

USO DE IMAGENS DE ALTA RESOLUÇÃO ESPACIAL E GEOBIA PARA IDENTIFICAÇÃO DO LEITO REGULAR DE CURSOS D'ÁGUA.

Bruna Felix de Almeida¹

Edson Augusto Melanda²

RESUMO

O uso desordenado do território impacta negativamente a paisagem e o ciclo hidrológico dos rios, sobretudo pelo desmatamento e à impermeabilização do solo. O Código Florestal trata das Áreas de Preservação Permanente (APPs) e utiliza como critério o leito regular dos rios. Porém, há subjetividade nessa definição, o que dificulta a correta delimitação e preservação desses espaços. Este estudo objetivou delimitar a borda da calha do leito de um curso d'água em épocas de alta e baixa pluviometria, identificando o melhor momento do ano para essa atividade. A metodologia empregou a técnica GEOBIA, aplicada a imagens de alta resolução obtidas por RPA. Os resultados mostraram acurácia global de 0,8 em ambos os períodos, com índices Kappa de 0,6 e 0,7, respectivamente, confirmando a eficácia da técnica. A pesquisa contribui para uma melhor definição das APPs e conservação dos recursos hídricos.

Palavras-chave: Sensoriamento Remoto; Recurso Hídrico; APP; Segmentação GeoIA.

USE OF HIGH SPATIAL RESOLUTION IMAGERY AND GEOBIA FOR THE IDENTIFICATION OF THE REGULAR RIVERBED

ABSTRACT

The disordered land use negatively affects landscapes and river hydrological cycles, mainly due to deforestation and soil sealing. The Forest Code defines Permanent Preservation Areas (APPs) using the regular riverbed as a criterion. However, the subjectivity in this definition hinders accurate delimitation and protection of these areas. This study aimed to delimit the edge of a riverbed during high and low rainfall periods to identify the best time of year for this task. The methodology employed the GEOBIA technique applied to high-resolution images obtained by RPA. Results showed an overall accuracy of 0.8 in both periods, with Kappa indices of 0.6 and 0.7, confirming the method's effectiveness. The research contributes to better APP definition and water resource conservation.

keywords: Remote sensing; Water Resource; APP; Segmentation; GeoAI.

¹Mestra em Engenharia Urbana – Universidade Federal de São Carlos (UFSCAR), Email: brunafelixalmeida@gmail.com

²Doutor em Ciências da Computação – GeIA, Universidade Federal de São Carlos - UFSCAR, Email: melanda@ufscar.br

USO DE IMÁGENES DE ALTA RESOLUCIÓN ESPACIAL Y GEOBIA PARA LA IDENTIFICACIÓN DEL LECHO REGULAR DE LOS CURSOS DE AGUA

RESUMEN

El uso desordenado del territorio afecta negativamente al paisaje y al ciclo hidrológico de los ríos, principalmente por la deforestación y la impermeabilización del suelo. El Código Forestal define las Áreas de Preservación Permanente (APP) según el lecho regular del río. Sin embargo, la subjetividad en esa definición dificulta la delimitación y protección adecuadas de estas áreas. Este estudio tuvo como objetivo delimitar el borde del lecho de un río en períodos de alta y baja pluviometría para identificar el mejor momento del año para esa tarea. La metodología empleó la técnica GEOBIA aplicada a imágenes de alta resolución obtenidas con RPA. Los resultados mostraron una precisión global de 0,8 en ambos períodos, con índices Kappa de 0,6 y 0,7, confirmando la eficacia del método. La investigación contribuye a una mejor definición de las APP y a la conservación de los recursos hídricos.

Palabras clave: Sensado Remoto; Recurso hídrico; APP; Segmentación; GeoIA.

INTRODUÇÃO

As alterações no meio ambiente de modo geral são decorrentes de atividades humanas como práticas agrícolas, expansão urbana, obras de engenharia e operações de remanejo da terra, que modificam o arranjo espacial da paisagem (ARAÚJO, 2015; ALVES; MEDEIROS, 2016). Essas apropriações do espaço, quando ocorrem sem um planejamento adequado, ocasionam impactos ambientais.

Segundo Coelho et al. (2011), impacto ambiental refere-se às alterações sociais e ecológicas provocadas por perturbações no ambiente, relacionadas à interação entre sociedade e natureza, que se transformam de forma desigual e dinâmica. Entre esses impactos, destaca-se a problemática da devastação das matas ciliares, também conhecidas como Áreas de Preservação Permanente (APPs).

O artigo 4º do novo Código Florestal (Lei nº 12.651/2012) estabelece que as APPs atuam principalmente na conservação do regime hidrológico, contribuindo para a estabilização das linhas de drenagem natural e de suas margens. Em paisagens agrícolas, essas áreas atuam como filtros biológicos frente à erosão laminar, lixiviação, deriva e fluxo lateral de agroquímicos, além de exercerem funções de isolamento ecológico e quebra-vento (GASPARINI et al., 2013).

Diante da importância da preservação deste recurso, a Lei nº 12.651/2012 estabelece medidas mínimas para as APPs em torno dos cursos hídricos, com o objetivo de preservar o fluxo gênico entre as espécies da flora e da fauna, promovendo a formação de corredores ecológicos e, conseqüentemente, reduzindo a fragmentação dos habitats (COELHO et al., 2011; BRASIL, 2012).

Entretanto, mesmo com a aprovação do vigente Código Florestal, ainda persistem questões em aberto, como a falta de clareza quanto à delimitação da borda da calha do leito regular, ou seja, à definição da largura dos cursos d'água (CAMPAGNOLO et al., 2017). Essa largura interfere diretamente na definição das medidas mínimas das APPs ao longo dos corpos hídricos.

Por isso, de acordo com Barbosa (2019), recomenda-se realizar as demarcações dos rios em períodos de baixa pluviometria, quando o curso d'água se encontra com sua vazão natural reduzida. Nessa condição, o leito regular torna-se mais facilmente identificável, por estar bem delimitado e confinado entre as margens, apresentando escoamento constante.

Dada a importância ecológica desses recursos, torna-se necessário fiscalizar e monitorar essas áreas para examinar os impactos das ações humanas, sendo o mapeamento do uso e cobertura da terra uma ferramenta útil para avaliar a dinâmica da paisagem e suas alterações. De acordo com Vivoni et al. (2014), o sensoriamento remoto constitui uma fonte essencial para a geração de mapas temáticos, pois fornece uma representação contínua e altamente consistente da superfície terrestre, a partir da captura de imagens aéreas, como as provenientes de satélites.

Destaca-se, ainda, o crescente uso de aeronaves remotamente pilotadas (Remotely Piloted Aircraft – RPA), geralmente de pequeno a médio porte, capazes de transportar sensores diversos, como câmeras ópticas, multiespectrais e de vídeo. Esses equipamentos permitem a captura de imagens com alta resolução espacial, ampliando as possibilidades de monitoramento ambiental (NOOR et al., 2018).

O mapeamento temático por meio de sensores embarcados em RPAs é baseado na classificação de imagens, que pode ser realizada tanto por análise visual quanto por meio de algoritmos computacionais. Com o avanço tecnológico, novos sensores remotos foram desenvolvidos, fornecendo imagens com resolução espacial cada vez mais alta. Esse progresso trouxe consigo o desafio de investigar técnicas mais eficazes para explorar e interpretar o conteúdo dessas imagens (KALANTAR et al., 2017).

A classificação tradicional de imagens baseada em pixels utiliza a informação de cada pixel de forma isolada, classificando-os por meio de algoritmos probabilísticos ou determinísticos (FOLHARINI e SOUZA, 2017). Essa abordagem considera apenas as diferenças espectrais individuais de cada pixel, sem levar em conta suas relações espaciais com os vizinhos, o que pode comprometer a precisão em imagens de alta resolução.

Com o avanço da tecnologia computacional, foi desenvolvida a Análise de Imagem Baseada em Objeto Geográfico (GEOBIA), uma abordagem que oferece estrutura metodológica para interpretar classes complexas, definidas por propriedades espectrais e espaciais (BLASCHKE, 2010).

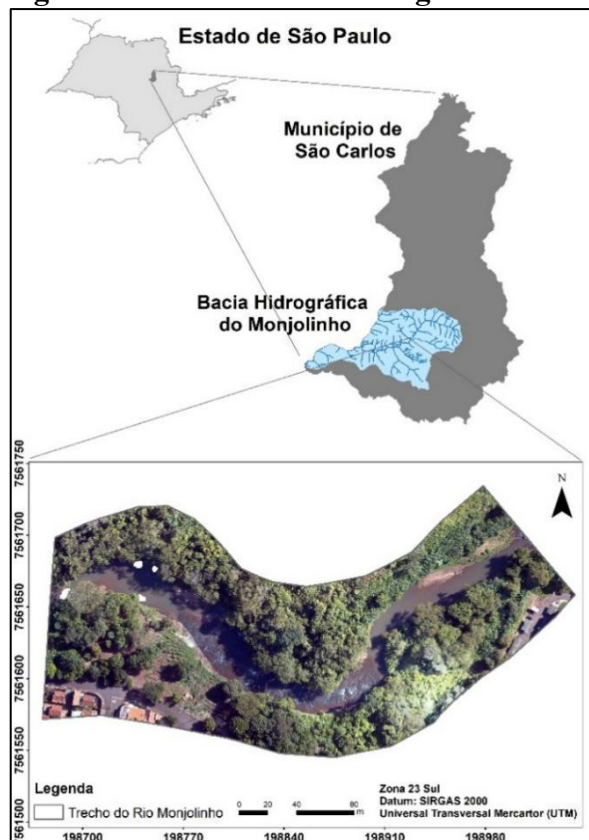
Nesta abordagem, a classificação é feita de maneira semiautomática, e o elemento de classificação - o pixel - não é analisado isoladamente. Em vez disso, utiliza-se o agrupamento de pixels que formam objetos (segmentos), os quais passam a conter atributos com características espectrais e espaciais semelhantes (SANTOS et al., 2022).

Considerando o avanço das técnicas de GEOBIA aplicadas à interpretação de imagens de alta resolução espacial, este estudo tem como objetivo delimitar, de maneira semiautomática, a borda do leito regular de um curso hídrico em períodos de alta e baixa pluviometria, a fim de verificar qual é o momento mais adequado para a realização dessas demarcações.

MATERIAIS E MÉTODOS

Área de estudo

O trecho de curso d'água escolhido está localizado no município de São Carlos – SP, na Bacia Hidrográfica do Monjolinho (Figura 1).

Figura 1: Trecho do curso d'água escolhido.

Fonte: Elaborado pela autora.

O município está a 241 km da capital do estado de São Paulo, entre as coordenadas 22°09'39" e 21°35'50" de latitude sul e 48°05'27" e 47°43'09" de longitude oeste, ocupando uma área de aproximadamente 1.136,91 km², com população estimada de 254.484 habitantes, sendo considerada uma cidade de médio porte (IBGE, 2020).

O trecho do curso d'água escolhido possui uma extensão de aproximadamente 412 m e pertence ao rio principal da Bacia Hidrográfica do Monjolinho, como demonstrado na Figura 1. Essa bacia ocupa parte do perímetro urbano, onde reside uma grande parte da população do município, e, segundo os dados do SEADE (2019), 95% dos habitantes estão concentrados no perímetro urbano.

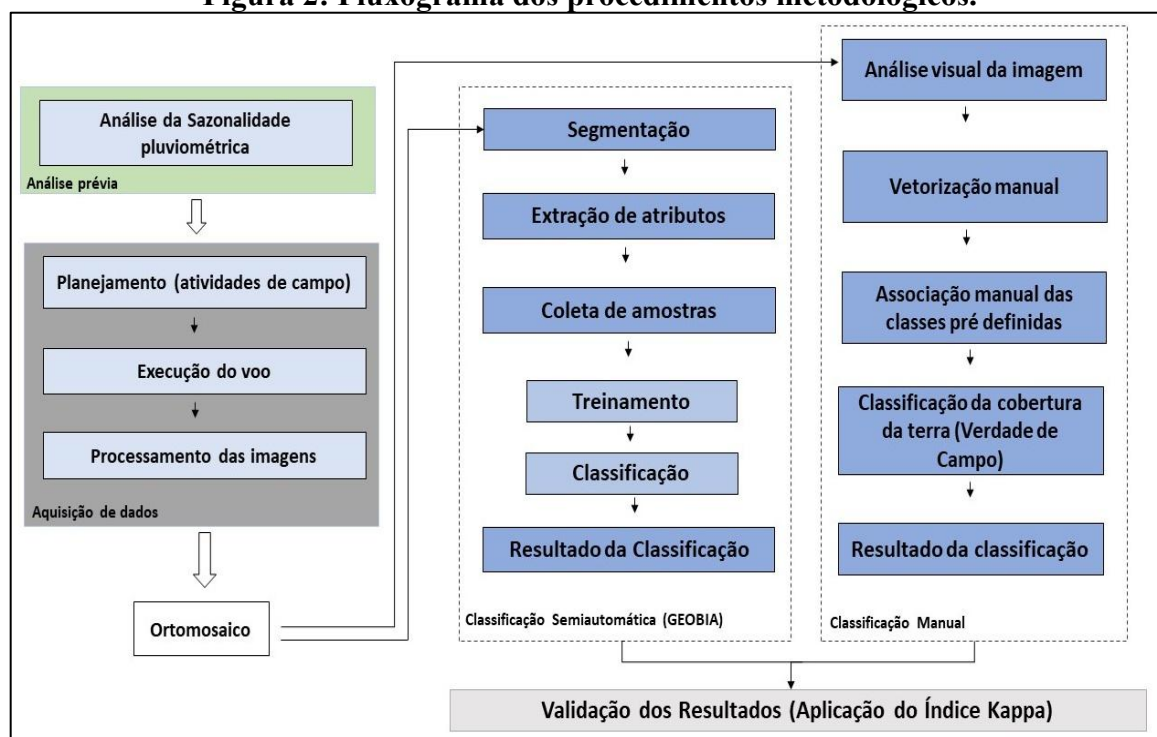
Esse processo de ocupação se intensificou a partir da segunda metade do século XX e acompanhou a tendência nacional de priorizar o fluxo de automóveis na construção do espaço urbano. Como consequência, nota-se que a presença de trechos de cursos d'água em áreas urbanas está sendo cada vez mais suprimida (SEADE, 2019).

É importante ressaltar que, segundo o Macrozoneamento descrito no Plano Diretor do município de São Carlos, essa área está inserida na Macrozona de Expansão Urbana, sendo considerada uma região de crescente pressão por ocupação urbana — o que pode afetar diretamente as demarcações das APPs (SEADE, 2019). Sendo assim, escolheu-se o trecho do curso d'água apresentado na Figura 1 para a realização das análises de desempenho das técnicas propostas neste estudo.

Procedimentos metodológicos

Os procedimentos metodológicos se iniciaram com a análise da sazonalidade pluviométrica do município de São Carlos – SP (Figura 2). Em seguida, foi realizado o planejamento de campo e os levantamentos aéreos com RPA, nos períodos de alta e baixa pluviometria.

Figura 2: Fluxograma dos procedimentos metodológicos.



Fonte: Elaborado pela autora.


Após a captura das imagens, estas foram processadas e, a partir delas, foi gerado o ortomosaico da área de estudo. O passo seguinte consistiu na aplicação da técnica GEOBIA, iniciando-se com a segmentação e a extração de atributos. Em seguida, foram definidas as

classes utilizadas para identificar os alvos presentes na imagem, o que serviu de base para a coleta de amostras. A etapa posterior envolveu o treinamento, a classificação, a avaliação da acurácia e, por fim, a análise dos resultados.

Para a validação da classificação, foi utilizada a verdade de campo (classificação manual), comparando-se os resultados obtidos com a classificação semiautomática (GEOBIA), a fim de calcular o Índice Kappa (IK) e a acurácia global.

A análise da sazonalidade pluviométrica foi essencial para compreender a delimitação correta do curso hídrico. Segundo Christofolletti (1980), o leito regular do rio corresponde aos espaços que podem ser ocupados pelo escoamento das águas. Esse leito é geralmente bem delimitado, com margens definidas, e o fluxo apresenta frequência suficiente para impedir o crescimento da vegetação, como ilustrado na Figura 3.

Figura 3: Leito regular e leito maior de um rio.



Fonte: Barbosa, 2019.

De acordo com Barbosa (2019), a definição inadequada da calha do rio pode gerar dificuldades na demarcação das Áreas de Preservação Permanente (APPs). Por exemplo, áreas marginais sujeitas a inundações periódicas podem deixar de ser consideradas. Dessa forma, os limites das APPs acabam incidindo sobre o mesmo espaço ocupado pelas áreas de várzea, deixando tais ecossistemas duplamente desprotegidos.

Sendo assim, foi realizada a aquisição dos dados pluviométricos dos últimos três anos da Estação Meteorológica de São Carlos (INMet), com os quais se calculou a média anual de chuvas registradas, conforme demonstrado na Tabela 1.

Tabela 1: Médias históricas dos dados meteorológicos de São Carlos.

MÊS	PRECIPITAÇÃO (mm)
Janeiro	274,7

Fevereiro	224,4
Março	142,9
Abril	62,7
Maiο	50,9
Junho	28,6
Julho	28,3
Agosto	22,8
Setembro	60,2
Outubro	102,6
Novembro	144,5
Dezembro	218,8

Fonte: Instituto Nacional de Meteorologia (INMet).

Desse modo, pode-se inferir que os meses de julho, agosto e início de setembro representam os melhores períodos para a identificação da calha do leito regular do rio, por se tratarem de meses com baixa pluviometria, durante os quais o nível da água se encontra rebaixado à sua calha natural. Já os meses de dezembro a março correspondem ao período de maior vazão do rio, devido à elevada precipitação na região, conforme demonstrado na Tabela 1.

Em seguida, realizou-se o planejamento das atividades de campo. Para esta etapa, foi utilizado o aplicativo móvel Map Pilot, da empresa norte-americana Drone Made Easy. Esse aplicativo foi escolhido por oferecer acesso gratuito e por apresentar funcionalidades adequadas para a realização dos voos. Entre elas, destaca-se a possibilidade de recobrir áreas maiores por meio de voos sucessivos: o sistema interrompe automaticamente o voo ao atingir a faixa de segurança de carga da bateria. Após o pouso e a substituição da bateria, o voo é retomado a partir do ponto de interrupção anterior, evitando falhas no aerolevanteamento. Além disso, o aplicativo permite o ajuste da altitude de voo, possibilitando o acompanhamento das variações topográficas do terreno durante a operação.

A coleta de dados por meio de aerolevanteamento foi feita com a RPA DJI Phantom 4, disponível para os alunos do grupo de pesquisa do Núcleo de Geoprocessamento (NGeo) da Universidade Federal de São Carlos (UFSCar).

Os voos foram planejados com base nas seguintes especificações: altitude de 120 metros; sobreposição longitudinal e transversal de 80% x 80%; e GSD (*Ground Sample Distance* – distância da amostra do solo) com resolução espacial de 3,52 cm.

Foram realizados dois voos, nos meses de setembro e março, representando os períodos de baixa e alta pluviometria, respectivamente.

Após essa etapa, realizou-se o processamento digital das imagens no software Agisoft Metashape (versão de teste), o que possibilitou a obtenção dos ortomosaicos da área de estudo.

Concluída a geração dos ortomosaicos, aplicou-se a técnica GEOBIA. Para esta etapa, foi utilizado o software de acesso livre TerraView, versão 5.6.3, considerado apto a manipular dados espaciais, imagens e regiões resultantes do processo de segmentação, além de integrar outros tipos de dados geográficos (KORTING et al., 2011).

A primeira etapa da GEOBIA se inicia com a segmentação da imagem. Nessa fase, é aplicado o algoritmo de Crescimento de Regiões, baseado em Bins et al. (1996), disponível no software mencionado anteriormente. Esse algoritmo utiliza duas variáveis principais: o limiar de similaridade e o tamanho mínimo de segmentos. Os valores dessas variáveis devem ser ajustados conforme a realidade de cada estudo, sendo necessário determiná-los de forma empírica para alcançar uma segmentação eficaz (BRAZ et al., 2021). Neste estudo, foi usada a abordagem de tentativa e erro com o objetivo de encontrar os valores mais adequados para a delimitação dos alvos da imagem.

A próxima etapa consistiu na extração de atributos, utilizando o plugin GeoDMA. Esse plugin, incorporado ao software TerraView, permite aplicar técnicas de mineração de dados com base em aprendizado de máquina, possibilitando a identificação de padrões entre os objetos gerados na etapa de segmentação.

Em termos operacionais, o GeoDMA auxilia no relacionamento entre os atributos extraídos e a classificação da imagem. Esses atributos correspondem a características espectrais e espaciais que integram dados matriciais (imagens) e vetoriais (segmentos), conforme descrito por Braz et al. (2021).

Finalizada a extração de atributos, iniciou-se a etapa de coleta de amostras. Para isso, foram estabelecidas três classes principais: Rio, Vegetação e Construções, definidas com base na análise visual das imagens e no conhecimento prévio da área (Tabela 2).

Tabela 2: Definições das classes de cobertura do solo.

Classe	Segmento da imagem	Cor para representação no mapa
--------	--------------------	--------------------------------

Vegetação		
Construções		
Rio		

Fonte: Elaborado pela autora.

A coleta de amostras da imagem segmentada foi distribuída de forma equilibrada ao longo da área de estudo, com o objetivo de representar adequadamente a variabilidade interna das classes. Para isso, foram selecionados objetos de uma mesma classe com diferentes tons, formas e demais variações visuais relevantes.

Após a coleta de amostras, realizou-se a etapa de classificação. O objetivo dessa fase foi rotular os objetos da imagem de acordo com as classes previamente definidas. Para isso, foi aplicado o algoritmo C5.0 Decision Trees, disponível no plugin GeoDMA, que utilizou as amostras coletadas para gerar um conjunto de regras de classificação.

Como resultado, obteve-se um arquivo no formato .SHP (Shapefile), contendo uma tabela em que todos os segmentos foram associados a uma classe de cobertura do solo.

A validação dos resultados foi realizada por meio da aplicação do índice Kappa, conforme proposto por Congalton e Green (2009), conforme apresentado na Tabela 3, além da utilização da verdade de campo como referência.

A verdade de campo foi obtida no software ArcGIS 10.5, por meio de análise visual da imagem seguida da classificação manual, com o objetivo de validar e comparar os resultados gerados pela aplicação da técnica GEOBIA. .

Tabela 3: Intervalo de aceitação para os resultados do índice Kappa.

Índice Kappa (K)	Características
$K < 0,4$	Regular
$K = 0,4 \text{ a } K < 0,8$	Razoável
$K \geq 0,8$	Excelente

Fonte: Adaptado de Congalton e Green (2009).

Para possibilitar a determinação do Índice Kappa (IK), foi realizado o cruzamento entre os arquivos vetoriais (.SHP) resultantes da classificação manual e da classificação semiautomática, por meio da ferramenta “Interseção”, disponível no software ArcGIS 10.5.

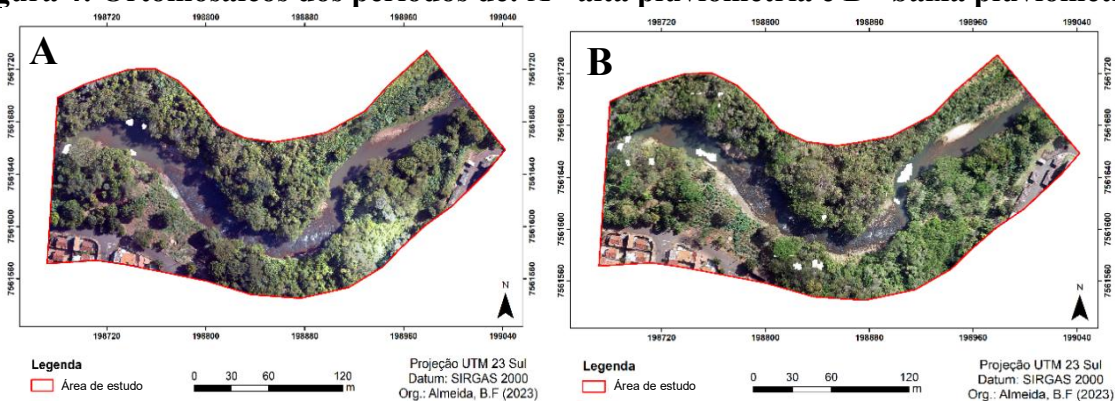
O resultado desse cruzamento foi uma tabela contendo duas colunas: uma com os rótulos atribuídos manualmente e outra com os resultados da classificação semiautomática. Cada linha da tabela corresponde a um segmento da imagem, permitindo a análise da concordância entre os métodos ao longo de toda a área classificada.

Por fim, o resultado da interseção foi exportado em formato CSV e importado para o software R Studio. Desse modo, foi possível realizar a análise de validação da classificação do uso e cobertura do solo com base nos dados cruzados.

RESULTADOS E DISCUSSÕES

Os resultados deste estudo têm início com a apresentação dos ortomosaicos gerados a partir do processamento digital das imagens obtidas nos períodos de alta e baixa pluviometria (Figura 4). Os voos foram realizados nos dias 29 de março e 1º de setembro, ambos no período da manhã, entre 9h e 11h. .

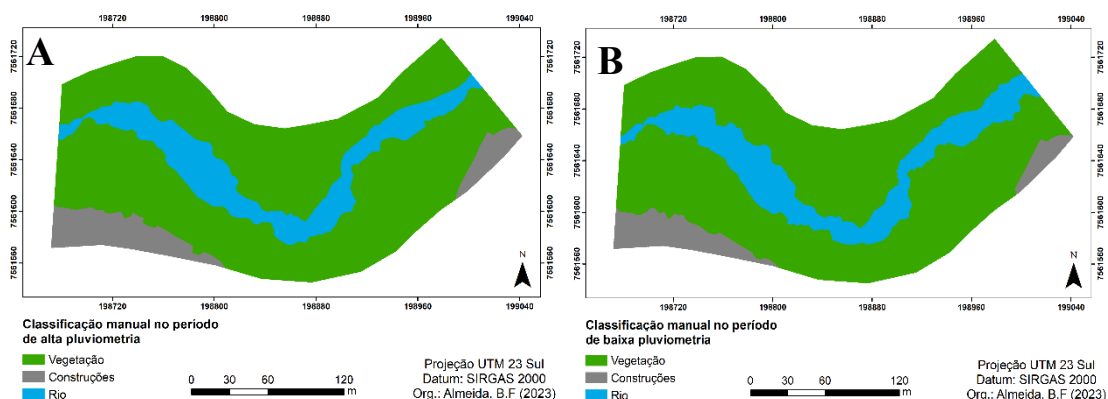
Figura 4: Ortomosaicos dos períodos de: A - alta pluviometria e B - baixa pluviometria.



Fonte: Elaborado pela autora.

Devido à alta resolução das imagens, foi possível realizar manualmente, de forma confiável, a detecção, o reconhecimento e a vetorização dos diferentes alvos. A Figura 5 apresenta os resultados da interpretação e classificação das imagens.

**Figura 5: Classificação manual do uso e ocupação do solo nos períodos:
A- alta pluviometria e B - baixa pluviometria.**



Fonte: Elaborada pela autora.

A Tabela 4 apresenta as áreas (em m²) e as respectivas porcentagens de ocupação associadas a cada classe de uso e cobertura do solo na área de estudo.

Tabela 4: Área e porcentagem de ocupação da classificação manual nos períodos de alta e baixa pluviometria.

	Alta pluviometria		Baixa Pluviometria	
Classes	Área (m ²)	Ocupação (%)	Área (m ²)	Ocupação (%)
Vegetação	33.436,2	75,24%	33.424,1	75,21%
Construções	3.215,6	7.24%	3.142,1	7.07%
Rio	7.788,8	17,53%	7.874,4	17,72%
Total	44.440,6	100%	44.440,6	100%

Fonte: Elaborado pela autora.


As áreas correspondentes a cada classe de uso e ocupação do solo apresentaram poucas variações entre os dois períodos analisados, uma vez que se referem à mesma região de estudo.

É importante destacar que essas pequenas diferenças não interferiram na obtenção dos dados finais, pois cada classificação foi realizada de forma independente.

A seguir, as classificações semiautomáticas (GEOBIA) tiveram início com o processo de segmentação. Segundo Hay e Castilla (2008), uma boa segmentação é aquela que não supersegmenta nem subsegmenta os objetos de interesse. Foram realizados testes com diferentes parâmetros do algoritmo de Crescimento de Regiões, e os melhores resultados no período de alta pluviometria foram obtidos com o valor de 100 para o tamanho mínimo de segmentos e 0,07 para o limiar de similaridade.

Em relação ao período de baixa pluviometria, os parâmetros obtidos foram os seguintes: 100 para o tamanho mínimo de segmentos e 0,05 para o limiar de similaridade. A Figura 6 apresenta os resultados das segmentações realizadas para ambos os períodos analisados.

**Figura 6: Trecho da segmentação final dos períodos:
A- alta pluviometria B- baixa pluviometria.**



Fonte: Elaborado pela autora.

A segmentação das imagens dos períodos de alta e baixa pluviometria resultou em 67.309 e 54.618 polígonos, respectivamente. Nas imagens apresentadas na Figura 6, observa-se uma boa segmentação dos alvos. Apesar de alguns fragmentos estarem supersegmentados, a classe “Rio” apresentou bordas bem definidas, o que favoreceu o desempenho das etapas subsequentes do processamento.

Após a segmentação, foi realizada a extração dos atributos espaciais e espectrais utilizando a ferramenta “*Feature Extraction*”, disponível no plugin GeoDMA. Considerando a alta resolução espacial das imagens, optou-se por utilizar todos os atributos disponíveis (Tabela 5), com o objetivo de aprimorar a acurácia da classificação.

Tabela 5: Atributos espaciais e espectrais.

Métricas espectrais		Métricas espaciais
Amplitude	Contraste	Ângulo
Assimetria	Dissimilaridade	Ajuste retangular
Coeficiente de variação	Energia	Ajuste retangular
Curtose	Entropia	Altura da caixa
Desvio padrão	Homogeneidade	Área
Média	Razão (taxa) de banda	Área de caixa
Mediana		Círculo circunscrito
Moda		Dimensão fractal

Multimodalidade		Elipse circunscritas
Soma		Perímetro de caixa
Tamanho da amostra		Perímetros
Valor máximo		Proporção perímetro área
Valor mínimo		Raio
Variância		Raio de Giratória

Fonte: Adaptado (KORTING, 2011).

A coleta de amostras foi realizada com o objetivo de abranger um número elevado de elementos representativos da área de estudo. Considerando a alta resolução espacial, observou-se elevada heterogeneidade espectral mesmo entre segmentos pertencentes à mesma classe de uso e cobertura do solo, o que justifica o número ampliado de amostras coletadas (Tabela 6).

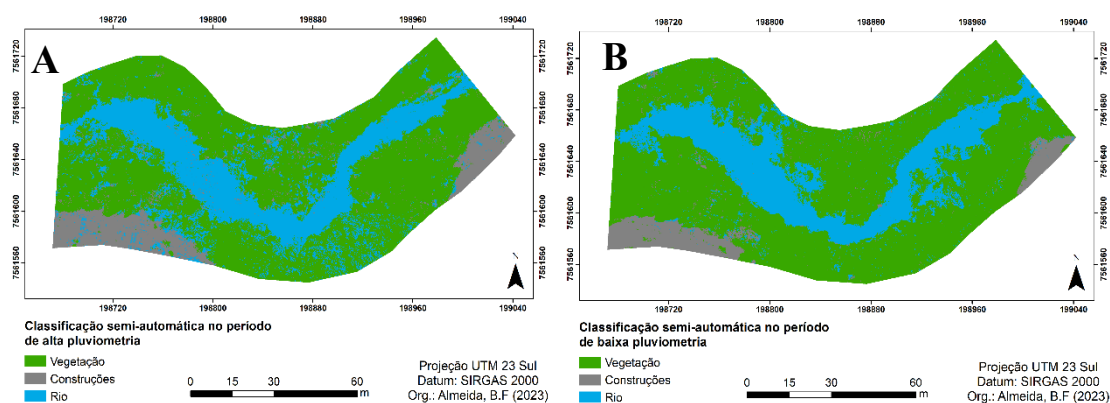
Tabela 6: Número de amostras para o período de alta e baixa pluvimetria.

Classes	Nº de amostras (alta pluvimetria)	Nº de amostras (baixa pluvimetria)
Vegetação	1.028	1.329
Construções	754	448
Rio	955	648
Total	2.737	2.425

Fonte: Elaborada pela autora.

Após a coleta das amostras, foi executada a classificação semiautomática para toda a extensão da imagem. Nessa etapa, aplicou-se o algoritmo de árvore de decisão, versão C5.0, disponível no plugin GeoDMA. Como resultado, foram gerados 67.309 e 54.308 polígonos para os períodos de alta e baixa pluvimetria, respectivamente (Figura 7).

**Figura 7: Classificação semiautomática nos períodos:
A- alta pluvimetria e B- baixa pluvimetria.**



Fonte: Elaborado pela autora.

A Tabela 7 apresenta as áreas (em m²) correspondentes a cada classe de cobertura do solo nos períodos de alta e baixa pluviometria, bem como suas respectivas porcentagens.

Tabela 7: Área e porcentagem de ocupação da classificação semiautomática no período de alta e baixa pluviometria.

	Alta pluviometria		Baixa pluviometria	
Classes	Área (m)	Ocupação (%)	Área (m)	Ocupação (%)
Vegetação	27.622,3	62%	30.220,4	68%
Construções	4.571,7	10%	3.166,1	7%
Rio	12.246,5	28%	11.054,1	25%
Total	44.440,6	100%	44.440,6	100%

Fonte: Elaborado pela autora.

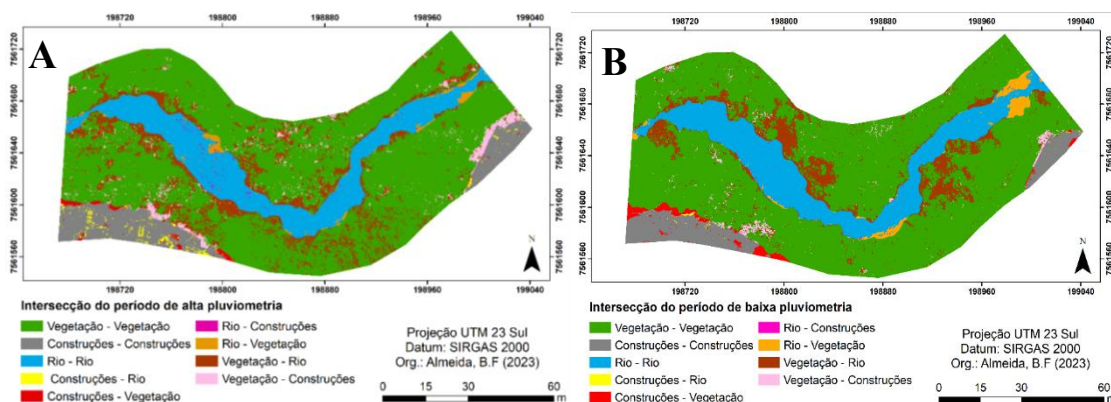
Ao realizar uma análise visual da Figura 7, nota-se a ocorrência de confusões na classificação de algumas áreas. Ao comparar os resultados da classificação manual (Tabela 4) com os da semiautomática (Tabela 7), observam-se diferenças nas áreas de ocupação no período de alta pluviometria: Vegetação (13,08%), Construções (3,05%) e Rio (10,03%). No período de baixa pluviometria, as diferenças foram de aproximadamente 7% para as classes Vegetação e Rio, enquanto a classe Construções apresentou uma discrepância de apenas 0,05%.

Após essa análise preliminar, observa-se que, em termos práticos de área, os resultados obtidos com a aplicação da técnica GEOBIA foram significativamente próximos aos da vetorização manual em ambos os períodos analisados. Para confirmar essa tendência, foi necessária a realização da validação estatística das classificações.

VALIDAÇÃO DOS RESULTADOS

Para isso, foi inicialmente realizada a interseção dos resultados entre os mapas das classificações manual (verdade de campo) e semiautomática (GEOBIA), com o objetivo de identificar visualmente as áreas onde ocorreram confusões entre as classes. A Figura 8 ilustra os resultados dessa comparação.

Figura 8: Intersecção dos resultados entre a classificação manual e a semiautomática nos períodos: A - alta pluviometria B – baixa pluviometria.



Fonte: Elaborado pela autora.

A confusão entre classes ocorre quando áreas que pertencem a uma determinada categoria de cobertura e uso do solo são erroneamente classificadas como outra. Por exemplo, regiões que deveriam ser classificadas como Construções foram rotuladas como Rio, gerando o erro identificado como Construções-Rio. Com o objetivo de quantificar esse tipo de inconsistência classificatória, foi elaborada a Tabela 8, que apresenta a porcentagem de confusão entre algumas classes nos mapas analisados (Figura 8).

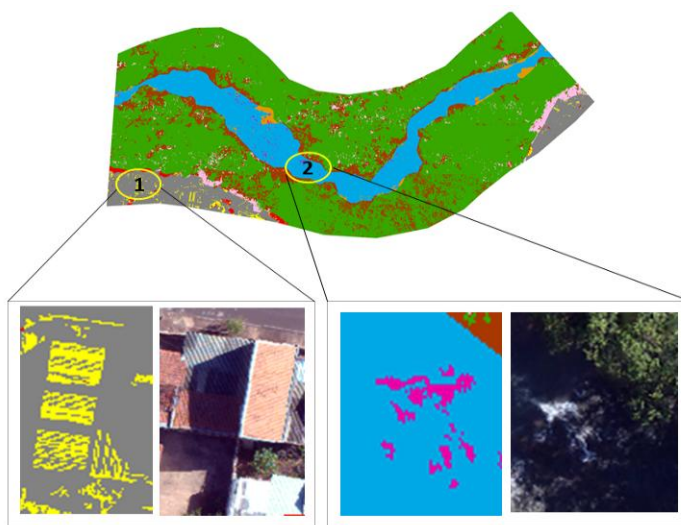
Tabela 8: Área e porcentagem de ocupação dos mapas nos períodos de alta e baixa pluviometria.

Classes	Alta pluviometria		Baixa pluviometria	
	Área (m²)	Ocupação	Área (m²)	Ocupação
Rio-Rio	6877.2	15%	7144.9	16%
Vegetação - Vegetação	27013.5	61%	29112.0	66%
Construções – Construções	3362.3	8%	2908.8	7%
Construções -Rio	259.5	1%	37.0	0.1%
Construções - Vegetação	215.4	0.5%	492.8	1.1%
Rio- Construções	70.2	0.2%	19.0	0.04%
Rio- Vegetação	391.7	1%	325.8	0.7%
Vegetação - Construções	1138.8	3%	538.1	1%
Vegetação -Rio	5112.0	12%	3862.2	9%
Total	44440.6	100%	44440.6	100%

Fonte: Elaborado pela autora.

Para analisar com mais detalhe as classes de confusão envolvendo a categoria “Rio”, foram identificadas quatro situações principais: Construções–Rio, Rio–Construções, Rio–Vegetação e Vegetação–Rio. De modo geral, essas confusões ocorreram em razão das semelhanças espectrais entre os alvos. A Figura 9 destaca dois trechos representativos da interseção entre os mapas, referentes ao período de alta pluviometria.

Figura 9: Confusão entre as classes no período de alta pluviometria, trechos: 1-(Construções-Rio); 2 - (Rio-Construções).



Fonte: Elaborado pela autora.

No primeiro e no segundo trecho, observa-se a presença de fragmentos mais esbranquiçados, correspondentes às respostas espectrais dos telhados e do leito do rio em movimento. A confusão entre as classes ocorreu devido à semelhança espectral desses alvos, representados no mapa pelas cores amarelo e rosa.


Ao realizar a análise da porcentagem de ocupação (Tabela 7), nota-se que essas classes apresentam baixa representatividade: a primeira (Construções–Rio) corresponde a 1% da área total de estudo, enquanto a segunda (Rio–Construções) representa 0,2%.

Em relação às mesmas classes de confusão, no período de baixa pluviometria, também foram observados fragmentos mais esbranquiçados. Ao analisar os dados da Tabela 7, nota-se que a classe Construções–Rio apresenta a segunda menor porcentagem de ocupação da área, com 0,1%, enquanto a classe Rio–Construções possui a menor proporção, com 0,04%.

Essas porcentagens de confusão são consideradas pouco expressivas, especialmente quando se leva em conta o alto nível de detalhamento proporcionado pela resolução espacial das imagens.

Os trechos Rio–Vegetação e Vegetação–Rio estão destacados na Figura 10. A confusão observada no terceiro trecho (Rio–Vegetação) ocorreu devido à aparência de sombras ao redor do rio, representadas no mapa pela cor marrom. Nota-se que essa confusão ocorreu em diversos pontos ao longo do curso hídrico, em razão da semelhança espectral entre áreas sombreadas e certas regiões da vegetação. Cabe destacar que a porcentagem de ocupação associada a essa confusão foi mínima, representando apenas 1% do total da área analisada (Tabela 7).

Figura 10: Confusão entre as classes no período de alta pluviometria, trechos: 3-(Rio-Vegetação) e 4-(Vegetação-Rio).



Fonte: Elaborado pela autora.

A confusão observada no quarto trecho (Vegetação–Rio), representado no mapa pela cor laranja, ocorreu devido à sobreposição da copa das árvores sobre o leito do rio. Em relação à porcentagem de ocupação, essa classe apresentou 12%, sendo a quarta maior ocorrência na área de estudo.

Dessa maneira, destaca-se que, nessa região específica, a aplicação de procedimentos de correção para remoção de artefatos resultantes da classificação pode contribuir para a melhoria dos resultados finais.

Em relação ao período de baixa pluviometria, destacam-se as mesmas confusões entre as classes, com ocorrência predominante nas bordas do rio. Para esse período, observa-se que

a porcentagem de ocupação das áreas de confusão foi menor em comparação ao período de alta pluviometria: 9% para o terceiro trecho (Vegetação–Rio) e 0,7% para o quarto trecho (Rio–Vegetação).

Após verificar a heterogeneidade no tamanho e na quantidade de polígonos, foi necessário padronizar tanto a área quanto o número de objetos (polígonos), conforme apresentado na Tabela 9, a fim de viabilizar a aplicação do Índice Kappa. Ressalta-se que essa padronização foi realizada com base nos dados obtidos a partir da interseção descrita na etapa anterior.

Tabela 9: Quantidade de polígonos nos períodos de alta e baixa pluviometria.

	Alta pluviometria	Baixa pluviometria
Classes	Qtd. de polígonos	Qtd. de polígonos
Rio-Rio	2.197	981
Vegetação - Vegetação	50.030	48.910
Construções – Construções	3.424	1.675
Construções -Rio	584	124
Construções - Vegetação	252	291
Rio- Construções	332	83
Rio- Vegetação	638	784
Vegetação - Construções	1.933	974
Vegetação -Rio	8.713	1.968
Total	1.872,30	3.289,55

Fonte: Elaborado pela autora.

O intuito dessa padronização foi obter uma base comum de comparação entre as duas classificações. Para isso, considerou-se a resolução da imagem de 10 cm/pixel. Após a padronização, obteve-se um total de 4.414.302 objetos para ambos os períodos analisados. Posteriormente, a tabela resultante foi exportada para o software R Studio, onde foram realizadas a geração da matriz de confusão e o cálculo do índice Kappa e da acurácia (Tabela 10).

Tabela 10: Valores encontrados nas Matrizes de confusões para os períodos de alta e baixa pluviometria.

Matrix de Confusão (Alta pluviometria)				Matrix de Confusão (Baixa pluviometria)			
	Rio	Veg.	Const.		Rio	Veg.	Const.
Rio	68.6876	39.000	7.088	Rio	71.5074	69.790	1.851

Veg.	509.520	268.3900	11.2748	Veg.	38.5366	288.2472	53.506
Const.	24.860	2.1026	329.284	Const.	3.631	47.694	254.889
Kappa	0.6628			Kappa	0.7102		
Acurácia	0.8382			Acurácia	0.8727		

Fonte: Elaborado pela autora.

De acordo com os níveis de desempenho do classificador propostos por Congalton e Green (2009), apresentados na Tabela 2, os valores de Índice Kappa obtidos - 0,6682 e 0,7102 - são considerados “Razoáveis”. Esses resultados são reforçados pelos valores de acurácia global, que foram de 0,8382 e 0,8727, indicando um desempenho satisfatório para ambos os períodos analisados. Quanto mais próximos de 1, maiores são a consistência e a confiabilidade da classificação.

CONSIDERAÇÕES FINAIS

Neste estudo, as imagens adquiridas por meio de RPA possibilitaram elevado nível de detalhamento do uso e da ocupação do solo. Essas imagens apresentaram alta heterogeneidade espectral entre os alvos, o que favoreceu a distinção entre as diferentes classes e facilitou a vetorização manual utilizada para a coleta de exemplos de treinamento. Essa etapa foi fundamental para a aplicação da técnica GEOBIA, que utiliza redes neurais na segmentação e classificação de imagens. A abordagem semiautomática demonstrou ser uma alternativa promissora para este tipo de análise.

É importante ressaltar que o GeoDMA, por estar associado ao TerraView, integra todas as etapas da aplicação da abordagem GEOBIA — como segmentação, extração e seleção de atributos, coleta de amostras, geração da árvore de decisão e classificação — em uma única plataforma. Além da vantagem de ambos serem softwares livres, essa integração representa um avanço significativo, considerando a recorrente necessidade de utilizar múltiplos programas computacionais em processos similares.

Os resultados apresentados indicaram uma boa acurácia da classificação, com valor global de 0,8 em ambos os períodos analisados e índices Kappa de 0,6 e 0,7 para os períodos de alta e baixa pluviometria, respectivamente. Esses bons resultados demonstram a eficácia da classificação baseada na técnica GEOBIA, combinada com mineração de dados atrelada ao algoritmo de indução de árvores de decisão, aplicada a imagens de alta resolução espacial obtidas por meio de RPA.

Pode-se dizer que os objetivos do trabalho foram atingidos, uma vez que foi possível delimitar a borda do leito regular do rio em ambos os períodos, apesar da ocorrência de áreas de confusão entre classes. É importante salientar que não houve variações significativas nos valores de Índice Kappa e acurácia. No entanto, a análise da tabela de interseção mostrou que a classe ‘Rio’ obteve melhor desempenho classificatório no período de baixa pluviometria, considerando a proporção de área corretamente identificada.

Sendo assim, os dados apresentados poderão ser úteis para embasar estudos futuros voltados ao cálculo da largura dos cursos hídricos, bem como para orientar a delimitação adequada de Áreas de Preservação Permanente.

Agradecimentos

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e tecnológico (CNPq) pelo apoio financeiro a pesquisa 131518/2021-6.

REFERÊNCIAS

ALVES, J. B.; MEDEIROS, F. S. Impactos ambientais e delimitação da Área de Preservação Permanente do rio Espinharas no trecho urbano de Patos-PB. **Redes**, Santa Cruz do Sul, v. 21, n. 2, p. 107-130, 2016.

ARAÚJO, P. S. Diagnóstico da supressão de vegetação nativa em Áreas de Preservação Permanente contida no Código Florestal brasileiro de 2012. **Revista de Estudos Jurídicos**, 2015.

BARBOSA, G. D. **Delimitação da Área de Preservação Permanente no rio Apodi/Mossoró**. Trabalho de Conclusão de Curso. Universidade Federal do Rio Grande do Norte. 2019.

BINS, L.; FONSECA, L.; ERTHAL, G.; II, F. Satellite imagery segmentation: a region growing approach. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8. *Proceedings...* Salvador: Instituto Nacional de Pesquisas Espaciais, 1996. v. 8, p. 677-680. 2, 25.

BLASCHKE, T. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier B.V., v. 65, n. 1, p. 2-16, jan. 2010.

BRASIL. **Lei nº 12.651**, de 25 de maio de 2012. Código Florestal Brasileiro. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/l12651.htm> Acesso em 14 de abril de 2022.

BRAZ, A. M.; KORTING, T. S.; MARTINS, A. P.; BRAZ, A. M. Geobia E Mineração de Dados para Classificação de Imagens de Altíssima Resolução Espacial. **Estudos Geográficos: Revista Eletrônica de Geografia**, v. 19, n. 3, p. 209-224, 2021.

CAMPAGNOLO, K.; SILVEIRA, G. L.; MIOLA, A. C.; SILVA, R. L. L. Área de Preservação Permanente de um rio e análise da legislação de proteção da vegetação nativa. **Ciência Florestal**, Santa Maria, v. 27, n. 3, p. 831-842, 2017.

CHRISTOFOLETTI, A. (1980). **Geomorfologia**. São Paulo. Edgard Blücher, 2ª edição, 83 p.

COELHO, R. C. T. P.; BUFFON, I.; GUERRA, T. Influência do uso e ocupação do solo na qualidade da água: um método para avaliar a importância da zona ripária. **Ambi-Água**, Taubaté, v. 6, n. 1, p. 104-117, 2011.

CONGALTON, R. G.; GREEN, K. Assessing the accuracy of remotely sensed data: principles and practices. 2. ed. Boca Raton: CRC Press, 2009.

FOLHARINI O., SOUZA S., Sirius Oliveira. Classificação geobia aplicada a gestão de bacias hidrográficas: o caso da microbacia do córrego monte alegre. **REDE-Revista Eletrônica do PRODEMA**, v. 10, n. 2, 2017.

FUNDAÇÃO SEADE: Disponível em: <<http://www.perfil.seade.gov.br/>> Acesso em: março de 2022.

GASPARINI, K. A. C.; LYRA, G. B. FRANCELINO, M. R.; DELGADO, F. C.; OLIVEIRA JUNIOR, J. F. de; FACCO, A. G. Técnicas de geoprocessamento e sensoriamento remoto aplicadas na identificação de conflitos do uso da terra em Seropédica-RJ. **Revista Floresta e Ambiente**, v. 20, n. 3, p. 296-306, 2013.

HAY, G; CASTILLA, G. Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline. Objectbased image analysis - spatial concepts for knowledge-driven remote sensing applications. Berlin, Heidelberg: **Springer-Verlag**, cap. 1.4, p. 75 89. 2008.

IBGE. *Instituto de Geografia e Estatística*. Divisão territorial Brasileiro e limites territoriais: **IBGE cidades – São Carlos**, 2020. Disponível em: <<https://cidades.ibge.gov.br/brasil/sp/saocarlos/panorama>>. Acesso em: 13 de maio de 2022.

KALANTAR, B.; MANSOR, S.B.; SAMEEN, M.I.; PRADHAN, B.; SHAFRI, H.Z.M. Dronebased land-cover mapping using a fuzzy unordered rule induction algorithm integrated into object-based image analysis. *Int. J. Remote Sens.*, 38, 2535–2556. 2017.

KORTING, T. S.; DUTRA, L.V.; FONSECA, L. M. G. A Resegmentation Approach for Detecting Rectangular Objects in High-Resolution Imagery. **IEEE Geoscience and Remote Sensing Letters**. v. 8, p. 621-625, 2011.

NOOR, M; ABDULLA, A.; HASHIM, M. Remote sensing UAV/drones and its applications for urban areas: a review. *IOP Conference Series: Earth and Environmental Science*, v. 169, n. 01, 2018.

SANTOS, B. D., PINHO, C. M. D., OLIVEIRA, G. E. T., KORTING, T. S., ESCADA, M. I. S., AMARAL, S. Identifying precarious settlements and urban fabric typologies based on GEOBIA and Data mining in Brazilian Amazon Cities. *Remote Sensing*, v. 14, n. 3, p. 704, 2022.

VIVONI, E. R.; RANGO, A.; ANDERSON, C. A.; PIERINI, N. A.; SCHREINERMCGRAW, A. P.; SARIPALLI, S.; LALIBERTE, A. S. Ecohydrology with unmanned aerial vehicles. *Ecosphere*, v. 5, n. 10, p. 130-144, 2014.