



ISSN: 2447-3359

REVISTA DE GEOCIÊNCIAS DO NORDESTE

*Northeast Geosciences Journal*

v. 10, n° 1 (2024)

<https://doi.org/10.21680/2447-3359.2024v10n1ID33713>



## Comparação entre abordagens orientada a objetos geográficos e pixel a pixel para classificação supervisionada de imagens MSI / Sentinel-2

### *Comparison between approaches to geographic objects and per pixel for supervised classification of MSI / Sentinel-2 imagery*

Danrlei De Conto<sup>1</sup>; Nilzo Ivo Ladwig<sup>2</sup>; Juliana Debiasi Menegasso<sup>3</sup>; Thaise Sutil<sup>4</sup>

<sup>1</sup> Geoprosul Engenharia e Geoprocessamento, Criciúma/SC, Brasil. Email: danrleideconto@hotmail.com

ORCID: <https://orcid.org/0000-0002-1256-4263>

<sup>2</sup> Universidade Federal de Santa Catarina, Programa de Pós-Graduação em Geografia, Florianópolis/SC, Brasil. Email: ladwignilzo11@gmail.com

ORCID: <https://orcid.org/0000-0003-3031-0192>

<sup>3</sup> Universidade do Extremo Sul Catarinense - UNESC, Criciúma/SC, Brasil. Email: julianaorleans@gmail.com

ORCID: <https://orcid.org/0000-0002-2442-6028>

<sup>4</sup> Universidade do Extremo Sul Catarinense - UNESC, Criciúma/SC, Brasil. Email: thaise.sutil@gmail.com

ORCID: <https://orcid.org/0000-0001-5766-4260>

**Resumo:** As técnicas convencionais de classificação de imagens orbitais por pixel concentram-se apenas nos atributos espectrais da imagem. Por outro lado, os classificadores baseados em objetos geográficos (GEOBIA) vão além, considerando não apenas os atributos espectrais, mas também características como forma, tamanho, textura e distribuição espacial. Nesse contexto, este estudo tem como objetivo comparar os métodos GEOBIA e Pixel a Pixel para a classificação supervisionada de uso e cobertura da Terra utilizando imagens de alta resolução. A pesquisa foi conduzida em uma área de 72 km<sup>2</sup> da cena 22JFP capturada pelo satélite Sentinel-2. No método GEOBIA, as etapas incluíram segmentação de imagens, extração de atributos e classificação supervisionada utilizando o algoritmo C4.5. Enquanto isso, na abordagem por pixel, foi empregado o algoritmo de máxima verossimilhança (MAXVER). Os resultados indicam que a classificação por GEOBIA demonstrou índices de concordância (como Exatidão Global, Kappa e Kappa condicional) superiores em comparação com a classificação Pixel a Pixel. Além disso, a abordagem GEOBIA alcançou maior precisão do produtor para classes como massa de água, rejeito mineral, solo exposto e sombra. Na avaliação da precisão do usuário, a metodologia GEOBIA também mostrou resultados superiores para áreas urbanizadas, sombras e vegetação rasteira.

**Palavras-chave:** Sensoriamento Remoto; Uso da Terra; Exatidão Global.

**Abstract:** Conventional per-pixel orbital image classification techniques focus only on the spectral features of the image. On the other hand, Geographic Object-Based Image Analysis (GEOBIA) classifiers go further, considering not only spectral features but also characteristics such as shape, size, texture, and spatial distribution. In this context, this study aimed to compare the GEOBIA and per-pixel methods for the supervised classification of land use and cover using high-resolution images. The research was conducted in an area of 72 km<sup>2</sup> of scene 22JFP captured by the Sentinel-2 satellite. In the GEOBIA method, the steps included image segmentation, feature extraction, and supervised classification using the C4.5 algorithm. In turn, the maximum likelihood algorithm (MAXVER) was employed in the per-pixel approach. The results indicate that the classification using GEOBIA demonstrated higher agreement indices (e.g., Overall Accuracy, Kappa, and Conditional Kappa) than the per-pixel classification. Moreover, the GEOBIA approach achieved higher producer accuracy for classes such as water bodies, mineral waste, bare soil, and shade. In assessing user accuracy, the GEOBIA methodology also showed superior results for urbanized areas, shade, and ground vegetation.

**Keywords:** Remote Sensing; Land Use; Overall Accuracy.

Recebido: 25/08/2023; Aceito: 10/04/2024; Publicado: 24/05/2024.

## 1. Introdução

Existe uma grande demanda por mapas temáticos produzidos por meio de classificação de imagens, sendo assim, realizar uma análise comparativa entre métodos de classificação torna-se importante em diversos estudos de gestão de recursos naturais (PINHO *et al.*, 2005; GAO, 2008; BHASKARAN *et al.*, 2010; JEBUR *et al.*, 2013; TEHRANY *et al.*, 2013; COHENCA; CARVALHO, 2015; CHAOFAN *et al.*, 2016; PRUDENTE *et al.*, 2017).

A aquisição de dados espaciais se tornou relativamente mais fácil com a ajuda da tecnologia de sensoriamento remoto, que ganhou ampla aceitação como uma fonte confiável de informação (BHASKARAN *et al.*, 2010). Os dados orbitais de sensoriamento remoto representam uma ferramenta confiável para mapear a dinâmica de uso e cobertura da Terra em larga escala, em diferentes resoluções (PRUDENTE *et al.*, 2017).

Segundo Meneses e Sano (2014), os métodos de classificação de imagens podem ser divididos conforme alguns critérios: paramétricos ou não paramétricos, espectrais ou espaciais e supervisionados ou não supervisionados. São, ainda, agrupados em classificadores por pixel ou por objetos (regiões).

Em sua maioria os classificadores efetuam a classificação por pixels, considerando apenas propriedades espectrais dos pixels e usando medidas de distâncias ou probabilidade para encontrar regiões homogêneas pertencentes a classes específicas (MENESES; SANO, 2014). Já os classificadores por regiões consideram também atributos texturais, tornando o processo de classificação mais similar à análise feita por intérpretes humanos, resultando em coeficientes de exatidão mais elevados (BRITES *et al.*, 2014).

Entre 1980 e 1990 boa parte das análises de imagens de satélite era baseada em algoritmos estatísticos por pixel, desde então um dos algoritmos mais utilizados para classificação com base em pixels é o de Máxima Verossimilhança (MAXVER) (PRUDENTE *et al.*, 2017). Entretanto, ao longo dos anos as resoluções espectrais, espaciais e temporais das imagens passaram por um processo de evolução, facilitando a acessibilidade às imagens orbitais com maiores resoluções. Neste sentido, foi necessário buscar novas metodologias e técnicas que ultrapassassem a análise Pixel a Pixel. Uma das abordagens, que surgiu nesse processo, foi a análise de imagens orientada a objetos geográficos, conhecida como GEOBIA ou ainda OBIA (MORAES, 2018).

A classificação de imagens usando método GEOBIA recebeu considerável atenção nos últimos anos para interpretar imagens de sensoriamento remoto. A GEOBIA se assemelha com a combinação olho-cérebro humano, utilizando para a análise atributos como tamanho, textura, forma e ocorrência dos objetos além das informações espectrais (ADDINK *et al.*, 2012).

Além das diversas abordagens que tem surgido, vale ressaltar que novas séries de satélites, que disponibilizam imagens gratuitas com características distintas, têm sido lançadas nos últimos anos, um exemplo é a série Sentinel. A missão Sentinel-2 visa monitorar a variabilidade nas condições da superfície terrestre por meio de sua ampla faixa de imageamento e alta capacidade de revisita. O projeto Sentinel-2 tem como objetivos adquirir sistematicamente imagens multiespectrais de alta resolução com alta frequência de revisita, dar continuidade a séries de imagens multiespectrais de séries de satélites como SPOT e LANDSAT e fornecer dados de observação para a próxima geração de produtos operacionais, como mapas de cobertura da Terra, mapas de mudanças e variáveis geofísicas (ESA, 2014).

Desta forma, o objetivo deste trabalho foi realizar uma comparação entre as abordagens GEOBIA e Pixel a Pixel para classificação supervisionada de uso e cobertura da Terra com imagens de alta resolução.

## 2. Metodologia

### 2.1 Localização e caracterização da área de estudo

A área de estudo está localizada na região Sul do estado de Santa Catarina, Brasil, abrangendo parte dos municípios de Criciúma e Forquilha (Figura 1). A área é delimitada pelas latitudes 28°39'55,03" e 28°44'50,85" Sul e pelas longitudes 49°26'40,20" e 49°21'41,01" Oeste, e possui 7200 hectares de extensão. A escolha da área baseou-se na multiplicidade de classes de uso e cobertura da Terra identificadas.

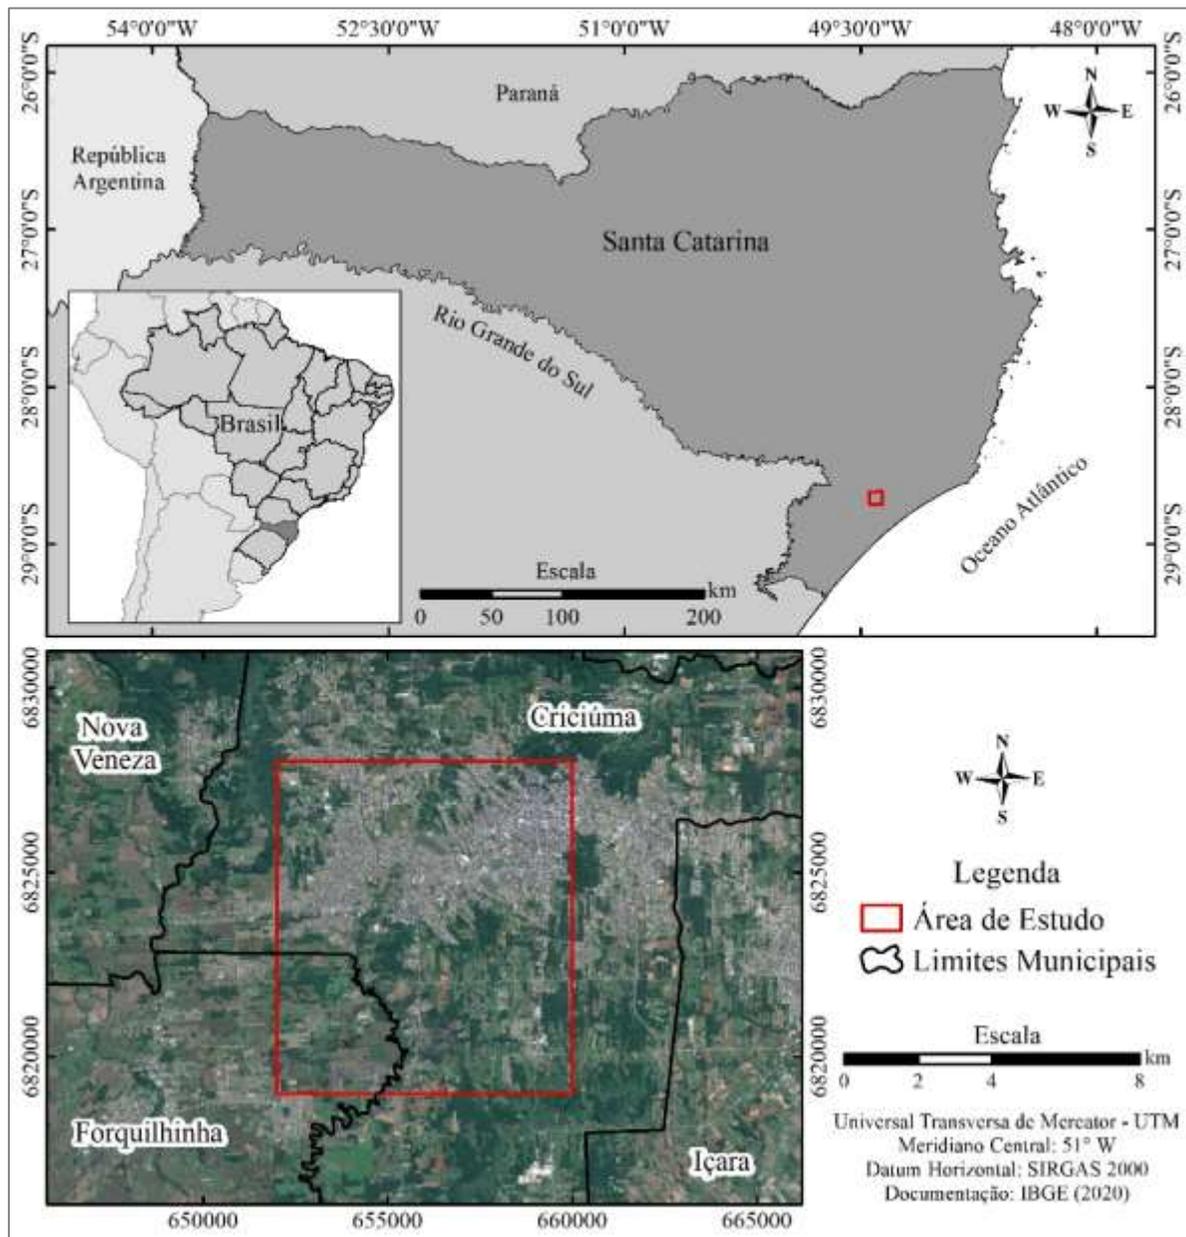


Figura 1 – Localização da área de estudo  
 Fonte: Autores (2019).

A metodologia adotada neste estudo segue o fluxograma apresentado na Figura 2. Os processos de seleção de dados, pré-processamento das imagens e análise da acurácia temática foram os mesmos para os métodos de abordagem orientada ao objeto e abordagem pixel a pixel, utilizados para classificar o uso e a cobertura da Terra na análise comparativa.

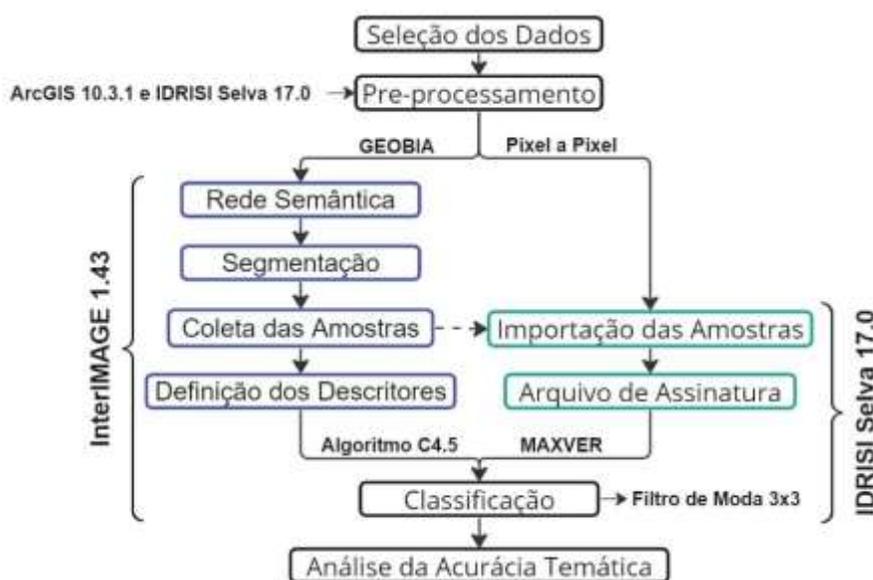


Figura 2 – Fluxograma de trabalho  
 Fonte: Autores (2019).

## 2.2 Materiais utilizados

Para realização do estudo foram utilizadas as bandas do satélite Sentinel-2B, cena 22JFP, capturadas pelo sensor MSI com resolução espacial de 10 m e 20 m, num total de 10 bandas. Detalhes sobre parâmetros de resolução das imagens utilizadas podem ser verificados na Tabela 1. As imagens do dia 30/04/2019 não apresentam cobertura de nuvens e foram adquiridas gratuitamente no site Earth Explorer do USGS (United States Geological Survey).

Tabela 1 – Especificações técnicas das bandas do sensor MSI utilizadas

Nº da banda	Banda	Comprimento de onda central (nm)	Largura de banda (nm)	Resolução espacial (m)	Resolução radiométrica
2	Blue	492,1	66	10	12 bits
3	Green	559,0	36	10	
4	Red	664,9	31	10	
5	Red Edge 1	703,8	16	20	
6	Red Edge 2	739,1	15	20	
7	Red Edge 3	779,7	20	20	
8	NIR	832,9	106	10	
8a	Red Edge 4	864,0	22	20	
11	SWIR 1	1610,4	94	20	
12	SWIR 2	2185,7	185	20	

Fonte: Adaptado de ESA (2014).

Foram necessários softwares para a execução das etapas de pré-processamento, processamento e pós-processamento. O software ArcGIS versão 10.3.1 para delimitação da área de estudo, recorte e composição das imagens, procedimento de avaliação da acurácia temática e cartografia temática. O InterIMAGE versão 1.43 foi utilizado para a realização das etapas de classificação orientada a objetos. Já o software IDRISI Selva versão 17.0, foi empregado para realizar o melhoramento

de contraste das imagens e para a classificação Pixel a Pixel. Os softwares ArcGIS e IDRISI Selva utilizados são licenciados pela Universidade do Extremo Sul Catarinense, já o InterIMAGE é uma plataforma livre de código aberto.

Para potencializar a análise das imagens de sensoriamento remoto foram realizadas operações de pré-processamento como: conversão do formato JPEG2000 para GeoTIFF; recorte da área de estudo; padronização da resolução espacial, reamostragem das bandas com resolução espacial de 10 metros para 20 metros; melhoramento de contraste e composição das 10 bandas em uma única imagem.

Por meio de análise visual das imagens e do conhecimento prévio da área de interesse, e dada a resolução das imagens, foram definidas as classes de uso e cobertura da Terra a serem mapeadas, sendo elas: área urbanizada, massa de água, rejeito mineral, solo exposto, sombra, vegetação arbórea e vegetação rasteira.

### 2.3 Abordagem análise de Imagens Orientada a Objetos Geográficos

Na plataforma InterIMAGE, foi criado um novo projeto, tendo como imagem padrão a composição das dez bandas utilizadas neste estudo. Embora no processamento se possa especificar qual ou quais bandas serão utilizadas, foram criadas duas camadas para interpretação visual, sendo uma composição das bandas R4/G3/B2 (cor natural) e uma composição das bandas R8/G4/B3 (falsa cor). Esta numeração não corresponde a numeração do sensor.

A rede semântica é um modelo de conhecimento utilizado para interpretar a imagem. No entanto, para classificação com o algoritmo C4.5 é necessário que todas as classes estejam no mesmo nível hierárquico. Uma rede semântica com um nó para cada classe de uso e cobertura da Terra. Foi estabelecida nessa rede que todas as classes se encontram no mesmo nível hierárquico (Figura 3).



Figura 3 – Rede semântica estabelecida  
Fonte: Autores (2019).

Com o uso do menu Samples Editor foi executada a segmentação da imagem e a coleta das amostras de treinamento. A segmentação foi realizada pelo algoritmo TA\_Baatz\_Segmenter, proposto por Baatz e Schäpe (2000), utilizando como parâmetros de entrada pesos 1 para todas as bandas, compactness weight 0,8, color weight 0,5, scale parameter 120, reliability 0,2 e euclidean distance threshold 20.

Segmentos amostrais foram coletados para indicar ao algoritmo de classificação as características de cada uma das classes. Os segmentos amostrados e os demais segmentos foram então exportados para o formato shapefile com descritores espectrais e de forma. Os descritores utilizados foram: média, entropia, relação de bandas; brilho, área, compacidade, comprimento e largura dos segmentos, além dos índices NDVI (Normalized Difference Vegetation Index), NDBSI (Normalized Difference Bare Soil Index) e NDWI (Normalized Difference Water Index).

A classificação foi realizada atribuindo ao primeiro nó da rede semântica o operador top-down TA\_C45\_Classifier, definindo o arquivo de segmentação contendo as amostras e os descritores nos campos Training Set File e Input Shape File.

## 2.4 Abordagem Pixel a Pixel

Para evitar a subjetividade da coleta das amostras, as mesmas áreas amostrais utilizadas na GEOBIA, foram utilizadas na classificação pixel a pixel. Para isso, o arquivo de amostras em formato shapefile foi importado no software IDRISI Selva versão 17.0. No entanto, devido a incompatibilidades dos bancos de dados, não foi possível criar o arquivo de assinaturas, sendo necessário digitalizar cada um dos polígonos amostrais.

A partir das áreas amostrais foi criado o arquivo de assinaturas e realizada a classificação pelo algoritmo de MAXVER, usando probabilidade igual para todas as classes de interesse. Para remover pixels isolados, aplicou-se um filtro de moda com janela 3x3, como sugerido por Crósta (1992).

## 2.5 Análise da Acurácia

Quando se deseja avaliar a acurácia temática de classes com pequenas áreas, a distribuição aleatória estratificada se mostra mais adequada. O valor mínimo de pontos de referência para áreas inferiores a 400 km<sup>2</sup> e com menos de 12 classes deve ser de 50 pontos por classe (CONGALTON, 1988; 1991).

Sendo assim, para avaliação da acurácia temática gerou-se uma malha com 350 pontos de referência, sendo 50 pontos em cada classe de uso e cobertura da Terra gerada por meio de classificação orientada a objeto. A malha foi gerada com o uso da ferramenta Create Random Points do ArcGIS.

Por fotointerpretação os pontos de referência foram avaliados quanto a classe de uso e cobertura, recebendo o código da classe correspondente. Por fim, os pontos foram cruzados por intersecção com os mapas gerados, bem como analisada a frequência, usando as ferramentas Spatial Join e Frequency do software ArcGIS.

### 2.5.1 Matriz de Confusão

Uma das técnicas mais utilizadas na avaliação da acurácia da classificação é o emprego da Matriz de Confusão, também conhecida como Matriz de Erro (CONGALTON, 1991). Neste trabalho a matriz foi utilizada como ponto de partida para uma série de técnicas estatísticas descritivas e analíticas, como sugerem Suarez e Candeias (2012).

Conforme Congalton e Green (2009) esta matriz é uma representação bastante eficaz da acurácia da classificação gerada, uma vez que as acurácias individuais de cada classe são descritas, levando em consideração os erros de inclusão e omissão. O erro de inclusão acontece quando uma área é incluída em uma classe à qual não pertence, já o erro de omissão ocorre quando uma área é excluída da classe à qual pertence.

A Matriz de Confusão é uma matriz quadrada de números definidos em linhas e colunas que expressam o número de unidades da amostra (pixel ou objeto), atribuída a uma categoria particular relativo à categoria atual. Normalmente, as colunas representam os dados de referência e as linhas, a classificação gerada (SUAREZ; CANDEIAS, 2012). Sendo assim, com os dados gerados foi montada uma Matriz de Confusão, possibilitando o cálculo de parâmetros de acurácia.

### 2.5.2 Exatidão Global, Acurácia do Produtor e Usuário

O índice de Exatidão Global é uma estatística descritiva proposta por Helldén (1980). Segundo Congalton e Green (2009), é a soma da diagonal principal da Matriz de Confusão (unidades classificadas corretamente) dividida pelo número total de unidades da amostra.

A probabilidade de uma amostra (pixel ou objeto) de referência ser classificada corretamente (medida do erro de omissão) é conhecida como Acurácia do Produtor. Quando o número total de amostras corretas em uma classe é dividido pelo número total de amostras classificadas na classe, tem-se a medida do erro de inclusão, conhecida como Acurácia do Usuário (SUAREZ; CANDEIAS, 2012). Desta forma com base na Matriz de Confusão foi calculada a Exatidão Global e as Acurácias dos Produtos e Usuário para as duas abordagens de classificação.

### 2.5.3 Kappa

O índice Kappa é um coeficiente de concordância para escalas nominais que avalia a proporção de concordância. A sua importância é justificada em função do mesmo utilizar todos os elementos da Matriz de Confusão (COHEN, 1960).

A partir da Matriz de Confusão é possível o uso de técnicas de estatística analítica, como as técnicas discretas multivariadas, uma vez que as mesmas são apropriadas em função dos dados de classificação serem discretos e não contínuos. Os dados também são distribuídos de forma normal (CONGALTON, 1988).

O índice Kappa proposto por Cohen (1960) é uma técnica discreta multivariada, que pode ser expressa pela equação 1:

$$K = \frac{P_O - P_{CO}}{1 - P_{CO}} \tag{1}$$

Em que:  $K$  = coeficiente de concordância Kappa;

$$P_O = \frac{\sum_{i=1}^M n_{ii}}{N},$$
 representando a porção de pontos de referência concordantes;

$$P_{CO} = \frac{\sum_{i=1}^M n_{i+}n_{+i}}{N^2},$$
 representando a porção de pontos atribuídos ao acaso;

Em que:  $N$  = número total de pontos da matriz de confusão;  $n$  = elemento da matriz de confusão;  $n_{ii}$  = elementos da diagonal principal da matriz de confusão;  $n_{i+}$  = somatório da linha para dada classe temática;  $n_{+i}$  = somatório da coluna para dada classe temática.

Além do índice Kappa, pode-se calcular o Kappa condicional, que tem como intuito avaliar a acurácia de cada classe temática, e é calculado com base no mesmo princípio utilizado para avaliação global da classificação (CONGALTON; GREEN, 2008). Pode ser expresso pela equação 2:

$$K_C = \frac{N x_{ii} - x_{i+} x_{+i}}{N x_{i+} - x_{i+} x_{+i}} \tag{2}$$

A fim de testar a significância estatística da diferença entre os dois índices de Kappa calculados (GEOBIA e Pixel a Pixel), foi utilizado o teste Z (CONGALTON; GREEN, 2008), conforme equação 3:

$$Z = \frac{k_2 - k_1}{\sqrt{\sigma_{k_2}^2 + \sigma_{k_1}^2}} \tag{3}$$

Em que:  $K_1$  = índice Kappa da classificação por GEOBIA,  $K_2$  = índice Kappa da classificação por Pixel a Pixel,  $\sigma^2$  = variância do índice Kappa.

### 3. Resultados e discussão

#### 3.1 Abordagem Análise de Imagens Orientada a Objetos Geográficos

A classificação por GEOBIA evidencia o predomínio das classes área urbanizada (34,29%), vegetação rasteira (33,67%) e vegetação arbórea (22,59%), já as classes sombra e massa de água representam juntas menos de 1% da área de estudo (Tabela 2 e Figura 4).

Tabela 2 – Áreas por abordagem orientada a objeto

Classes de Uso e Cobertura	Área (ha)	%
Área urbanizada	2468,71	34,29
Massa de água	36,14	0,50
Rejeito mineral	75,40	1,05
Solo exposto	544,31	7,56
Sombra	24,74	0,34
Vegetação arbórea	1626,35	22,59
Vegetação rasteira	2424,35	33,67
Total	7200,00	100,00

Fonte: Autores (2019).

Na figura 4 é possível identificar visualmente, no quadrante nordeste da área de estudo, a presença de regiões das classes sombra e rejeito mineral em meio a uma grande região da classe área urbanizada. A razão deste sombreamento pode ser atribuída ao fato de ser uma área urbana verticalizada. A classificação de áreas de rejeito mineral, por outro lado, trata-se de conflitos com áreas de pavimentos e telhados escuros parcialmente sombreadas, que apresentaram resposta espectral similar a essa classe.

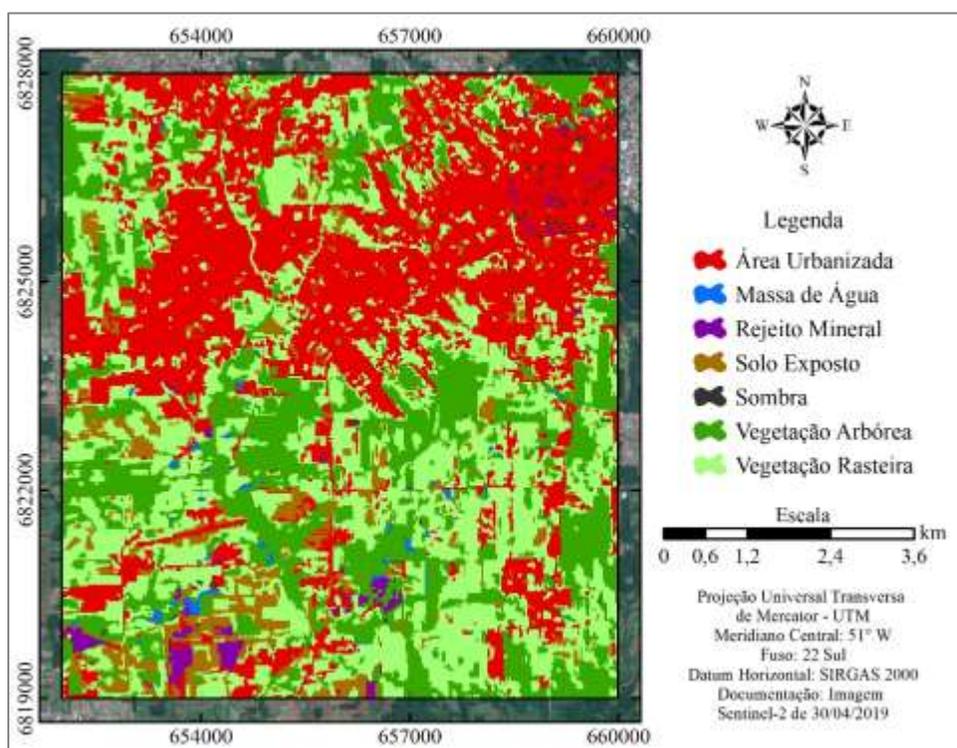


Figura 4 – Uso e cobertura da Terra por GEOBIA  
 Fonte: Autores (2019).

A matriz de confusão representa a relação entre as classes mapeadas e os dados de referência. A Tabela 3 contém a matriz de confusão gerada a partir do mapeamento temático por GEOBIA e dos 350 pontos de referência. A diagonal principal da matriz de confusão representa os pontos em que a classificação foi assertiva, destacando-se a classe área urbanizada, seguida pelas classes de vegetação arbustiva e rasteira. A classe que apresentou menor assertividade nos pontos de referência foi a classe sombra.

Os valores que estão fora da diagonal principal representam erros de classificação, não havendo concordância entre pontos de referência e o produto da classificação. A maior fonte de erro na classificação de nove áreas urbanizadas, foi na classe sombra. Erros expressivos são observados também entre as classes área urbanizada e solo exposto, vegetação arbórea e massa de água e vegetação rasteira e solo exposto.

Tabela 3 – Matriz de confusão da classificação orientada a objeto

		Dado de Referência							
Dado Classificado	Classes	MA	RM	SE	SO	AU	VA	VR	Total
	MA	34	0	2	3	4	7	0	50
	RM	0	41	1	3	5	0	0	50
	SE	0	0	34	1	7	1	7	50
	SO	1	5	2	25	9	6	2	50
	AU	0	1	2	0	46	0	1	50
	VA	0	0	0	0	0	42	8	50
	VR	0	0	2	0	1	5	42	50
	<b>Total</b>	<b>35</b>	<b>47</b>	<b>43</b>	<b>32</b>	<b>72</b>	<b>61</b>	<b>60</b>	<b>350</b>

MA – Massa de água, RM – Rejeito mineral, SE – Solo exposto, SO – Sombra, AU – Área urbanizada, VA – Vegetação arbórea e VR – Vegetação rasteira

Fonte: Autores (2019).

### 3.2 Abordagem Pixel a Pixel

Assim como observado na classificação por GEOBIA, na classificação Pixel a Pixel a classe área urbanizada é a mais expressiva, representando 39,93% da área, sendo seguida pelas classes vegetação rasteira (30,54%) e vegetação arbórea (21,82%). Por outro lado, as classes massa de água (0,38%) e rejeito mineral (0,90%) são menos expressivas (Tabela 4 e Figura 5).

Tabela 4 – Áreas por abordagem Pixel a Pixel

Classes de Uso e Cobertura	Área	
	Hectares	%
Área urbanizada	2874,72	39,93
Massa de água	27,08	0,38
Rejeito mineral	64,44	0,90
Solo exposto	311,64	4,33
Sombra	152,56	2,12
Vegetação arbórea	1570,76	21,82
Vegetação rasteira	2198,80	30,54
<b>Total</b>	<b>7200,00</b>	<b>100,00</b>

Fonte: Autores (2019).

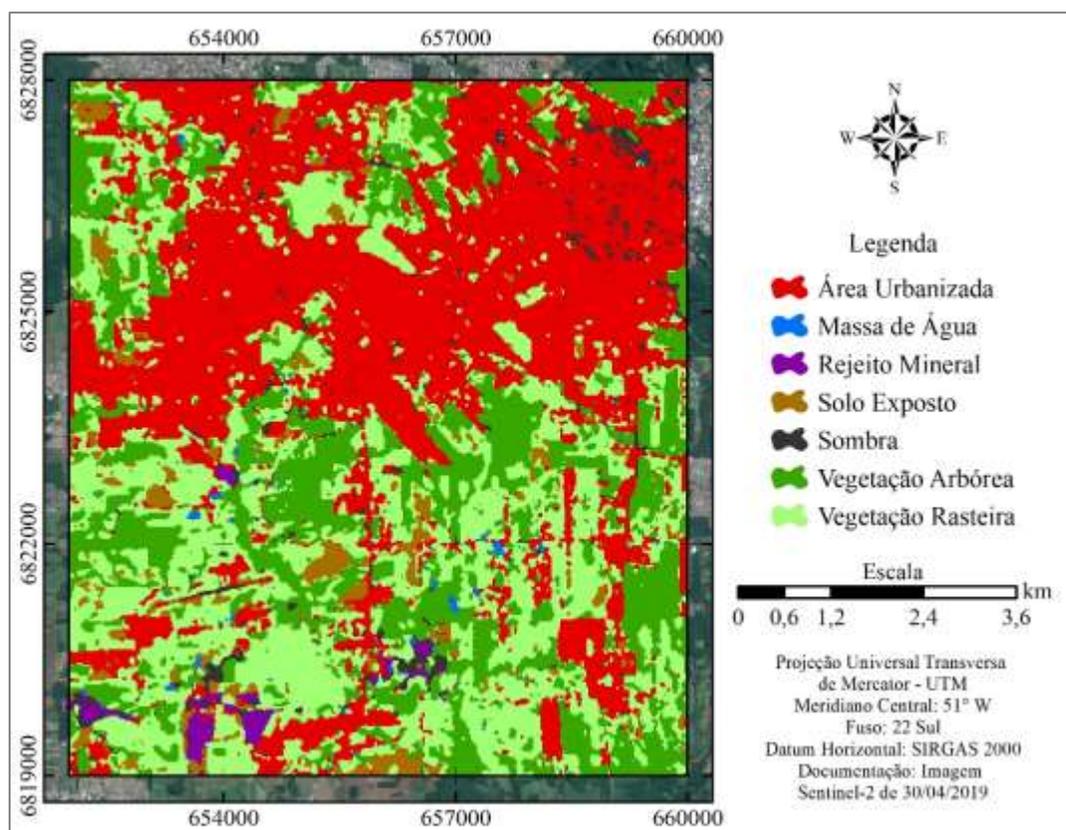


Figura 5 – Uso e cobertura da Terra por abordagem Pixel a Pixel

Fonte: Autores (2019).

A classificação supervisionada pelo algoritmo MAXVER (Figura 5) apresenta, assim como na classificação por GEOBIA, várias áreas da classe sombra na porção urbana mais verticalizada, além de polígonos da classe sombra espalhados pela área de estudo, principalmente próximas as áreas de rejeito mineral. Diferentemente da classificação por GEOBIA, a por pixel não apresentou conflitos entre as classes rejeito mineral e área urbanizada em porções urbanas verticalizadas.

No tocante a acurácia (Tabela 5), a classe rejeito mineral apresentou a maior assertividade de classificação, quando analisados os pontos de referência, seguida das classes solo exposto e vegetação arbórea. Já a classe sombra teve um resultado ruim, apresentando muitos conflitos com as classes área urbanizada, massa de água e rejeito mineral, sendo que as últimas são classes com baixo albedo na maioria das bandas do espectro ótico refletido, tendo pouco contraste espectral em relação à sombra. Conflito também expressivo ocorreu entre solo exposto e vegetação rasteira, o que pode decorrer da existência de áreas com vegetação baixa ou esparsa.

Tabela 5 – Matriz de confusão da classificação Pixel a Pixel

	Dado de Referência								
	Classes	MA	RM	SE	SO	AU	VA	VR	Total
Dado Classificado	MA	20	1	0	1	0	2	0	24
	RM	0	33	0	0	1	1	1	36
	SE	1	1	23	1	1	0	0	27
	SO	12	11	2	20	12	6	1	64
	AU	0	1	4	9	57	1	7	79
	VA	0	0	1	1	0	46	6	54
	VR	2	0	13	0	1	5	45	66
	Total	35	47	43	32	72	61	60	350

MA – Massa de água, RM – Rejeito mineral, SE – Solo exposto, SO – Sombra, AU – Área urbanizada, VA – Vegetação arbórea e VR – Vegetação rasteira

Fonte: Autores (2019).

### 3.3 Comparação: GEOBIA x Pixel a Pixel

Os dados quantitativos de áreas pelos dois métodos de classificação são apresentados na Tabela 6. Além de ser a maior nas duas classificações, a classe área urbanizada também foi a que apresentou maior diferença de área entre os métodos. Chama atenção ainda a diferença nas classes sombra e solo exposto, uma vez que ambas exibem grande diferença proporcional a área. A classe vegetação arbórea teve a maior concordância em ambos os métodos.

Tabela 6 – Áreas das classes de uso e cobertura da Terra

Classes de Uso e Cobertura	GEOBIA		Pixel a Pixel	
	Área (ha)	%	Área (ha)	%
Área urbanizada	2468,71	34,29	2874,72	39,93
Massa de água	36,14	0,50	27,08	0,38
Rejeito mineral	75,40	1,05	64,44	0,90
Solo exposto	544,31	7,56	311,64	4,33
Sombra	24,74	0,34	152,56	2,12
Vegetação arbórea	1626,35	22,59	1570,76	21,82
Vegetação rasteira	2424,35	33,67	2198,80	30,54
<b>Total</b>	<b>7200,00</b>	<b>100,00</b>	<b>7200,00</b>	<b>100,00</b>

Fonte: Autores, 2019.

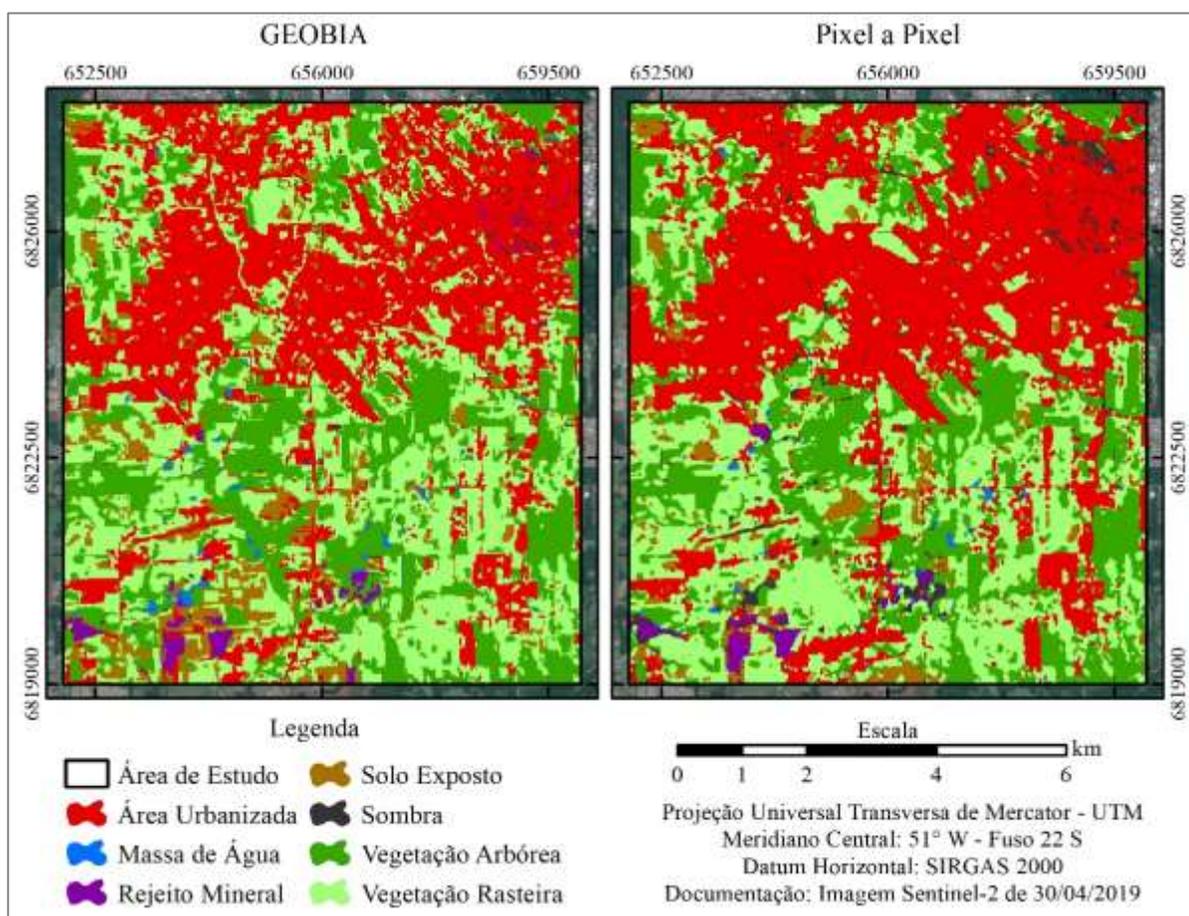


Figura 6 – Uso e cobertura da Terra: GEOBIA e Pixel a Pixel  
Fonte: Autores (2019).

Comparando visualmente os mapas gerados (Figura 6), a classificação por GEOBIA demonstrou um maior detalhamento na geometria das feições de uso e cobertura, enquanto a Pixel a Pixel aparenta ser mais generalista. No trabalho realizado por Pinho *et al.*, (2005), com imagem Ikonos, identificou-se que de maneira geral os resultados por GEOBIA preservam melhor a geometria dos alvos de interesse.

O resultado da GEOBIA demonstra ter maior coerência na classificação das áreas sombreadas, limitando estas a área urbana mais verticalizada. No entanto, a classificação pixel a pixel se mostra mais assertiva no mapeamento da classe rejeito mineral, não apresentando conflitos em área urbana.

### 3.3.1 Análise da acurácia temática

Com as matrizes de erro foram calculados os coeficientes de concordância que indicam a acurácia total e individual de cada classe. Quando avaliada de maneira geral a classificação por GEOBIA apresentou 75,43% de exatidão global e índice Kappa 71,33% (Figura 7). A classificação baseada em pixels também gerou bons resultados, no entanto inferiores ao anterior, com exatidão global de 69,71% e Kappa 64,26%.

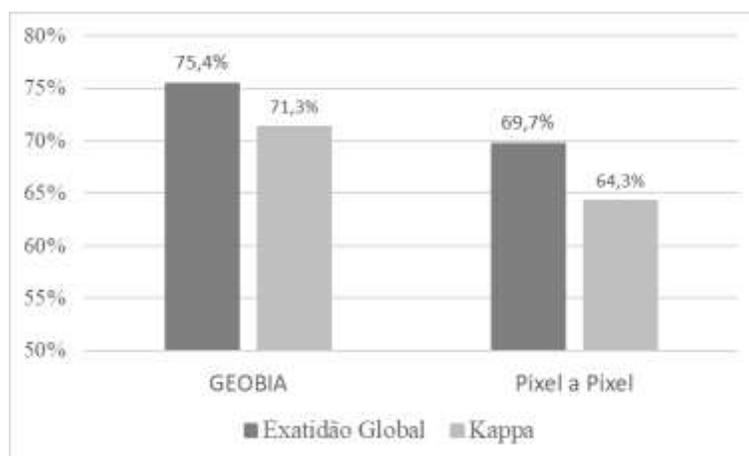


Figura 7 – Coeficientes de concordância total  
 Fonte: Autores (2019).

É possível observar que nas duas abordagens o índice Kappa apresenta valores de concordância menores que na exatidão global. Essa diferença segundo Cohen (1960) pode se dar pela utilização de todas as células da matriz no cálculo do índice de Kappa, incluindo assim os erros de omissão e inclusão das classes.

O padrão nos coeficientes de concordância total encontrado neste estudo é semelhante ao encontrado por Gao (2013), JEBUR *et al.* (2013), Chaofan *et al.* (2016), Qiu *et al.* (2017) e Prudente *et al.* (2017). Por outro lado, Cohenca e Carvalho (2015) obtiveram coeficientes de concordância total para pixel a pixel superiores aos de GEOBIA, que pode ter ocorrido em função da resolução espacial (30 metros) da imagem de trabalho.

A partir da matriz de erro é possível calcular medidas de acurácia individualmente para cada classe temática, como acurácia do produtor e acurácia do usuário (Tabela 7). Na classificação por GEOBIA a classe massa de água apresentou 97,1% de acurácia do produtor, e a menor acurácia do produtor foi da classe área urbanizada com 63,9% e um erro de omissão de 36,1%. Já no que se refere à acurácia do usuário, as áreas urbanizadas obtiveram 92,0%, ou seja, apenas 8% de erro de inclusão. Por outro lado, a classe sombra obteve apenas 50% de acurácia.

Tabela 7 – Acurácia por classe temática de uso e cobertura da Terra

Classes de Uso e Cobertura	GEOBIA		Pixel a Pixel	
	AP (%)	AU (%)	AP (%)	AU (%)
Área urbanizada	63,9	92,0	79,2	72,2
Massa de água	97,1	68,0	57,1	83,3
Rejeito mineral	87,2	82,0	70,2	91,7
Solo exposto	79,1	68,0	53,5	85,2
Sombra	78,1	50,0	62,5	31,3
Vegetação arbórea	68,9	84,0	75,4	85,2
Vegetação rasteira	70,0	84,0	75,0	68,2

AP – Acurácia do Produtor; AU – Acurácia do Usuário

Fonte: Autores (2019).

A classificação por pixels apresenta, no que se refere à acurácia do produtor, 79,2% de na classe área urbanizada como melhor resultado e além de duas classes com menos de 60% de acurácia, solo exposto 53,5% e massa de água 57,1%, valores considerados regulares. Já na acurácia do usuário, a classe rejeito mineral apresentou 91,7% de acurácia ou 8,3% de erro de inclusão. As áreas de sombra, entretanto foram mapeadas com apenas 31,3% de acurácia, tendo 68,7% de erro de inclusão.

Assim como nos coeficientes de concordância total, na acurácia classe a classe (produtor e usuário), a classificação por GEOBIA demonstrou acurácia superior a classificação pixel a pixel.

Além dos índices já calculados optou-se por calcular também o Kappa condicional (Tabela 8). Na análise, verifica-se que as classes em ambas as classificações apresentam diferenças. Na classe vegetação arbórea a diferença é pouco expressiva, já nas demais observam-se diferenças maiores, assim como em outros coeficientes já calculados, a classe sombra apresentou a maior diferença.

*Tabela 8 – Kappa condicional de uso e cobertura*

Classes de Uso e Cobertura	GEOBIA	Pixel a Pixel
Área urbanizada	64,44	81,48
Massa de água	79,21	90,37
Rejeito mineral	63,52	83,11
Solo exposto	44,97	24,33
Sombra	89,93	64,94
Vegetação arbórea	80,62	82,06
Vegetação rasteira	80,69	61,60

*Fonte: Autores (2019).*

Em um aspecto geral, a abordagem por GEOBIA apresenta coeficientes de concordância maiores em relação a classificação Pixel a Pixel. O teste de hipótese realizado entre os índices Kappa demonstrou que com nível de 5% não há diferença significativa ( $z = 1,81$ ) de acurácia entre as duas abordagens. Sendo assim, a classificação por GEOBIA não aumentou a acurácia significativamente num intervalo de confiança de 95%. Vale ressaltar que para um intervalo de confiança de 90%, a diferença seria significativa, conforme padrão de distribuição normal (CONGALTON; GREEN, 2008).

#### 4. Considerações finais

Neste trabalho, foram comparadas as abordagens de GEOBIA e Pixel a Pixel, para a classificação do uso e cobertura da Terra, em imagem de alta resolução. Os resultados obtidos nos coeficientes de concordância (exatidão global, Kappa e Kappa condicional) evidenciam que a classificação por GEOBIA obteve resultados superiores se comparado com a classificação Pixel a Pixel. O teste de hipótese demonstrou que com intervalo de confiança de 95% não houve diferença significativa.

A abordagem por GEOBIA apresentou maior acurácia do produtor em relação a pixel a pixel, para as classes de: massa de água, rejeito mineral, solo exposto e sombra. Na análise da acurácia do usuário, a abordagem GEOBIA proporcionou resultados superiores para: área urbanizada, sombra e vegetação rasteira. A classe vegetação arbórea teve resultados semelhantes nas duas abordagens (diferença de 1,2).

De maneira geral a classificação por GEOBIA, demonstrou estatisticamente o método indicado para análise de imagens Sentinel-2. Contudo, é necessário maior aprofundamento teórico para obter resultados mais expressivos, uma vez que não foi localizado na literatura pesquisas que compararam as duas abordagens para essas imagens.

Neste sentido, é recomendável que estudos futuros sejam realizados, afim de explorar diferentes metodologias de análise dessas imagens. Salienta-se ainda, que as imagens do sistema sensor Sentinel-2, assim como o InterIMAGE são disponibilizados de forma gratuita, cabe assim a comunidade científica explorá-los.

#### Agradecimentos

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e a Fundação de Amparo à Pesquisa e Inovação do Estado de Santa Catarina (Fapesc).

## Referências

- ADDINK, Elisabeth A.; VAN COILLIE, Fricke M.b.; JONG, Steven M. de. Introduction to the GEOBIA 2010 special issue: From pixels to geographic objects in remote sensing image analysis. *International Journal of Applied Earth Observation and Geoinformation*, [s.l.], v. 15, p.1-6, abr. 2012.
- BAATZ, Martin; SCHÄPE, Arno. Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation. In: *ANGEWANDTE GEOGRAPHISCHE INFORMATIONSVERARBEITUNG*, 12., 2000, Salzburg. Proceedings... Heidelberg: Herbert Wichmann Verlag, 2000. p. 1 - 542.
- BHASKARAN, Sunil; PARAMANANDA, Shanka; RAMNARAYAN, Maria. Per-pixel and object-oriented classification methods for mapping urban features using Ikonos satellite data. *Applied Geography*, [s.l.], v. 30, n. 4, p.650-665, dez. 2010.
- BRITES, Ricardo Seixas; BIAS, Edilson de Souza; ROSA, Antônio Nuno de Castro Santa. Classificação por Regiões. In: MENESES, Paulo Roberto; ALMEIDA, Tati de. *Introdução ao Processamento de Imagens de Sensoriamento Remoto*. Brasília: UnB, 2014. Cap. 13. p. 209-220.
- CHAOFAN, Wu; JINSONG, Deng; KE, Wang; LIGANG, Ma; TAHMASSEBI, Amir Reza Shah. Object-based classification approach for greenhouse mapping using Landsat-8 imagery. *International Journal of Agriculture and Biological Engineer* 9(1): 79. 2016.
- COHENCA, Daniel; CARVALHO, Raquel. Comparação de métodos de classificação OBIA, Máxima Verossimilhança e Distância Mínima em imagem OLI/Landsat-8 em área de alta diversidade de uso do solo. In: *SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO*, 16. Anais... João Pessoa: Inpe, 2015. p. 1035 - 1042.
- CONGALTON, Russell G. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, [s.l.], v. 37, n. 1, p.35-46, jul. 1991.
- CONGALTON, Russell G. A Comparison of Sampling Schemes Used in Generating Error Matrices for Assessing the Accuracy of Maps Generated from Remotely Sensed Data. *Photogrammetric Engineering and Remote Sensing*, [s.l.], v. 54, n. 5, p.593-600, maio 1988.
- CONGALTON, Russell G.; GREEN, Kass. *Assessing the accuracy of Remotely Sensed Data: Principles and Practices*. 2. ed. New York: Crc Press, 2008. 183 p.
- COHEN, Jacob. A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, [s.l.], v. 20, n. 1, p.37-46, abr. 1960. SAGE Publications.
- CRÓSTA, Álvaro Penteadó. *Processamento digital de imagens de sensoriamento remoto*. Campinas, SP: IG/UNICAMP, 1992. 170p.
- ESA, European Space Agency. *Sentinel-2 User Handbook*. Paris: Esa, 2015. 64 p.
- GAO, Jay. Mapping of Land Degradation from ASTER Data: A Comparison of Object-Based and Pixel-Based Methods. *Giscience & Remote Sensing*, [s.l.], v. 45, n. 2, p.149-166, abr. 2008.
- HELLDÉN, Ulf. *A Test of Landsat-2 Imagery and Digital Data for Thematic Mapping: Illustrated by an Environmental Study in Northern Kenya*. Lund: University Of Lund, 1980. 63 p.
- JEBUR, Mustafa Neamah et al. Per-pixel and object-oriented classification methods for mapping urban land cover extraction using SPOT 5 imagery. *Geocarto International*, [s.l.], v. 29, n. 7, p.792-806, 13 nov. 2013.
- LANDIS, J. Richard; KOCH, Gary G.. The Measurement of Observer Agreement for Categorical Data. *Biometrics*, [s.l.], p.159-174, mar. 1977.

- 
- MENESES, Paulo Roberto; SANO, Edson Eyji. Classificação Pixel a Pixel de Imagens. In: MENESES, Paulo Roberto; ALMEIDA, Tati de. *INTRODUÇÃO AO PROCESSAMENTO DE IMAGENS DE SENSORIAMENTO REMOTO*. Brasília: UnB, 2014. Cap. 12. p. 191-208.
- MORAES, Sofia Royer. *ABORDAGEM GEOBIA PARA A CLASSIFICAÇÃO DO USO E COBERTURA DA TERRA EM ÁREA URBANA ASSOCIADAS AO DESENVOLVIMENTO DE FRAMEWORK PARA MONITORAMENTO DE INUNDAÇÕES NO MUNICÍPIO DE LAJEADO/RS*. 2018. 104 f. Dissertação (Mestrado) - Curso de Programa de Pós-graduação em Sensoriamento Remoto e Geoprocessamento, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2018.
- PINHO, Carolina Moutinho Duque de; FEITOSA, Flávia da Fonseca; KUX, Hermann. Classificação automática de cobertura do solo urbano em imagem IKONOS: Comparação entre a abordagem pixel-a-pixel e orientada a objetos. In: *SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO*, 12., 2005, Goiânia. Anais... São José dos Campos: Inpe, 2005. p. 4217 - 4224.
- PRUDENTE, Victor H. R; SILVA, Bruno B. da; JOHANN, Jerry A.; MERCANTE, Erivelto; OLDONI, Lucas V. COMPARATIVE ASSESSMENT BETWEEN PER-PIXEL AND OBJECT-ORIENTED FOR MAPPING LAND COVER AND USE. *Engenharia Agrícola*, [s.l.], v. 37, n. 5, p.1015-1027, set. 2017. FapUNIFESP.
- QIU, Bingwen; LU, Difei; TANG, Zhenghong; CHEN, Chongcheng; ZOU, Fengli. Automatic and adaptive paddy rice mapping using Landsat images: Case study in Songnen Plain in Northeast China. *Science of The Total Environment*, [s.l.], v. 598, p.581-592, nov. 2017.
- SUAREZ, Alerson Falieri; CANDEIAS, Ana Lúcia Bezerra. AVALIAÇÃO DE ACURÁCIA DA CLASSIFICAÇÃO DE DADOS DE SENSORIAMENTO REMOTO PARA O MUNICÍPIO DE MARAGOGIPE. In: *SIMPÓSIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS E TECNOLOGIAS DA GEOINFORMAÇÃO*, 4., 2012, Recife. Anais... Recife: UFPE, 2012. p. 001 - 0010.
- TEHRANY, Mahyat Shafapour; PRADHAN, Biswajeet; JEBUV, Mustafa Neamah. A comparative assessment between object and pixel-based classification approaches for land use/land cover mapping using SPOT 5 imagery. *Geocarto International*, [s.l.], v. 29, n. 4, p.351-369, 5 abr. 2013.