



UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO  
INSTITUTO DE FLORESTAS  
CURSO DE GRADUAÇÃO EM ENGENHARIA FLORESTAL

**GABRIEL DE OLIVEIRA INACIO**

**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.**

Prof. Dr. BRUNO ARAUJO FURTADO DE MENDONÇA  
Orientador

SEROPÉDICA, RJ  
SETEMBRO - 2022



UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO  
INSTITUTO DE FLORESTAS  
CURSO DE GRADUAÇÃO EM ENGENHARIA FLORESTAL

**GABRIEL DE OLIVEIRA INACIO**

**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.**

Monografia apresentada ao Curso de Engenharia Florestal, como requisito parcial para a obtenção do Título de Engenheiro Florestal, Instituto de Florestas da Universidade Federal Rural do Rio de Janeiro.

Prof. Dr. BRUNO ARAUJO FURTADO DE MENDONÇA  
Orientador

SEROPÉDICA, RJ  
SETEMBRO - 2022

**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.**

**GABRIEL DE OLIVEIRA INACIO**

APROVADA EM: 08 de setembro de 2022

BANCA EXAMINADORA:

---

Prof. Dr. Bruno Araujo Furtado de Mendonça - DS/IF/UFRRJ  
Orientador

---

Prof. Dr. Emanuel José Gomes de Araújo - DS/IF/UFRRJ  
Membro

---

Me. Danilo Henrique dos Santos Ataíde  
Membro

## DEDICATÓRIA

Dedico este trabalho a minha madrinha e avó Léa (in memoriam), que foi minha maior apoiadora e incentivadora durante toda minha graduação, e que apesar de estar distante, continua presente, todos os dias dentro de mim.

*“Não existe um caminho para a felicidade. A felicidade é o caminho.”*

Thich Nhat Hanh

## AGRADECIMENTOS

Agradeço a Deus por permitir que eu esteja aqui firme e forte, apesar das adversidades e dificuldades dos últimos anos.

Aos meus pais, por toda dedicação, paciência, incentivo, amor e carinho e por sempre acreditarem em mim e por estarem sempre ao meu lado, acreditando no meu potencial.

Aos meus irmãos queridos, pela sincera parceria, pela cumplicidade, por sempre deixarem momentos difíceis mais leves e por me transbordar de amor e felicidade.

Ao meu orientador Bruno Araújo, pela paciência, compreensão e aprendizado, me ajudando a concluir mais uma etapa da minha vida.

A Rafaela Vettoraci, pela parceria, por me tornar uma pessoa melhor diariamente e por deixar minhas rotinas sempre mais leves. Muito obrigado por todo amor e por toda felicidade transmitida.

Aos meus amigos, Túlio Viera, Luiza Marins, Deia Pereira, Julia Cavalcante, Vivian Nogueira e Isabela Mattos pelo apoio de todos esses anos, por serem como uma família para mim em Seropédica e por estarem sempre do meu lado em momentos de felicidade e dificuldades.

Aos irmãos que a vida me deu, Nicolau Rizzo, Felipe Santana e João Francisco, pela confiança, por estarem sempre comigo e por todas as experiências e momentos de muita felicidade proporcionados.

A Rosangela Vettoraci, Raquel Vettoraci e Ricardo Abukater, por literalmente serem como uma segunda família pra mim, pela superação de momentos difíceis e por me proporcionarem muita alegria e amor.

A minha maravilhosa e inesquecível Universidade Federal Rural do Rio de Janeiro, pela experiência incrível que guardarei para a vida toda.

## RESUMO

O município de Seropédica, localizado na baixada fluminense do Rio de Janeiro, carece de planejamento territorial. Com isso, as ferramentas de sensoriamento remoto surgem como importantes aliadas para o melhor ordenamento territorial, por meio de análises de uso e ocupação do solo. Uma das maneiras de se avaliar e obter resultados que possam caracterizar uma determinada área é por meio da classificação supervisionada, que pode ser executada com uso de diferentes imagens e satélites, o que pode deixar o usuário ou o avaliador confuso sobre qual satélite viabiliza a análise mais precisa. Portanto, a área de estudo do presente trabalho refere-se ao município de Seropédica, em que se avaliou diferentes satélites/sensores: CBERS 4A/WPM, SENTINEL 2B/MSI e LANDSAT 8/OLI na classificação supervisionada utilizando o classificador *Random Forest* no software QGIS 3.22. A precisão de classificação supervisionada realizada para cada método avaliado, foi avaliada a partir dos índices Kappa e Exatidão Global. Por fim, concluiu-se que a classificação de todas as imagens apresentou parâmetros excelentes com distinções de uso de cada imagem relacionadas aos tamanhos de pixel de cada imagem, em que a imagem CBERS 4A e SENTINEL 2 possuem utilização para classificação de áreas de menores extensões, enquanto que a imagem LANDSAT 8 possui melhor aplicação para áreas de maiores extensões.

**Palavras-chave:** Ordenamento Territorial; Sensoriamento remoto; Classificação Supervisionada.

## ABSTRACT

The municipality of Seropédica, located in the baixada fluminense of Rio de Janeiro, lacks territorial planning. With this, the remote sensing tools emerge as important allies for a better territorial planning, through land use and occupation analysis. One of the ways to evaluate and obtain results that can characterize a given area is through supervised classification, which can be performed with the use of different images and satellites, which can leave the user or evaluator confused about which satellite enables the most accurate analysis. Therefore, the study area of this work refers to the municipality of Seropédica, where different satellites/sensors were evaluated: CBERS 4A/WPM, SENTINEL 2B/MSI and LANDSAT 8/OLI in the supervised classification using the *Random Forest* classifier in QGIS 3.22 software. The accuracy of supervised classification performed for each method evaluated, was evaluated from Kappa indices and Overall Accuracy. Finally, it was concluded that the classification of all images presented excellent parameters with distinctions of use of each image related to the pixel sizes of each image, in which the CBERS 4A and SENTINEL 2 images have use for classification of areas of smaller extensions, while the LANDSAT 8 image has better application for areas of larger extensions.

**Keywords:** Land Planning; Remote Sensing; Supervised Classification.

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>1</b>
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b> .....	<b>3</b>
2.1	Contexto histórico do Geoprocessamento e dos Sistemas de Informações Geográficas .....	3
2.2	O Geoprocessamento e os Sistemas de informações Geográficas.....	4
2.3	Sensoriamento Remoto .....	5
2.4	Classificação do uso do solo .....	6
2.5	Assinatura espectral .....	7
2.6	Índices espectrais e os diferentes sensores.....	7
<b>3</b>	<b>MATERIAIS E MÉTODOS</b> .....	<b>11</b>
3.1	Área de Estudo .....	11
3.2	Processamento e análises dos dados .....	12
3.3	Aquisição de Dados e Classificação das Imagens .....	13
3.4	Definição das classes de uso e cobertura .....	15
3.5	Avaliação da Acurácia da Classificação .....	16
<b>4</b>	<b>RESULTADOS E DISCUSSÃO</b> .....	<b>18</b>
4.1	Avaliação da Acurácia .....	18
4.2	Classificação do uso e cobertura do solo .....	23
4.2.1	CBERS 4A – Sensor WPM .....	24
4.2.2	SENTINEL 2 – Sensor MSI .....	26
4.2.3	LANDSAT 8 - Sensor OLI.....	28
4.3	Análise conjunta das classificações de uso e cobertura do solo .....	30
<b>5</b>	<b>CONCLUSÃO</b> .....	<b>35</b>
<b>6</b>	<b>REFERÊNCIAS</b> .....	<b>36</b>

## LISTA DE TABELAS

<b>Tabela 1.</b> Descrição de local e data de aquisição das imagens dos diferentes satélites.....	14
<b>Tabela 2.</b> Intervalo de qualidade de classificação segundo o índice Kappa.....	18
<b>Tabela 3.</b> Matriz de confusão da classificação para a imagem do satélite CBERS 4A.....	19
<b>Tabela 4.</b> Erro de omissão da classificação para a imagem do satélite CBERS 4A.....	19
<b>Tabela 5.</b> Erro de comissão da classificação para a imagem do satélite CBERS 4A.....	20
<b>Tabela 6.</b> Matriz de confusão da classificação para a imagem do satélite SENTINEL 2. ....	20
<b>Tabela 7.</b> Erro de omissão da classificação para a imagem do satélite SENTINEL 2. ....	21
<b>Tabela 8.</b> Erro de comissão da classificação para a imagem do satélite SENTINEL 2. ....	21
<b>Tabela 9.</b> Matriz de confusão da classificação para a imagem do satélite LANDSAT 8.....	22
<b>Tabela 10.</b> Erro de omissão da classificação para a imagem do satélite LANDSAT 8.....	22
<b>Tabela 11.</b> Erro de comissão da classificação para a imagem do satélite LANDSAT 8.....	23
<b>Tabela 12.</b> Validação estatística da classificação supervisionada no município de Seropédica. .....	23

## LISTA DE FIGURAS

<b>Figura 1.</b> Assinatura espectral .....	7
<b>Figura 2.</b> Mapa de localização do município de Seropédica .....	12
<b>Figura 3.</b> Fluxograma Metodológico .....	13
<b>Figura 4.</b> Chave de classificação .....	15
<b>Figura 5.</b> Mapa de uso e cobertura da terra para imagem do satélite CBERS 4A, sensor WPM .....	25
<b>Figura 6.</b> Gráfico de áreas, em hectare, para as diferentes classes de uso do solo, de acordo com processamento da imagem do satélite CBERS 4A, sensor WPM .....	26
<b>Figura 7.</b> Mapa de uso e cobertura da terra para imagem do satélite SENTINEL 2, sensor MSI .....	27
<b>Figura 8.</b> Gráfico de áreas, em hectare, para as diferentes classes de uso do solo, de acordo com processamento da imagem do satélite SENTINEL 2, sensor MSI .....	28
<b>Figura 9.</b> Mapa de uso e cobertura da terra para imagem do satélite LANDSAT 8, sensor OLI .....	29
<b>Figura 10.</b> Gráfico de áreas, em hectare, para as diferentes classes de uso do solo, de acordo com processamento da imagem do satélite LANDSAT 8, sensor OLI .....	30
<b>Figura 11.</b> Mapas comparativos para melhor visualização dos diferentes tamanhos de pixels .....	34

## 1 INTRODUÇÃO

Diversos municípios localizados na região metropolitana do Estado do Rio de Janeiro sofrem com a falta de ordenamento territorial, em que espaços urbanos crescem de maneira acelerada e conseqüentemente fragmentos florestais e recursos hídricos são degradados pelas interferências antrópicas. Com o município de Seropédica, localizado na baixada fluminense, a situação de falta de planejamento territorial é uma realidade, com espaços urbanos crescendo, hidrografia regional sofrendo com a poluição hídrica, formações florestais sendo degradadas e o avanço de atividades mineradoras sendo responsáveis por grandes mudanças na paisagem da região. Segundo Santos (2016), uma das principais fontes econômicas do município é a extração mineral, em que até 2011 o distrito areeiro do município era o principal produtor de areia do Estado do Rio de Janeiro, o que vem causando intensas mudanças na paisagem local, com área total de espelhos d'água aumentando consideravelmente.

A cidade de Seropédica incorpora a urbanização tardia em um espaço de transformação rural, tendo a maioria de sua área ocupado por atividades agrícolas, e que, conseqüentemente, apresenta baixos níveis de ocupação urbana (RIBEIRO E O'NEILL, 2012). Diante dessa situação, Seropédica enfrenta conflitos pelo uso da terra, que envolve a conversão de suas terras agrícolas para uso urbano, a manutenção de seus areais e do aterro sanitário que recebe resíduos do Rio de Janeiro dentro de suas fronteiras, ou seja, situação que coloca pressão sob seus recursos hídricos e remanescentes florestais, ameaçando a diversidade biológica local.

As mudanças nas áreas naturais causadas pelas atividades humanas representam uma grande ameaça à biodiversidade. A superpopulação e os altos padrões de consumo levaram à conversão de áreas florestadas para uso humano, com conseqüências trágicas para as espécies que vivem nessas áreas (CASTRO e FERNADÉZ, 2022). O conhecimento da dinâmica da paisagem em uma determinada área é um fator importante para um bom planejamento e sustentabilidade ambiental. Desta forma, o sensoriamento remoto orbital tornou-se uma importante ferramenta para obtenção de informações de mapeamento de uso do solo e é a base para o planejamento territorial regional (BARBOSA, 2009).

O uso do sensoriamento remoto para obtenção de dados relacionados ao uso e ocupação do solo para o monitoramento e análise de recursos naturais tem se difundido, onde um dos principais objetivos é diferenciar e identificar a composição de diferentes materiais de superfície, sejam tipos de vegetação, padrões de uso, afloramentos rochosos, corpos d'água e outros. Esta distinção e identificação deve-se ao comportamento específico dos materiais de

superfície no espectro eletromagnético, que pode ser utilizado para identificar o seu comportamento (CROSTA, 1993).

A classificação digital é uma das principais funções do processamento digital de imagens de sensoriamento remoto, sendo amplamente utilizada em mapeamentos temáticos, incluindo uso e ocupação do solo. A classificação de uma imagem baseia-se em identificar os elementos presentes nela associando cada um de seus pixels a uma determinada categoria temática. São feitas comparações entre pelo menos duas bandas do espectro para comparar o mesmo pixel com possíveis respostas diferentes (FITZ, 2008). Segundo Barbosa (2009), o sucesso da análise de imagens de sensoriamento remoto depende de fatores além dos princípios básicos de interpretação, como quando a imagem de satélite foi adquirida, tipo de produto, bandas espectrais, escala da imagem e, finalmente, a experiência do analista, que no fim, darão a consistência para as análises.

Para os diferentes tipos de estudos estão disponíveis, em múltiplas plataformas oficiais, diversos tipos de imagens que podem ser utilizadas para confecção de mapas temáticos com classificações do uso do solo de determinada região. Segundo Ponzoni e Almeida (1996), a precisão dos mapas temáticos é determinada pelas chamadas matrizes de erro ou contingência, que consistem em números iguais de linhas e colunas que representam o confronto entre os resultados da classificação (visual ou numérica) de um produto de sensoriamento remoto (mapas temáticos) e a verdade do terreno ou outra informação que seja considerada referência.

De acordo com Florenzano (2002), o processamento de imagens de satélite para obtenção de classificações de uso do solo, permitem estudar e monitorar fenômenos naturais dinâmicos (erosão, inundações, etc.) e fenômenos antropogênicos no meio ambiente. Esses fenômenos impressos na paisagem são registrados nas imagens produzidas pelo sensoriamento remoto, e sua análise permite identificar, calcular e monitorar áreas de desmatamento, o crescimento de áreas impermeabilizadas e a identificação de áreas sujeitas a processos erosivos.

Portanto, o presente trabalho visou utilizar de técnicas do geoprocessamento para realizar uma classificação supervisionada, utilizando o mesmo classificador, para o município de Seropédica, no qual foram utilizadas imagens de três satélites diferentes, sendo eles: CBERS 4A, SENTINEL 2 e LANDSAT 8. Como forma de avaliar e validar os resultados obtidos com as classificações foram confeccionadas matriz de confusão para cada imagem para posterior cálculos de parâmetros estatísticos, com o intuito de analisar se o modelo de classificação utilizado condiz com a realidade, em que se pode relatar as particularidades de uso para cada imagem.

## **2 REVISÃO BIBLIOGRÁFICA**

### **2.1 Contexto histórico do Geoprocessamento e dos Sistemas de Informações**

#### **Geográficas**

De acordo com Xavier da Silva (2001), estudos e documentos confirmam que a geografia é uma ciência antiga. O Processamento Eletrônico de Dados, pelo contrário, é o mais recente campo de informação. Neste enquadramento, os Sistemas de Informação Geográfica, utilizando o Geoprocessamento, formam uma estrutura de interface entre Geografia, processamento de dados e comunicação.

Alguns autores afirmam que na década de 1950, o Reino Unido (por meio de pesquisas botânicas) e os EUA (pesquisa de volume de tráfego) tentaram pela primeira vez automatizar o processamento de dados com características espaciais, com o objetivo principal de reduzir os rendimentos e os custos de manutenção dos mapas. Observou-se que esses sistemas ainda não poderiam ser classificados como "sistemas de informação geográfica" (CÂMARA e DAVIS, 2003).

O sistema aritmético informatizado abriu oportunidades para pesquisas sobre o uso de grandes quantidades de dados, principalmente dados espaciais, que costumavam armazenar e gerenciar dados censitários. No final da década de 1950, meteorologistas, geólogos e geógrafos incorporaram mapas gerados por computador em seus trabalhos (SILVA, 2003).

Segundo Ibrahim (2014), a manipulação dos dados geográficos antes da computação é feita por meio de mapas ou outros documentos impressos, que são produzidos com auxílio de bases. Como resultado, falhas e limitações se repetem. Portanto, um fator importante, neste caso, o surgimento dos sistemas de informação geográfica, surgidos no Canadá apenas na década de 1960, foi desenvolvido como parte de um programa governamental cujo objetivo principal era o inventário dos recursos naturais. O autor também afirma que naquela época a mão de obra precisava ser muito especializada, os computadores eram caros e os interessados precisavam desenvolver seus próprios programas. Este processo é custoso e demorado. E assim, os dados geográficos começam a ser processados por meio de um conjunto de técnicas matemáticas e computacionais conhecidas como geoprocessamento.

De acordo com Câmara (1996), a década de 1980 seria o período em que a tecnologia dos sistemas de informações geográficas (SIG) começou a se acelerar e continua até hoje. O mesmo autor afirmou ainda que, na época, a tecnologia era limitada por altos custos de hardware e poucas pesquisas específicas sobre a disciplina, de modo que o SIG se beneficiou muito da democratização trazida pelos avanços da microinformática e da implantação de centros de pesquisa sobre o tema.

O geoprocessamento no Brasil será iniciado, pesquisado e difundido no início da década de 1980 pelo Prof. Jorge Xavier da Silva da Universidade Federal do Rio de Janeiro, onde, juntamente com um grupo do Laboratório de Geoprocessamento do Departamento de Geografia, desenvolveram Saga (System for Geo-Environmental Analysis) com poderosos recursos de análise geográfica, no qual tinham uma grande capacidade de estudos (IBRAHIN, 2014).

Segundo Zaidan (2017), além da equipe de pesquisa formada pelo professor Jorge Xavier da Silva, três outros grupos merecem destaque nacional: a AeroSul, em meados da década de 1980, desenvolveu um sistema de processos cartográficos automatizados; Mais tarde, eles formaram a empresa MaxiDATA e introduziram o MaxiCAD, que é amplamente utilizado em mapeamento por computador; Centro de Pesquisa e Desenvolvimento da TELEBRÁS, que teve início em 1990 com o desenvolvimento do SAGRE (Sistema Automático de Gerenciamento de Rede Externa), o uso generalizado do Geoprocessamento no setor de comunicações. Também em 1984, o INPE (Centro Nacional de Pesquisas Espaciais), que estabeleceu uma equipe para desenvolver tecnologia de geoprocessamento e sensoriamento remoto (Divisão de Processamento de Imagens (DPI). De 1984 a 1990, a DPI desenvolveu o SITIM (Sistema de Processamento Gráfico) e SGI (Sistema de Informação Local), nativo PC/DOS, e, a partir de 1991, o SPRING (I - Sistema de Processamento de Informação Geográfica), para locais UNIX e MS/Windows.

## **2.2 O Geoprocessamento e os Sistemas de informações Geográficas**

Analisando o contexto histórico e as contribuições de diversos profissionais, entende-se que o geoprocessamento hoje é uma importante ferramenta na etapa de coleta e processamento de informações relacionadas às questões ambientais. Usando determinados programas, dados existentes podem ser interpretados ou agrupados de forma rápida e eficiente para gerar uma série de informações relacionadas, como modelos numéricos para determinar elevação, forma, inclinação e muito mais (CALDAS DA SILVA, 2006).

De acordo com Costa et al. (2009), o geoprocessamento torna-se ferramenta importante e essencial, quando se tem o discernimento que o meio ambiente possui suas fragilidades e potencialidades, que podem ser avaliadas de maneira integrada, através de mapeamentos, harmonizando suas características naturais com suas restrições, além de que, esse mapeamento constitui umas das principais ferramentas utilizadas pelos órgãos públicos na elaboração do planejamento territorial ambiental.

Segundo o INPE (2020), um conjunto de estudos e técnicas destinados a coletar, tratar e processar dados de referência espaciais é conhecido como geoprocessamento. As atividades que os compõem são realizadas por sistemas específicos comumente chamados de sistemas de informação geográfica (SIG). Os sistemas de geoprocessamento são projetados para processar dados contendo informações geográficas ou georreferenciadas, desde a coleta até a geração de mapas regulares que podem estar em diferentes formatos estendidos.

Com um entendimento preliminar e simplista, o SIG pode ser visto como uma ferramenta para projetos de construção de mapas. No entanto, o SIG incluiu cada vez mais funções. Em particular, eles fornecem técnicas e procedimentos sofisticados de processamento de dados e análise espacial para visualizar dados de forma mais intuitiva do que aqueles obtidos por meio de relatórios e gráficos tradicionais (CRUZ e CAMPOS, 2016).

Mais amplamente, o SIG consiste em ambientes para armazenamento, processamento e análise de dados, aplicação de modelos e processamento de séries temporais, onde cenários passados e atuais podem ser visualizados e cenários futuros simulados. Com isso, o SIG pode efetivamente expressar conceitos de expressão territorial, como unidades de uso potencial do solo, áreas de influência para parâmetros específicos, áreas-chave, centros dinâmicos de energia, etc., que podem fornecer valiosos serviços para planejamento e proteção ambiental (XAVIER DA SILVA, 2001; MINISTÉRIO DO MEIO AMBIENTE - MMA, 1996).

De acordo com Câmara et al. (2005), o SIG será utilizado como uma importante ferramenta de geração de informações que podem solucionar diversos problemas de forma rápida e precisa, sempre facilitando os processos de tomada de decisão em diversos campos ambientais, econômicos e sociais.

### **2.3 Sensoriamento Remoto**

O sensoriamento remoto pode ser entendido como qualquer técnica que obtenha imagens da superfície da Terra ou qualquer outro tipo de dados por meio da captura e registro da energia refletida ou emitida da superfície terrestre (FLORENZANO, 2011).

Segundo Caldas (2006), a compreensão das imagens obtidas por sensoriamento remoto inclui o entendimento de que objetos na superfície da Terra, como vegetação, água e solo, refletem, absorvem e transmitem radiação eletromagnética em proporções dependentes do comprimento de onda de acordo com suas características biofísicas e/ou propriedades químicas. Portanto, ainda segundo o mesmo autor, a interpretação das imagens é baseada em elementos básicos, extraindo informações de objetos, regiões ou fenômenos, considerando cor/tom, textura, tamanho, forma, sombreamento, altura padrão e posição.

As imagens coletadas por sensores remotos possuem algumas características que as distinguem de outras imagens digitais, com propriedades estruturais e de resolução próprias, onde essas imagens de satélite podem ser interpretadas visualmente e utilizando técnicas automatizadas, cada uma com vantagens e desvantagens (CRÓSTA, 2002).

#### **2.4 Classificação do uso do solo**

Qualquer tipo de empreendimento e/ou qualquer tipo de atividade relacionada ao manejo do solo, requerem um reconhecimento e detalhamento do espaço físico territorial. Portanto seja uma atividade ligada às obras de engenharia e arquitetura, ou ainda, ligadas ao manejo e conservação de solos, é importante um estudo de descrição da superfície do solo e as suas utilizações. A cobertura existente e o uso atual da terra podem ser mapeados e descritos usando métodos de classificação de imagens de satélite (RIBEIRO e CENTENO, 2001).

Segundo Rex et al. (2018), atualmente, o desenvolvimento é pautado em princípios sustentáveis, dessa forma, o monitoramento ambiental global terá como aliado a ciência sobre o uso da terra e a mudança da cobertura do solo. Segundo o mesmo autor, o conhecimento sobre o estado de uso e cobertura da terra é uma informação vital para atender a uma variedade de necessidades da sociedade, incluindo gestão de recursos naturais, pesquisa ambiental, planejamento urbano e desenvolvimento sustentável.

Segundo o Instituto Brasileiro de Geografia e Estatística - IBGE (2007), a expansão urbana no Brasil está associada ao desenvolvimento da agricultura e pecuária, o que inclui a adoção de sistemas intensivos de manejo do solo, em que esses sistemas de manejo aceleram a degradação do solo, independentemente da capacidade de uso da terra. Nos levantamentos de atributos do solo, áreas heterogêneas são subdivididas em partes menores e relativamente uniformes na definição desses atributos para sua classificação, o que produz conhecimento que contribui para a compreensão do uso do solo que pode ser utilizado de forma sustentável no planejamento de sua conservação (IBGE, 2007).

De acordo com Ribeiro e Centeno (2001), a classificação do uso do solo pode ser feita de forma rápida e eficiente por meio de técnicas digitais, onde são utilizadas imagens de satélite, o que envolve a associação de um determinado “pixel” da imagem a uma determinada classe por meio de critérios estabelecidos. O objetivo da classificação é: classificar, distinguir e categorizar.

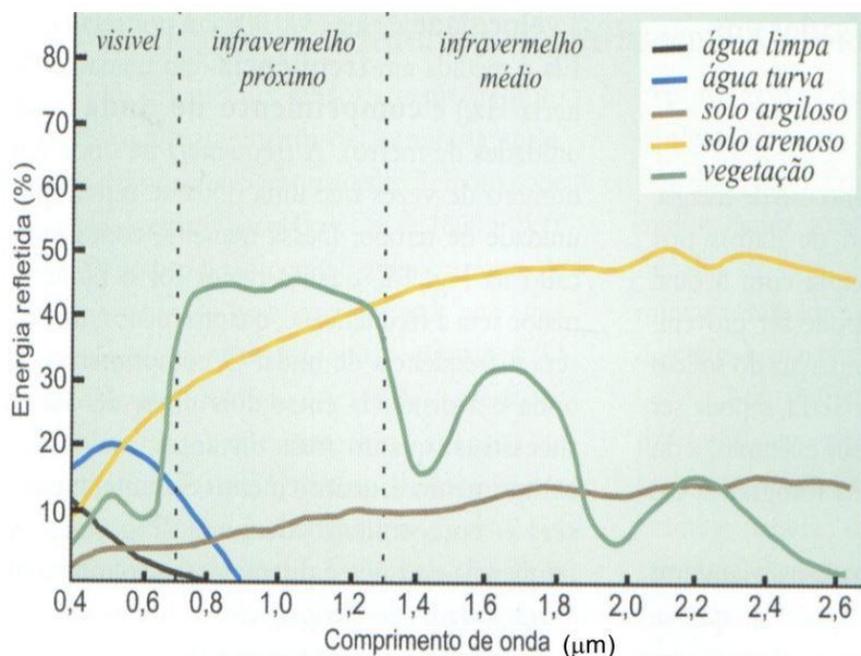
Com a finalidade de dar qualidade aos estudos de classificação do uso do solo e para que os mapeamentos desenvolvidos tenham o detalhamento esperado, são utilizados materiais disponíveis gratuitamente, em que se pode citar as imagens multiespectrais geradas a partir dos

sistemas-sensores Landsat-8/OLI, Sentinel-2/MSI ou ainda CBRES-4A/WPM (REX et al., 2018).

## 2.5 Assinatura espectral

A energia eletromagnética pode ser ordenada de forma contínua devido ao seu comprimento de onda ou frequência, denominado espectro eletromagnético, que apresenta subdivisões de acordo com as características de cada região devido ao tipo de processo físico que a produz, ou seja, o tipo de interação que ocorre entre a radiação e o objeto incidente e a transparência da atmosfera em relação à radiação (NOVO, 1989).

Segundo Brys (2008), as mudanças na proporção, em que objetos terrestres, como vegetação, água e solo, que refletem, absorvem e transmitem essa radiação eletromagnética, são representadas por curvas, em decorrência dos respectivos comprimentos de onda dependentes de propriedades bio-físico-químicas, definindo suas respostas espectrais. Conforme a figura 1, é demonstrado diferentes assinaturas espectrais.



**Figura 1:** Assinatura espectral. Fonte: Adaptado de Florenzano (2007).

## 2.6 Índices espectrais e os diferentes sensores

Existem diversas técnicas no geoprocessamento, em que, após a obtenção das imagens de satélites, a interpretação de respostas espectrais é feita de forma manual, o que pode

caracterizar os estudos e análises como de baixa precisão, além de requerer muito tempo para as rotinas de verificações (XU, 2007).

De acordo com Zha et al. (2003), muitos procedimentos de interpretação de respostas espectrais podem ser caracterizados como trabalhosos, com isso, enfatizou a importância de automatizar os procedimentos necessários para avaliar o uso da cobertura do solo, apresentando o uso de índices de espectro gerados a partir de combinações de bandas de satélite.

Os índices espectrais normalizados são apresentados como uma medida capaz de identificar as diversas informações presentes na superfície terrestre por meio dos elementos multiespectrais contidos nas imagens de satélite, classificando-os assim como solo exposto, edificações, cobertura vegetal, corpos d'água. Além de normalizar ou minimizar os efeitos associados à coleta de dados espaciais, esses índices espectrais são projetados para distinguir informações de interesse de outros alvos de similaridade espectral. No entanto, por serem derivados de expressões matemáticas envolvendo valores de refletância, esses índices são sensíveis a mudanças nas assinaturas espectrais em diferentes fisiologias vegetais (FRANÇA et al., 2012; PEREIRA et al., 2016).

Os índices espectrais podem ser obtidos por diversos sensores, sendo um deles, por meio do satélite CBERS-4A, oriundo do programa CBRES, de parceria entre Brasil e China no setor técnico-científico espacial. O CBERS- 4A é um satélite de sensoriamento remoto de média resolução equipado com uma carga útil óptica operando no espectro visível com faixa de resolução de 2 a 60 metros. Suas imagens são utilizadas para diversas finalidades no monitoramento ambiental, entre as quais pode se destacar o controle de desmatamento, queimadas, monitoramento de recursos hídricos, ocupação do solo, entre outros (INPE, 2018).

O CBERS 4A possui três sensores diferentes. O primeiro sensor é a câmera Multiespectral (MUX), que possui três bandas no visível e uma banda no infravermelho com resolução espacial de 16 m. Já o outro sensor é a câmera de Campo Largo (WFI) que também possui três bandas no visível e uma banda infravermelha, espacialmente resolvido, a taxa é de 55 m. Por último, o terceiro sensor, a *Wide Scan Multispectral and Panchromatic Camera* (WPM), com três bandas do visível e uma do infravermelho, cada uma com resolução espacial de 8 m e banda pancromática de 2 m (INPE, 2018). Conforme o Quadro 1, são descritas as características do satélite CBERS 4A.

**Quadro 1.** Descrição dos sensores do satélite CBERS 4A.

<b>CBERS 4A</b>				
<b>Sensor</b>	<b>Bandas</b>	<b>Resolução Espectral (p.m)</b>	<b>Resolução Espacial (m)</b>	<b>Resolução Temporal (dias)</b>
<b>WPM</b>	P	0,45 - 0,90	2	31
	B1	0,45 - 0,52	8	
	B2	0,52- 0,59		
	B3	0,63 - 0,69		
	B4	0,77 - 0,89		
<b>MUX</b>	B5	0,45 - 0,52	16,5	
	B6	0,52- 0,59		
	B7	0,63 - 069		
	B8	0,77 - 0,89		
<b>WFI</b>	B13	0,45 - 0,52	55	5
	B14	0,52 - 0,59		
	B15	0,63 - 0,69		
	B16	077 - 089		

Fonte: Adaptado de INPE (2018).

Outros dois importantes sensores utilizados para obtenção de elementos multiespectrais são encontrados no satélite Landsat 8, proveniente da missão Landsat. O satélite Landsat 8 foi lançado em fevereiro de 2013 e desde o ano de seu lançamento, ele foi usado para adquirir mais de 1,1 milhão de imagens gravadas destinadas a apoiar pesquisas agrícolas, mapeamento de uso do solo, manejo florestal, desastres naturais e mudanças na superfície da terra (USGS, 2022). Os dois sensores do Landsat 8 são: Thermal Infrared Sensor (TIRS) que mede a temperatura superficial da Terra por meio de duas bandas espectrais na faixa do infravermelho termal, com resolução espacial de 100 metros e o Operational Land Imager (OLI) com bandas espectrais nas faixas do visível, infravermelho próximo e infravermelho de onda curta, com resolução espacial de 30 metros e 15 metros (pancromática) (USGS, 2022). No Quadro 2 são descritas as características do satélite Landsat 8.

**Quadro 2.** Descrição dos sensores, bandas e resoluções espectral, espacial e temporal do satélite Landsat 8.

<b>Landsat 8</b>				
<b>Sensor</b>	<b>Bandas</b>	<b>Resolução Espectral (µm)</b>	<b>Resolução Espacial (m)</b>	<b>Resolução Temporal (dias)</b>
<b>OLI</b>	B1	0,43 - 0,45	30	16
	B2	0,45 - 0,51		
	B3	0,53 - 0,59		
	B4	0,64- 0,67		
	B5	0,85 - 0,88		
	B6	1,57 - 1,65		
	B7	2,11- 2,29		
	B8	0,50 - 0,68	15	
<b>TIRS</b>	B9 B10	1,36 - 1,38 10,6- 11,19	30 100	
	B11	11,5 - 12,51		

Fonte: Adaptado de USGS (2022).

A obtenção de elementos multiespectrais também pode ser feita por um sensor, presente no satélite Sentinel-2, da missão Sentinel que começou em 2014, sendo o primeiro satélite óptico operado pela Agência Espacial Européia (ESA) da série. Lançado em 2015, possui uma ampla gama de aplicações para monitoramento de agricultura, florestas, áreas costeiras, águas interiores, desastres naturais e uso e ocupação do solo. O satélite Sentinel-2 está equipado com um sensor *Multispectral Instrument* (MSI) com 13 bandas espectrais, com resolução espacial de 10 m na banda do visível, 20 m na banda do infravermelho e 60 m na banda de correção atmosférica (ESA, 2022). Na Tabela 3 são descritas as características do satélite Sentinel 2.

**Quadro 3.** Descrição dos sensores do satélite Sentinel-2.

<b>Sentinel 2 / MSI</b>			
<b>Bandas</b>	<b>Resolução Espectral (p.m)</b>	<b>Resolução Espacial (m)</b>	<b>Resolução Temporal (dias)</b>
<b>B1</b>	0,44	60	10
<b>B2</b>	0,49	10	
<b>B3</b>	0,56		
<b>B4</b>	0,66		
<b>B5</b>	0,7	20	
<b>B6</b>	0,74		
<b>B7</b>	0,78		
<b>B8</b>	0,84		
<b>B8A</b>	0,86	60	
<b>B9</b>	0,94		
<b>B10</b>	1,37	20	
<b>B11</b>	1,61		
<b>B12</b>	2,19		

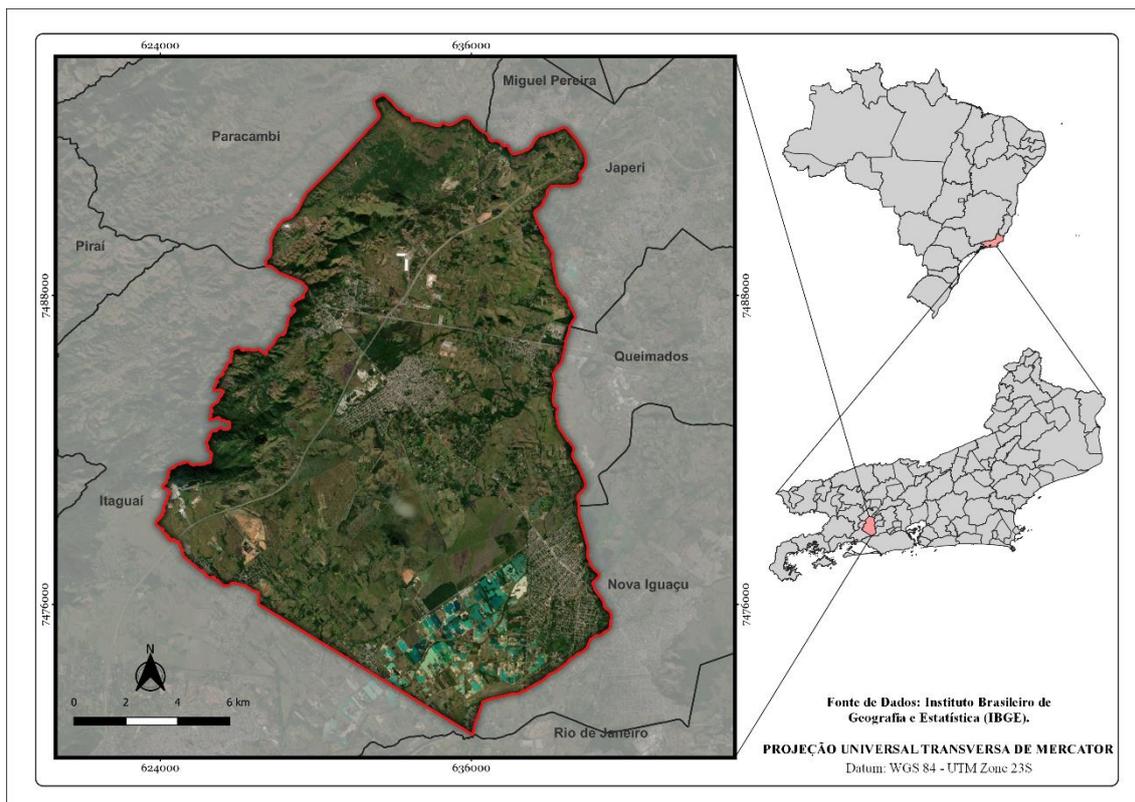
Fonte: Adaptado de ESA (2022).

### **3 MATERIAIS E MÉTODOS**

#### **3.1 Área de Estudo**

O estudo foi desenvolvido no município de Seropédica, que possui área de aproximadamente 265,19 km<sup>2</sup> (IBGE, 2022), localizado na região metropolitana do estado do Rio de Janeiro, mais precisamente na região oeste da baixada fluminense, conforme ilustrado pela Figura 2.

Embora politicamente considerada parte da região metropolitana do Rio de Janeiro, está geograficamente localizada em uma área da planície litorânea do Rio de Janeiro chamada Baixada de Sepetiba. Essa região é margeada, em sua parte sul, pelo Oceano Atlântico, o interior desta planície funde o oeste e noroeste da Serra do Mar, o leste do Maciço da Pedra Branca, o nordeste da Serra da Mantiqueira e os contínuos morros baixos ao norte e nordeste, na chamada paisagem do Mar de Morros (JACCOUD, 2006).



**Figura 2.** Mapa de localização do município de Seropédica. Fonte: elaborado pelo autor.

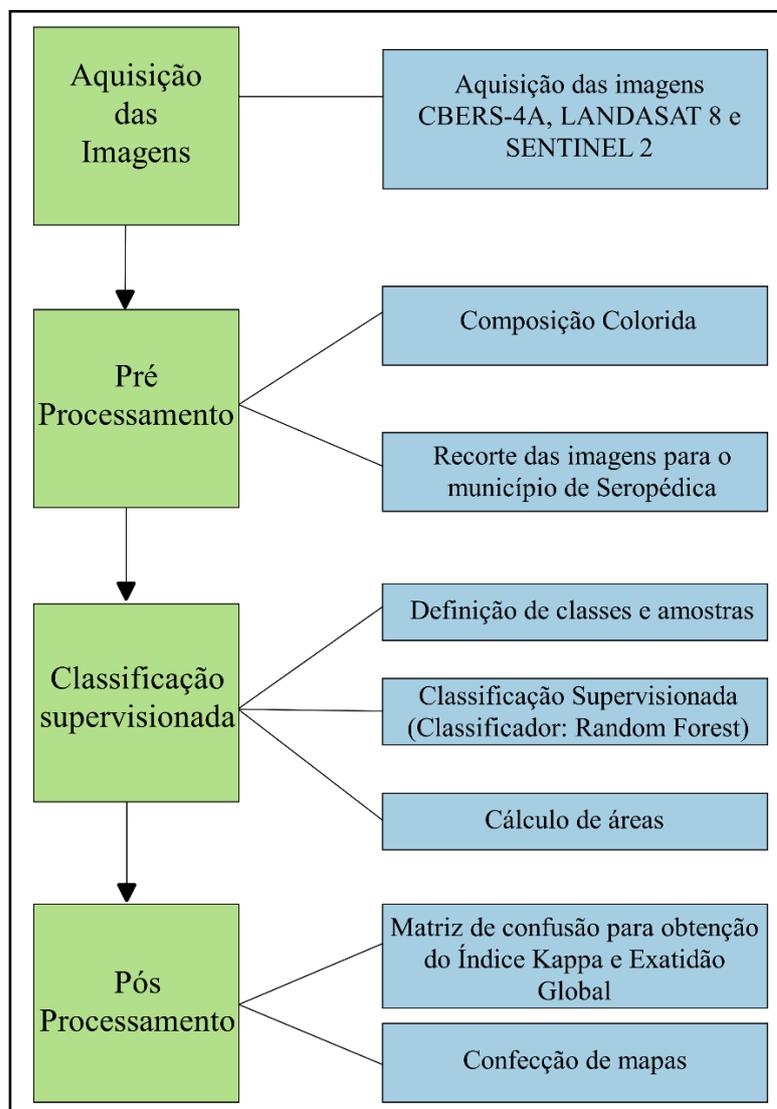
Segundo a classificação de Köppen, o clima da região é do tipo ‘Aw’, com chuvas concentradas entre novembro e março, precipitação anual média de 1.213 mm e temperatura média anual de 23,9 °C (Carvalho et al., 2011).

O município está inserido no bioma mata atlântica, no entanto, de acordo com Costa et. al. (2013), Seropédica sofre com intenso desmatamento por toda a sua extensão, em que a história de ocupação humana na região, onde vários ciclos agrícolas se alternaram aliados à prática de pecuária extensiva, quase que nada deixou de remanescente quanto à primitiva cobertura florestal. Segundo o mesmo autor, os remanescentes florestais de melhor qualidade, que estão fragmentados e isolados, continuam sofrendo com processos de degradação ecológica sendo, aos poucos, transformados em áreas secundárias que se apresentam em graus de sucessão variados.

### 3.2 Processamento e análises dos dados

A metodologia do presente trabalho pode ser entendida de maneira rápida e direta por meio da Figura 3, em que foram utilizadas quatro etapas para compor todo o processamento das

imagens dos diferentes satélites. Portanto as etapas foram: 1. Aquisição das Imagens; 2. Pré Processamento; 3. Classificação Supervisionada; 4. Pós Processamento.



**Figura 3.** Fluxograma Metodológico. Fonte: elaborado pelo autor.

### 3.3 Aquisição de Dados e Classificação das Imagens

As imagens foram obtidas por meio de sites e plataformas oficiais, em que para a imagem referente ao satélite/sensor CBERS 4A/WPM a obtenção foi realizada no site do Instituto Nacional De Pesquisas Espaciais (INPE, 2022), já a imagem referente ao satélite/sensor SENTINEL 2/MSI a aquisição foi feita no site do programa Copernicus, que é um programa de observação da Terra da União Europeia (ESA, 2022), enquanto que para a imagem referente ao satélite/sensor LANDSAT 8/OLI a obtenção foi realizada no site do Serviço Geológico do Estados Unidos (USGS, 2022). Os detalhes de datas e locais de aquisição das diferentes imagens estão descritos pela tabela 1.

**Tabela 1.** Descrição de local e data de aquisição das imagens dos diferentes satélites.

Aquisição das Imagens				
Satélite / Nível	Site/Plataforma	Data	Elevação Solar	Azimute Solar
CBERS 4A L4	INPE	27/01/2022	67,38°	83,22°
LANDSAT 8 Level 2	USGS	29/04/2022	42,34°	40,65°
SENTINEL 2 Level 2A	COPERNICUS	07/06/2022	52,41°	30,74°

Fonte: elaborado pelo autor.

A tentativa foi de adquirir as imagens nas mesmas datas, para não haver modificações nas formas de uso e ocupação do solo, no entanto, imagens com mesmas datas estavam apresentando grande influência do índice de cobertura de nuvens, dessa forma, as imagens com as datas mais próximas e com menor índice de nuvens foram as apresentadas anteriormente na tabela. Todas as amostras coletadas foram polígonos, em formato shapefile, confeccionados por meio do software QGIS.22, a partir da análise das imagens adquiridas, tendo como referências imagens do Google Earth e conhecimentos prévios da área. Foi realizada uma classificação supervisionada para cada imagem dos diferentes satélites, em que foi utilizado o complemento *Dzetsaka: Classification Tool*, utilizando o classificador *Random Forest* no software QGIS 3.22.

Segundo Teixeira (2022), o classificador de *Random Forest* é uma ferramenta especial em cenários de aprendizado de máquina com base na criação iterativa e aleatória de árvores de decisão que usam um conjunto de regras e condições que definem classes para criar aleatoriamente várias árvores de decisão com base no modelo criado. Essas árvores são usadas para classificar todos os pixels. De forma simplificada, a técnica é baseada na agregação de múltiplas árvores de decisão. Assim, ele processa um conjunto de árvores de decisão geradas dentro de um mesmo objeto - um conjunto de árvores - onde cada objeto passa por um processo de votação (*bagging*) para selecionar a classificação mais votada.

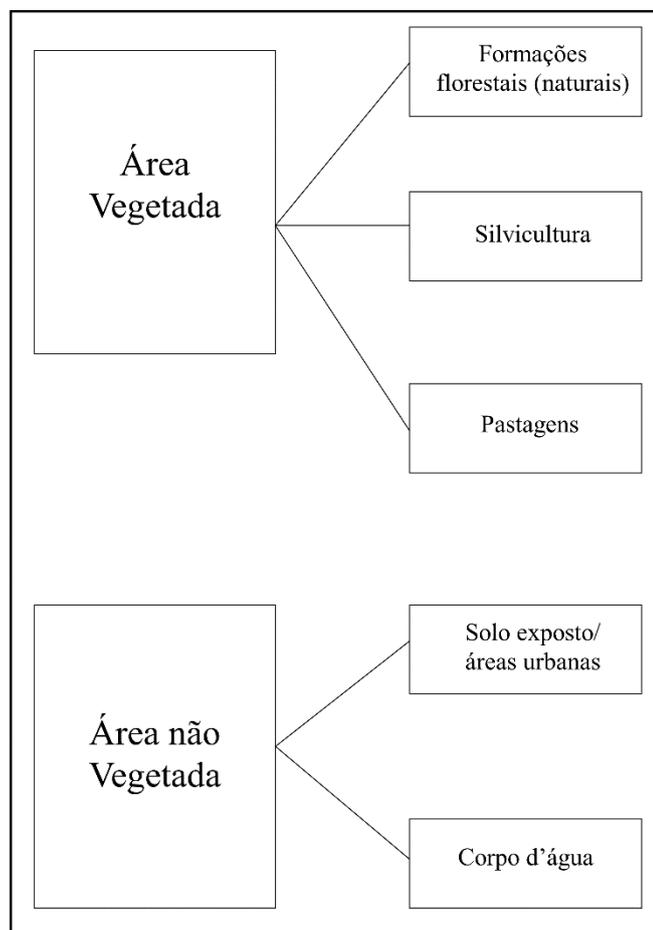
Posteriormente, com as classificações resultantes, são feitas análises dos rasters, com o objetivo de calcular e obter as áreas de cada padrão das diferentes classes de uso e cobertura da terra. Este procedimento foi feito com o QGIS 3.22, em que os cálculos foram feitos por meio de um algoritmo do software que retorna a área e contagem de cada valor único em dados de camada raster, ou seja, o algoritmo calcula o número de pixels para cada classe e posteriormente

multiplica pela área de cada pixel (de acordo com a imagem em que foi feita a classificação), sendo obtido a área, em m<sup>2</sup>, para cada classe de uso do solo.

Importante destacar que todos os mapeamentos produzidos seguiram o sistema de referência de coordenadas com a projeção Universal Transversa de Mercator (UTM) e o Datum SIRGAS 2000 – Zona 23S.

### 3.4 Definição das classes de uso e cobertura

A identificação das classes de uso e cobertura do solo foi realizada a partir da análise das feições presentes na área de estudo. Tendo em vista que as imagens utilizadas para interpretação são provenientes dos sensores *Wide Scan Multispectral and Panchromatic Camera* (WPM) do Satélite CBERS 4A, *Operational Land Imager* (OLI) do Satélite LANDSAT 8 e *Multispectral Instrument* (MSI) a bordo do Satélite SENTINEL 2, a chave de identificação das classes (Figura 4) leva em consideração as resoluções espaciais e espectrais das imagens.



**Figura 4.** Chave de classificação. Fonte: elaborado pelo autor.

A divisão da chave de uso e ocupação ocorreu inicialmente entre vegetação e não vegetação, e a parte de vegetação compreende as classes temáticas finais formações florestais (naturais), silvicultura e pastagens que, devido às características da imagem, seguem as seguintes definições:

- Formações florestais (naturais): Caracterizada por ter o dossel fechado.
- Silvicultura: Áreas destinadas à silvicultura (principalmente *Eucalyptus* spp.), que foram alocadas dentro de área vegetada devido ao seu estrato arbóreo pronunciado.
- Pastagens: agrupa todas as fitofisionomias campestres naturais, assim como as áreas destinadas ao uso pastoril.

Já as áreas não vegetadas compreendem as classes temáticas finais solo exposto/áreas urbanas e corpo d'água, que, seguindo as características das imagens, possuem as seguintes definições:

- Solo exposto/áreas urbanas: Agrupam as características de qualquer local de ocupação antrópica, áreas degradadas e solo exposto.
- Corpo d'água: englobam tanto corpos d'água naturais como lagos, lagoas e rios quanto corpos d'água artificiais.

### **3.5 Avaliação da Acurácia da Classificação**

Com o objetivo de verificar a qualidade dos dados obtidos com as classificações, foram feitas matrizes de confusão para as diferentes imagens de cada satélite, para posterior cálculo do índice Kappa. Portanto, a matriz de confusão gerada entre os polígonos e a classificação realizada foi utilizada para realização do cálculo da Exatidão Global e do índice Kappa.

A matriz de confusão é uma forma de expressar a qualidade obtida a partir da classificação de imagens digitais, com isso, a matriz exprime-se através da análise de amostras de treinamento em conjunto com os dados de classificação (PRINA e TRENTIN, 2015).

Congalton (1991) descreve o uso de critérios para avaliar e comparar a exatidão da cartografia temática. Segundo o autor, a matriz de erros pode servir como ponto de partida para a aplicação de uma série de técnicas estatísticas descritivas e analíticas. Os índices de exatidão global são obtidos por meio da estatística descritiva, onde o número total de pixels classificados corretamente (a diagonal da matriz) é dividido pelo número total de pixels da matriz, conforme

ilustrado na equação a seguir, em que  $F_m$  = exatidão global;  $X_i$  = elementos na diagonal;  $N$  = total de elementos amostrados.

$$F_m = \frac{\sum X_i}{N} \times 100$$

De acordo com Perroca e Gaidzinski (2003), o índice Kappa, possui um intervalo entre 0 e 1 e pode ser definida como uma variável que mede o grau de consistência dos dados, gerando um aspecto da confiabilidade e acurácia da classificação, onde quanto mais próximo de 1, melhor a qualidade da classificação. O índice tem sido amplamente utilizado em outros estudos porque permite a comparação com outros trabalhos, além de ser mais sensível para estimar variações de erros que podem ocorrer tanto no momento de omissão como de inclusão (ABDALLA; VOLOTÃO, 2013).

O Índice Kappa é o método estatístico em que se mede a qualidade da classificação, o quanto ela concorda com as amostras de exatidão. O coeficiente é calculado a partir da equação apresentada a seguir, em que  $r$  é o número de linhas na matriz de erro,  $x_{ii}$  é o número de observações na linha  $i$  e na coluna  $i$ , para  $x_{i+}$  e  $x_{+i}$  são os valores totais das linhas  $i$  e colunas  $i$ , e  $N$  é o número total de classes (CONGALTON, 1991).

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})}$$

Os valores obtidos pelo índice Kappa, para cada imagem classificada, foram analisados (Tabela 2), conforme os intervalos e níveis de desempenho proposto por Fonseca (2000), em que índices entre 0,21 e 0,4 são considerados razoáveis e entre 0,41 e 0,6, bons; e entre 0,61 e 0,8, muito bons; e entre 0,81 e 1, excelentes.

**Tabela 2.** Intervalo de qualidade de classificação segundo o índice Kappa.

<b>Valor do índice Kappa</b>	<b>Qualidade da Classificação</b>
< 0,00	Péssimo
0,00-0,20	Ruim
0,21-0,40	Razoável
0,41-0,60	Boa
0,61-0,80	Muito boa
0,81-1,00	Excelente

Fonte: Adaptado de Fonseca (2000).

## **4 RESULTADOS E DISCUSSÃO**

### **4.1 Avaliação da Acurácia**

As amostras coletadas por meio do software QGIS 3.22 e as imagens classificadas dos diferentes satélites foram utilizados para gerar uma matriz de confusão para o cálculo do índice Kappa e a exatidão global, esse procedimento é feito para saber o quão cada método foi bem classificado, afirmando a sua aproximação com o meio real.

Interessante notar que em todas as imagens classificadas, foi apresentado uma boa separação entre as classes, em que, no processo de classificação, foi obtido o mapa com classes bem individualizadas e coerentes. No entanto, é possível perceber que houve confusão, em algumas áreas, dos pixels de silvicultura com formações florestais (naturais), mas já era de se esperar, por conta da semelhança de tons e refletância. De acordo com Sano et al. (2007), a separação de determinadas feições, em alguns momentos, pode ser dificultada em razão da sazonalidade da vegetação natural e das confusões espectrais presentes entre as classes temáticas distintas.

Apesar da existência dessas confusões temáticas observadas nas construções das regras e conseqüentemente nas classificações realizadas, acreditasse que os mapas gerados contenham um panorama da situação do uso e ocupação do solo do município, não interferindo significativamente nas análises realizadas a partir desses resultados.

Um comportamento interessante é o de que a classe de corpo d'água foi a que apresentou, para todas as imagens, os menores erros de omissão e comissão, que pode ser explicado pelas assinaturas espectrais distintas para essa classe. Esses pequenos números de erros para esta classe foram constatados por Teixeira (2022), que relatou erros de omissão para

classe de corpo d'água chegando a 0% para imagem LANDSAT 8, representando elevados valores de acurácia.

A Tabela 3 apresenta a matriz de confusão resultante das classificações para a imagem do satélite CBERS 4A, enquanto que as Tabelas 4 e 5 representam os erros de omissão e comissão para as diferentes classes.

Dentre as classes avaliadas, a classe corpo d'água foi a que apresentou menor erro de omissão, com 99,89% de acurácia do produtor, enquanto que a classes formações florestais (naturais) e silvicultura apresentaram os maiores erros tanto de omissão como de comissão.

**Tabela 3.** Matriz de confusão da classificação para a imagem do satélite CBERS 4A. Em que: solo exposto/áreas urbanas (1); pastagens (2); formações florestais (naturais) (3); corpo d'água (4); silvicultura (5).

<b>Classes</b>	1	2	3	4	5	Coluna Total
Solo exposto/áreas urbanas	10276	65	0	7	1	10349
Pastagens	153	77742	19	2	447	78363
Formações florestais (naturais)	0	10	7862	0	688	8560
Corpo d'água	0	3	0	8965	0	8968
Silvicultura	2	271	987	1	9456	10717
<b>Linha Total</b>	<b>10431</b>	<b>78091</b>	<b>8868</b>	<b>8975</b>	<b>10592</b>	<b>116957</b>

Fonte: elaborado pelo autor.

**Tabela 4.** Erro de omissão da classificação para a imagem do satélite CBERS 4A.

<b>Acurácia do Produtor (Erro de Omissão)</b>		
Solo exposto/áreas urbanas	98,51%	1,49% erro de omissão
Pastagens	99,55%	0,45% de erro de omissão
Formações florestais (naturais)	88,66%	11,44% de erro de omissão
Corpo d'água	99,89%	0,11% de erro de omissão
Silvicultura	89,27%	10,73% de erro de omissão

Fonte: elaborado pelo autor.

**Tabela 5.** Erro de comissão da classificação para a imagem do satélite CBERS 4A.

Acurácia do Usuário (Erro de Comissão)		
Solo exposto/áreas urbanas	99,29%	0,71% erro de comissão
Pastagens	99,21%	0,79% erro de comissão
Formações florestais (naturais)	91,85%	8,15% erro de comissão
Corpo d'água	99,97%	0,3% erro de comissão
Silvicultura	88,23%	11,77% erro de comissão

Fonte: elaborado pelo autor

A Tabela 6 apresenta a matriz de confusão resultante das classificações para a imagem do satélite SENTINEL 2, enquanto que as Tabelas 7 e 8 representam os erros de omissão e comissão para as diferentes classes.

Para a imagem do satélite SENTINEL 2, a classe de corpo d'água não apresentou erro de omissão e a classe de pastagens apresentou 0,16% de erro de omissão. Por outro lado, as classes de formações florestais (naturais) e silvicultura continuam apresentando as menores acurácias do produtor com 87,18% e 89,90% respectivamente.

**Tabela 6.** Matriz de confusão da classificação para a imagem do satélite SENTINEL 2. Em que: solo exposto/áreas urbanas (1); pastagens (2); formações florestais (naturais) (3); corpo d'água (4); silvicultura (5).

Classes	1	2	3	4	5	Coluna Total
Solo exposto/áreas urbanas	407	2	0	0	0	409
Pastagens	6	3124	6	0	4	3140
Formações florestais (naturais)	0	1	306	0	38	345
Corpo d'água	1	0	0	363	0	364
Silvicultura	0	2	39	0	374	415
Linha Total	414	3129	351	363	416	<b>4673</b>

Fonte: elaborado pelo autor

**Tabela 7.** Erro de omissão da classificação para a imagem do satélite SENTINEL 2.

<b>Acurácia do Produtor (Erro de Omissão)</b>		
Solo exposto/áreas urbanas	98,31%	1,69% erro de omissão
Pastagens	99,84%	0,16% erro de omissão
Formações florestais (naturais)	87,18%	12,82% erro de omissão
Corpo d'água	100,00%	0% erro de omissão
Silvicultura	89,90%	10,10% erro de omissão

Fonte: elaborado pelo autor.

**Tabela 8.** Erro de comissão da classificação para a imagem do satélite SENTINEL 2.

<b>Acurácia do Usuário (Erro de Comissão)</b>		
Solo exposto/áreas urbanas	99,51%	0,49% erro de comissão
Pastagens	99,49%	0,51% erro de comissão
Formações florestais (naturais)	88,70%	11,13% erro de comissão
Corpo d'água	99,73%	0,27% erro de comissão
Silvicultura	90,12%	9,88% erro de comissão

Fonte: elaborado pelo autor.

A Tabela 9 apresenta a matriz de confusão resultante das classificações para a imagem do satélite LANDSAT 8, enquanto que as Tabelas 10 e 11 representam os erros de omissão e comissão para as diferentes classes.

Para a imagem LANDSTA 8, houveram três classes que não apresentaram erro de omissão, que foram as classes de corpo d'água, solo exposto/áreas urbanas e pastagens. No entanto, a classe formações florestais (naturais) foi a que apresentou menor acurácia do produtor, com um valor de 92,68%, ou seja, seguindo o comportamento da classificação das imagens anteriores.

Interessante perceber na imagem LANDSAT 8 que apenas duas classes apresentaram erros, no caso, formações florestais (naturais) e silvicultura. Para Freires et al. (2019), esse comportamento se deve ao fato de que em uma imagem OLI/LANDSAT-8 os extratos vegetativos não apresentam faixas de transições nítidas, resultando em repostas distintas por

consequência da mistura espectral, portanto, nessas situações o classificador encontra grandes dificuldades em discernir estes diferentes extratos de vegetação.

**Tabela 9.** Matriz de confusão da classificação para a imagem do satélite LANDSAT 8. Em que: solo exposto/áreas urbanas (1); pastagens (2); formações florestais (naturais) (3); corpo d'água (4); silvicultura (5).

<b>Classes</b>	1	2	3	4	5	Coluna Total
Solo exposto/áreas urbanas	45	0	0	0	0	45
Pastagens	0	348	0	0	0	348
Formações florestais (naturais)	0	0	38	0	1	39
Corpo d'água	0	0	0	40	0	40
Silvicultura	0	0	3	0	49	52
<b>Linha Total</b>	<b>45</b>	<b>348</b>	<b>41</b>	<b>40</b>	<b>50</b>	<b>524</b>

Fonte: elaborado pelo autor.

**Tabela 10.** Erro de omissão da classificação para a imagem do satélite LANDSAT 8.

<b>Acurácia do Produtor (Erro de Omissão)</b>		
Solo exposto/áreas urbanas	100,00%	0% erro de omissão
Pastagens	100,00%	0% erro de omissão
Formações florestais (naturais)	92,68%	7,32% erro de omissão
Corpo d'água	100,00%	0% erro de omissão
Silvicultura	98,00%	2% erro de omissão

Fonte: elaborado pelo autor.

**Tabela 11.** Erro de comissão da classificação para a imagem do satélite LANDSAT 8.

<b>Acurácia do Usuário (Erro de Comissão)</b>		
Solo exposto/áreas urbanas	100,00%	0% erro de comissão
Pastagens	100,00%	0% erro de comissão
Formações florestais (naturais)	97,44%	2,56% erro de comissão
Corpo d'água	100,00%	0% erro de comissão
Silvicultura	94,23%	5,77% erro de comissão

Fonte: elaborado pelo autor.

Por meio das análises das acurácias, foi constatado que as imagens dos satélites CBERS 4A e SENTINEL 2 apresentaram acurácia inferior ao LANDSAT 8. Comportamento constatado por Carnaúba (2021), que associou este padrão à resolução espacial das imagens, em que quanto maior a resolução, maiores são as chances de confusões, resultando em valores de acurácia menores.

A análise da matriz de confusão permitiu avaliar os resultados estatísticos (Tabela 12) das classificações para as diferentes imagens de cada satélite, obtendo resultados que foram avaliados de acordo com os índices Kappa e a exatidão global.

De acordo com Fonseca (2000), os resultados foram positivos, em que todas as imagens de todos os satélites apresentaram qualidade consideradas excelentes.

**Tabela 12.** Validação estatística da classificação supervisionada no município de Seropédica.

<b>Satélite - Sensor</b>	<b>Exatidão Global</b>	<b>Índice Kappa</b>	<b>Qualidade da Classificação</b>
CBERS 4A - WPM	97,73%	0,96	Excelente
SENTINEL 2 - MSI	97,87%	0,96	Excelente
LANDSAT 8 - OLI	99,85%	0,98	Excelente

Fonte: elaborado pelo autor.

#### **4.2 Classificação do uso e cobertura do solo**

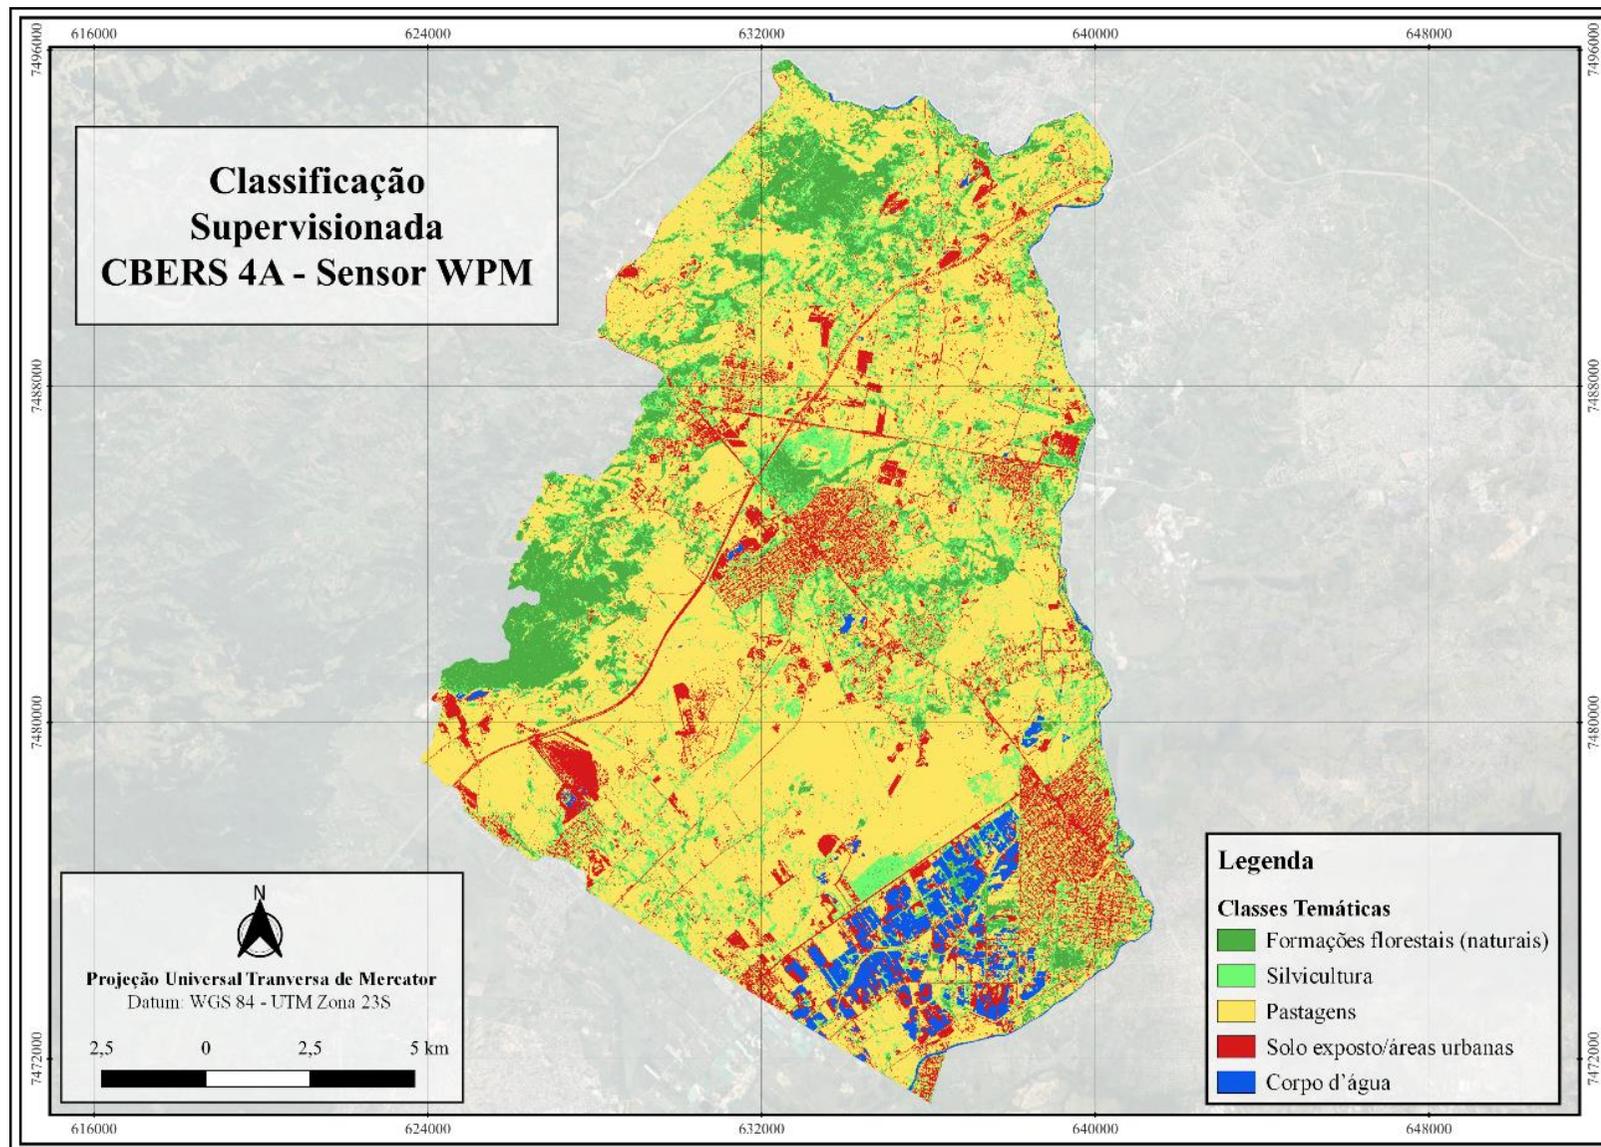
Por meio dos resultados das classificações supervisionadas para as diferentes imagens, foram obtidos os mapeamentos das classes do uso e cobertura do solo para o município de Seropédica. Os mapas produzidos permitem entender a dinâmica espacial utilizando as imagens

dos diferentes satélites, sendo possível compreender as diferentes classificações de usos da terra, de determinada imagem, de acordo com o seu tamanho de pixel.

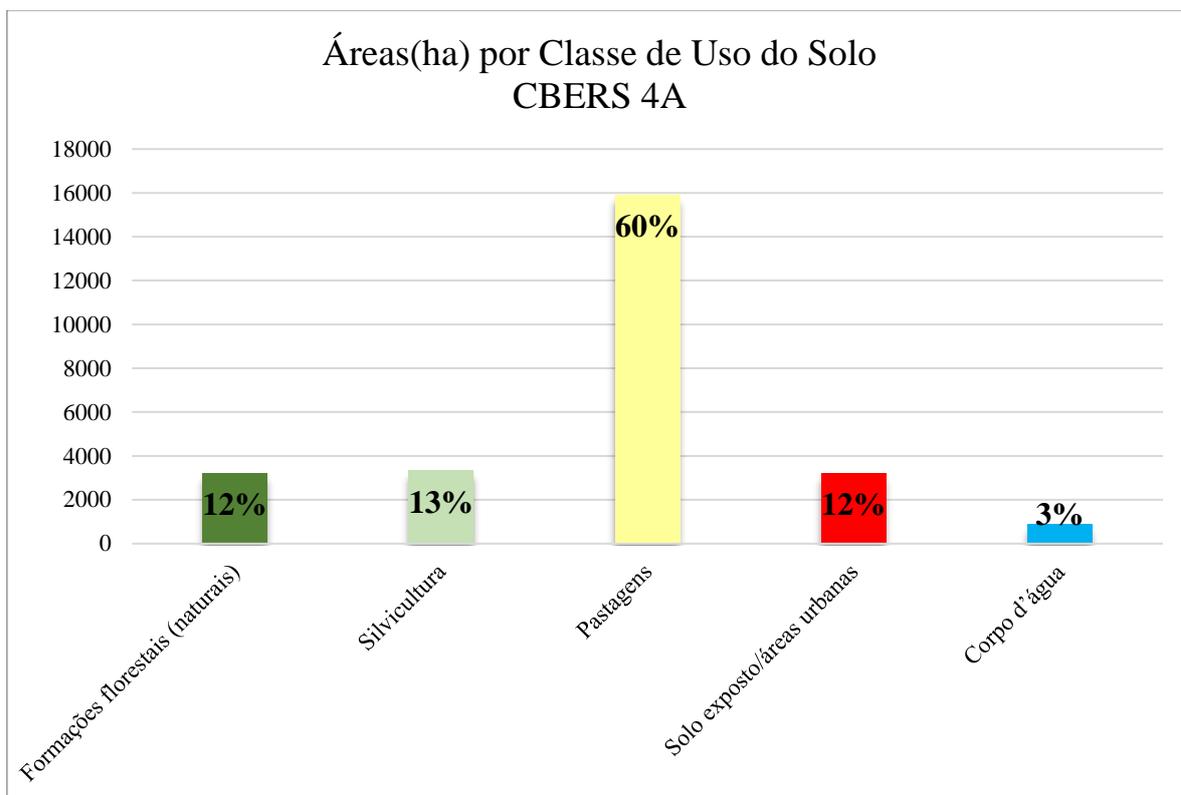
#### **4.2.1 CBERS 4A – Sensor WPM**

Para a imagem do satélite CBERS 4A, sensor WPM, foi gerado o mapa de uso e classificação do solo e um gráfico representativo das diferentes classes com suas respectivas áreas em hectare (Ha).

A figura 5 demonstra os resultados obtidos por meio da classificação supervisionada executada, e a figura 6 representa as áreas, em hectare, para as diferentes classes de uso do solo.



**Figura 5.** Mapa de uso e cobertura da terra para imagem do satélite CBERS 4A, sensor WPM. Fonte: elaborado pelo autor.



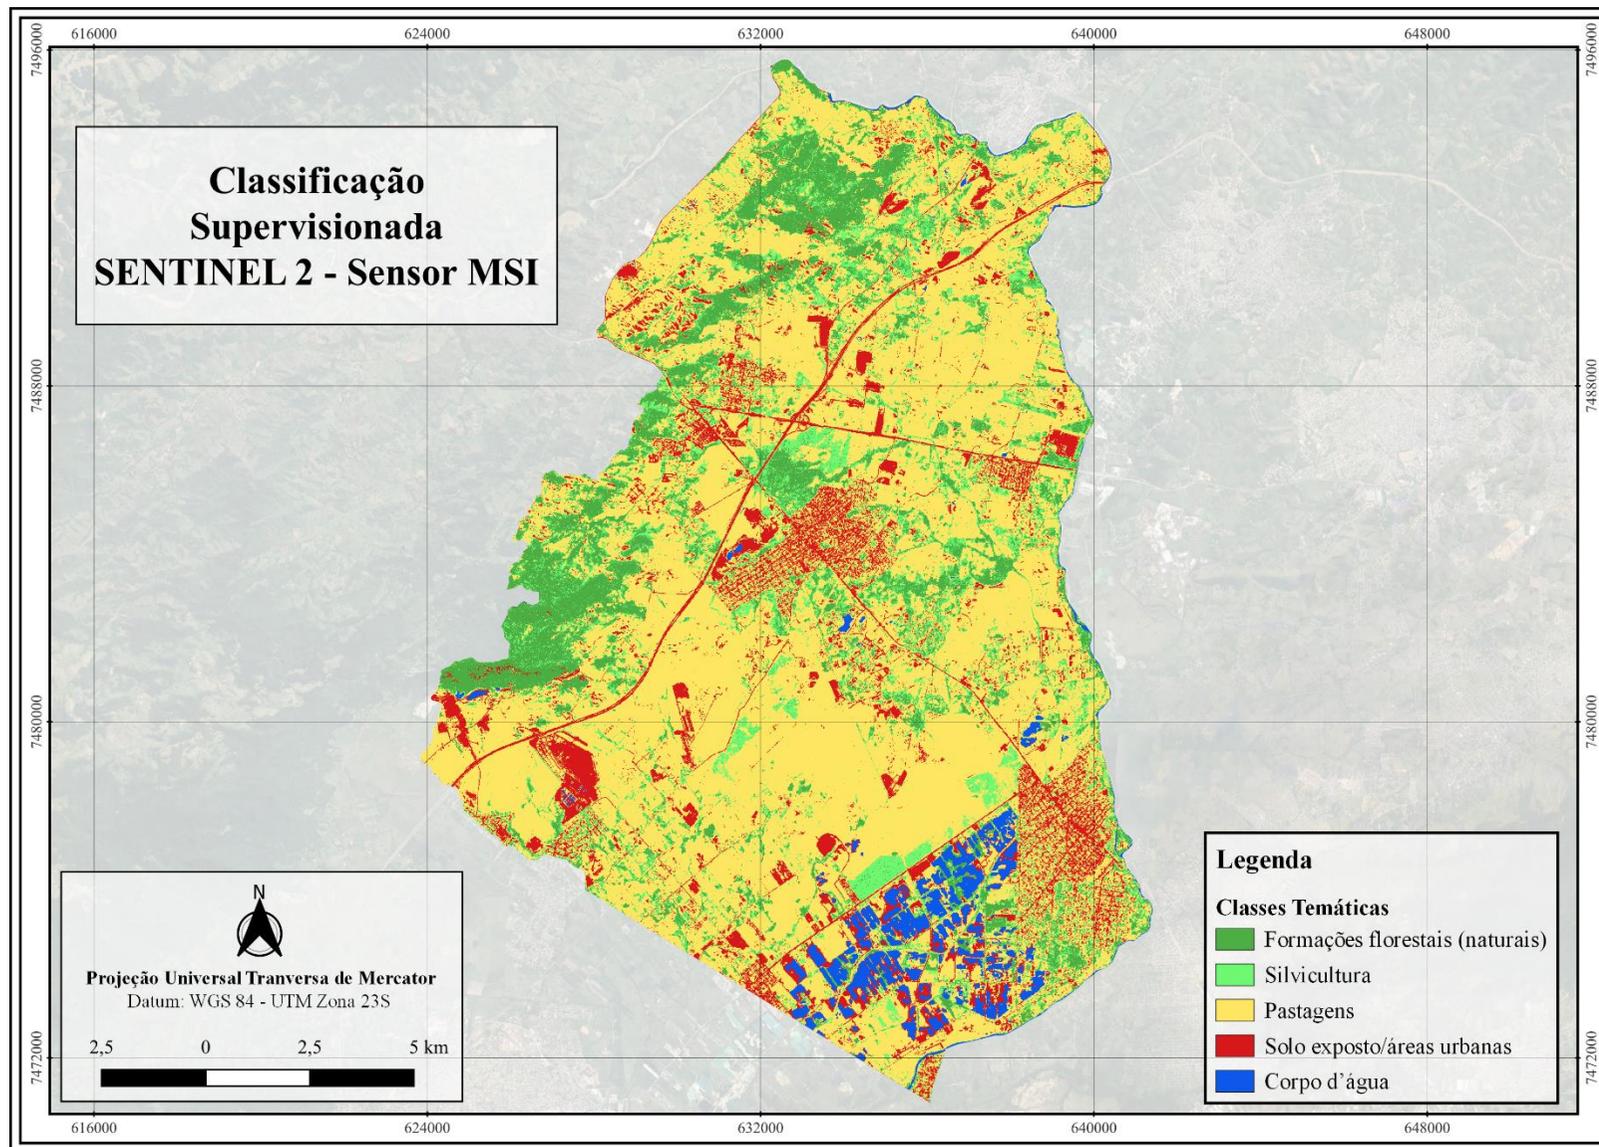
**Figura 6.** Gráfico de áreas, em hectare, para as diferentes classes de uso do solo, de acordo com processamento da imagem do satélite CBERS 4A, sensor WPM. Fonte: elaborado pelo autor.

Analisando o mapeamento em conjunto com o gráfico de áreas, fica nítido que o município de Seropédica possui, na maior parte de seu território, áreas de pastagens. É possível perceber que as áreas de formações florestais (naturais), silvicultura e solo exposto/áreas urbanas, possuem quase que as mesmas extensões em área, no entanto possuem tamanho muito menor em relação a classe de pastagens.

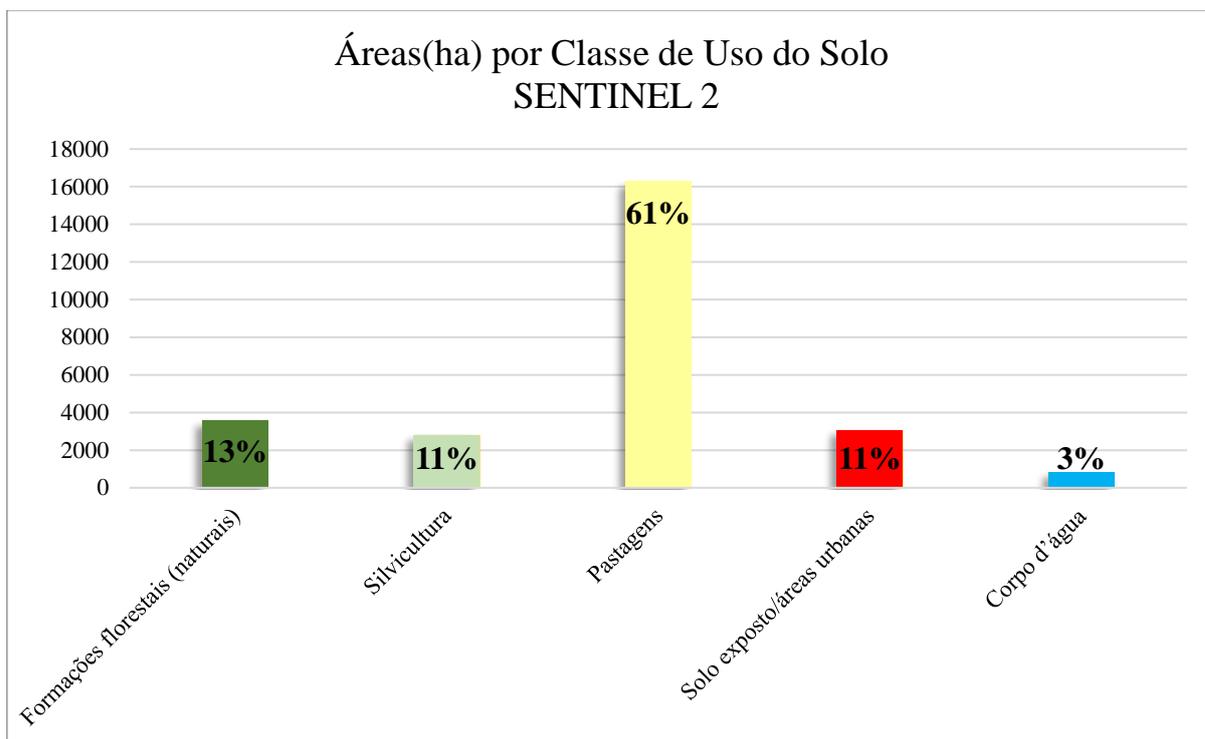
#### 4.2.2 SENTINEL 2 – Sensor MSI

Para a imagem do satélite SENTINEL 2, sensor MSI, foi gerado o mapa de uso e classificação do solo e um gráfico representativo das diferentes classes com suas respectivas áreas em hectare (Ha).

A figura 7 demonstra os resultados obtidos por meio da classificação supervisionada executada, e a figura 8 representa as áreas, em hectare, para as diferentes classes de uso do solo.



**Figura 7.** Mapa de uso e cobertura da terra para imagem do satélite SENTINEL 2, sensor MSI. Fonte: elaborado pelo autor.



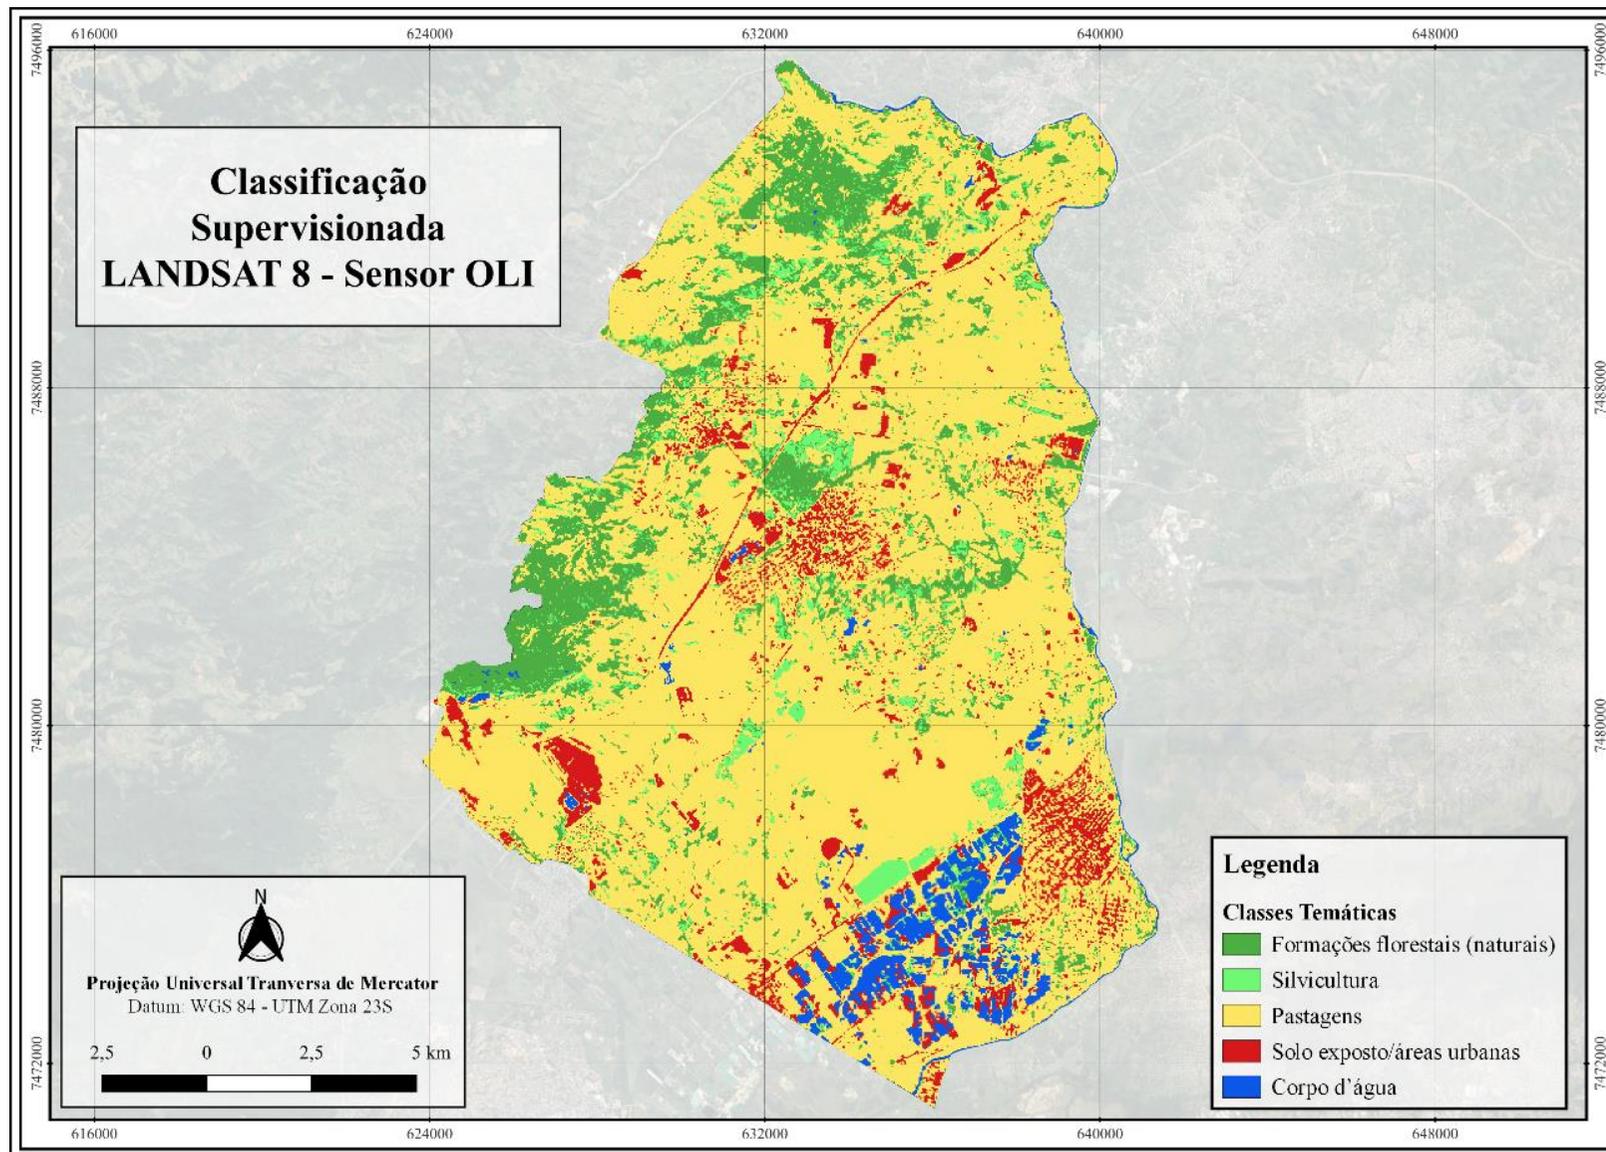
**Figura 8.** Gráfico de áreas, em hectare, para as diferentes classes de uso do solo, de acordo com processamento da imagem do satélite SENTINEL 2, sensor MSI. Fonte: elaborado pelo autor.

As diferenças de áreas continuam seguindo o mesmo comportamento dos resultados encontrados com a imagem do satélite CBERS 4A, demonstrando a maioria da extensão do território de Seropédica ocupado por pastagens. No entanto, é importante notar que a classificação da imagem do satélite SENTINEL 2 apresentou áreas de pastagens ainda maiores, tendo como resultado uma área maior que 16.000 hectares e, conseqüentemente, apresentou uma diminuição de área das outras classes, principalmente da classe de silvicultura.

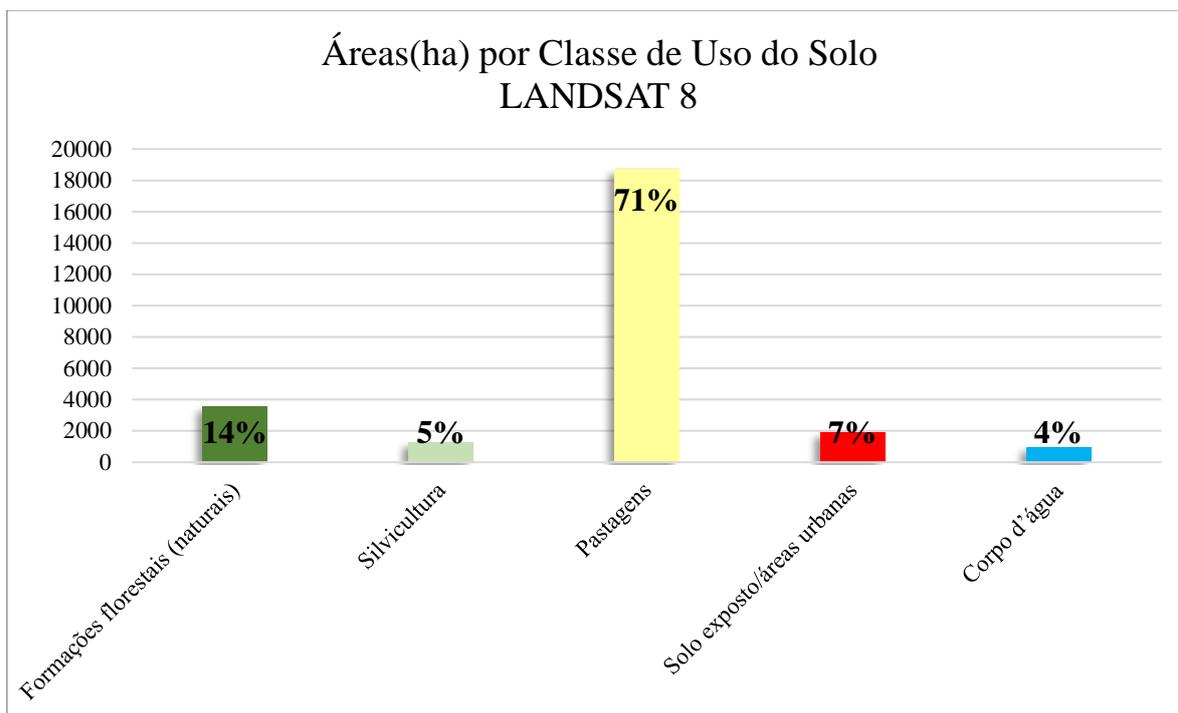
#### 4.2.3 LANDSAT 8 - Sensor OLI

Para a imagem do satélite LANDSAT 8, sensor OLI, foi gerado o mapa de uso e classificação do solo e um gráfico representativo das diferentes classes com suas respectivas áreas em hectare (Ha).

A figura 9 demonstra os resultados obtidos por meio da classificação supervisionada executada, e a figura 10 representa as áreas, em hectare, para as diferentes classes de uso do solo.



**Figura 9.** Mapa de uso e cobertura da terra para imagem do satélite LANDSAT 8, sensor OLI. Fonte: elaborado pelo autor.



**Figura 10.** Gráfico de áreas, em hectare, para as diferentes classes de uso do solo, de acordo com processamento da imagem do satélite LANDSAT 8, sensor OLI. Fonte: elaborado pelo autor.

Na classificação da imagem do satélite LANDSAT 8 foram obtidos resultados com diferenças de áreas ainda mais acentuadas, no qual, a classe de pastagens, agora apresenta uma área superior à 18.000 hectares e uma diminuição ainda maior da classe de silvicultura e uma evidente redução na área da classe de solo exposto/áreas urbanas. No gráfico das diferenças das áreas em porcentagem, essa discrepância de áreas se torna mais visível, demonstrando que os tamanhos de pixels, das diferentes imagens de cada satélite, podem influenciar diretamente nos resultados das classificações supervisionadas.

#### 4.3 Análise conjunta das classificações de uso e cobertura do solo

Os mapeamentos e as análises de áreas das diferentes classes são importantes para o monitoramento da expansão urbana, de áreas sensíveis, de áreas protegidas ou ainda das bacias hidrográficas presentes na região, para que o desenvolvimento da região possa vir acompanhado de um planejamento territorial. No entanto, de acordo com Santos (2016), o município de Seropédica diante da proclamada certeza do crescimento econômico, vinda principalmente após obras importantes de urbanização, o desejo da administração municipal por um processo de

industrialização em seu território não é acompanhado de um planejamento territorial que suporte esse futuro cenário de crescimento.

Os mapas gerados através da classificação possuem importantes informações visuais a respeito da dinâmica da ocupação e uso do solo, em que ficou nítido que o município de Seropédica possui a maioria da extensão do seu território ocupado por pastagens, com grande parte de suas formações florestais degradadas, principalmente por ação antrópica, no qual se observa, por exemplo, a atividade mineradora de areia, bem presente na região, que de acordo com Gasparini et. al. (2013), o município mostrou áreas de mineração com razoável extensão na porção sul por se tratar de uma área de extração de areia para construção civil.

Por meio dos mapeamentos e gráficos produzidos, foi possível perceber que determinadas classes temáticas de uso do solo apresentaram aumento ou diminuição de área, quando comparadas as classificações das diferentes imagens dos diferentes satélites. Esse comportamento pode ser melhor observado nos gráficos de área apresentados anteriormente (figuras 6, 8 e 10) das diferentes classes para as três imagens obtidas.

Quando comparado as áreas de cada classe para as diferentes imagens, percebe-se que as áreas para as imagens dos satélites CBERS 4A e SENTINEL 2 possuem pouca diferença, sendo notado um pequeno aumento da área de pastagens e formações florestais (naturais) e uma pequena diminuição da classe de silvicultura e solo exposto/áreas urbanas. No entanto quando se introduz na comparação as áreas das classes da imagem do satélite LANDSAT 8, percebe-se um aumento evidente da classe de pastagens e, em contrapartida, uma diminuição evidente da classe de silvicultura e de solo exposto/áreas urbanas.

Essa diferença de área para as diferentes imagens pode ser explicada pelo tamanho dos pixels de cada imagem. Portanto o tamanho do pixel interfere diretamente na classificação resultante, já que quanto maior o pixel, maior a quantidade de misturas espectrais e, conseqüentemente, podem envolver mais de uma classe de uso e cobertura do solo. Com isso classes que apresentam áreas menores, como silvicultura e solo exposto/áreas urbanas tiveram maior dificuldade de serem classificadas nas imagens com pixels maiores, enquanto que classes com áreas mais extensas, como é o caso de pastagens, não tiveram essa dificuldade, pelo contrário, como pastagens é a classe que realmente em maior extensão no município, então houve uma generalização de pixels com semelhança de tons e refletância para esta classe.

Esse comportamento de variação da extensão de áreas foi constatado por Freires et al. (2019), que ao comparar as classificações de imagens OLI/Landsat-8 e MSI/Sentinel 2, percebeu desconformidades no tamanho das áreas das classes de uso de cobertura do solo,

confirmando que estes desempenhos estão relacionados às diferentes resoluções espaciais das imagens das quais foram obtidas.

Portanto, para diminuição desses problemas, algumas medidas podem ser tomadas com o intuito de diminuir a confusão das classes temáticas, entre essas medidas, encontra-se a utilização de imagens com melhores resoluções espaciais, espectrais e radiométricas, assim como a utilização de mais dados auxiliares (AMARAL et al., 2009).

Um outro ponto interessante, é o de que a classe de corpo d'água possui pequena extensão, mas não sofreu influência desse comportamento pois possui uma assinatura de tons e refletância muito distintos de todas as outras classes. A avaliação deste comportamento foi esclarecida por Pereira et al. (2016), que ao delimitar e mapear corpos d'água utilizando imagens do satélite LANDSAT 8, constatou que por meio de diversos índices utilizados para o cálculo de corpo d'água, todas foram eficientes na detecção de pixels que continham apenas informação de água, em que as confusões apenas ocorreram com pixels que se encontravam em área de transição entre classes, misturando a resposta espectral.

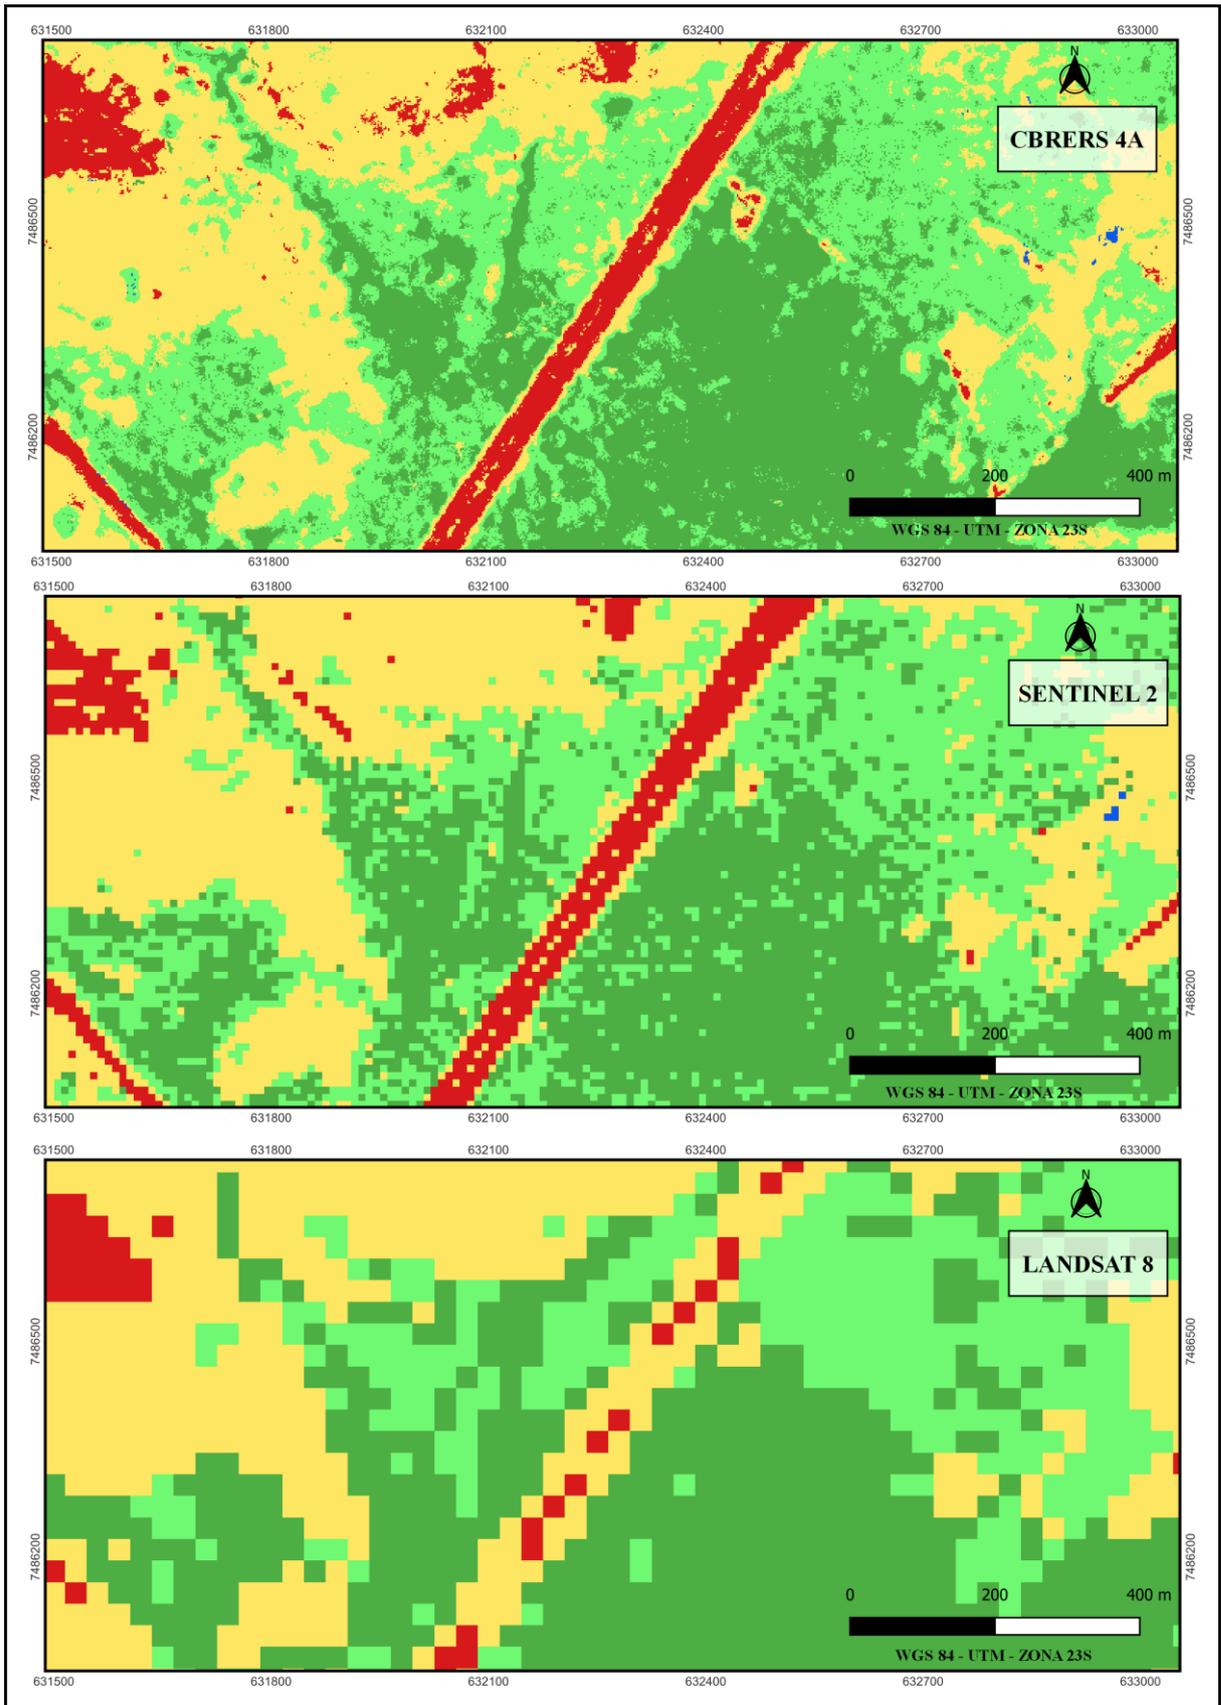
Além disso, importante entender o objetivo das análises que se deseja efetuar, em que imagens com pixels maiores seriam indicadas para análises de áreas com maiores extensões, enquanto que estudos de áreas com extensões menores, o mais indicado seriam imagens com pixels menores. De acordo com Freires et al. (2019), quanto maior a resolução espacial de determinada imagem de satélite maior a possibilidade de detalhamento de alvos na superfície, em que imagens com maior resolução, possibilitam estudos com aplicações que demandam maiores escalas de representação, enquanto que imagens de menor resolução espacial são indicados para estudo com menores níveis de detalhe, ou alvos que apresentem maior homogeneidade.

Portanto, entendesse que a resolução espacial das imagens está diretamente relacionada com as escalas que análises e estudos poderão ser desenvolvidos, em que a imagem do satélite/sensor CBERS 4A/WPM poderia estar sendo utilizada para análises em escalas maiores, já a imagem do satélite/sensor SENTINEL 2/MSI e a imagem do satélite/sensor LANDSAT 8/OLI seria utilizada para análises em escalas menores. Este entendimento é descrito por Boggione et. al. (2009) que definiu escalas em imagens de sensoriamento remoto, concluindo que a escala está diretamente relacionada com detalhes da imagem, portanto, as imagens CBERS por possuírem, uma resolução espacial nominal maior que uma imagem LANDSAT, ela estaria atendendo à análises em escalas maiores. Segundo o mesmo autor, por meio de equações que relacionam a resolução espacial nominal e o tamanho dos pixels das imagens, pode-se determinar que a imagem CBERS 4A/WPM atende à uma escala de 1:4.000,

a imagem SENTINEL 2/MSI atende à uma escala de 1:20.000 enquanto que a imagem LANDSAT 8/OLI atende à uma escala de 1:60.000.

Fica nítido que as imagens de baixa resolução (pixels maiores) apresentam o objeto com menor distinção visual em sua estrutura, sendo possível análises em pequenas escalas. Ao contrário, em imagens de média e alta resolução (pixels menores) os objetos são visualizados de forma detalhada, com estrutura realçada, o que torna ótimo o trabalho em grandes escalas.

A diferença de resolução que interfere diretamente na classificação supervisionada e no uso de análises em diferentes escalas pode ser melhor observada e entendida quando comparadas as imagens classificadas, de um mesmo local, em mesma escala, conforme ilustrado pela figura 11.



**Figura 11.** Mapas comparativos para melhor visualização dos diferentes tamanhos de pixels.  
Fonte: elaborado pelo autor.

## 5 CONCLUSÃO

Após todas as etapas de processamento e análise com o uso das imagens dos satélites CBERS 4A, SENTINEL 2 e LANDSAT 8, ficou nítido a eficácia da classificação supervisionada do uso e cobertura do solo com mapeamentos resultantes de grande importância no auxílio de estudos ambientais, além de que, fica clara novamente a importância das aplicações de sensoriamento remoto, detectando áreas e objetos, mapeando áreas e otimizando o tempo de estudo associado a bons resultados.

As análises evidenciaram que o município de Seropédica possui, majoritariamente, a extensão do seu território ocupado por pastagens (apresentando mais de 60% do território em todas as classificações), com a ocorrência de formações florestais naturais mais concentradas próximas a regiões sudoeste e região norte do município, além de evidenciar a presença de áreas com solo exposto e corpo d'água concentradas na região sul, resultado de atividade intensa de mineração de areia, bem conhecida na região.

A classificação supervisionada utilizando a imagem do satélite CBERS 4A, sensor WPM apresentou resultados com qualidade excelente, de acordo com o Índice Kappa, em que fica claro, que dentre as outras imagens, esta é que apresenta maior nível de detalhe na classificação, em função do tamanho dos seus pixels (2m x 2m), podendo ser utilizada para análises de áreas de menores extensões.

Para a classificação da imagem do satélite SENTINEL 2, sensor MSI, também foi obtido qualidade excelente de classificação de acordo com Índice Kappa, apresentando uma exatidão global consistente, em que, apesar de apresentar tamanho de pixel maior que a imagem do satélite CBERS 4A, também apresentou classificação bem detalhada podendo ser utilizada como ferramenta importante no auxílio de estudos ambientais.

A imagem do satélite LANDSAT 8, sensor OLI, é a que apresenta pixels de maiores dimensões, interferindo de maneira mais significativa na resolução, em que classes que possuem áreas de menor extensão, como silvicultura e solo exposto/áreas urbanas, tiveram maior dificuldade de serem identificadas. No entanto isso não interferiu de maneira significativamente na classificação, em que foi obtido uma qualidade excelente de acordo com o Índice Kappa e uma exatidão global consistente, o que mostra que a imagem pode ter resultados de classificação supervisionada de qualidade, sendo indicadas para áreas de maiores extensões.

## 6 REFERÊNCIAS

- ABDALLA, L. S.; VOLOTÃO, C. F. D. S. Estudo da configuração de diferentes arquiteturas de redes neurais artificiais MLP para classificação de imagens ópticas. Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Foz do Iguaçu, PR, Brasil, INPE. Anais. 2013.
- AMARAL, M. V. F.; DE SOUZA, A. L.; SOARES, V. P.; SOARES, C. P. B.; LEITE, H. G.; MARTINS, S. V.; FERNANDES FILHO, E. I.; DE LANA, J. M. Avaliação e comparação de métodos de classificação de imagens de satélites para o mapeamento de estádios de sucessão florestal. Revista Árvore, v.33, n.3, p.369-378, 2009.
- BARBOSA, A. P. Comparação de métodos de classificação de imagens, visando o gerenciamento de áreas citrícolas. Botucatu, 2009. 65 f. Dissertação (Mestrado em Agronomia/Energia na Agricultura) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista.
- BOGGIONE, G. A., DA SILVA, M. V. A., DE CARVALHO JUNIOR, N. R., TELES, T. L., & DE NAZARENO, N. R. X. Definição da escala em imagens de sensoriamento remoto: uma abordagem alternativa. Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil, 25-30 abril 2009, INPE, p. 1739-1746.
- BRYNS, Leonardo Monteiro. Página Dinâmica para Aprendizado do Sensoriamento Remoto. Orientador: Prof. Dr. Sérgio Florêncio de Souza. 2008. 170 f. Dissertação (Mestrado em Sensoriamento Remoto) - UFRGS/CEPSRM, Porto Alegre- RS, 2008.
- CALDAS-DA-SILVA, A. J.: Geoprocessamento e análise ambiental para determinação de corredores de hábitat na Serra da Concórdia, Vale do Paraíba – RJ, Instituto de Florestas, UFRRJ, Rio de Janeiro, 2006.
- CÂMARA, G.: Desenvolvimento de Sistemas de Informação Geográfica no Brasil: Desafios e Oportunidades. Palestra proferida na Semana de Geoprocessamento do Rio de Janeiro, Rio de Janeiro, Brasil, INPE, DPI, outubro de 1996.
- CÂMARA, G. e DAVIS, C. Introdução. In: CÂMARA, G.; DAVIS, C. e MONTEIRO, A. M. V. (Ed.). Introdução à Ciência da Geoinformação. São José dos Campos: INPE, 2003. p.1-5.
- CÂMARA, G., THOMÉ, R., FREITAS, U. e MONTEIRO, A. M.: Interoperability In Practice: Problems in Semantic Conversion from Current Technology to OpenGIS. 2nd. INTERNATIONAL CONFERENCE ON INTEROPERABLE OPERATING SYSTEMS, Zurique, 2005.
- CARNAÚBA, E. A. A. Mapeamento do uso e ocupação da terra utilizando os satélites Landsat 8, Sentinel 2B e Cbers 4A em área de agricultura no município de Limoeiro do Norte-CE. 2021.
- CARVALHO D. F., SILVA D. G., SOUZA A. P., GOMES D. P., ROCHA H. S. Coeficientes da equação de Angström-Prescott e sua influência na evapotranspiração de referência em Seropédica, RJ. Revista Brasileira de Engenharia Agrícola 2011; 15(8): 108-116.
- CASTRO, E. B. V., FERNANDÉZ, F. A. S. A fragmentação florestal na Reserva Biológica da Poço das Antas como consequência das intervenções de engenharia na bacia do rio São João (RJ). In: Anais do III Congresso Brasileiro de Unidades de Conservação; 2002. Fortaleza: Rede Nacional Pró-Unidades de Conservação, 2002. p. 649-659.
- CONGALTON, R.G. A review of assessing the accuracy classificatons of remotely sensed data. Remote Sensing Environment, v. 37, p.35-46, 1991.

- COSTA, N. M. C. da; COSTA, V. C. da; SANTOS, J. P. C.: Definição E Caracterização De Áreas De Fragilidade Ambiental, Com Base Em Análise Multicritério, Em Zona De Amortecimento De Unidades De Conservação. In: 12º Encuentro de Geógrafos da América Latina – EGAL 2009, 2009, Montivideo – Uruguai. 12 Encuentro de Geógrafos da América Latina – Caminhada em uma América Latina em Transformación, 2009.
- COSTA, O. B., SILVA C. V. J., SOUZA A. H. N., Uso do solo e fragmentação da paisagem no município de Seropédica – RJ, Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, INPE, Foz do Iguaçu, PR, Brasil, 13 a 18 de abril de 2013.
- CROSTA, A. P. Processamento digital de imagens de sensoriamento remoto. Campinas: IG/UNICAMP, 1993. 170p. (ed. rev.)
- CRÓSTA, A. P.: Processamento Digital De Imagens De Sensoriamento Remoto. Instituto de Geociências. UNICAMP. São Paulo. 2002.
- CRUZ, I., CAMPOS, V. B. G.: Sistemas De Informações Geográficas Aplicados À Análise Espacial Em Transportes, Meio Ambiente E Ocupação Do Solo, IME, Rio de Janeiro, 2016.
- EUROPEAN SPACE AGENCY (ESA). Copernicus Open Access Hub. Disponível em: <<https://scihub.copernicus.eu/dhus/#/home>>. Acesso em: 25 maio 2022.
- EUROPEAN SPACE AGENCY (ESA). Sentinel online. Disponível em: <<https://sentinel.esa.int/web/sentinel/missions>>. Acesso em: 07 julho 2022.
- FITZ, P. R. Geoprocessamento sem complicação. São Paulo: Oficina de Textos, 2008. 160p.
- FLORENZANO, T. G. Imagens de satélite para estudos ambientais. - São Paulo: Oficina de textos, 2002.
- FLORENZANO, T. G. Iniciação em sensoriamento remoto. 2ª ed. São Paulo, SP: Oficina de Textos, 2007.
- FLORENZANO, T. G.: Iniciação em Sensoriamento Remoto. São Paulo, 2011.
- FRANÇA, A. F.; TAVARES JUNIOR, J. R.; MOREIRA FILHO, J. C. C. Índices NDVI, NDWI e NDBI como ferramentas ao mapeamento temático do entorno da lagoa olho d'água, em Jabotão dos Guararapes – PE. IV Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação. Recife – PE, 06 – 09 de maio de 2012.
- FREIRES, E. V. et al. Comparação de Imagens OLI/Landsat-8 e MSI/Sentinel-2 no mapeamento de cobertura e uso da terra no Maciço de Uruburetama, Ceará. Anuário do Instituto de Geociências-UFRJ, Rio de Janeiro, v. 42, n. 4, p. 427-442, 2019.
- GASPARINI, Kaio Allan Cruz et al. Técnicas de geoprocessamento e sensoriamento remoto aplicadas na identificação de conflitos do uso da terra em Seropédica-RJ. Floresta e Ambiente, v. 20, p. 296-306, 2013.
- IBGE. Instituto Brasileiro de Geografia e Estatística. Cidade e Estados. 2022. Disponível em: <<https://www.ibge.gov.br/cidades-e-estados/rj/seropedica.html>>. Acesso em: 15 julho 2022.
- IBGE. Instituto Brasileiro de Geografia e Estatística. Manual técnico de pedologia. 2.ed. Rio de Janeiro, 2007. 316p.
- IBRAHIN, F. I. D.: Introdução ao Geoprocessamento Ambiental. 1. ed. Brasil: Saraiva, 2014. 11 p.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). Sem autor. DIVISÃO DE GERAÇÃO DE IMAGENS, 2022. Disponível em: <<http://www2.dgi.inpe.br/catalogo/explore>>. Acesso em: 27 maio 2022.

INPE. Bernardo F. T. Rudorff. Brasil (Org.) PRODUTOS DE SENSORIAMENTO REMOTO. Disponível em: <<http://www3.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm>>. Acesso em: 05 julho 2022.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). Sem autor. SOBRE O CBRES, SATÉLITE SINO-BRASILEIRO DE RECURSOS TERRESTRES, 2018. Disponível em: <<http://www.cbres.inpe.br/sobre/index.php>>. Acesso em: 07 julho 2022.

JACCOUD, C. F. S. Produção de Biomassa de Eucalyptus Urophylla em Três Classes de Solos em Seropédica, RJ [monografia]. Seropédica: Instituto de Florestas, Universidade Federal Rural do Rio de Janeiro; 2006.

MINISTÉRIO DO MEIO AMBIENTE, DOS RECURSOS HÍDRICOS E DA AMAZÔNIA LEGAL. Detalhamento da metodologia para execução do zoneamento ecológico econômico pelos estados da Amazônia Legal. Brasília: MMA, 1996. 43p.

NOVO, E. M. L. M. Sensoriamento Remoto: princípios e aplicações. São Paulo. ed. : Edgard Blücher, 1989, 308p.

PEREIRA, A. A.; TEIXEIRA, F. R.; LIBONATI, R.; MELCHIORI, E. A.; CARVALHO, L. M. T.: Avaliação De Índices Espectrais Para Identificação De Áreas Queimadas No Cerrado Utilizando Dados Landsat Tm. IFSULDEMINAS. Poços de Caldas, Minas Gerais, 2016.

PEREIRA, G. H. A., LOHMANN, M., MAGANHOTTO, R. F., 2016. Proposta e avaliação de índices para delimitar e mapear corpos d'água utilizando imagens do satélite LANDSAT 8. Revista Brasileira de Geografia Física 09, 1956-1968.

PERROCA, M. G.; GAIDZINSKI, R. R. Avaliando a confiabilidade interavaliadores de um instrumento para classificação de pacientes - coeficiente Kappa. Rev. Esc. Enferm. USP, 2003; n. 1, v.37, p. 72-80.

PONZONI, F. J.; ALMEIDA, E. S. A estimativa do parâmetro kappa (k) da análise multivariada discreta no contexto de um SIG. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8, 1996, Salvador. Anais... São José dos Campos: INPE, 1996. Artigos, p. 729-733. CD-ROM, On-line. ISBN 85-17-00014-5. Disponível em: <<http://marte.dpi.inpe.br/col/sid.inpe.br/deise/1999/02.05.09.39/doc/T130.pdf>>. Acesso em 05 de agosto de 2022.

PRINA, B. Z.; TRENTIN, R. GMC: Geração de Matriz de Confusão a partir de uma classificação digital de imagem do ArcGIS®. In: Simpósio Brasileiro de Sensoriamento Remoto, 17, 2015, João Pessoa. Anais... João Pessoa: INPE, p. 131 – 139.

REX, F. E.; KÄFER, P. S.; DEBASTIANI, A. B.; KAZAMA, V. S.: Potencial De Imagens Msi (Sentinel-2) Para Classificação Do Uso e Cobertura Da Terra. Enciclopédia Biosfera, Centro Científico Conhecer - Goiânia, v.15 n.27; 2018. 219 p.

RIBEIRO, S. R. A.; CENTENO, J. S.: Classificação do Uso do Solo Utilizando Redes Neurais e o Algoritmo MAXVER. Anais X SBSR, Sessão Poster, INPE, Foz do Iguaçu, 2001. P. 1341-1348.

RIBEIRO, M.A E O'NEIL, M.M.V.C. Contrastes entre a metrópole e o interior fluminense a partir da dinâmica populacional. Geo UERJ, v.14, nº. 23, v. 1, p. 262-301, 2012.

- SANO, E.E.; ROSA, R.; BRITO, J.L.S.; FERREIRA, L.G; BEZERRA, H.S. Mapeamento da cobertura vegetal natural e antrópica do bioma Cerrado por meio de imagens Landsat ETM+. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. Anais. Natal: INPE, 2009. p.1199-1206.
- SANTOS, Vinicius Perrut dos et al. Avaliação dos impactos sócio ambientais na bacia hidrográfica do Valão dos Bois em Seropédica-RJ. 2016.
- SILVA, A. D. B. Sistema de Informações Geo-referenciadas: conceitos e fundamentos. Campinas: UNICAMP, 2003. 240 p.
- TEIXEIRA, E. P. Análise espacial e temporal do uso e cobertura do solo nas Reservas Extrativistas da Costa Paraense. Orientadora: Sanae Nogueira Hayashi. 2022. 45 f. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Ambiental e Energia Renováveis) – Universidade Federal Rural da Amazônia, Campus Capanema, 2022.
- U.S. Department of the interior (USGS). Earth Explorer. Disponível em: <<https://earthexplorer.usgs.gov/>>. Acesso em: 25 maio 2022.
- U.S. Department of the interior (USGS). Landsat Missions. Disponível em: <[https://www.usgs.gov/land-resources/nli/landsat/landsat-satellite-missions?qt-science\\_support\\_page\\_related\\_con=2#qt-science\\_support\\_page\\_related\\_con](https://www.usgs.gov/land-resources/nli/landsat/landsat-satellite-missions?qt-science_support_page_related_con=2#qt-science_support_page_related_con)>. Acesso em: 4 junho 2022.
- XAVIER-DA-SILVA, J. Geoprocessamento para Análise Ambiental. Rio de Janeiro: sn, 2001. 228 p.
- XU, H. Extration of Urban Built-up Land Features from Landsat Imagery Using a Thematic-oriented Index Combination Technique. Photogrammetrie Engineering e Remote Sensing Vol.73, December 2007.
- ZAIDAN, R.T.: Geoprocessamento Conceitos e Definições. Revista de Geografia–PPGEO - UFJF. Juiz de Fora, v.7, n.2, (Jul-Dez) p.195-201, 2017.
- ZHA, Y.; Gao, J.; Ni, S. (2003). “Use of normalized difference built-up index in automatically mapping urban areas from TM imagery”. International Journal of Remote Sensing 2.