

Análise de algoritmos de segmentação de imagens e de inteligência artificial na caracterização do uso e cobertura do solo

RESUMO

O uso e cobertura do solo refere-se as áreas geridas pelo ser humano (uso) e as camadas sobre a superfície do solo (cobertura), como florestas, corpos d'água e áreas edificadas. Compreendê-lo é fundamental para o desenvolvimento sustentável e para a gestão dos recursos naturais, os quais têm impacto direto no bem-estar das comunidades. A análise do uso e cobertura do solo se constitui em um indicador de sustentabilidade e permite o monitoramento regular com avaliação das mudanças ocorridas ao longo do tempo. Para tanto, pode-se empregar técnicas de segmentação e classificação em imagens de Sensoriamento Remoto (SR) por meio de Sistemas de Informações Geográficas (SIGs) e Processamento Digital de Imagens (PDI). Com isso, torna-se possível estimar com alta acurácia o uso e cobertura do solo, como o demonstrado neste estudo em um recorte na Área de Proteção Ambiental (APA) de Setiba, Guarapari-ES. Para atingir esse objetivo, foi realizada a Análise de Imagem Baseada em Objetos Geográficos (GEOBIA), em que foram testados algoritmos de segmentação (*Meanshift*, *SLIC* e *Watershed*) e de Aprendizado de Máquina (Florestas Aleatórias, Máquina de Vetores de Suporte e Árvores de Decisão) voltados à execução de classificação supervisionada. Esses algoritmos foram aplicados em uma imagem de banda composta do CBERS 04A, sensor WPM, com resolução espacial de 2 m. Como resultado, foram obtidos mapas de uso e cobertura do solo com exatidão global e índice Kappa acima de 90%, o que permitiu inferir que o método adotado foi suficientemente robusto para superar os desafios inerentes à classificação de imagens aplicada na caracterização do uso e cobertura do solo.

PALAVRAS-CHAVE: GEOBIA. Classificação. Aprendizado de Máquina. Processamento Digital de Imagens.

Renan Fabres Dalmonech

renandalmonech@ufpr.br
orcid.org/0000-0002-4289-9873
Universidade Federal do Paraná (UFPR),
Curitiba, Paraná, Brasil.

Thiago Arruda Silva

thiago.arrudas@ufpe.br
orcid.org/0009-0004-3582-7304
Universidade Federal de Pernambuco
(UFPE), Recife, Pernambuco, Brasil.

Daniel Cavalcanti Buarque Moreira

buarque.daniel@eb.mil.br
orcid.org/0000-0002-4354-6359
3º Centro de Geoinformação (3º CGEO),
Olinda, Pernambuco, Brasil.

Joel Borges dos Passos

joel.passos@ufpe.br
orcid.org/0000-0001-9191-1691
Universidade Federal de Pernambuco
(UFPE), Recife, Pernambuco, Brasil.

Tiago Prudencio Silvano

prudencio.tiago@eb.mil.br
orcid.org/0000-0002-3287-5907
3º Centro de Geoinformação (3º CGEO),
Olinda, Pernambuco, Brasil.

INTRODUÇÃO

Avanços recentes no Processamento Digital de Imagens (PDI), no Sensoriamento Remoto (SR) e nos Sistemas de Informações Geográficas (SIGs) têm se mostrado eficazes para a análise do uso e cobertura do solo em diferentes regiões. A aquisição e quantificação de dados de forma rápida e regular, a um custo acessível e em menor tempo têm levado a um maior uso de ferramentas computacionais para a obtenção de informações geográficas, antes somente disponíveis após custosos levantamentos de campo (JAYABASKARAN; DAS, 2023).

Informações sobre o uso e cobertura do solo obtidas de imagens de SR são amplamente utilizadas para a elaboração de mapas. Para tanto, faz-se uso de ferramentas de PDI como, por exemplo, segmentadores e classificadores capazes de tratar semelhanças e diferenças em termos de características espectrais, texturais, geométricas e contextuais, de modo a possibilitar a separação entre classes (ARYAL; SITAULA; FRERY, 2023).

O SR tem suas bases na medição da energia refletida por objetos na superfície terrestre, por meio de um sensor remoto instalado em uma plataforma, normalmente aérea ou orbital. Por meio do imageamento orbital, pode-se sistematizar a obtenção de dados geoespaciais, possibilitando a cobertura de grandes áreas em um curto intervalo de tempo (LOU *et al.*, 2023). Nos últimos anos, a disponibilização gratuita de imagens de satélites por parte de entidades governamentais do Brasil ampliou o uso do SR em vários campos, entre eles no de verificação do uso e cobertura do solo.

A dinâmica do uso e cobertura do solo é um indicador de atividades antrópicas, que aumentaram significativamente nas últimas décadas (ABERA *et al.*, 2023), com a rápida urbanização e consequente alteração de área verde (WANG *et al.*, 2023). Esse processo de antropização levanta questões ambientais importantes, como o aquecimento global, perda de áreas florestais e declínios na biodiversidade (MUMTAZ *et al.*, 2023), aumento da população e do consumo, urbanização excessiva e mudanças no estilo de vida (SADEGHI *et al.*, 2023).

A melhoria da qualidade das imagens geoespaciais, cada vez mais complexas e com mais informações armazenadas devido à maior resolução espacial, radiométrica e espectral de alguns sensores, tem demandado a utilização de novas técnicas para a extração de classes de interesse. Entre essas técnicas destinadas ao aumento de eficiência e redução de custos encontra-se a Inteligência Artificial (IA), que busca resolver problemas de maneira semelhante ao ser humano, mas de forma otimizada, dada a alta capacidade das máquinas em armazenar, processar e entregar resultados (MA *et al.*, 2023).

A IA pode ser definida como a capacidade computacional de desempenhar funções do modo como o faz a inteligência humana. Atualmente, é empregada na classificação e extração de objetos em imagens, otimizando o trabalho dos analistas, ao possibilitar que algumas etapas possam ser realizadas de forma automática ou ao menos semiautomática, com maior celeridade e economia de recursos (DUMDUMAYA; CABRERA, 2023). Para tanto, utiliza-se algoritmos de Aprendizado de Máquina, subgrupo da IA, que permitem ao computador aprender com base em dados de entrada fornecidos pelo analista. Além disso, os classificadores desse ramo da IA são capazes de produzir saídas com maior

acurácia, mesmo em conjuntos de dados complexos, como as imagens de SR (BISWAS *et al.*, 2023).

Os métodos de extração de dados de SR são divididos nas abordagens baseadas em *pixel* e baseadas em objetos. Os métodos baseados em *pixels* são normalmente mais eficazes para imagens de baixa e média resolução espacial, como imagens multiespectrais dos satélites Sentinel (10 m) e Landsat (30 m). Esses métodos comumente sofrem com o ruído do tipo sal e pimenta (*salt and pepper*) ao lidar com dados de alta resolução, o que dificulta a obtenção de informações geográficas detalhadas. Por seu turno, os métodos baseados em objetos são capazes de melhorar a classificação do uso e cobertura do solo com a utilização de informações relacionadas à textura, contexto, forma dos objetos da cena etc. (YANG *et al.*, 2023).

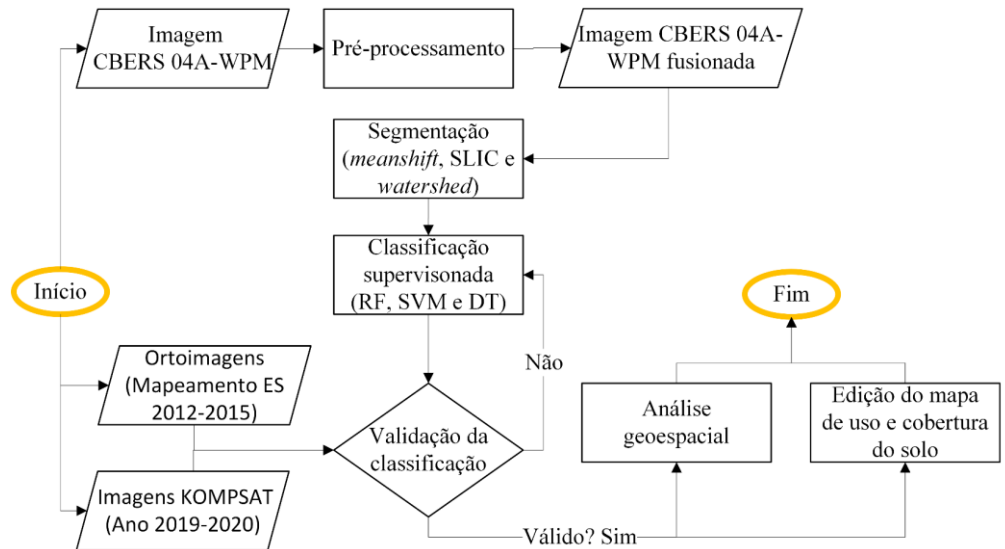
A Análise de Imagem Baseada em Objetos Geográficos (*Geographic Object-Based Image Analysis, GEOBIA*) é, assim, uma alternativa aos métodos baseados em *pixels*. De uma forma geral, nessa abordagem, primeiro busca-se segmentar a imagem, por meio do agrupamento de *pixels* adjacentes, cumprindo critérios de semelhança entre eles para formar objetos. Posteriormente, utiliza-se as características espectrais, texturais e de forma, extraídas dos objetos homogêneos segmentados, em algoritmos de Aprendizado de Máquina, para atribuir-lhes a uma classe de interesse (NININHAZWE *et al.*, 2023).

Nesse contexto, este estudo teve como objetivo realizar avaliações dos algoritmos segmentadores *Meanshift*, Agrupamento Iterativo Linear Simples (*Simple Linear Iterative Clustering, SLIC*) e *Watershed*, e de classificadores de Aprendizado de Máquina de Floresta Aleatória (*Random Forest, RF*), Máquina de Vetores de Suporte (*Support Vector Machine, SVM*) e Árvore de Decisão (*Decision Tree, DT*), para a caracterização do uso e cobertura do solo. Esperou-se com isso contribuir para a identificação de classes de interesse com base na segmentação e na classificação de imagens em abordagem GEOBIA aplicada em imagens CBERS 04A-WPM.

MATERIAL E MÉTODOS

O método descrito nesta seção foi operacionalizado na plataforma QGIS, por meio das funções nativas e dos complementos Orfeo *ToolBox* (OTB) e *Terminus*, conforme apresentado na Figura 1. Inicialmente, foram adquiridas imagem CBERS 04A-WPM e ortoimagens do Projeto de Mapeamento do Espírito Santo 2012-2015, provenientes de levantamento aerofotogramétrico, e do satélite KOMPSAT 3/3A, ano 2019-2020, ambas de altíssima resolução espacial (respectivamente, 25 e 50 cm). A imagem CBERS 04A-WPM foi pré-processada, de modo a melhorar a sua resolução espacial de 8 m para 2 m, por meio do processo de fusão de bandas espectrais. Após, foram realizadas as etapas de segmentação e classificação, seguida de uma validação estatística, apoiada nas ortoimagens aérea e orbital disponibilizadas pelo Estado do Espírito Santo. Validado o processamento, foi possível realizar a edição do mapa de uso e cobertura do solo da área de estudo, com estimativa das áreas de cada uma das classes mapeadas.

Figura 1 – Fluxograma para obtenção do mapa de uso e cobertura do solo




Fonte: Autoria própria (2024).

ÁREA DE ESTUDO

A área de estudo foi delimitada por um recorte na região norte da Área de Proteção Ambiental (APA) de Setiba, criada pela Lei nº 5.651, de 26 de maio de 1998. Essa APA localiza-se no Município de Guarapari-ES. Conforme pode ser observado na Figura 2, esse recorte contemplou uma porção de área urbana e de área rural, com curso/corpos d'água, vegetação densa, pastos e plantações, o que tornou sua escolha oportuna e de interesse para a realização de testes com algoritmos de segmentação e classificação de imagens.

Figura 2 – Área de estudo: recorte de área norte da APA de Setiba, Guarapari-ES



Fonte: Autoria própria (2024).

IMAGENS CBERS 04A-WPM

O CBERS 04A, sexto membro da série de satélites CBERS, foi inserido em órbita em 2019, tendo como característica a pluralidade de sensores, que lhe confere a habilidade de atender a diversas finalidades, entre elas a análise do uso e cobertura do solo (INPE, 2019). Entre os autores atuais que utilizaram insumos CBERS 04A, pode-se citar:

- a) Santos, Neris e Coelho (2023), para avaliação da dinâmica do uso e cobertura do solo;
- b) Dal’Asta *et al.* (2023), para definição da espacialidade de 26 comunidades quilombolas em Oriximiná/PA e análise da ocupação dos territórios quilombolas na Amazônia; e
- c) Santos *et al.* (2023), em modelos de classificação, abordagem GEOBIA, mineração de dados e algoritmos de Aprendizado de Máquina.

A imagem CBERS 04A-WPM (Tabela 1) foi obtida do catálogo da Divisão de Geração de Imagens (DGI), do Instituto Nacional de Pesquisas Espaciais (INPE), por meio do endereço eletrônico <<http://www.dgi.inpe.br/catalogo/explore>>, em formato GeoTIFF.

Tabela 1 – Imagem CBERS 04A adquirida do catálogo DGI/INPI

Ano	mês	ID da cena	Sensor	Resolução espacial	Órbita	Ponto
2023	10	CBERS4A_WPM1961 3920231024	WPM	2 e 8 m	196	139

Fonte: Adaptado de DGI (2024).

As principais características do sensor WPM foram dispostas na Tabela 2. A imagem CBERS 04A-WPM foi submetida ao processo de fusão de bandas, o que permitiu obter um produto de 2 m de resolução espacial e possibilitou a extração de objetos presentes na cena com maior riqueza de detalhes.


Tabela 2 – Características do sensor WPM do satélite CBERS 04A

Atributo	Valor
Resolução temporal	31 dias
Largura de faixa imageada	92 km
Resolução espacial	Banda PAN: 2 m; Bandas RGB-NIR: 8 m
Resolução radiométrica	10 bits
Bandas	P (PAN): 0,45-0,90; B1 (azul): 0,45-0,52 µm; B2 (verde): 0,52-0,59 µm; B3 (vermelho): 0,63-0,69 µm; B4 (infravermelho próximo, NIR): 0,77-0,89 µm

Fonte: Adaptado de INPE (2019).

Os níveis de processamento de imagens CBERS 04A, disponibilizadas no catálogo da DGI/INPI, seguem o disposto na Figura 3.

Figura 3 – Níveis de processamento das imagens CBERS 04A fornecidas pela DGI/INPE

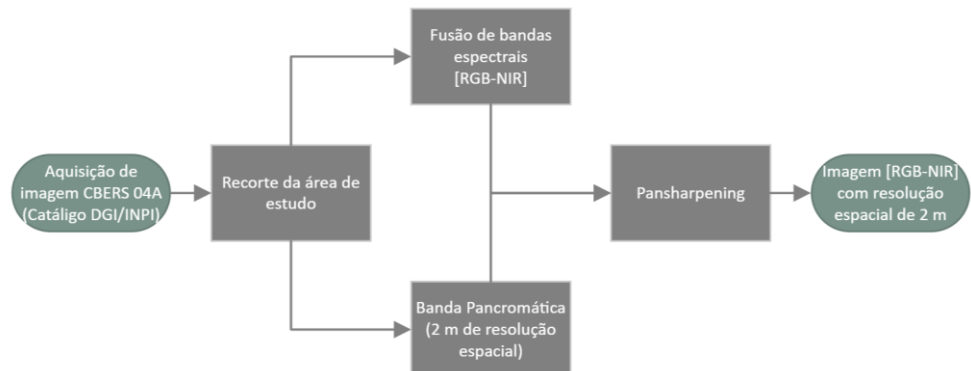


Fonte: Adaptado de DGI (2021).

As imagens orbitais brutas (nível 0, L0) apresentam distorções geométricas importantes que impossibilitam sua utilização direta para a produção de mapas acurados. Assim, deve-se realizar a correção geométrica e radiométrica das imagens, o que constitui uma etapa fundamental para a geração de dados com alta qualidade geoespacial. Por sua vez, as imagens L4 estão prontas para uso, com correção radiométrica e geométrica realizada, além da ortorretificação, o que as torna mais adequadas para o PDI (DGI, 2021). Por essas características, optou-se neste estudo por utilizar a imagem CBERS 04A em nível de processamento L4.

O pré-processamento realizado sobre a imagem CBERS 04A-WPM foi o constante da Figura 4. No QGIS, essa imagem foi reprojeta para SIRGAS 2000, Zona UTM 24S, referente à área de estudo. Após, procedeu-se ao recorte da área de estudo, seguido da fusão de bandas espectrais do azul, verde, vermelho e infravermelho próximo (RGB-NIR). Por fim, foi realizada a operação de *pansharpening*, com emprego da banda pancromática. Assim, obteve-se uma imagem de composição colorida de quatro bandas espectrais, de alta resolução espacial (2 m).

Figura 4 – Pré-processamento da imagem CBERS 04A-WPM




Fonte: Autoria própria (2024).

ANÁLISE DE IMAGEM BASEADA EM OBJETOS GEOGRÁFICOS (GEOBIA)

O fluxo de trabalho utilizado para a GEOBIA foi composto pelas seguintes fases (Figura 5): aquisição de imagem CBERS 04A-WPM; segmentação, que consistiu em segregar a imagem nos objetos que a compõem; representação e descrição, no qual foram extraídas as informações úteis dos objetos da imagem, sendo composta pelas subfases de coleta de amostras de treinamento e teste e extração de estatísticas representativas das classes; classificação, na qual os objetos foram atribuídos às suas respectivas classes; e elaboração de produtos cartográficos temáticos, que neste estudo se traduziu na elaboração de mapas de uso e cobertura do solo.

Figura 5 – Fluxo de trabalho da abordagem GEOBIA



Fonte: Autoria própria (2024).

Segmentação

Normalmente, a primeira fase da abordagem GEOBIA consiste em segmentar a imagem em objetos significativos, agrupando *pixels* com base em suas características espaciais e espectrais. Cada parte segmentada da imagem é chamada de objeto e tem tamanho, forma e localização espacial (OUMA *et al.*, 2023). Assim, o objetivo desta etapa foi o de obter regiões individualizadas que formassem uma imagem composta por áreas conectadas por bordas, sem sobreposições, por meio dos algoritmos de segmentação *Meanshift*, *SLIC* e *Watershed*.

A assertividade dos algoritmos de segmentação depende da semelhança dentro de um segmento e da diferença entre regiões adjacentes. A segmentação é frequentemente utilizada em situações em que os alvos detectados são homogêneos ou para extrair e reconhecer objetos em uma imagem. Para tanto, associa-se um grupo de *pixels* vizinhos com base em parâmetros preconcebidos, obtendo-se regiões moderadamente homogêneas (objetos de interesse) (PALANIVEL; SELVAN, 2023).

Meanshift

O *Meanshift* é um algoritmo não supervisionado usado para identificar agrupamentos (*clusters*) dentro de um conjunto de dados. Baseado no conceito de densidade, concentra-se em encontrar as regiões de alta densidade e promover ajustes iterativamente para separação de regiões, de acordo com a forma e homogeneidade dos *pixels* adjacentes. O algoritmo não requer nenhuma informação prévia sobre o número de *clusters* presentes nos dados, tornando-o particularmente útil na análise exploratória. Seus parâmetros principais são o raio espacial, raio de alcance e tamanho mínimo da região, formadores de uma função de *kernel* utilizada para agrupar *pixels* semelhantes nos domínios espacial e espectral (COMANICIU; MEER, 2002). Para a realização da segmentação *Meanshift*, foi utilizado o OTB/QGIS. Exemplos dos testes realizados para definição dos parâmetros se encontram dispostos na Tabela 3.

Tabela 3 – Segmentação *Meanshift*: testes para definição de parâmetros

SIG	Complemento	Raio espacial	Raio de alcance	Tamanho mínimo da região
QGIS	OTB	5	15	100
		1	15	100
		1	5	100
		1	5	50
		1	5	40
		1	5	30
		1	5	20
		1	3	20

Fonte: Autoria própria (2024).

O parâmetro de tamanho mínimo da região precisou ser selecionado de forma flexível, levando-se em conta os objetos constantes da cena e a resolução espacial da imagem. Conforme XUE *et al.* (2023), para áreas de estudo com objetos maiores, o seu valor deve ser aumentado adequadamente. Quando o valor desse parâmetro é reduzido, os segmentos formados serão pequenos, o que pode gerar perda de eficiência computacional pelo aumento substancial na quantidade de segmentos na cena (problema de supersegmentação). Se o seu valor for aumentado, os agrupamentos formados serão grandes, o que pode eventualmente conter diferentes objetos dentro do mesmo segmento (problema de subsegmentação).

SLIC

O Algoritmo SLIC produz *superpixels*, por meio do agrupamento de *pixels* próximos, baseado na similaridade em termos de cor e proximidade espacial. O agrupamento realizado é baseado em cinco dimensões: três de cor no espaço “Lab” e duas coordenadas espaciais (linha, coluna). O processo consiste em selecionar centros separados por uma distância regular em termos de linhas e colunas. Analisa-se a similaridade e proximidade de cada *pixel* em relação a esses centros. Quanto maior a distância adotada, menor o número de centros, e consequentemente, de segmentos gerados.

Para a realização da segmentação SLIC, foi utilizado o complemento *Terminus/QGIS*. Foram realizados um conjunto de testes para definição dos parâmetros de número de segmentos, compacidade e sigma (σ). Alguns dos parâmetros testados manualmente foram expostos na Tabela 4. O primeiro refere-se ao número aproximado de segmentos na imagem de saída. A compacidade equilibra a proximidade do espaço das cores e do espaço da imagem. Por seu turno, o sigma (σ) – largura do *kernel* de suavização do filtro Gaussiano – refere-se a um importante pré-processamento que pode ser realizado para a obtenção de melhor resultado na imagem segmentada de saída.

Tabela 4 – Segmentação SLIC: testes para definição de parâmetros

SIG	Complemento	Segmentos (n)	Compacidade	Sigma
QGIS	<i>Terminus</i>	10.000	0,01	1
		20.000	0,01	
		30.000	0,01	
		30.000	0,1	
		30.000	1	
		40.000	0,01	
		40.000	0,1	
		40.000	0,05	

Fonte: Autoria própria (2024).

Watershed

O *Watershed* é um algoritmo de delineamento de objetos em imagens, não supervisionado, baseado em bordas, que converte uma imagem em um gradiente semelhante a uma superfície do terreno e identifica a região de influência de cada mínimo local na imagem como um único objeto (YANG *et al.*, 2023). Para tanto, faz uso de dois parâmetros principais: limiar de profundidade e nível de inundação. Alguns testes manuais realizados para verificação dos parâmetros que melhor se adequassem à cena podem ser observados na Tabela 5.

Tabela 5 – Segmentação *Watershed*: testes para definição de parâmetros

SIG	Complemento	Limiar de profundidade	Nível de inundação
QGIS	OTB	0,01	0,1
		0,001	0,1
		0,005	0,1
		0,005	0,01
		0,005	0,15
		0,05	0,1
		0,001	0,2
		0,004	0,12

Fonte: Autoria própria (2024).

CLASSIFICAÇÃO

Para a classificação, após a obtenção da imagem CBERS 04A-WPM, devido pré-processamento e segmentação, foi realizada a definição de classes, por meio de análise visual dos objetos constantes da cena. Com uso dos objetos obtidos na segmentação, foram coletadas amostras representativas das classes. Algoritmos de classificação supervisionada foram aplicados sobre a imagem segmentada. Posteriormente, validados os resultados, pôde-se proceder à edição do mapa de uso e cobertura do solo e a estimação das respectivas áreas ocupadas por cada uma das classes extraídas da imagem CBERS 04A-WPM.

Definição de classes

Foram definidas oito classes (Quadro 1) por meio da análise visual dos objetos presentes na cena (THOMASBERGER *et al.*, 2023), passíveis de classificação e de interesse para a caracterização do uso e cobertura do solo, dada as especificidades da área de estudo.

Quadro 1 – Descritivo de classes utilizadas na classificação da imagem CBERS 04A-WPM

Classe	Descrição
Floresta densa	Área com alta concentração de espécies vegetais de médio e grande porte
Vegetação rasteira/pasto	Áreas abertas cobertas com vegetação gramínea; campos, gramados e pastagens
Vegetação superficial de corpo d'água	Camada de vegetação superficial sobre cursos e corpos d'água; manguezais e plantas superficiais aquíferas
Solo exposto/via não pavimentada	Região com solo descoberto; vegetação mínima ou inexistente; inclui o sistema de arruamentos sem camada superficial, de terra batida
Área construída	Estruturas artificiais; prédios, casas e estacionamentos concretados
Corpos d'água	Rios, lagos e lagoas, naturais ou artificiais
Sombra	Áreas de oclusão que impossibilitam a determinação do uso e cobertura do solo
Via pavimentada	Malha viária com camada superficial de asfalto

Fonte: Autoria própria (2024).

Amostragem

Os alvos na imagem com baixo grau de pertinência ou com características espectrais próximas a outras classes, como vegetação rasteira/pasto e vegetação superficial de corpo d'água, podem ter maior probabilidade de gerar erros na classificação, por confusão espectral. Procurou-se então encontrar descritores e parâmetros que melhorassem a diferenciação das classes. Para isso, amostras foram coletadas manualmente a fim de extrair os padrões – características espectrais, forma, textura e vizinhança – de cada um dos descritores, o que possibilitou uma melhor compreensão de cada uma das classes.

O conjunto amostral coletado foi dividido para o treinamento e validação dos classificadores: após a coleta de conjuntos no quantitativo total disposto na Tabela 6, foi realizada a repartição de 70% para o treinamento dos algoritmos e 30% para a validação (WEITKAMP; KARIMI, 2023).

Tabela 6 – Conjuntos amostrais coletados por classe e por segmentador

Classes	Treinamento (70%)			Validação (30%)		
	<i>Watershed</i>	SLIC	<i>Meanshift</i>	<i>Watershed</i>	SLIC	<i>Meanshift</i>
Floresta densa	31	31	31	13	13	13
Vegetação rasteira/pasto	31	36	32	13	16	14
Vegetação superficial de corpo d'água	32	31	31	14	13	13
Solo exposto/via não pavimentada	37	36	35	16	16	15
Área construída	31	32	32	13	14	14
Corpos d'água	34	41	33	14	18	14
Sombra	34	29	30	15	13	13
Via pavimentada	32	32	34	14	14	14
Total	262	268	258	112	117	110

Fonte: Autoria própria (2024).

Algoritmos classificadores


Com as amostras coletadas manualmente nas imagens segmentadas pelos algoritmos *Meanshift*, SLIC e *Watershed*, pôde-se treinar os algoritmos de classificação supervisionada RF, SVM e DT. Diferentes parâmetros foram testados e, com o auxílio do conjunto amostral de validação, buscou-se aqueles que melhor ajustassem o classificador aos dados da imagem CBERS 04A-WPM.

RESULTADOS E DISCUSSÕES

SEGMENTAÇÃO

Os resultados da segmentação pelo algoritmo *Watershed* podem ser observados na Figura 6. Esse algoritmo segmentador aplicado à área de estudo produziu um resultado satisfatório, baseado no ajuste manual dos parâmetros limiar de profundidade e nível de inundação. Para as combinações (0,01; 0,1), (0,001; 0,1) e (0,005; 0,1), verificou-se que os seguimentos formados, em um total de, respectivamente, 106.760, 117.864 e 114.415, possibilitaram uma segmentação razoável dos objetos da cena. Contudo, foram observados objetos compostos por apenas um ou dois *pixels*, o que indica problemas de supersegmentação. Com o ajuste dos parâmetros para (0,005; 0,01), a supersegmentação aumentou, com a formação de 239.291 segmentos. No polo inverso, os valores (0,005; 0,15), (0,05; 0,1) e (0,001; 0,2) produziram uma segmentação insuficiente, com a junção de diferentes objetos da imagem dentro de um mesmo segmento. O melhor ajuste observado foi com a combinação (0,004; 0,12), que produziu um total de 89.575 segmentos.

Figura 6 – Extrato comparativo dos resultados da segmentação *Watershed* com uso de diferentes parâmetros



Fonte: Autoria própria (2024).

Os resultados da segmentação pelo algoritmo SLIC podem ser observados na Figura 7. A segmentação SLIC para a área de estudo produziu um resultado satisfatório baseado no ajuste manual dos parâmetros número de seguimentos e compacidade. Para a escolha (10.000; 0,01), verificou-se que os seguimentos formados, em um total de 5.050, não foram suficientes para segmentar todos os objetos da cena. Com o ajuste dos parâmetros para (20.000; 0,01), o problema de segmentação insuficiente persistiu, mas pôde-se notar uma melhora na definição dos objetos, com um total de 13.569 segmentos. Mantendo-se o número de segmentos em 30.000 e compacidade 0,01, notou-se uma nova melhora na segmentação. A definição dos parâmetros em (30.000; 0,1) apresentou boa definição dos objetos na cena, o que se perde ao serem adotados os valores (30.000; 1), que já não é capaz de segmentar os objetos, formando-se quadrados sem sentido semântico para a cena. Os melhores ajustes foram obtidos com os parâmetros (40.000; 0,1) e (40.000; 0,05), com um total de, respectivamente, 34.032 e 32.903 segmentos. Os testes realizados com valores superiores a 40.000 de número de seguimentos e com compacidades variáveis não proporcionaram bons resultados.

Figura 7 – Extrato comparativo dos resultados da segmentação SLIC com uso de diferentes parâmetros



Fonte: Autoria própria (2024).

Os resultados da segmentação pelo algoritmo *Meanshift* podem ser observados na Figura 8. Esse segmentador aplicado à área de estudo produziu um resultado satisfatório baseado no ajuste manual dos parâmetros raio espacial, raio de alcance e tamanho mínimo da região. Para a combinação (5; 15; 100), verificou-se que os seguimentos formados, em um total de 6.629, não foram suficientes para segmentar todos os objetos da cena. Com o ajuste dos parâmetros para (1, 15, 100), o problema de segmentação insuficiente persistiu, com diminuição do total de segmentos para 6.475. O problema de segmentação insuficiente também afetou a combinação (1, 5, 100), que alcançou 7.150 segmentos totais. A partir da combinação (1, 5, 50), ou seja, diminuindo-se o tamanho mínimo da região para 50, houve um ganho considerável na segmentação dos objetos da cena, com um total de 14.876 segmentos. O melhor resultado foi obtido para a combinação dos parâmetros em (1, 5, 20), com 36.603 segmentos. Testes posteriores com diminuição do raio de alcance para 3 provocaram uma hipersegmentação, uma vez que houve a repartição de objetos anteriormente bem delineados.

Figura 8 – Extrato comparativo dos resultados da segmentação *Meanshift* com uso de diferentes parâmetros

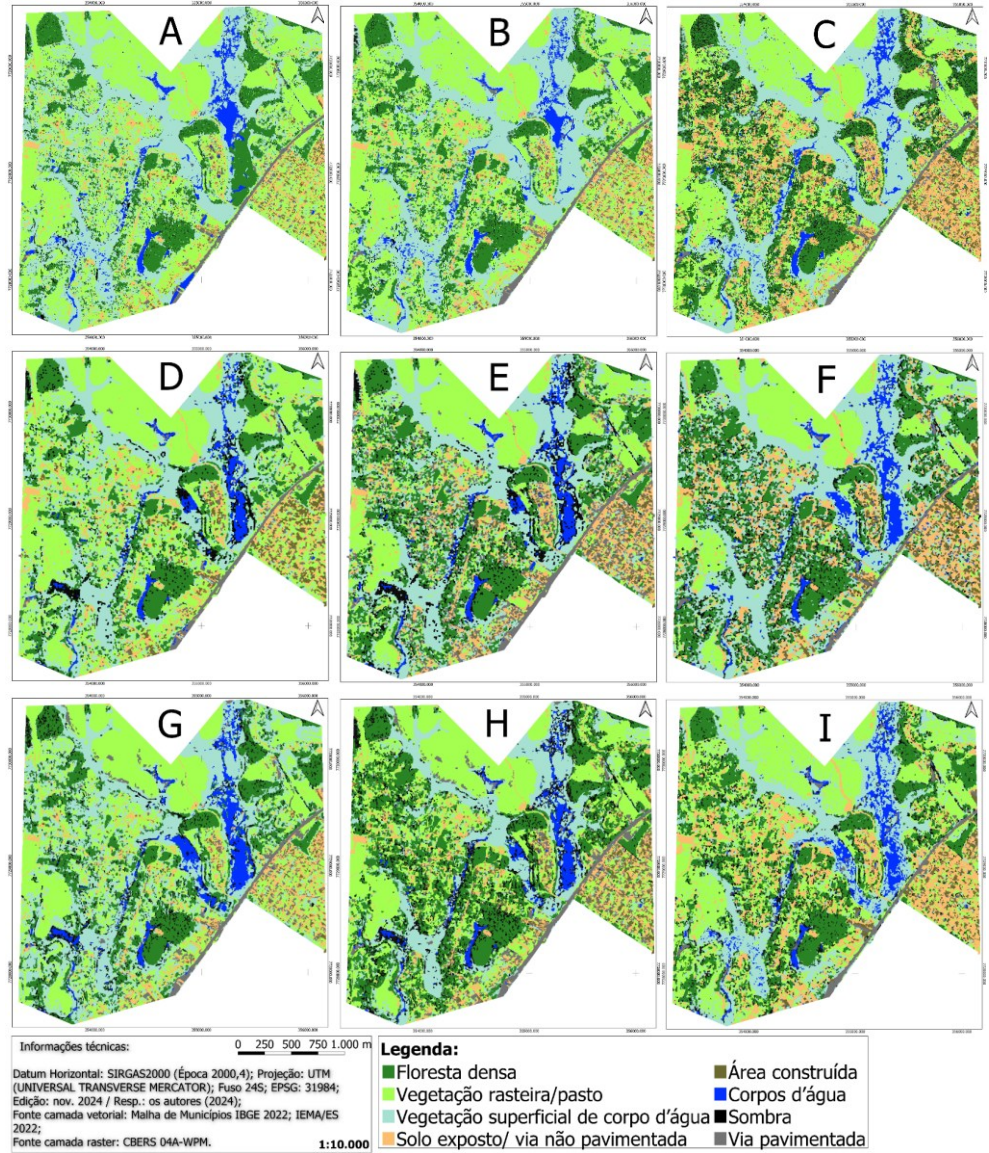


Fonte: Autoria própria (2024).

CLASSIFICAÇÃO

Com o emprego de diferentes classificadores de Aprendizado de Máquina e testes realizados com diferentes parâmetros para esses classificadores, foram selecionados os algoritmos que apresentaram os melhores resultados, para cada uma das segmentações realizadas em etapa anterior. Os algoritmos mais acurados (DT, SVM e RF) nos testes realizados tiveram seus resultados expostos na forma de mapas de uso e cobertura do solo (Figura 9).

Figura 9 – Mapas de uso e cobertura do solo: segmentação *Watershed* e classificadores DT (A), RF (B) e SVM (C); segmentação SLIC e classificadores DT (D), RF (E) e SVM (F); e segmentação *Meanshift* e classificadores DT (G), RF (H) e SVM (I)



Fonte: Autoria própria (2024).

VALIDAÇÃO

A validação dos resultados obtidos foi realizada por meio dos quatro índices de qualidade para avaliação de produtos cartográficos: exatidão global, Eq. (1), índice Kappa, Eq. (2), acurácia do produtor e do usuário, todos derivados da matriz de confusão (CONGALTON, 1991).

$$EG = \frac{\sum_{i=1}^r x_{ii}}{N} * 100 \quad (1)$$

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

sendo *EG* a exatidão global, calculada por meio da soma da diagonal da matriz de confusão (elementos corretamente classificados) sobre o total de elementos *N*, e *K* o índice Kappa, medida da concordância real dada pelo valor calculado pelos elementos diagonais da matriz de confusão, menos o produto total da linha e coluna. O valor obtido representa o total corretamente classificado na imagem. Quanto mais próximo de 1 o valor do Kappa, melhor terá sido o desempenho do classificador (CONGALTON, 2001).

As matrizes de confusão da melhor classificação obtidas pelo algoritmo RF aplicado sobre cada resultado dos segmentadores e elaboradas com auxílio do conjunto de validação podem ser conferidas no Quadro 2 (segmentador *Watershed*), Quadro 3 (segmentador SLIC) e Quadro 4 (segmentador *Meanshift*). Com base nessas matrizes de confusão e nas demais de cada um dos classificadores analisados, foram constituídas as Tabela 7 (segmentador *Watershed*), Tabela 8 (segmentador SLIC) e Tabela 9 (segmentador *Meanshift*), que trazem a acurácia do produtor e do usuário alcançadas pelos classificadores RF, SVM e DT.

Quadro 2 – Matriz de confusão para o resultado obtido da segmentador *Watershed* e classificador RF. Na coluna foram dispostas as classes previstas pelo modelo e nas linhas a verdade de campo

Classes	Floresta densa	Vegetação rasteira/pasto	Vegetação superficial de corpo d' água	Solo exposto/ via não pavimentada	Área construída	Corpos d' água	Sombra	Via pavimentada	Total
Floresta densa	13	0	0	0	0	0	0	0	13
Vegetação rasteira/pasto	0	12	0	1	0	0	0	0	13
Vegetação superficial de corpo d' água	0	0	13	0	0	1	0	0	14
Solo exposto/ via não pavimentada	0	1	0	14	1	0	0	0	16
Área construída	0	0	0	1	12	0	0	0	13
Corpos d' água	0	0	0	0	0	14	0	0	14
Sombra	0	0	0	0	0	0	15	0	15
Via pavimentada	0	0	0	0	0	0	0	14	14
Total	13	13	13	16	13	15	15	14	112

Fonte: Autoria própria (2024).

Quadro 3 – Matriz de confusão para o resultado obtido do segmentador SLIC e classificador RF. Na coluna foram dispostas as classes previstas pelo modelo e nas linhas a verdade de campo

Classes	Floresta densa	Vegetação rasteira/pasto	Vegetação superficial de corpo d' água	Solo exposto/ via não pavimentada	Área construída	Corpos d' água	Sombra	Via pavimentada	Total
Floresta densa	13	0	0	0	0	0	0	0	13
Vegetação rasteira/pasto	0	16	0	0	0	0	0	0	16
Vegetação superficial de corpo d' água	0	0	13	0	0	0	0	0	13
Solo exposto/ via não pavimentada	0	1	0	15	0	0	0	0	16
Área construída	0	0	0	2	12	0	0	0	14
Corpos d' água	0	0	0	0	0	18	0	0	18
Sombra	0	0	0	0	0	1	12	0	13
Via pavimentada	0	0	0	0	0	0	0	14	14
Total	13	17	13	17	12	19	12	14	117

Fonte: Autoria própria (2024).

Quadro 4 – Matriz de confusão para o resultado obtido do segmentador *Meanshift* e classificador RF. Na coluna foram dispostas as classes previstas pelo modelo e nas linhas a verdade de campo

Classes	Floresta densa	Vegetação rasteira/pasto	Vegetação superficial de corpo d' água	Solo exposto/ via não pavimentada	Área construída	Corpos d' água	Sombra	Via pavimentada	Total
Floresta densa	13	0	0	0	0	0	0	0	13
Vegetação rasteira/pasto	0	13	1	0	0	0	0	0	14
Vegetação superficial de corpo d' água	0	0	13	0	0	0	0	0	13
Solo exposto/ via não pavimentada	0	0	0	15	0	0	0	0	15
Área construída	0	0	0	1	13	0	0	0	14
Corpos d' água	0	0	0	0	0	13	1	0	14
Sombra	0	0	0	0	0	0	13	0	13
Via pavimentada	0	0	0	0	0	0	0	14	14
Total	13	13	14	16	13	13	14	14	110

Fonte: Autoria própria (2024).

Tabela 7 – Acurácia do produtor e do usuário por classe com emprego do segmentador *Watershed*

Classes	Acurácia do produtor (%)			Acurácia do usuário (%)		
	DT	RF	SVM	DT	RF	SVM
Floresta densa	92,86	1	92,86	1	1	1
Vegetação rasteira/pasto	86,67	92,31	86,67	1	92,31	1
Vegetação superficial de corpo d'água	1	1	93,33	85,71	92,86	1
Solo exposto/via não pavimentada	92,31	87,5	82,35	75	87,5	87,5
Área construída	85,71	92,31	1	92,31	92,31	84,61
Corpos d'água	82,35	93,33	1	1	1	92,86
Sombra	1	1	1	1	1	93,33
Via pavimentada	1	1	1	85,71	1	92,86

Fonte: Autoria própria (2024).

Tabela 8 – Acurácia do produtor e do usuário por classe com emprego do segmentador *SLIC*

Classes	Acurácia do produtor (%)			Acurácia do usuário (%)		
	DT	RF	SVM	DT	RF	SVM
Floresta densa	1	1	1	1	1	1
Vegetação rasteira/pasto	93,75	94,12	1	93,75	1	1
Vegetação superficial de corpo d'água	1	1	92,86	1	1	1
Solo exposto/via não pavimentada	83,33	88,23	84,21	93,75	93,75	1
Área construída	1	1	1	85,71	85,71	78,57
Corpos d'água	94,44	94,74	1	94,44	1	88,88
Sombra	1	1	1	92,31	92,31	1
Via pavimentada	93,33	1	93,33	1	1	1

Fonte: Autoria própria (2024).

Tabela 9 – Acurácia do produtor e do usuário por classe com emprego do segmentador *Meanshift*

Classes	Acurácia do produtor (%)			Acurácia do usuário (%)		
	DT	RF	SVM	DT	RF	SVM
Floresta densa	1	1	86,67	1	1	1
Vegetação rasteira/pasto	1	1	1	78,57	92,86	85,71
Vegetação superficial de corpo d'água	81,25	92,86	92,86	1	1	1
Solo exposto/via não pavimentada	1	93,75	88,23	1	1	1
Área construída	1	1	1	1	92,86	85,71
Corpos d'água	1	1	1	85,71	92,86	85,71
Sombra	86,67	92,86	92,85	1	1	1
Via pavimentada	1	1	1	1	1	1

Fonte: Autoria própria (2024).

Na Tabela 10 foram dispostas a exatidão global e o índice Kappa para cada um dos conjuntos de segmentadores e classificadores empregados. Como se pode verificar, o segmentador *Meanshift*, em combinação com o classificador RF, obteve o resultado mais acurado dentre todos os demais testados: exatidão global igual a 97,27% e índice Kappa igual a 96,88%. Não obstante, verifica-se que, pelo índice Kappa, todos os resultados obtidos são ditos “quase perfeitos”, quando observada a classificação preconizada por Landis e Koch (1977), disposta no Quadro 5, que descreve o grau de concordância para cada intervalo do índice Kappa.

Tabela 10 – Exatidão global e índice Kappa para os classificadores DT, SVM e RF

Segmentador	Algoritmo classificador	Exatidão global (%)	Índice Kappa (%)
<i>Watershed</i>	DT	91,96	90,81
	SVM	93,75	92,85
	RF	95,53	94,89
SLIC	DT	94,87	94,12
	SVM	95,73	95,11
	RF	96,58	96,08
<i>Meanshift</i>	DT	95,45	94,81
	SVM	94,54	93,76
	RF	97,27	96,88

Fonte: Autoria própria (2024).

Quadro 5 – Força da classificação conforme índice Kappa

Índice Kappa (K)	Grau de concordância
Menor que 0	Pobre
$0 < \kappa \leq 0,2$	Fraca
$0,2 < \kappa \leq 0,4$	Justa
$0,4 < \kappa \leq 0,6$	Moderada
$0,6 < \kappa \leq 0,8$	Sólida
$0,8 < \kappa \leq 1$	Quase perfeita

Fonte: Adaptado de Landis e Koch (1977).

USO E COBERTURA DO SOLO

Das métricas de qualidade dos mapas de uso e cobertura elaborados, verificou-se que o mapa que obteve os melhores índices de EG, índice Kappa, acurácia do produtor e do usuário foi o derivado da combinação do segmentador *Meanshift* e classificador RF. Por meio desse mapa, foram calculadas as áreas ocupadas pelas classes e a área ocupada em relação à área de estudo total (6,78 km²). Os resultados foram dispostos na Tabela 11.


Tabela 11 – Área ocupada pelas classes de uso e cobertura do solo na porção norte da APA de Setiba, Guarapari-ES, conforme mapa de uso e cobertura do solo obtido pelo emprego do segmentador *Meanshift* e classificador RF

Classe	Área total (km ²)	Área relativa (%)
Floresta densa	1,561	23,03
Vegetação rasteira/pasto	2,1	30,99
Vegetação superficial de corpo d'água	1,32	19,48
Solo exposto/ via não pavimentada	0,44	6,49
Área construída	0,153	2,26
Corpos d'água	0,201	2,97
Sombra	0,616	9,09
Via pavimentada	0,386	5,69
Total	6,78	100

Fonte: Autoria própria (2024).

Como pode-se verificar, a maior área da porção norte da APA de Setiba está ocupada pela classe vegetação rasteira/pasto (aproximadamente 31% da área total). As classes solo exposto/via não pavimentada, área construída e via pavimentada somadas ocupam uma área relativa de quase 15%. Assim, verificou-se que 45,43% da área total analisada sofreu perdas de áreas naturais por antropização. Houve uma incerteza devido à classe sombra, que ocupou 9,09% da área total, gerada pela geometria do sensor e posição do Sol no momento da tomada da imagem, o qual impossibilitou a correta classificação das classes sombreadas. As classes naturais, do tipo floresta densa, vegetação superficial de corpo d'água e corpos d'água ocupam uma área de cerca de 45,48%. Essa distribuição pode ser visualizada na Figura 10.

Figura 10 – Áreas naturais e antrópicas calculadas para a área de estudo



Fonte: Autoria própria (2024).

ANÁLISE DOS RESULTADOS

A incorporação de regras cada vez mais intrincadas, utilização de uma variedade de fontes de dados, combinação de parâmetros espectrais e espaciais e inclusão de informações topológicas e contextuais resultam em uma maior dependência da análise supervisionada com uso de algoritmos de Aprendizado de Máquina. Conforme observado nos resultados obtidos com a segmentação e classificação da imagem CBERS 04A-WPM, o método utilizado não está livre de erros, contudo permitiu extrair as classes de uso e cobertura do solo presentes da cena com alta exatidão global e índice Kappa (ambos acima de 90%).

Os resultados obtidos com a GEOBIA foram promissores, apesar de que ajustes na abordagem ainda precisam ser realizados. Por exemplo, os valores de parâmetros para diferentes algoritmos segmentadores não possuem um melhor valor para qualquer tipo de imagem de entrada, tendo o analista que executar testes para a descoberta de quais parâmetros utilizar. Isso certamente adiciona subjetividade ao processo, por depender do conhecimento e habilidades do analista na correta escolha dos parâmetros que, em seu entendimento, conduzam o algoritmo a obter melhores resultados. Assim, embora permita uma maior flexibilidade, com incorporação do conhecimento do analista ao processo, também pode introduzir pontos de falha.

No geral, os algoritmos segmentadores empregados obtiveram resultados condizentes quando realizados ajustes e testes manuais para otimização dos parâmetros. Não obstante, houve uma importante supersegmentação e subsegmentação em algumas áreas da imagem segmentada ao se aplicar algoritmos de segmentação disponíveis nos complementos OTB e *Terminus* do QGIS. O erro de supersegmentação significa que um segmento é menor do que o objeto geográfico correspondente, enquanto a subsegmentação ocorre quando os objetos adjacentes são combinados como um único objeto, levando a um erro difícil de reverter na etapa de classificação. Os problemas de segmentação observados influem na qualidade do método adotado, uma vez que a GEOBIA possui grande dependência da qualidade da segmentação.

Embora exista muitos algoritmos e novos desenvolvimentos voltados para a segmentação de imagens de SR, ainda se mostra um desafio obter de forma confiável resultados de segmentação sem erros para imagens de SR. Por exemplo, parâmetros inadequados podem levar a erros de segmentação. Outro ponto para possíveis falhas está na classificação supervisionada com uso de algoritmos de Aprendizado de Máquina, uma vez que o resultado depende da experiência e habilidade do analista, o que torna a subjetividade inevitável.

Quanto às vantagens da GEOBIA observadas neste estudo estão a alta acurácia obtida com o emprego dessa abordagem e a capacidade de extrair informações em nível de objetos geográficos, e não apenas sobre *pixels*, utilizando-se de informação espectral e não espectral – textura, forma, contexto e relações de proximidade.

CONSIDERAÇÕES FINAIS

De um modo geral foi possível obter resultados satisfatórios que demonstraram o potencial da GEOBIA para a caracterização do uso e cobertura do solo com emprego de imagens CBERS 04A-WPM. Por meio dessa abordagem, que utiliza outras informações além das espectrais, pôde-se verificar que os objetos constantes da imagem puderam ser extraídos com alta acurácia, apesar da imagem utilizada não possuir uma alta resolução espectral, com apenas quatro bandas disponíveis para análise (RGB-NIR).

O método empregado se mostrou robusto o suficiente para determinar e quantificar o uso e cobertura do solo em recorte da APA de Setiba, com a utilização de técnicas de PDI, imagem de SR e o *software* livre QGIS. Essa abordagem permitiu a obtenção de mapas de uso e cobertura do solo detalhado, em escala 1:10.000, com uma acurácia de classificação aceitável – acima de 90% para os algoritmos classificadores DT, SVM e RF.

Como limitações ao estudo, cita-se a média resolução espectral do sensor WPM/CBERS 04A, com quatro bandas disponíveis para diferenciação dos alvos. A imagem desse sensor permitiu diferenciar a maior parte dos alvos da cena, mas algumas classes de assinatura espectral próximas nas bandas disponíveis apresentaram confusão espectral. A utilização de imagens do satélite Landsat 8 (30 m de resolução espacial), sensor OLI, ou do satélite Sentinel (10 m) podem oferecer a resposta para essa limitação, contudo com sacrifício da alta resolução espacial de imagens CBERS 04A-WPM (2 m), o que pode não ser uma alternativa válida ao se trabalhar com escalas cadastrais (1:10.000 ou superiores).

Para trabalhos futuros, recomenda-se que sejam testadas outras áreas de estudo empregando-se o método deste estudo, para fins de comparação com os resultados obtidos. Também, a realização de um novo estudo na área de recorte em períodos futuros pode ajudar a estabelecer as mudanças ocorridas no uso e cobertura do solo na APA de Setiba, o que poderia contribuir para um maior controle, por parte das autoridades competentes, na gestão dos recursos naturais e para a implementação de novas políticas públicas voltadas ao desenvolvimento sustentável da região.

Analysis of image segmentation algorithms and artificial intelligence in the characterization of land use and cover

ABSTRACT

Land use and cover refers to the areas managed by humans (use) and the layers on the surface of the ground (cover), such as forests, bodies of water and built-up areas. Understanding it is fundamental to sustainable development and the management of natural resources, which has a direct impact on the well-being of communities. Analysis of land use and cover is an indicator of sustainability and allows regular monitoring and assessment of changes over time. To this end, segmentation and classification techniques can be used on Remote Sensing (RS) images using Geographic Information Systems (GIS) and Digital Image Processing. This makes it possible to estimate land use and land cover with high accuracy, as demonstrated in this study in a section of the Setiba Environmental Protection Area, Guarapari-ES. To achieve this goal, Geographic Object-Based Image Analysis (GEOBIA) was carried out, in which segmentation algorithms (Meanshift, SLIC and Watershed) and Machine Learning algorithms (Random Forests, Support Vector Machines and Decision Trees) were tested for supervised classification. These algorithms were applied to a composite band image from CBERS 04A, sensor WPM, with a spatial resolution of 2 m. As a result, land use and land cover maps were obtained with global accuracy and a Kappa index of over 90%, which allowed us to infer that the method adopted was sufficiently robust to overcome the challenges inherent in image classification applied to the characterization of land use and land cover.

KEYWORDS: GEOBIA. Classification. Machine Learning. Digital Image Processing.

REFERÊNCIAS

ABERA, T.; HEISKANEN, J.; MAEDA, E.; ODONGO, V.; PELLIKKA, P. Impacts of land cover and management change on top-of-canopy and below-canopy temperatures in Southeastern Kenya. **Science of The Total Environment**, v. 874, ISSN 0048-9697, 2023. DOI. <https://doi.org/10.1016/j.scitotenv.2023.162560>.

ARYAL, J.; SITAULA, C.; FRERY, A. C. Land use and land cover (LULC) performance modeling using machine learning algorithms: a case study of the city of Melbourne, Australia. **Sci Rep**, v. 13, 13510, 2023. DOI. <https://doi-org.ez22.periodicos.capes.gov.br/10.1038/s41598-023-40564-0>.

BISWAS, J.; JOBAER, M. A.; HAQUE, S. F.; SHOZIB, M. S. I.; LIMO, Z. A. Mapping and monitoring land use land cover dynamics employing Google Earth Engine and machine learning algorithms on Chattogram, Bangladesh. **Heliyon**, v. 9, n. 11, ISSN 2405-8440, 2023. DOI. <https://doi.org/10.1016/j.heliyon.2023.e21245>.

COMANICIU, D.; MEER, P. Mean shift: a robust approach toward feature space analysis. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 24, n. 5, p. 603-619, 2002. DOI. [10.1109/34.1000236](https://doi.org/10.1109/34.1000236).

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sens. Environ.**, v. 37, p. 35-46, 1991. DOI. [https://doi.org/10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B).

CONGALTON, R. G. Accuracy assessment and validation of remotely sensed and other spatial information. *Int. J. Wildland Fire*, v. 10, p. 321-328, 2001. DOI. <https://doi.org/10.1071/WF01031>.

DAL'ASTA, A. P.; NAMIKAWA, L. M.; CORTES, J. P. S.; SILVA, D. F. Caracterização de comunidades quilombolas em Oriximiná (Pará) com imagens CBERS 04A e Planet Scope. In: ANAIS do XX Simpósio brasileiro de Sensoriamento Remoto, 2023, Florianópolis. **Anais eletrônicos...** São José dos Campos, INPE, v. 20, 2023. Disponível em: <https://proceedings.science/sbsr-2023/trabalhos/caracterizacao-de-comunidades-quilombolas-em-oriximina-para-com-imagens-cbers-4a?lang=pt-br>. Acesso em: 03 nov. 2023.

DIVISÃO DE GERAÇÃO DE IMAGENS (DGI). Instituto Nacional de Pesquisas Espaciais. Governo federal. Brasil. **Níveis de processamento das imagens dos satélites CBERS e Amazônia**. 2021. Disponível em: http://www.dgi.inpe.br/documentacao/arquivos/NiveisdeProcessamentoCBERSA_MZ.pdf. Acesso em: 05 nov. 2023.

DIVISÃO DE GERAÇÃO DE IMAGENS (DGI). Instituto Nacional de Pesquisas Espaciais. Brasil. **Catálogo de imagens CBERS 04A**. 2024. Disponível em: <http://www.dgi.inpe.br/catalogo/explore>. Acesso em: 10 jan. 2024.

DUMDUMAYA, C. E.; CABRERA, J. S. Determination of future land use changes using remote sensing imagery and artificial neural network algorithm: A case study of Davao City, Philippines. **Artificial Intelligence in Geosciences**, ISSN 2666-5441, v. 4, p. 111-118, 2023. DOI. <https://doi.org/10.1016/j.aiig.2023.08.002>.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). Governo Federal. Brasil. **CBERS 04A: Especificações Técnicas**. 2019. Disponível em: <http://www.cbbers.inpe.br/sobre/cbbers04a.php>. Acesso em: 05 nov. 2023.

JAYABASKARAN, M.; DAS, B. Land Use Land Cover (LULC) Dynamics by CA-ANN and CA-Markov Model Approaches: A Case Study of Ranipet Town, India. **Nature Environment and Pollution Technology**, v. 22, n. 3, p. 1251-1265, 2023. DOI. <https://doi.org/10.46488/NEPT.2023.v22i03.013>.

LANDIS, J. R.; KOCH, G. G. An application of hierarchical kappa-type statistics in the assessment of majority agreement among multiple observers. **Biometrics**, v. 33, n. 2, p. 363-374, 1977. DOI. <https://doi.org/10.2307/2529786>.

LOU, P.; WU, T.; CHEN, J.; FU, B.; ZHU, X.; CHEN, J.; WU, X.; YANG, S.; LI, R.; LIN, X.; SHANG, C.; WEN, A.; WANG, D.; LA, Y.; MA, X. Recognition of Thaw Slumps Based on Machine Learning and UAVs: A Case Study in the Qilian Mountains, Northeastern Qinghai-Tibet Plateau. **International Journal of Applied Earth Observation and Geoinformation**, v. 116, 2023. DOI. <https://doi.org.ez22.periodicos.capes.gov.br/10.1016/j.jag.2022.103163>.

MA, H.; ZHAO, W.; LI, F.; YAN, H.; LIU, Y. Study on Remote Sensing Image Classification of Oasis Area Based on ENVI Deep Learning. **Polish Journal of Environmental Studies**, v. 32, n. 3, p. 2231-2242, 2023. DOI. [10.15244/pjoes/160190](https://doi.org/10.15244/pjoes/160190).

MUMTAZ, F.; LI, J.; LIU, Q.; ARSHAD, A.; DONG, Y.; LIU, C.; ZHAO, J.; BASHIR, B.; GU, C.; WANG, X.; ZHANG, H. Spatio-temporal dynamics of land use transitions associated with human activities over Eurasian Steppe: Evidence from improved residual analysis. **Science of The Total Environment**, v. 905, 166940, ISSN 0048-9697, 2023. DOI. <https://doi.org/10.1016/j.scitotenv.2023.166940>.

NININHAZWE, F.; THÉAU, J.; ANTOINE, G. M.; VARIN, M. Mapping invasive alien plant species with very high spatial resolution and multi-date satellite imagery using object-based and machine learning techniques: A comparative study.

GIScience & Remote Sensing, v. 60, n. 1, 2023. DOI. 10.1080/15481603.2023.2190203.

OUMA, Y. O.; KEITSILE, A.; NKWAE, B.; ODIRILE, P.; MOALAFHI, D.; QI, J. Urban land-use classification using machine learning classifiers: comparative evaluation and post-classification multi-feature fusion approach. **European Journal of Remote Sensing**, [S. l.], v. 56, n. 1, 2173659, 2023. DOI. 10.1080/22797254.2023.2173659.

PALANIVEL, E.; SELVAN, S. Integrated mixture model and ensemble learning geographic object-based image analysis for road network extraction. **Journal of Spatial Science**, 2023. DOI. 10.1080/14498596.2023.2217787.

SADEGHI, S. H.; CHAMANI, R.; SILABI, M. Z.; TAVOSI, M.; KATEBIKORD, A.; DARVISHAN, A. K.; MOOSAVI, V.; SADEGHI, P. S.; VAFAKHAH, M.; REKABDARKOLAEI, H. M. Watershed health and ecological security zoning throughout Iran. **Science of The Total Environment**, v. 905, 167123, ISSN 0048-9697, 2023. DOI. <https://doi.org/10.1016/j.scitotenv.2023.167123>.

SANTOS, B. D.; PINHO, C. M. D.; PÁEZ, A.; AMARAL, S. Identifying Urban and Socio-Environmental Patterns of Brazilian Amazonian Cities by Remote Sensing and Machine Learning. **Remote Sens.**, v. 15, n. 12, 3102, 2023. DOI. <https://doi.org/10.3390/rs15123102>.

SANTOS, G. G.; NERIS, J. P. F.; COELHO, R. F. R. Avaliação das mudanças espaço-temporal e social no uso da terra no PAE Ilha Mamangal, baixo Tocantins, município de Igarapé-Miri entre os anos de 1990 e 2022. **Caderno de Geografia**, [S. l.], v. 33, n. 74, ISSN 2318-2962, 2023. DOI. 10.5752/p.2318-2962.2023v33n74p830.

THOMASBERGER, A.; NIELSEN, M. M.; FLINDT, M. R.; PAWAR, S.; SVANE, N. Comparative Assessment of Five Machine Learning Algorithms for Supervised Object-Based Classification of Submerged Seagrass Beds Using High-Resolution UAS Imagery. **Remote Sens.**, v. 15, 3600, 2023. DOI. <https://doi.org/10.3390/rs15143600>.

WANG, H.; LIU, Y.; WANG, Y.; YAO, Y.; WANG, C. Land cover change in global drylands: A review. **Science of The Total Environment**, v. 863, 160943, ISSN 0048-9697, 2023. DOI. <https://doi.org/10.1016/j.scitotenv.2022.160943>.

WEITKAMP, T.; KARIMI, P. Evaluating the Effect of Training Data Size and Composition on the Accuracy of Smallholder Irrigated Agriculture Mapping in Mozambique Using Remote Sensing and Machine Learning Algorithms. **Remote Sens.**, [S. l.], v. 15, n. 12, 2023. DOI. <https://doi.org/10.3390/rs15123017>.

YANG, K.; YE, Z.; LIU, H.; SU, X.; YU, C.; ZHANG, H.; LAI, R. A new framework for GEOBIA: accurate individual plant extraction and detection using high-resolution RGB data from UAVs. **International Journal of Digital Earth**, v. 16, n. 1, p. 2599-2622, 2023. DOI. 10.1080/17538947.2023.2233484.

XUE, H.; XU, X.; ZHU, Q.; YANG, G.; LONG, H.; LI, H.; YANG, X.; ZHANG, J.; YANG, Y.; XU, S.; YANG, M.; LI, Y. Object-Oriented Crop Classification Using Time Series Sentinel Images from Google Earth Engine. **Remote Sens.**, v. 15, 1353, 2023. DOI. <https://doi.org/10.3390/rs15051353>.

Recebido: 18 set. 2024

Aprovado: 08 nov. 2024

DOI: 10.3895/rbgeo.v13n1.19131

Como citar: DALMONECH, R. F.; SILVA, T. A.; MOREIRA, D. C. B.; PASSOS, J. B.; SILVANO, T. P. Análise de algoritmos de segmentação de imagens e de Inteligência Artificial na caracterização do uso e cobertura do solo. **R. bras. Geom.**, Curitiba, v. 13, n. 1, p. 025-051, jan./jun. 2025. Disponível em: <<https://periodicos.utfpr.edu.br/rbgeo>>. Acesso em: XXX.

Correspondência:

Renan Fabres Dalmonech

Rua Goiânia, 1253, CEP 82940-150, Curitiba, Paraná, Brasil.

Direito autoral: Este artigo está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.

