais e os resultados da classificação, essa matriz possui um número de linhas e colunas correspondente ao número de classes espectrais do estudo. A partir dela, são calculados os erros de omissão (exclusão) e de comissão (inclusão) para cada classe (Meneses; Almeida, 2012). Na Figura 5 é apresentado um exemplo de matriz de confusão, obtida a partir de classificação não supervisionada pelo algoritmo MaxVer, na qual possui nove classes de treinamento.

Figura 5 – Exemplo de Matriz de Confusão. Em que: VN = Vegetação Nativa, EU = Eucalipto, SE = Seringueira, AG = Água, SO = Solo Exposto, FR = Fruticultura, CA= Cana-de-açúcar, RC = Restos Culturais e PA = Pastagem.

Classe	VN	SE	AG	EU	SO	FR	CA	PA	RC
VN	68,14	4,76	0	0	0	0	0	4,08	0
SE	0	95,24	0	0	0	0	0	0	0
AG	0	0	100	0	0	0	0	0	0
EU	6,98	0	0	100	0	0	18,18	0	0
SO	8,60	0	0	0	75	0	9,09	16,33	0
FR	4,65	0	0	0	0	75	0	0	0
CA	0	0	0	0	0	0	54,55	10,2	0
PA	2,33	0	0	0	0	0	18,18	46,94	0
RC	9,30	0	0	0	25	25	0	22,45	100
Total (%)	100	100	100	100	100	100	100	100	100

Fonte: Romero *et al.* (2019)

Segundo Vale *et al.* (2018), a exatidão global é um parâmetro que pode ser calculado a partir da matriz de confusão, no qual seria a divisão entre os valores presentes na diagonal da matriz de confusão (A) e o valor total de amostras de validação (n), exemplificada pela Equação 1:

$$EG = \frac{A}{n} \times 100 \quad (1)$$

Por fim, o Índice Kappa é uma medida de concordância que avalia o quanto as observações diferem das esperadas, permitindo uma interpretação sobre a precisão dos dados analisados (Vale *et al.* 2018). Pode ser calculado com base na Equação 2:

$$K = \frac{[n \times \sum_{i=1}^r x_{ij} - \sum_{i=1}^r (x_i \times x_j)]}{[n^2 - \sum_{i=1}^r (x_i \times x_j)]} \quad (2)$$

Na equação, *r* corresponde ao número de linhas na matriz de confusão, *x_{ij}* indica a contagem de observações na linha *i* e coluna *j*, e *n* é o total de observações (Vale *et al.* 2018). O método é amplamente utilizado para validação da classificação, que pode variar entre 0 e 1 (Meneses; Almeida, 2012). Esses valores indicam a qualidade do produto, sendo dividido em seis categorias de qualidade (Tabela 4).

Tabela 4 – Parâmetros do Índice Kappa

DESEMPENHO	ÍNDICE KAPPA
Péssimo	< 0
Ruim	0 – 0,2

Razoável	0,2 – 0,4
Boa	0,4 – 0,6
Muito Boa	0,6 – 0,8
Excelente	0,8 – 1,0

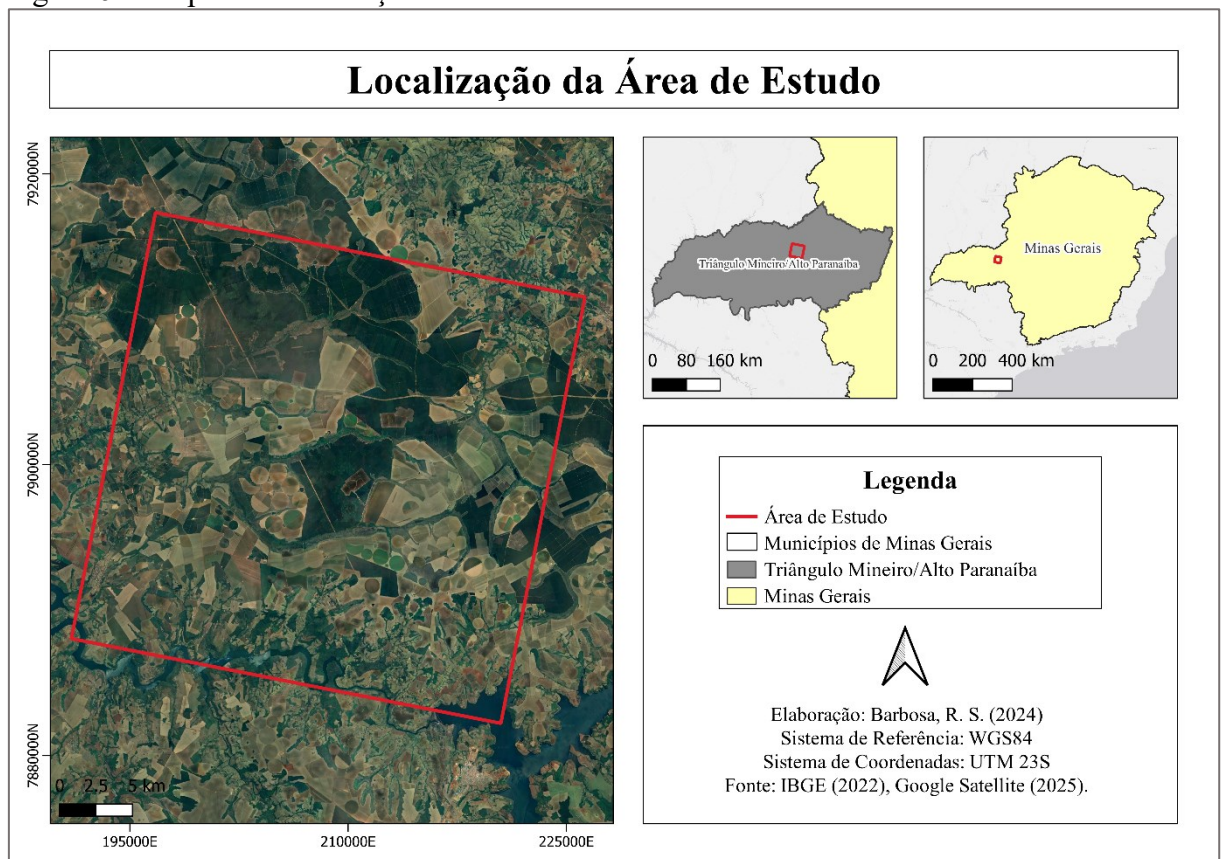
Fonte: Figueiredo; Vieira (2007).

4 MATERIAL E MÉTODOS

4.1 Área de Estudo

A área de estudo compreende os municípios de Indianópolis, Nova Ponte, Romaria e Estrela do Sul, localizados na mesorregião do Triângulo Mineiro e Alto Paranaíba, Estado de Minas Gerais. Essa região está inserida no bioma Cerrado, caracterizado por sua grande biodiversidade e importância ecológica (Guarlado, 2023). A delimitação da área foi definida conforme as cenas disponíveis do satélite PRISMA, pois este apresenta maiores desafios para a aquisição de produtos, visto que é necessário realizar uma solicitação prévia para obtenção das imagens (Figura 6).

Figura 6 – Mapa de Localização.



Fonte: a autora (2025).

4.2 Material

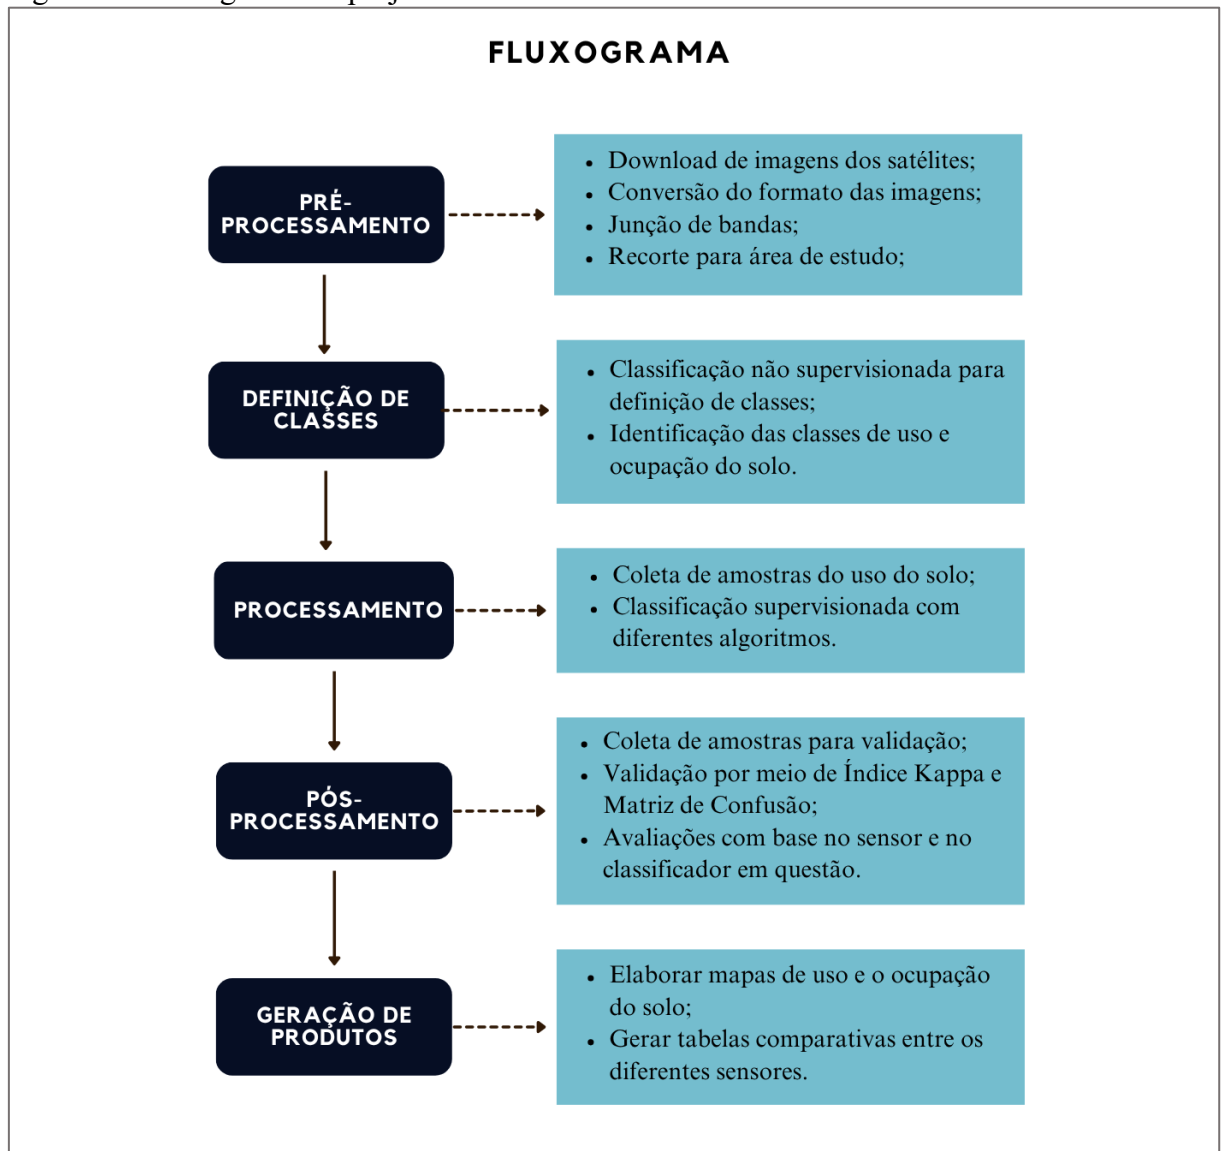
Para realização deste trabalho, utilizou-se imagens dos satélites PRISMA, Sentinel-2 e CBERS 04A datadas em 2022, com objetivo de comparar o desempenho desses satélites em classificações supervisionadas, analisando em que medida suas resoluções espaciais e espectrais influenciam a acurácia do mapeamento.

Para processamento das imagens, foram empregados os *softwares* QGIS na versão 3.22.8, ENVI *Classic* e o programa RStudio. O QGIS é amplamente reconhecido como um *software* livre e de código aberto, o qual é utilizado para edição de camadas, processamento, análise de conjuntos de dados e confecção de mapas profissionais por meio de inúmeras ferramentas (QGIS, 202?). O *software* ENVI *Classic* é especializado em processamento de imagens, assim permite visualizar, explorar, analisar e apresentar dados de Sensoriamento Remoto e SIG (ENVI, 202?). A linguagem de programação R foi aplicada por meio do *software* RStudio, o qual oferece maior facilidade no uso da linguagem, sendo utilizado neste estudo para processamento dos dados PRISMA (Lopes *et al.* 2021). Além destes, foi usado o aplicativo Excel, para geração de tabelas e gráficos.

4.3 Métodos

A metodologia adotada para realização deste estudo ocorreu em cinco fases, sendo elas: pré-processamento, definição de classes, processamento, pós-processamento e geração de produtos. A Figura 7 apresenta o fluxograma das atividades desempenhadas:

Figura 7 – Fluxograma do projeto.



Fonte: a autora (2025).

4.3.1 Pré-processamento

Inicialmente, as imagens dos satélites foram obtidas por meio dos portais oficiais das agências responsáveis. As imagens Sentinel-2 e CBERS 04A foram adquiridas em acesso aberto, porém a imagem do satélite PRISMA exigiu solicitação formal à Agência Espacial Italiana, mediante justificativa técnica para liberação dos dados. O Quadro 1 descreve as características técnicas das imagens de satélite selecionadas para o estudo, incluindo informações sobre o satélite, sensor, nível de processamento, data de aquisição e fonte de obtenção.

Quadro 1 – Características das imagens adquiridas.

SATÉLITE	SENSOR	NÍVEL DE PROCESSAMENTO	DATA	PORTAL
CBERS 04A	WPM	L4	02/09/2022	INPE
Sentinel-2	MSI	2A	01/09/2022	Copernicus
PRISMA	HYP	L2D	29/08/2022	ASI

Fonte: a autora (2025).

A seleção priorizou imagens com datas de aquisição próximas, assegurando que as condições ambientais durante a tomada das imagens fossem similares. Essa uniformidade temporal é essencial para minimizar variações externas que poderiam influenciar a análise comparativa. Além disso, os níveis de processamento indicados asseguram que os dados passaram por correções atmosféricas, o que é fundamental para a confiabilidade dos resultados.

Após a aquisição das imagens, foram adotados os seguintes procedimentos para o pré-processamento de cada imagem em específico:

I. PRISMA

Após aquisição da imagem hiperespectral PRISMA, realizou-se a conversão do formato original (.he5) para o formato .GeoTIFF. Esta etapa foi executada por meio de código de programação em linguagem R no ambiente RStudio. O processo incluiu a extração das bandas espectrais do VNIR e SWIR, além de informações geográficas (latitude/longitude) e ângulos de visada do sensor, mantendo assim todos os metadados essenciais para as análises subsequentes. O código utilizado é apresentado a seguir (RadarGeo, 2021):

```
install.packages("remotes")
remotes::install_github("irea-cnr-mi/prismaread")
library(prismaread)
pr_convert(
  in_file      = "D:/2.    TCC/3.    Processamento/1.    Dados/1.
Prisma/PRS_L2D_STD_20220829132857_20220829132901_0001/PRS_L2D_STD_20
220829132857_20220829132901_0001.he5",
  out_folder   = "D:/2.    TCC/3.    Processamento/1.    Dados/1.
Prisma/GeoTiff",
  out_format   = "GTiff",
  VNIR         = T,
  SWIR         = T,
```

```

LATLON = T,
ANGLES = T
)

```

Como resultado da etapa anterior, obtiveram-se dois arquivos GeoTIFF distintos: um contendo as 66 bandas do VNIR e outro com as 173 bandas do SWIR. Para viabilizar a análise integrada dos dados espectrais, foi necessário realizar o empilhamento das bandas utilizando a ferramenta ‘*Layer Stacking*’ disponível no *software* ENVI Classic. Esta operação combinou as 239 bandas espectrais em uma única imagem hiperespectral, que foi utilizada posteriormente para desenvolvimento do estudo.

II. CBERS 04A

O pré-processamento das bandas adquiridas por meio do satélite CBERS, foi realizado em três etapas sequenciais. Inicialmente, a conversão do formato original para GeoTIFF ocorreu no aplicativo QGIS, garantindo a compatibilidade com os demais sistemas de processamento. Em seguida, realizou-se a junção de todas as bandas utilizando a ferramenta ‘*Layer Stacking*,’ disponível no *software* ENVI Classic, que permitiu a combinação das bandas espectrais em um único arquivo. Por fim, o recorte da imagem foi efetuado utilizando como máscara uma camada vetorial, definida conforme a área de estudo.

III. Sentinel 2

Para abranger toda a área de estudo, realizou-se o *download* de duas cenas das imagens Sentinel, e posteriormente, foi gerado um mosaico através da ferramenta ‘Mosaico’ disponível no menu ‘Raster’ do *software* QGIS. Este processo foi executado em lote, sendo primeiramente combinadas as cenas das bandas com resolução espacial de 10m (B02, B03, B04, B08), seguidas pelas bandas de 20m (B05, B06, B07, B8A, B11, B12), garantindo assim a integridade das características espectrais em cada grupo de resolução.

Posteriormente, efetuou-se a etapa de reprojeção e reamostragem utilizando a ferramenta ‘Reprojetar Coordenadas’ do mesmo *software*. Nesta fase, todas as bandas foram reprojetadas para o fuso 23S. Já na parte de reamostragem, as bandas B05, B06, B07, B8A, B11

e B12 foram reamostradas para a resolução de 10m através do método de vizinho mais próximo, permitindo a uniformização espacial com as demais bandas de maior resolução.


Com os dados devidamente padronizados, procedeu-se com empilhamento de bandas utilizando a ferramenta ‘*Layer Stacking*’ do *software* ENVI Classic, assim esta operação integrou as bandas processadas em um arquivo único de 10m.

Finalmente, aplicou-se o recorte na imagem utilizando uma *shapefile* que delimita a área de estudo, com base na área de estudo determinada a partir da imagem PRISMA. Esta etapa resultou em uma imagem final contendo apenas a região de interesse, otimizando assim o processamento nas fases posteriores de classificação e análise.

4.3.2 Definição de Classes


Após os procedimentos iniciais para cada um dos satélites, as imagens resultantes foram submetidas ao processo de classificação não supervisionada no ENVI, com base nos algoritmos ISODATA e *K-means*, para definição preliminar das classes de interesse. As Figuras 8 e 9 apresentam as classificações não supervisionadas com base na imagem CBERS, para ambos os classificadores citados anteriormente.

Figura 8 – Classificação não supervisionada a partir do algoritmo ISODATA.



Fonte: a autora (2025).

Figura 9 – Classificação não supervisionada a partir do algoritmo *K-means*.



Fonte: a autora (2025).

Devido à alta confusão entre as classes encontradas por meio do processo anterior, optou-se por utilizar a coleção 9 de Uso e Cobertura da Terra oferecida pelo MapBiomias, para definição das classes de interesse que compuseram o estudo. O Projeto disponibiliza o mapeamento anual do território brasileiro, apresentando inúmeras classes de uso do solo, a fim de representar da forma mais abrangente a superfície terrestre do Brasil.

O produto é oferecido em formato TIFF com uma resolução de 30m, consistindo em dados gerados por meio de classificação pixel a pixel de imagens provenientes do satélite Landsat. Este processo é realizado por meio de algoritmos avançados de aprendizado de máquina (*machine learning*), implementados na plataforma *Google Earth Engine* (GEE), a qual oferece alta capacidade de processamento em nuvem, permitindo o manuseio eficiente de grandes volumes de dados geoespaciais (MapBiomias, 2025).

Dessa forma, com base nos dados fornecidos pelo Projeto MapBiomias, a área de estudo engloba cerca de 15 classes de uso da terra, separadas em quatro níveis de acordo com suas

respectivas características. O Quadro 2 contém todas as classes mapeadas pelo projeto, contidas na área de estudo, e suas descrições detalhadas:

Quadro 2 – Descrição das Classes.

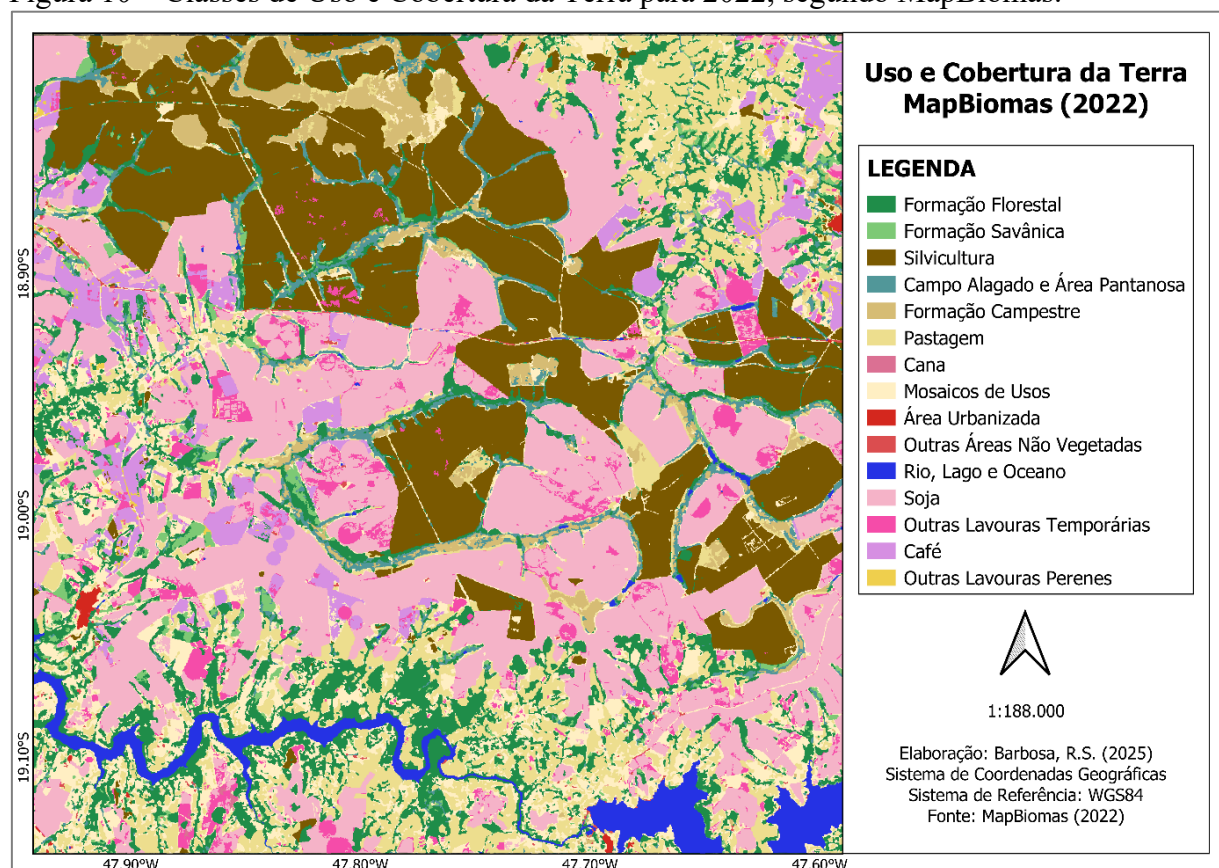
DESCRIÇÃO DAS CLASSES DA LEGENDA DA COLEÇÃO 9 DO MAPBIOMAS BRASIL				
Nível 1	Nível 2	Nível 3	Nível 4	Descrição Breve
Floresta	Formação Florestal			Tipos de vegetação com predomínio de espécies arbóreas, com formação de dossel contínuo (Mata Ciliar, Mata de Galeria, Mata Seca e Cerradão), além de florestas estacionais semidecíduais
	Formação Savânica			Formações savânicas com estratos arbóreo e arbustivo herbáceos definidos (Cerrado Sentido Restrito: Cerrado denso, Cerrado típico, Cerrado ralo e Cerrado rupestre).
Vegetação Herbácea e Arbustiva	Campo Alagado e Área Pantanosa			Vegetação com predomínio de estrato herbáceo sujeita ao alagamento sazonal (ex. Campo Úmido) ou sobre influência fluvial/lacustre (ex. Brejo). Em algumas regiões a matriz herbácea ocorre associada às espécies arbóreas de formação savânica (ex. Parque de Cerrado) ou de palmeiras (Vereda, Palmeiral).
	Formação Campestre			Formações campestres com predominância de estrato herbáceo (campo sujo, campo limpo e campo rupestre) e algumas áreas de formações savânicas como o Cerrado rupestre.
Agropecuária	Pastagem			Áreas de pastagem plantadas, diretamente relacionadas à atividade agropecuária. As áreas de pastagem natural, por sua vez, são predominantemente <u>caracterizadas como formações campestres ou campo alagado</u> , podendo ser submetidas ou não a práticas de pastejo
	Agricultura	Lavoura Temporária	Soja, Cana e outras	Áreas cultivadas com monocultura de soja, cana e outras
		Lavoura Perene	Café e outras	Áreas cultivadas com monocultura do café e outras.

	Silvicultura	Espécies arbóreas plantadas para fins comerciais (ex. pinus, eucalipto, araucária).
	Mosaico de Usos	Áreas de uso agropecuário onde não foi possível distinguir entre pastagem e/ou agricultura.
Área Não Vegetada	Área Urbanizada	Áreas com significativa densidade de edificações e vias, incluindo áreas livres de construções e infraestrutura.
	Outras Áreas Não Vegetadas	Áreas de superfícies não permeáveis (infraestrutura, expansão urbana ou mineração) não mapeadas em suas respectivas classes, regiões de solo exposto em área natural (exemplo: erosão e voçorocamento) ou em áreas de cultivo em entressafrá.
Corpos D'água	Rio, Lago e Oceano	Rios, lagos, represas, reservatórios e outros corpos d'água.

Fonte: Adaptado de MapBiomas (2025).

A Figura 10 apresenta o mapa de Uso e Cobertura da Terra, com base nos dados do MapBiomas para a área de estudo. Tal mapa foi utilizado como referência na próxima etapa, sendo de suma importância para guiar o presente trabalho.

Figura 10 – Classes de Uso e Cobertura da Terra para 2022, segundo MapBiomias.



Fonte: a autora (2025).

Com intuito de otimizar o processo de classificação, realizou-se a generalização das classes temáticas, agrupando aquelas que dispusessem de características espectrais e estruturais semelhantes, de modo que haja homogeneidade em cada classe (Quadro 3).

Vale ressaltar que algumas classes foram mantidas conforme a referência do MapBiomias, principalmente aquelas que se destacaram por seu comportamento espectral e por representarem áreas significativas na região de estudo. Como por exemplo, Soja e Cana foram agrupadas na mesma classe, enquanto Silvicultura foi mantida conforme o MapBiomias, devido à sua distinção espectral. Dessa forma, foram determinadas as seguintes classes para a condução do estudo:

Quadro 3 – Classes definidas para o estudo.

CLASSES	SIGLAS	REFERÊNCIA MAPBIOMIAS
Silvicultura	SIL	Silvicultura
Hidrografia	HID	Rio, Lago, Oceano
Pastagem	PAS	Pastagem e Mosaico de Usos
Lavouras Temporárias	TEMP	Soja, Cana e Outras Lavouras Temporárias
Lavouras Perenes	PER	Café e Outras Lavouras Perenes

Floresta	FLO	Formação Florestal e Savânica
Vegetação Herbácea e Arbustiva	HEB	Formação Campestre, Campo Alagado e Área Pantanosa

Fonte: a autora (2025).

É possível observar que a classe ‘Área Urbanizada’ não foi utilizada para condução do estudo, pois ela oferece muita confusão durante o processo de classificação, podendo causar interferência em outras classes consolidadas. Dessa maneira, as áreas urbanizadas da área de estudo foram vetorizadas para fins de visualização nos mapas finais.

4.3.3 *Processamento*

Na terceira etapa, foram coletadas amostras de treinamento para cada classe temática previamente definida, utilizando o *software* ENVI Classic. Esse processo foi realizado por meio da ferramenta ROI Tool, com a delimitação de polígonos distribuídos por toda a área de estudo. O objetivo foi garantir uma representatividade adequada das amostras, evitando viés causado pela concentração excessiva de informações espectrais em regiões específicas.

Em razão das diferentes resoluções espaciais das imagens utilizadas no estudo, cada uma apresentou uma amostragem distinta de pixels por classe temática. No entanto, foi adotado um padrão de amostragem consistente entre todas as imagens, de forma a garantir que as amostras de todas as imagens fossem iguais no quesito área. A Tabela 5 apresenta a quantidade de pixels obtida para cada classe, conforme o satélite utilizado.

Tabela 5 – Quantidade de pixels extraídos por satélite referente cada classe temática

SATÉLITE	RESOLUÇÃO ESPACIAL	QUANTIDADE DE PIXELS POR CLASSE	ÁREA
CBERS 04A	8m	14.063	900.000m ²
Sentinel-2	10m	9.000	900.000m ²
PRISMA	30m	1.000	900.000m ²

Fonte: a autora (2025).

Posteriormente, realizou-se a classificação supervisionada utilizando os algoritmos Paralelepípedo, MiniDist, MahaDist, MaxVer, RN e SVM, disponíveis na aba *Classification* no *software* ENVI Classic, para geração dos mapas de uso do solo. Vale ressaltar que todos os algoritmos foram utilizados com os parâmetros de entrada padrão, sem haver mudanças para nenhuma classificação em específico.

4.3.4 Pós-processamento

Esta etapa consiste na validação dos resultados obtidos anteriormente, empregando como métricas o Índice Kappa, a Exatidão Global e a Matriz de confusão. Para tanto, as amostras de validação foram coletadas por meio do *software* ENVI *Classic* utilizando a ferramenta ‘ROI *Tool*’ e, em seguida, processadas na ferramenta ‘*Confusion Matrix*’. Tal recurso possibilitou o cálculo dos parâmetros citados, fornecendo não apenas os valores de Índice Kappa e Exatidão Global, mas também uma avaliação detalhada do desempenho da classificação, a Matriz de Confusão e a tabela de Comissão e Omissão.

4.3.5 Geração de produtos

Tendo em vista as classificações obtidas e os parâmetros calculados, as classificações que apresentaram melhor desempenho foram submetidas ao processo de representação gráfica através do ambiente QGIS, onde foi possível realizar o layout para os mapas temáticos. Para construção dos mapas, foi utilizada a mesma paleta de cores fornecida pelo MapBiomass, a fim de facilitar a análise dos produtos.

5 RESULTADOS

Tendo em vista todos os processos realizados na seção 4.3, os primeiros resultados do presente estudo são apresentados na Tabela 6, que exhibe os valores de Índice Kappa e Exatidão Global obtidos no processo de validação. Essas métricas são fundamentais para avaliar a confiabilidade e a precisão da classificação, permitindo uma compreensão do desempenho da metodologia aplicada.

Tabela 6 – Panorama geral dos classificadores por satélite, considerando Exatidão Global (%) e Índice Kappa.

Classificador	CBERS 04A		Sentinel-2		PRISMA	
	Exatidão Global	Kappa	Exatidão Global	Kappa	Exatidão Global	Kappa
Distância de Mahalanobis	76,01%	0,7201	84,94%	0,8243	95,85%	0,9516
Máxima Verossimilhança	84,32%	0,8171	92,22%	0,9093	-	-
Distância Mínima	69,82%	0,6479	75,91%	0,7189	77,06%	0,7322
Paralelepípedo	62,12%	0,5596	64,28%	0,5868	43,95%	0,3476
Support Vector Machine	84,93%	0,8241	92,68%	0,9146	93,85%	0,9282
Redes Neurais	79,51%	0,761	91,77%	0,904	-	-

Fonte: a autora (2025).

De acordo com os resultados apresentados na Tabela 6, é possível verificar variações significativas no desempenho das classificações entre as diferentes imagens, refletindo as características particulares de cada uma. Dessa forma, a classificação por meio da imagem CBERS 04A, mostrou resultados relativamente inferiores, mas ainda robustos, com **Exatidão Global de 84,93%** e **Kappa de 0,8241** considerando o classificador SVM, assim refletindo um desempenho **muito bom** de acordo os níveis de qualidade do Índice Kappa.

O satélite Sentinel-2 apresentou os melhores resultados gerais, com valor máximo de **Exatidão Global em 92,68%** e valor de **Kappa em torno de 0,91**, indicando um **excelente** resultado com base nos parâmetros do Índice Kappa. Este desempenho consistente pode ser atribuído à uma combinação ideal entre resolução espacial e espectral, que favoreceu a discriminação de classes sem introduzir complexidade excessiva nos dados.

Já a imagem hiperespectral PRISMA, revelou um comportamento mais extremo, alternando entre os melhores e piores resultados individuais. Enquanto classificadores como *Support Vector Machine* e Distância de Mahalanobis alcançaram **excelentes** índices, superiores a **0,93 de Kappa**, algoritmos tradicionais como Paralelepípedo apresentaram desempenho muito abaixo (43,95%), evidenciando os desafios no processamento de dados hiperespectrais.

Os resultados apresentados na Tabela 6, evidenciaram limitações significativas em alguns classificadores quando aplicados ao satélite PRISMA: tanto o MaxVer quanto a RN não geraram classificações válidas para o estudo, ou seja, durante o processo de classificação estes algoritmos não geraram um produto final. Observa-se também que os classificadores MiniDist e Paralelepípedo apresentaram desempenho inferior em todos os satélites utilizados, com Índices Kappa variando de 0,34 a 0,58 para o algoritmo Paralelepípedo e de 0,64 a 0,73 para o MiniDist. Diante dessas constatações, optou-se por elaborar uma nova tabela contendo apenas os modelos que demonstraram resultados consistentes e satisfatórios, permitindo uma comparação mais clara entre os algoritmos mais eficazes.

Para representação gráfica, selecionou-se exclusivamente as classificações que alcançaram os melhores índices de precisão em cada satélite, conforme demonstrado na Tabela 7. Esta seleção baseou-se nos valores combinados de Exatidão Global e Índice Kappa, priorizando classificações que obtiveram Kappa acima de 0,8.

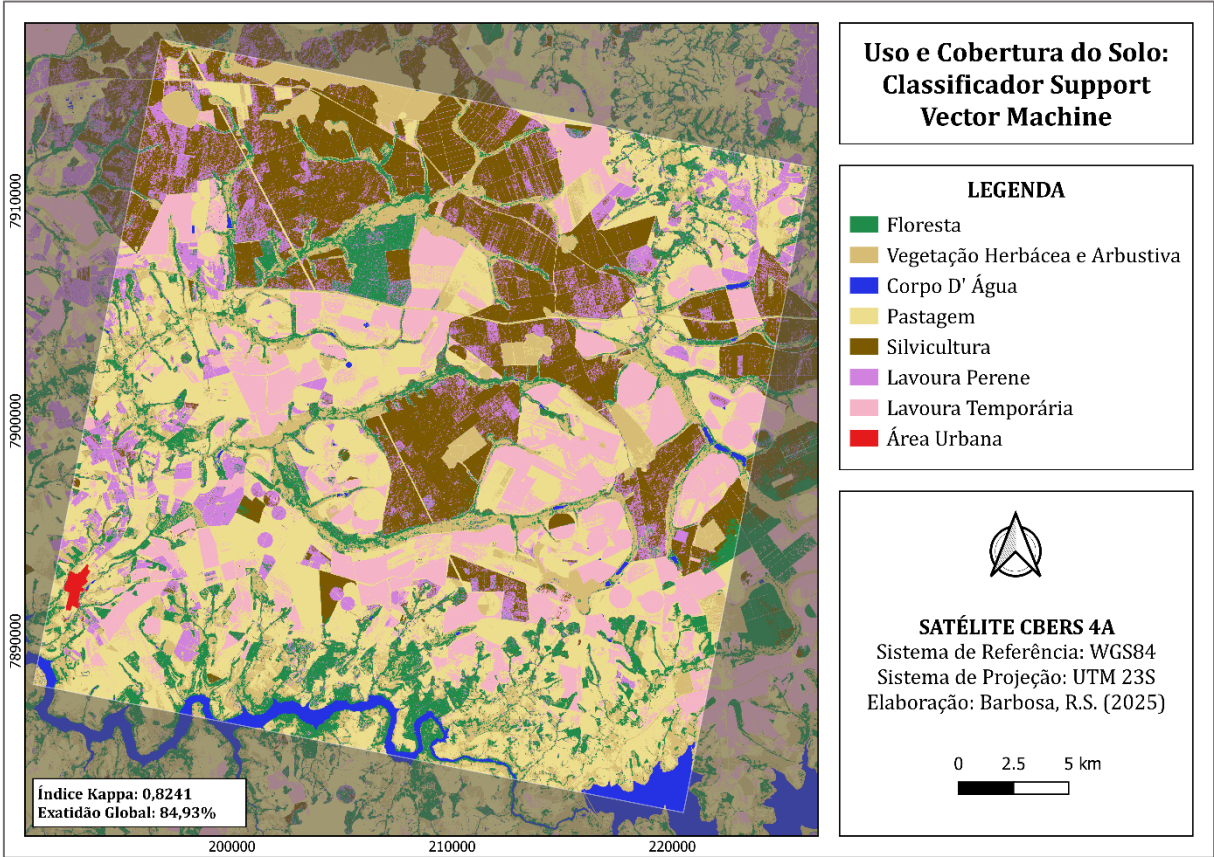
Tabela 7 – Desempenho comparativo dos classificadores Distância de Mahalanobis e Support Vector Machine (SVM) nos satélites CBERS 04A, Sentinel-2 e PRISMA, apresentando os valores de Exatidão Global (%) e Índice Kappa.

Classificador	CBERS 04A		Sentinel-2		PRISMA	
	Exatidão Global	Kappa	Exatidão Global	Kappa	Exatidão Global	Kappa
Distância de Mahalanobis	76,01%	0,7201	84,94%	0,8243	95,85%	0,9516
Support Vector Machine	84,93%	0,8241	92,68%	0,904	93,85%	0,9282

Fonte: a autora (2025).

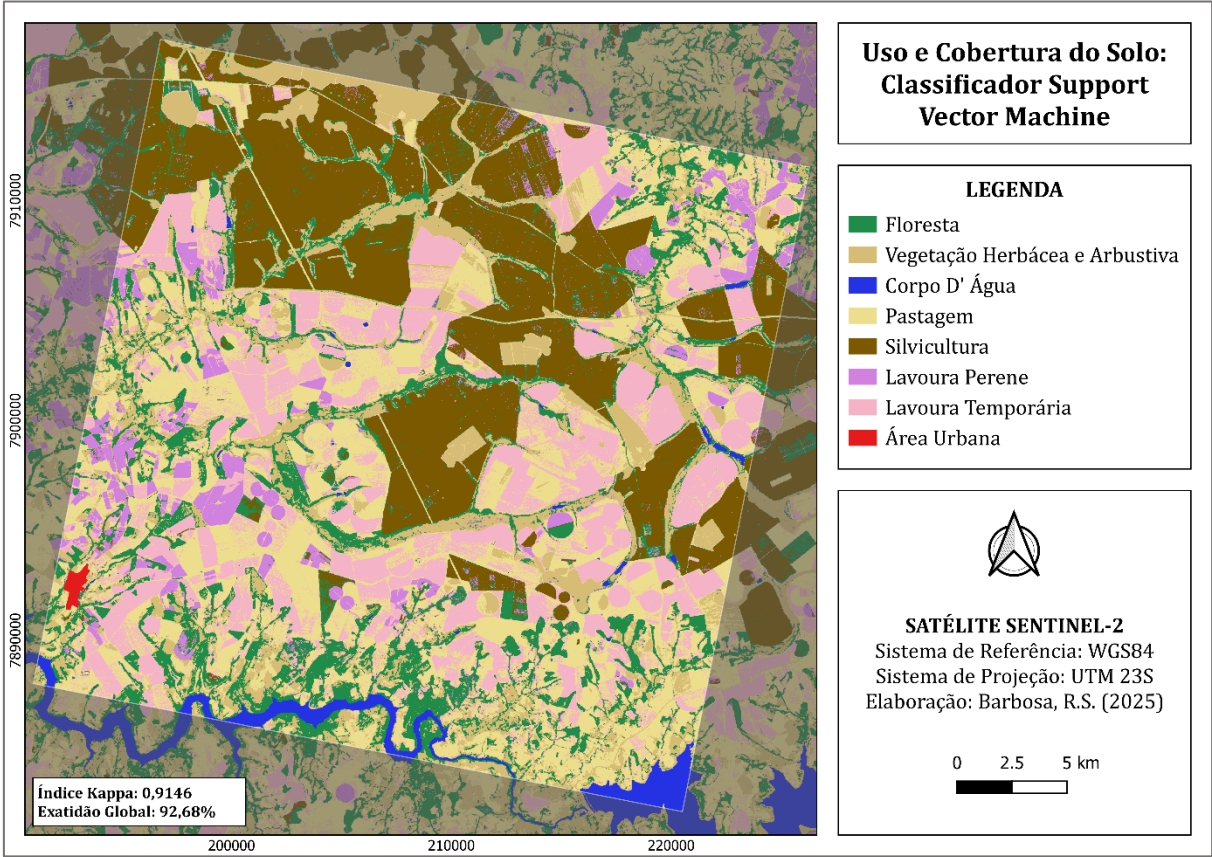
Os produtos cartográficos apresentados a seguir, correspondem as classificações dos satélites CBERS 04A e Sentinel-2 a partir do algoritmo SVM (Figuras 11 e 12), e para o satélite PRISMA com base no classificador MahaDist (Figura 13), que não apenas obtiveram as métricas mais elevadas, mas também mostraram consistência na discriminação das classes de uso e cobertura do solo.

Figura 11 – Mapa de uso e cobertura do solo a partir de classificação supervisionada pelo algoritmo SVM utilizando imagens do satélite CBERS 04A.



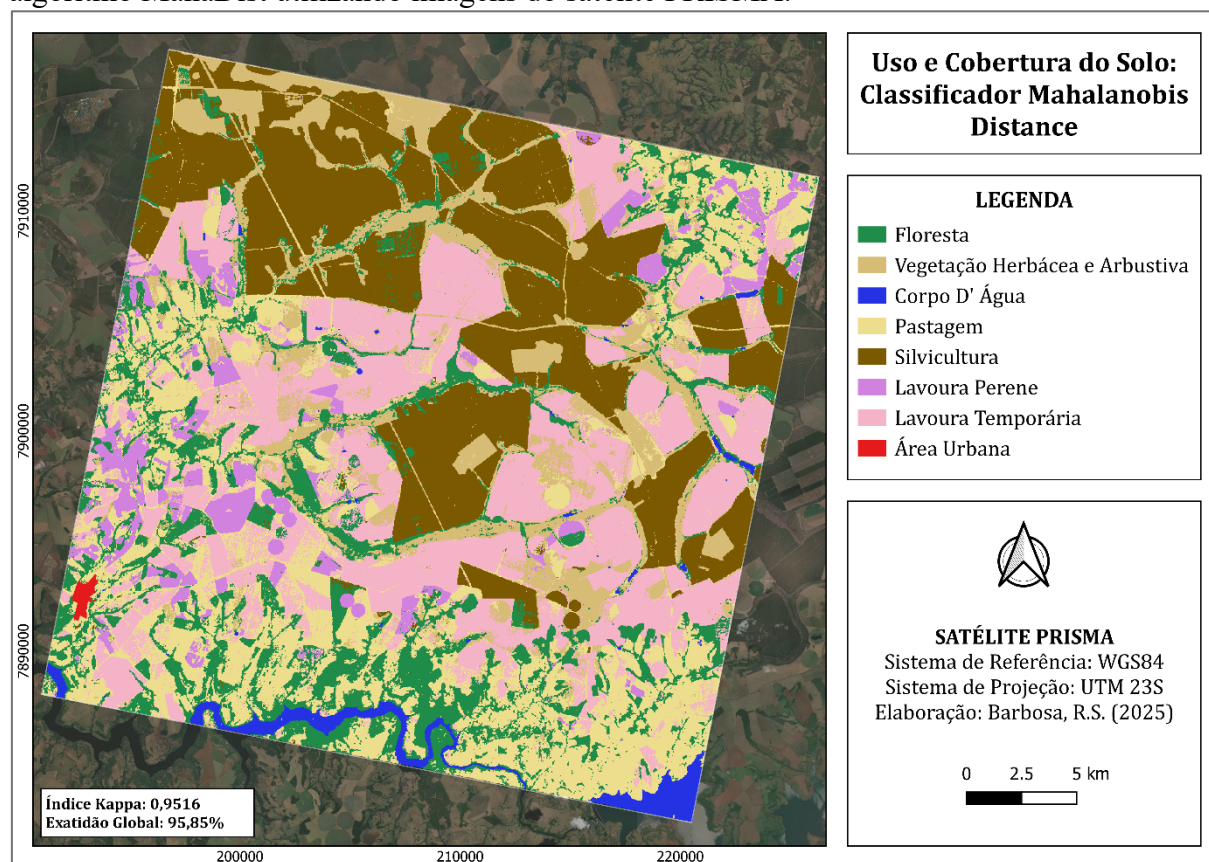
Fonte: a autora (2025).

Figura 12 – Mapa de uso e cobertura do solo a partir de classificação supervisionada pelo algoritmo SVM utilizando imagens do satélite Sentinel-2.



Fonte: a autora (2025).

Figura 13 – Mapa de uso e cobertura do solo a partir de classificação supervisionada pelo algoritmo MahaDist utilizando imagens do satélite PRISMA.

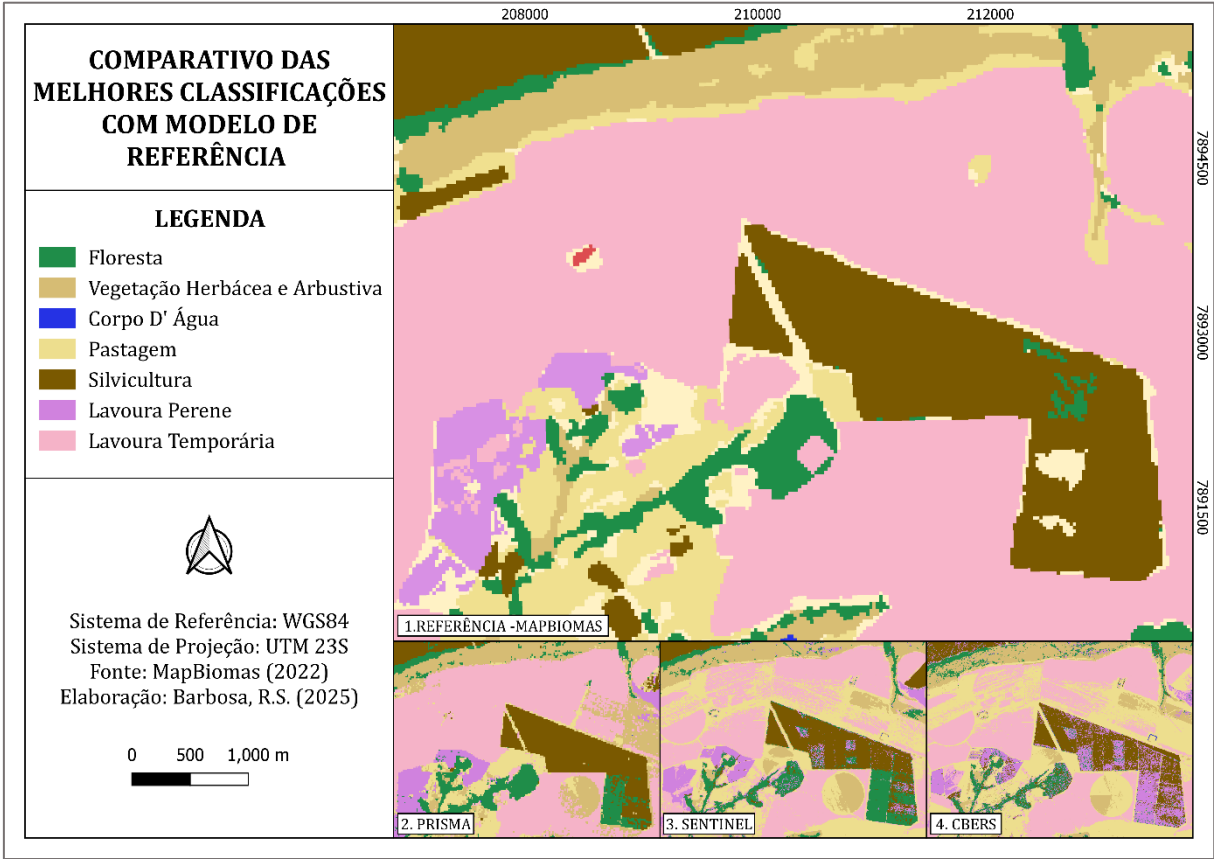


Fonte: a autora (2025).

É importante destacar que na seção de Resultados, foram apresentados exclusivamente os produtos cartográficos das classificações com melhor desempenho para cada satélite. Os demais mapas, correspondentes às classificações mencionadas na Tabela 7, encontram-se disponíveis nos Apêndices A, B e C deste trabalho.

Outro produto elaborado foi um mapa temático, contendo a base de referência e as classificações anteriormente apresentadas, com destaque para uma área específica selecionada para análise em maior detalhe (Figura 14). Esta representação gráfica permite avaliar visualmente: (i) a concordância entre as classificações e os dados de referência, e (ii) os padrões de discordância nas classes temáticas analisadas.

Figura 14 – Mapa comparativo entre as melhores classificações.



Fonte: a autora (2025).

Nas Tabelas 8, 9 e 10, são apresentadas as matrizes de confusão referentes à classificação supervisionada das imagens de cada satélite, com todos os valores expressos em porcentagem. Essas matrizes detalham os acertos e erros da classificação para cada classe temática, incluindo os respectivos erros de omissão e comissão. Esses resultados permitem uma avaliação quantitativa da acurácia do mapeamento, destacando as discrepâncias entre as classes previstas e as observadas, mas também a performance relativa de cada satélite em diferentes categorias de uso e cobertura do solo.

Tabela 8 – Matriz de Confusão (%) com Erros de Omissão (EO) e Comissão (EC) para o satélite CBERS 04A.

CBERS 04A: Support Vector Machine											
Referência											
Classificação	CLASSES	FLO	HEB	HID	PAS	PER	SIL	TEMP	TOTAL	EC	EO
	FLO	81,22	0	0	0	3,84	13,41	0	14,07	17,52	18,78
	HEB	1,1	99,54	0	9,96	0,04	0,04	0	15,81	10,06	0,46
	HID	0	0	100	0	0	0	0	14,29	0	0
	PAS	0	0,46	0	81,40	0,04	0	24,36	15,18	23,39	18,6
	PER	10,42	0	0	0	91	20,87	0	17,47	25,59	9

	SIL	7,25	0	0	0	5,09	65,68	0	11,15	15,82	34,32
	TEMP	0	0	0	8,64	0	0	75,64	12,04	10,25	24,36
	TOTAL	100	100	100	100	100	100	100	100		

Fonte: a autora (2025).

Tabela 9 – Matriz de Confusão (%) com Erros de Omissão (EO) e Comissão (EC) para o satélite Sentinel-2.

SENTINEL-2: Support Vector Machine											
Referência											
Classificação	CLASSES	FLO	HEB	HID	PAS	PER	SIL	TEMP	TOTAL	EC	EO
	FLO	94,16	0	0	0	0	1,76	8,69	15,10	9,78	5,84
	HEB	0,33	100	0	4,16	0	0	0	14,84	4,36	0
	HID	0	0	100	0	0	0	0	14,33	0	0
	PAS	0	0	0	91,19	0	0	26,07	16,83	21,82	8,81
	PER	3,93	0	0	0	100	0	0	14,71	3,86	0
	SIL	1,58	0	0	0	0	98,24	0,39	14,38	1,98	1,76
	TEMP	0	0	0	4,65	0	0	64,95	9,81	6,84	35,15
	TOTAL	100	100	100	100	100	100	100	100		

Fonte: a autora (2025).

Tabela 10 – Matriz de Confusão (%) com Erros de Omissão (EO) e Comissão (EC) para o satélite PRISMA.

PRISMA: Distância de Mahalanobis											
Referência											
Classificação	CLASSES	FLO	HEB	HID	PAS	PER	SIL	TEMP	TOTAL	EC	EO
	FLO	100	0,47	0	0,47	0	3,83	8,22	16,66	11,24	0
	HEB	0	97,20	0	8,49	0	0	0	15,12	7,96	2,8
	HID	0	0	100	0	0	0	0	14,05	0	0
	PAS	0	0,93	0	89,62	0	0	1,83	13,11	3,06	10,38
	PER	0	0	0	0	100	0	0	14,05	0	0
	SIL	0	0	0	0	0	96,17	1,83	13,71	1,95	3,83
	TEMP	0	1,4	0	1,42	0	0	88,13	13,31	3,02	11,87
	TOTAL	100	100	100	100	100	100	100	100		

Fonte: a autora (2025).

6 DISCUSSÃO

6.1 Comparativo entre classificadores

Entre os classificadores avaliados, o SVM destacou-se como o algoritmo mais consistente e eficiente em todos os satélites testados (Tabela 6). Sua capacidade de lidar com dados complexos foi particularmente evidente no PRISMA, com excelente Índice Kappa de 0,9282. O algoritmo também manteve desempenho elevado nos satélites multiespectrais: 0,8241 para o CBERS e 0,9146 utilizando Sentinel-2, comprovando sua versatilidade em diferentes resoluções espectrais e espaciais. No estudo de Rocha (2024), foi visto que ao aplicar o SVM em imagens Sentinel-2 para mapeamento de uso e cobertura do solo, apresentou Índices Kappa superiores a 0,9 nos períodos de 2019 e 2021, validando a eficácia do algoritmo para diferentes contextos de classificação.

O Máxima Verossimilhança demonstrou resultados muito próximos ao SVM nos satélites multiespectrais, com Kappa de 0,81 para CBERS e de 0,90 para Sentinel-2, demonstrando resultados excelentes, assim como no estudo de Hossu e Pons (2023), que reportaram acurácias de 86% e 92%, respectivamente, em classificações supervisionadas com este algoritmo. No entanto, sua inviabilidade no PRISMA sugere limitações em ambientes de alta resolução espectral, onde as suposições estatísticas do método podem não se sustentar.

O classificador Distância de Mahalanobis mostrou comportamento interessante, com desempenho excelente para o satélite PRISMA, obtendo Kappa de 0,9516, mas resultados mais modestos nos outros satélites, indicando que sua eficácia aumentou significativamente quando aplicado a dados com alta informação espectral.

Por outro lado, métodos mais simples como Distância Mínima e especialmente Paralelepípedo, apresentaram desempenho inferior em todos os cenários, com queda acentuada no PRISMA. Essa limitação dos algoritmos citados, encontra respaldo no estudo de Sousa, Pereira e Garcês Júnior (2021), que ao avaliar classificadores utilizando imagens Landsat 8 (com resolução espacial equivalente à do satélite PRISMA), registraram valores de Kappa consideravelmente baixos para o Distância Mínima e Paralelepípedo, de 0,433 e 0,13 respectivamente. Os resultados obtidos tanto no presente estudo quanto na literatura citada, levantam a hipótese que esses algoritmos possuem limitações para o processamento de imagens com menor resolução espacial, especialmente o Paralelepípedo.

A ausência de resultados para Redes Neurais no PRISMA, apesar de seu bom desempenho nos outros satélites, reforça a necessidade de calibração específica do algoritmo e

maior poder computacional para lidar com dados hiperespectrais, sugerindo que implementações padrões deste método podem não ser suficientes para extrair todo o potencial de satélites avançados.

Dessa forma, embora o PRISMA tenha demonstrado desempenho superior em dois classificadores específicos, sua inconsistência em outros algoritmos - que apresentaram bons resultados nos demais satélites - evidencia os desafios referentes ao trabalho com dados hiperespectrais. Essa variabilidade reforça a necessidade de empregar técnicas de aprendizado de máquina adaptadas à complexidade desses dados, visando extrair todo seu potencial espectral (Shaik; Periasamy; Zeng, 2023).


Em contraste, o Sentinel-2 destacou-se pela robustez e consistência, alcançando excelentes resultados na maioria dos algoritmos testados. Essa performance estável, somada à sua maior disponibilidade de dados e resolução espacial média, posiciona-o como uma alternativa mais vantajosa em muitos cenários práticos. A escolha entre os sensores, contudo, deve considerar as especificidades da aplicação: enquanto o PRISMA pode oferecer vantagens pontuais em análises que demandam alta resolução espectral, o Sentinel-2 apresenta um equilíbrio ideal entre desempenho e acessibilidade.

6.2 Avaliação dos melhores modelos

As matrizes de confusão (Tabelas 8, 9 e 10) revelaram padrões consistentes no desempenho dos classificadores SVM e MahaDist aplicados aos satélites CBERS, Sentinel-2 e PRISMA. Os resultados demonstram que certas classes apresentam desafios recorrentes, enquanto outras mantêm desempenho estável independentemente do satélite ou algoritmo utilizado.

As classes **Hidrografia** e **Vegetação Herbácea e Arbustiva** destacaram-se pelo excelente desempenho em todos os cenários analisados. Hidrografia alcançou classificação perfeita, sem erros de omissão ou comissão, tanto no CBERS quanto no Sentinel-2 utilizando SVM, e no PRISMA com Distância de Mahalanobis. Esse padrão confirma a distinção espectral única dos corpos d'água, que apresentam características de reflectância singulares, facilitando sua identificação mesmo com diferentes resoluções espaciais e espectrais. Na Figura 15, é possível observar um fragmento real da classe Hidrografia e sua correspondente área classificada, evidenciando a clara separação dos corpos d'água em relação às demais classes.

Figura 15 – Fragmento da classe Hidrografia e sua área classificada.



Fonte: a autora (2025).

A **Vegetação Herbácea e Arbustiva** também mostrou resultados elevados, com pequena confusão para os satélites CBERS e PRISMA e sem erros para o Sentinel-2, indicando que formações campestres possuem assinaturas espectrais bem definidas.

Por outro lado, classes agropecuárias apresentaram os maiores desafios classificatórios, com altos erros de omissão em ambos os satélites. A confusão entre **Pastagem** e **Lavoura Temporária** mostrou-se particularmente persistente, com taxa de erro a 4,65% para Pastagem com Temporária e 26,06% Temporária com Pastagem no Sentinel-2 e para o satélite CBERS 04A de 8,64% e 24,36% respectivamente. Essa confusão classificatória pode ser atribuída à similaridade fenológica entre pastagens e culturas temporárias em determinados estágios de desenvolvimento, especialmente quando as culturas estão em fase inicial de crescimento. O PRISMA, apesar de sua maior resolução espectral, não conseguiu resolver completamente esse problema, embora tenha reduzido as taxas de erro entre Pastagem e Temporária para 1,41% e Temporária com Pastagem em 1,82%, assim sugere-se que fatores além da assinatura espectral (como resolução espacial e época de imageamento) influenciaram nessa confusão.

A análise também revelou uma significativa confusão entre as classes de **Pastagem** e **Vegetação Herbácea e Arbustiva**, com taxas de pixels incorretos de 9,95% para o CBERS, 4,15% para o Sentinel-2 e 8,49% para o PRISMA. Essa confusão sugere que áreas de pastagem com vegetação mais densa ou em estágio avançado de crescimento, podem apresentar assinaturas espectrais semelhantes a vegetação herbácea e arbustiva (Figura 16), tendo em vista que áreas de pastagem natural podem ser caracterizadas como formações campestres ou campo alagado (MapBiomias, 2025).

Figura 16 – Fragmentos das classes de Pastagem e Vegetação Herbácea e Arbustiva, respectivamente.

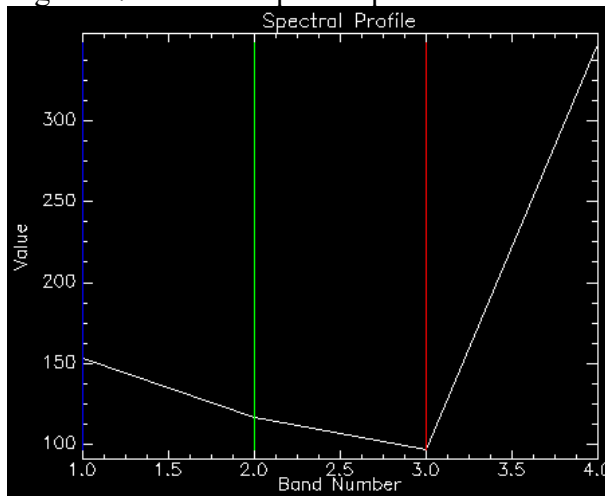


Fonte: a autora (2025).

Os resultados ainda revelaram um padrão consistente de confusão entre **Floresta**, **Silvicultura** e **Lavoura Perene**, especialmente evidente nos dados CBERS, onde cerca de 17,67% das áreas de Floresta foram classificadas como Silvicultura e Lavoura Perene, enquanto 34,28% das amostras de Silvicultura foram confundidas com Lavoura Perene e Floresta. Esse fenômeno foi menos pronunciado no Sentinel-2 com 5,51% e 1,76%, respectivamente, e no satélite PRISMA 3,83% apenas para confusão entre Silvicultura e Floresta. Assim, indicando que a maior resolução espectral do PRISMA contribuiu para melhorar a discriminação entre esses tipos de cobertura vegetal.

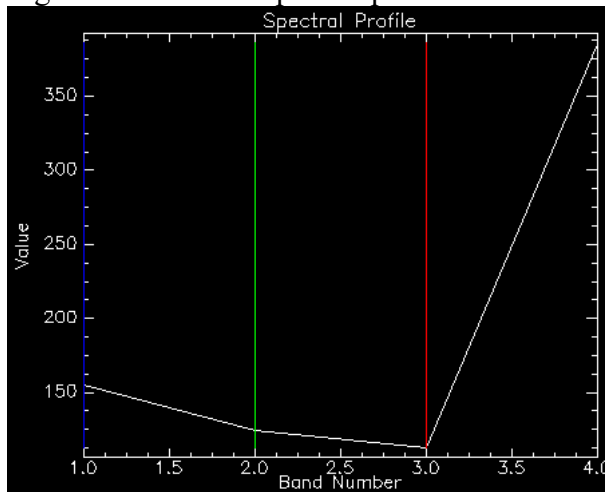
Contudo, os padrões de confusão identificados decorrem devido à alta similaridade espectral entre essas classes, o que compromete a discriminação pelos algoritmos de classificação. Como evidenciado nas Figuras 17, 18 e 19, as curvas espectrais das classes de Silvicultura, Lavoura Perene e Floresta não apenas apresentam comportamentos semelhantes, mas também valores de reflectância próximos, variando entre 150 e 350 para dados do satélite CBERS 04A.

Figura 17 – Curva espectral para a classe de Silvicultura.




Fonte: a autora (2025).

Figura 18 – Curva espectral para a classe de Lavoura Perene.



Fonte: a autora (2025).

Figura 19 – Curva espectral para a classe de Floresta.



Fonte: a autora (2025).

Por fim, o desempenho das classificações discutidas pode ser visualmente confirmado por meio dos mapas temáticos apresentados nas Figuras 11, 12, 13 e 14, que representam os produtos finais para os satélites CBERS 4A, Sentinel-2 e PRISMA, respectivamente, e um mapa comparativo dos melhores modelos. Essas representações gráficas evidenciam as áreas de maior acurácia, como as classes Hidrografia e Vegetação Herbácea, que aparecem bem definidas e homogêneas, corroborando os altos índices de precisão obtidos nas matrizes de confusão. Por outro lado, as regiões de transição entre Pastagem e Lavoura Temporária, assim como as áreas de sobreposição entre Floresta, Silvicultura e Lavoura Perene, são claramente identificáveis nos mapas, destacando-se como áreas com maior mistura de classes e, consequentemente, com maiores desafios.

7 CONCLUSÃO

Este trabalho buscou avaliar a acurácia do mapeamento de uso e ocupação do solo, utilizando imagens dos satélites CBERS 4A, Sentinel-2 e PRISMA, analisando a influência de suas resoluções espacial e espectral, o desempenho dos algoritmos de classificação e a compatibilidade entre satélites e métodos classificatórios. Os resultados demonstraram que cada satélite apresenta vantagens específicas, conforme suas características técnicas e aplicabilidades.

O PRISMA mostrou o melhor desempenho dentre todas as classificações realizadas, por meio do algoritmo Distância de Mahalanobis, com Índice Kappa de 0,95. O Sentinel-2, por sua vez, destacou-se como o satélite mais consistente, combinando boa resolução espacial e espectral, o que resultou em classificações excelentes para a maioria dos classificadores, especialmente com o algoritmo SVM. O CBERS 4A, embora com resolução espectral mais limitada, apresentou resultados satisfatórios, principalmente quando associado ao SVM.

Em síntese, a escolha do satélite e do método de classificação deve considerar o equilíbrio entre resolução espacial, espectral e o tipo de aplicação. Para mapeamentos operacionais, ou que exijam detalhamento espacial, o Sentinel-2 com SVM mostra-se como a combinação mais vantajosa, enquanto o PRISMA com ajustes metodológicos, pode ser eficaz em estudos que requeiram detalhamento espectral em áreas de maior extensão. Dessa forma, este trabalho reforça a importância da seleção criteriosa tanto do satélite quanto do algoritmo de classificação, considerando as particularidades específicas dos dados e os objetivos do mapeamento.

Como perspectiva para trabalhos futuros, sugere-se a exploração de linguagens de programação ou plataformas de processamento em nuvem, como o *Google Earth Engine*, visando maximizar o potencial espectral do PRISMA por meio de técnicas avançadas de análise de dados e *machine learning*.

REFERÊNCIAS

- AGENZIA SPAZIALE ITALIANA. **PRISMA Catalogue Client**. [S. l.], 2022. Disponível em: http://prisma.asi.it/js-cat-client-prisma-src/?code=e0ab4382-26bb-3cde-88cd-1bd5e0e1064e&state=928969e6419fa9bd63c679d4ceca5687&session_state=875d9d72d7408f199b83ac55d0d900ee1034a2be376b97afb571e5e1dd948738.I2bX0Bn0cZ2-JrD0aQBCEw. Acesso em: 06 ago. 2024.
- AGENZIA SPAZIALE ITALIANA. **PRISMA**. [S. l.], 201-?. Disponível em: <https://www.asi.it/en/earth-science/prisma/>. Acesso em: 23 out. 2024.
- ALMEIDA, A. S.; SANTOS, R. L.; CHAVES, J. M. Mapeamento de Uso e Ocupação do Solo no Município de Jeremoabo-BA: Uso do Algoritmo Máxima Verossimilhança (Maxver). In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15, 2011, Curitiba. **Anais [...]**. Curitiba: INPE, 2011. p.7255. Disponível em: <http://marte.sid.inpe.br/col/dpi.inpe.br/marte/2011/07.12.17.17/doc/p0787.pdf?metadataarepository=&mirror=urllib.net/www/2011/03.29.20.55>. Acesso em: 31 out. 2024.
- CHAVES, M. E. D.; PICOLI, M. C. A.; SANCHES, I. D. Recent Applications of Landsat 8/OLI and Sentinel-2/MSI for Land Use and Land Cover Mapping: A Systematic Review. **Remote Sensing**, [S. l.], v. 12, n. 18, p. 3062, 2020. DOI: <https://doi.org/10.3390/rs12183062>. Disponível em: <https://www.mdpi.com/2072-4292/12/18/3062>. Acesso em: 01 jul. 2025.
- COELHO, V. H. R.; MONTENEGRO, S. M. G. L.; ALMEIDA, C. das N.; LIMA, E. R. V. de; RIBEIRO NETO, A.; MOURA, G. S. S. de. Dinâmica do uso e ocupação do solo em uma bacia hidrográfica do semiárido brasileiro. **Revista Brasileira De Engenharia Agrícola e Ambiental**, [S. l.], v. 18, n.1, p. 64–72, jan. 2014. DOI: <https://doi.org/10.1590/S1415-43662014000100009>. Disponível em: <https://www.scielo.br/j/rbeaa/a/7hTsMfpbbPzGYzMTWwP6spw/?lang=pt#>. Acesso em: 26 out. 2024.
- COMO ABRIR imagens do prisma no R. [S. l.: s. n.], 2021. 1 vídeo (16 min). Publicado pelo canal RadarGeo. Disponível em: <https://www.youtube.com/watch?v=QseMRsNn5hk>. Acesso em: 17 jun. 2025.
- ENVI. **Aspectos**. [S. l.], 202-?. Disponível em: <https://www.envi.com.br/>. Aceso em: 23 out. 2024.
- EOPORTAL. **Satellite Missions Catalogue: PRISMA (Hyperspectral)**. [S. l.], 2023. Disponível em: <https://www.eoportal.org/satellite-missions/prisma-hyperspectral>. Acesso em: 28 out. 2024.
- EUROPEAN SPACE AGENCY. **S2 Mission**. [S. l.], 202-?. Disponível em: <https://sentiwiki.copernicus.eu/web/s2-mission#S2-Mission-Radiometric>. Acesso em: 23 out. 2024.
- FENSTERSEIFER, S. L. B.; SILVA, L. R. e. Análise multitemporal do uso e ocupação do solo, através de geoprocessamento. **Revista Liberato**, [S. l.], v. 20, n. 33, p. 87-94, jun. 2019.

Disponível em: <https://revista.liberato.com.br/index.php/revista/article/view/590>. Acesso em: 26 out. 2024.

FIGUEIREDO, G. C.; VIEIRA, C. A. O. Estudo do comportamento dos índices de Exatidão Global, Kappa e Tau, comumente usados para avaliar a classificação de imagens do sensoriamento remoto. *In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO*, 13, 2007, Florianópolis. **Anais [...]**. Florianópolis: INPE, 2007. p. 5755-5762. Disponível em: <http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2006/11.13.17.35/doc/5755-5762.pdf>. Acesso em: 29 out. 2024.

FLORENZANO, T. G. **Iniciação em Sensoriamento Remoto**. 3. ed. São Paulo: Oficina de Textos, 2011.

FURLANETTO, R.H.; NANNI, M.R.; CRUSIOL, L.G.T.; SILVA, G.F.C.; OLIVEIRA JUNIOR, A. de. Potencial de utilização de sensores multiespectral e hiperespectral no estudo de diferentes alvos agrícolas. *In: JORNADA ACADÊMICA DA EMBRAPA SOJA*, 12, 2017, Londrina. **Documentos [...]**. Londrina: Embrapa Soja, 2017, p. 146-154. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1072792/1/146.pdf>. Acesso em: 15 jul. 2025.

GUARLADO, L. **O que é Cerrado: características e biodiversidade**. IPAM Amazônia, [S. l.], 2023. Disponível em: <https://ipam.org.br/o-que-e-cerrado-caracteristicas-biodiversidade-e-desmatamento/>. Acesso em: 22 mai. 2025.

HOSSU, A. B.; PONS, N. A. D. Inventário de feições erosivas e monitoramento de sua evolução em imagens de satélite CBERS-4A, Landsat-8 e Sentinel-2. *In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO*, 20, 2023, Florianópolis. **Anais [...]**. Florianópolis: INPE, 2023. p. 340-343. Disponível em: <http://marte2.sid.inpe.br/col/sid.inpe.br/marte2/2023/05.12.12.10/doc/155542.pdf>. Acesso em: 18 jun. 2025.

INACIO, G. de O. **Mapeamento do uso e cobertura do solo utilizando imagens WPM/CBERS-4A, MSI/SENTINEL-2 e OLI/LANDSAT-8 para o município de Seropédica, RJ**. 2022. Trabalho de Conclusão de Curso (Graduação em Engenharia Florestal) – Instituto de Florestas, Universidade Federal Rural do Rio De Janeiro, Seropédica, 2022. Disponível em: <https://rima.ufrj.br/jspui/bitstream/20.500.14407/5767/1/Gabriel%20de%20Oliveira%20Inacio.pdf>. Acesso: 06 nov. 2024.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **Catálogo**. [S. l.], 2022. Disponível em: <https://www.dgi.inpe.br/catalogo/explore>. Acesso em: 19 jan. 2025.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **CBERS**. [S. l.], 202-?. Disponível em: <https://www.gov.br/inpe/pt-br/programas/cbers>. Acesso em: 23 out. 2024.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **CBERS: Câmeras Imageadoras**. [S. l.], 2024. Disponível em: <https://www.gov.br/inpe/pt-br/programas/cbers/sobre-o-cbers-1/cbers-04a/cameras-imageadoras>. Acesso em: 28 out. 2024.

LOPES, B. R.; GOMES, L. R. S.; BOAS, M. E. V. **Introdução ao uso software R**. Belo Horizonte: UFMG, 2021. Disponível em:

<https://www.est.ufmg.br/~monitoria/Material/ApostilaR/IntroducaoR1.html>. Acesso em: 24 out. 2024.

MENESES, P. R.; ALMEIDA, T. de. **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. Brasília: UnB, 2012. Disponível em: https://edisciplinas.usp.br/pluginfile.php/5550408/mod_resource/content/3/Livro-SensoriamentoRemoto.pdf. Acesso em: 06 nov. 2024.

NOVO, E. M. L. de M. **Sensoriamento Remoto: Princípios e Aplicações**. 4. ed. São Paulo: Blucher, 2010.

PACHECO, D. G. Análise das mudanças do uso e ocupação do solo no município de Araçuaí, Minas Gerais por meio de técnicas de sensoriamento remoto nos anos de 2000 e 2019.

Revista Cerrados, Montes Claros, MG, v. 19, n. 2, p. 303-322, 2021. DOI:

10.46551/rc24482692202128. Disponível em:

<https://www.periodicos.unimontes.br/index.php/cerrados/article/view/3889/4631>. Acesso em: 06 nov. 2024.

PROJETO MAPBIOMAS. **Códigos de Legenda**. [S. l.], 2025. Disponível em:

<https://brasil.mapbiomas.org/codigos-de-legenda/>. Acesso em: 21 maio 2025

PROJETO MAPBIOMAS. **Coleção 9 da Série Anual de Mapas de Cobertura e Uso da Terra do Brasil**. [S. l.], 2022. Disponível em: <https://brasil.mapbiomas.org/colecoes-mapbiomas/>. Acesso em: 12 maio 2025.

PROJETO MAPBIOMAS. **Visão Geral da Metodologia**. [S. l.], 2025. Disponível em:

<https://brasil.mapbiomas.org/visao-geral-da-metodologia/>. Acesso em: 21 maio 2025

QGIS. [S. l.], 202-?. Disponível em: <https://www.qgis.org/>. Acesso em: 23 out. 2024.

ROCHA, K. M. **Avaliação do uso e cobertura do solo utilizando imagens do satélite Sentinel-2 no estudo de desastres ambientais: o caso do rompimento da barragem de Brumadinho-MG**. 2024. Trabalho de Conclusão de Curso (Graduação em Engenharia Ambiental) – Instituto Federal de Educação, Ciência e Tecnologia da Bahia, Vitória da Conquista, 2024. Disponível em:

http://200.128.35.58/jspui/bitstream/123456789/631/2/MONOGRAFIA_FINAL.pdf. Acesso em: 19 jun. 2025.

ROMERO, C. W. da S.; SILVA, Y. de F. da; SILVA, I. D. C.; GARÇON, E. A. M.; LAMPARELLI, R. A. C.; ROCHA, J. V. Comparação entre resultados de classificação supervisionada para única data e para diferentes datas do município de Santa Fé do Sul-SP. *In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO*, 19, 2019, Santos. **Anais** [...]. Santos: INPE, 2019. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1108757/1/5063.pdf>. Acesso em: 17 jul. 2025.

SANTOS, A. B. dos; PETRONZIO, J. A. C. Mapeamento de uso e ocupação do solo do município de Uberlândia-MG utilizando técnicas de Geoprocessamento. *In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO*, 15, 2011, Curitiba. **Anais** [...]. Curitiba: INPE, 2011. p.6185. Disponível em: <http://marte.sid.inpe.br/col/dpi.inpe.br/marte/2011/07.28.18.42/doc/p0210.pdf>. Acesso em: 31 out. 2024.

SHAIK, R. U.; PERIASAMY, S.; ZENG, W. Potential Assessment of PRISMA Hyperspectral Imagery for Remote Sensing Applications. **Remote Sensing**, [s. l.], v. 15, n. 5, p. 1378, 2023. DOI: <https://doi.org/10.3390/rs15051378>. Disponível em: <https://www.mdpi.com/2072-4292/15/5/1378>. Acesso em: 02 jul. 2025.

SOLARI, R. A. F. **Aplicação de métodos de classificação supervisionada em imagens do Sentinel-2, como suporte ao cadastro ambiental rural**. 2017. Dissertação (Mestrado em Ciências Ambientais) - Faculdade UnB Planaltina, Universidade de Brasília, Brasília, 2017. Disponível em: <http://repositorio.unb.br/handle/10482/32350>. Acesso em: 06 nov. 2024.

SOUSA, A. S. S.; PEREIRA, P. R. M.; GARCÊS JÚNIOR, A. R. Avaliação da qualidade de classificadores de imagens Landsat 8 em ambiente computacional SAGA GIS para mapeamento de cobertura da terra no bioma Cerrado. **Revista de Geografia e Interdisciplinaridade**, Grajaú, MA, v. 7, e202128, p. 01-25, 2021. DOI: <http://dx.doi.org/10.18764/2446-6549.e202128>. Disponível: <https://periodicoseletronicos.ufma.br/index.php/interespaco/article/view/11964/9684>. Acesso em: 20 jun. 2025.

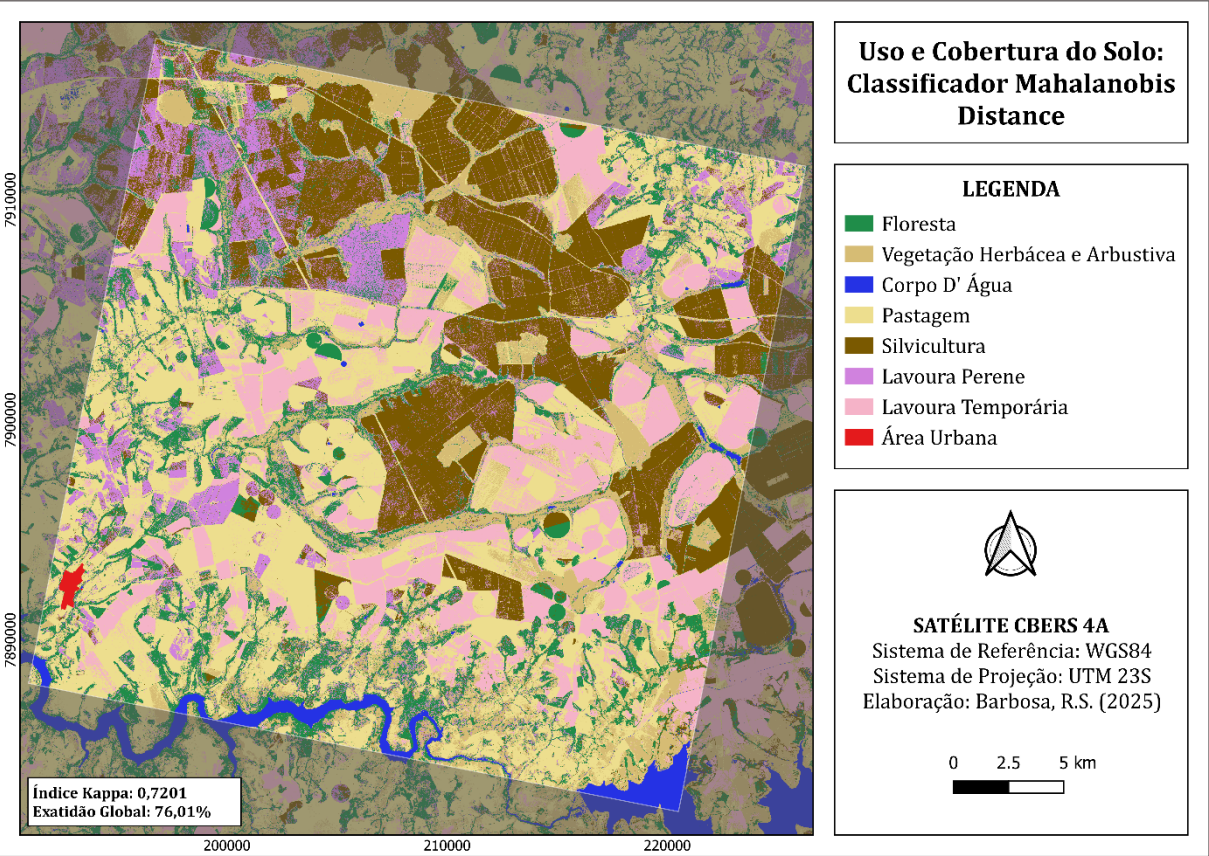
UNIVERSIDADE DE SÃO PAULO. Escola Superior de Agricultura “Luiz de Queiroz”. **Sistemas Sensores**. Piracicaba: USP/ESALQ, 2021. Disponível em: https://edisciplinas.usp.br/pluginfile.php/7862839/mod_resource/content/0/Sistemas%20Sensores.pdf. Acesso em: 06 nov. 2024.

VAEZA, R. F.; FILHO, P. C. de O.; MAIA, A. G.; DISPERATI, A. A. Uso e Ocupação do Solo em Bacia Hidrográfica Urbana a Partir de Imagens Orbitais de Alta Resolução. **Floresta e Ambiente**, [S. l.], v.17, n.1, p.23-29, 2010. DOI: doi 10.4322/floram.2011.003. Disponível em: <https://www.floram.org/article/10.4322/floram.2011.003/pdf/floram-17-1-23.pdf>. Acesso em: 06 nov. 2024.

VALE, J. R. B.; COSTA, J. A. da; SANTOS, J. F. dos; SILVA, E. L. S. da; FAVACHO, A. T. Análise comparativa de métodos de classificação supervisionada aplicada ao mapeamento da cobertura do solo no município de Medicilândia, Pará. **Revista de Geografia e Interdisciplinaridade**, Grajaú, MA, v. 4, n. 13, p. 26-44, 2018. DOI: <http://dx.doi.org/10.18764/2446-6549.v4n13p26-44>. Disponível: <https://periodicoseletronicos.ufma.br/index.php/interespaco/article/view/7884/5289>. Acesso em: 06 nov. 2024.

ZANOTTA, D. C.; FERREIRA, M. P.; ZORTEA, M. **Processamento de imagens de satélite**. [S. l.]: Oficina de Textos, 2019. Disponível em: https://books.google.com.br/books?hl=pt-BR&lr=&id=l6SWDwAAQBAJ&oi=fnd&pg=PT5&ots=YwL-W9me7c&sig=C_1nhZOvVrrLtH_nzDpn6ZNXXsI#v=onepage&q&f=false. Acesso em: 06 nov. 2024.

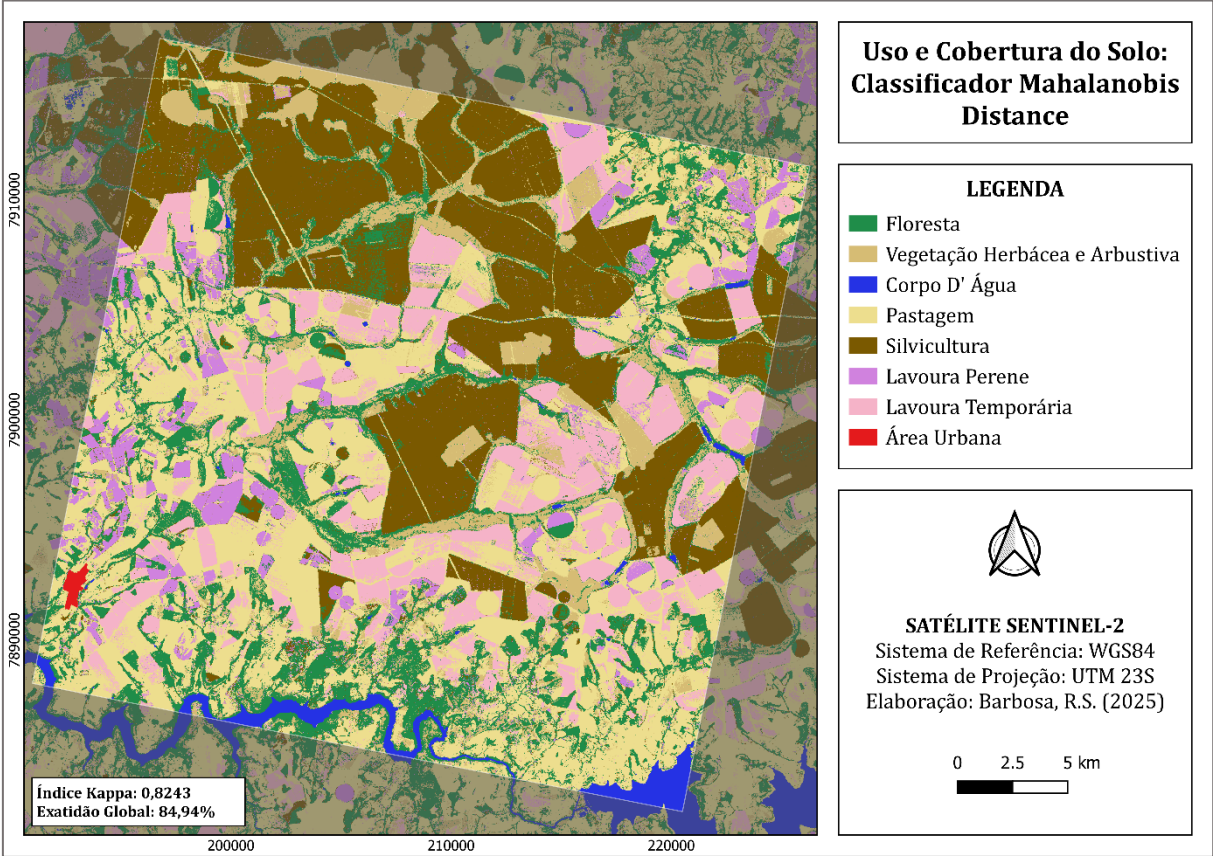
APÊNDICE A – RESULTADOS PARA CLASSIFICAÇÃO SUPERVISIONADA COM
BASE NO ALGORITMO MAHALANOBIS UTILIZANDO IMAGENS DO SATÉLITE
CBERS 04A



Mahalanobis Distance									
Classificação	Referência								
	Classes	Floresta	Herbácea	Hidrografia	Pastagem	Perene	Silvicultura	Temporária	Total
	Floresta	2149	85	0	63	299	67	265	2928
	Herbácea	76	2494	0	435	0	13	108	3126
	Hidrografia	0	14	2812	0	0	0	0	2826
	Pastagem	0	199	0	1545	4	0	785	2533
	Perene	458	4	0	0	2397	819	2	3680
	Silvicultura	129	5	0	0	112	1913	0	2159
	Temporária	0	11	0	769	0	0	1652	2432
	Total	2812	2812	2812	2812	2812	2812	2812	19684

Classes	Comissão (%)	Omissão (%)
Floresta	26.61	23.58
Herbácea	20.22	11.31
Hidrografia	0.5	0
Pastagem	39.01	45.06
Perene	34.86	14.76
Silvicultura	11.39	31.97
Temporária	32.07	41.25

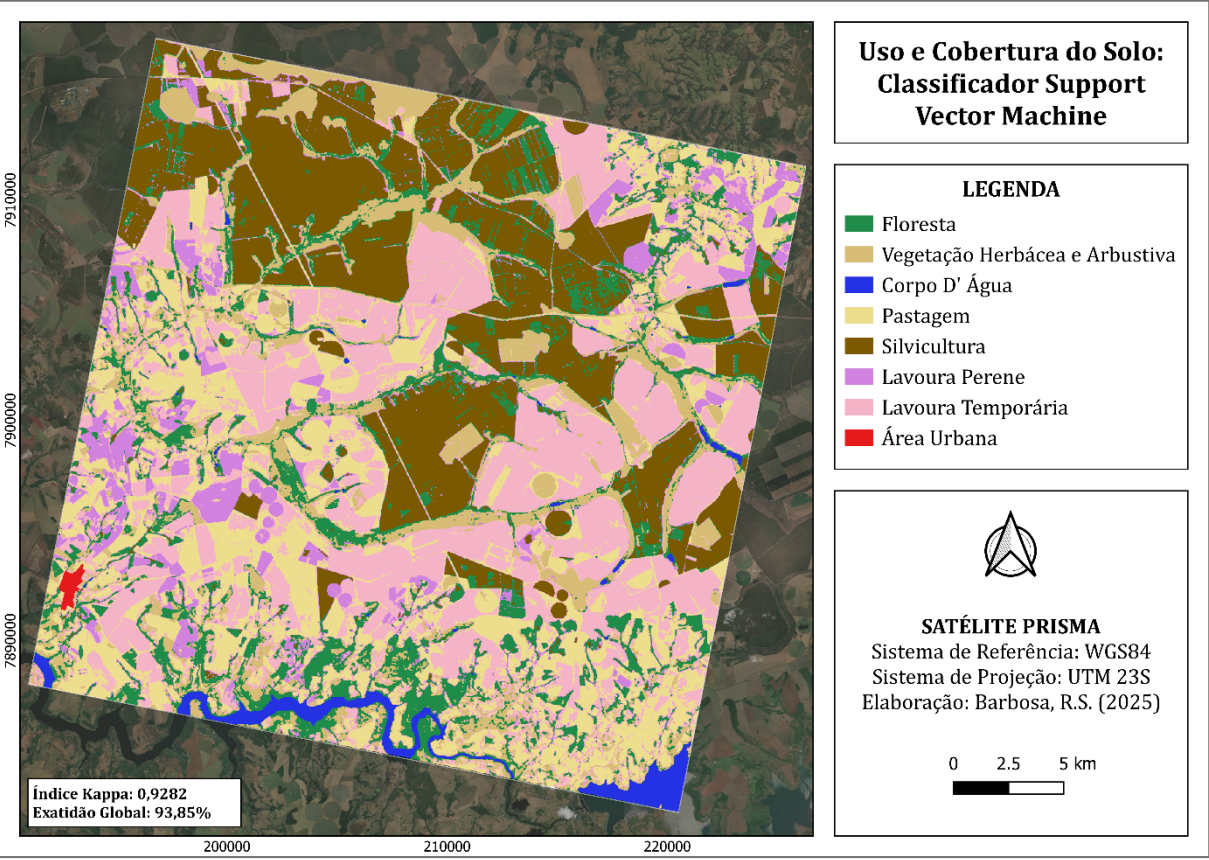
APÊNDICE B – RESULTADOS PARA CLASSIFICAÇÃO SUPERVISIONADA COM BASE NO ALGORITMO MAHADIST UTILIZANDO IMAGENS DO SATÉLITE SENTINEL



Mahalanobis Distance									
Classificação	Referência								
	Classes	Floresta	Herbácea	Hidrografia	Pastagem	Perene	Silvicultura	Temporária	Total
	Floresta	1586	0	0	21	24	151	168	1950
	Herbácea	18	1796	0	517	0	0	283	2614
	Hidrografia	0	0	1815	0	0	0	0	1815
	Pastagem	7	2	0	1176	0	0	287	1472
	Perene	110	0	0	2	1744	3	68	1927
	Silvicultura	112	0	0	0	23	1663	0	1798
	Temporária	0	0	0	111	0	0	978	1089
	Total	1833	1798	1815	1827	1791	1817	1784	12665

Classes	Comissão (%)	Omissão (%)
Floresta	18.67	13.48
Herbácea	31.29	0.11
Hidrografia	0	0
Pastagem	20.11	35.63
Perene	9.5	2.62
Silvicultura	7.51	8.48
Temporária	10.19	45.18

APÊNDICE C – RESULTADOS PARA CLASSIFICAÇÃO SUPERVISIONADA COM BASE NO ALGORITMO SVM UTILIZANDO IMAGENS DO SATÉLITE PRISMA



Support Vector Machine									
Classificação	Referência								
	Classes	Floresta	Herbácea	Hidrografia	Pastagem	Perene	Silvicultura	Temporária	Total
	Floresta	212	0	0	0	0	16	0	228
	Herbácea	3	214	0	0	0	0	0	217
	Hidrografia	0	0	210	0	0	0	0	210
	Pastagem	0	0	0	183	0	0	16	199
	Perene	0	0	0	0	210	0	0	210
	Silvicultura	6	0	0	0	0	193	22	221
	Temporária	0	0	0	29	0	0	181	210
	Total	221	214	210	212	210	209	219	1495

Classes	Comissão (%)	Omissão (%)
Floresta	11.24	0
Herbácea	7.96	2.8
Hidrografia	0	0
Pastagem	3.06	10.38
Perene	0	0
Silvicultura	1.95	3.83
Temporária	3.02	11.87