

---

# PARÂMETROS DE SEGMENTAÇÃO PARA A CLASSIFICAÇÃO SUPERVISIONADA DE IMAGENS LANDSAT 8, CBERS-4 E SENTINEL-2: ANÁLISE COMPARATIVA E VALIDAÇÃO ESTATÍSTICA

## SEGMENTATION PARAMETERS FOR SUPERVISED CLASSIFICATION OF IMAGES LANDSAT 8, CBERS-4 AND SENTINEL-2: COMPARATIVE ANALYSIS AND STATISTICAL VALIDATION

Amanda Moreira Braz<sup>1</sup>  
Adalto Moreira Braz<sup>2</sup>  
Patrícia Helena Mirandola Garcia<sup>3</sup>  
Matheus Henrique de Souza Barros<sup>4</sup>

---

**RESUMO:** O presente trabalho utilizou como área teste a Bacia Hidrográfica do Córrego Ribeirãozinho, localizada no município de Selvíria (MS). Objetivou-se comparar as classificações das imagens CBERS-4, *Landsat 8* e *Sentinel-2*, de acordo com a segmentação mais adequada para a área teste, de acordo com a interpretação dos analistas (autores do trabalho), utilizando o Sistema de Informações Geográficas (SIG) *SPRING*<sup>®</sup> 5.3. Para validar os resultados brutos, sem edições pós-classificatórias, aplicou-se os índices de acurácia *Kappa* e Exatidão Global, calculados a partir das matrizes de confusão estabelecidas pelo *SPRING*<sup>®</sup>. Para delimitar automaticamente a bacia, utilizou-se o SIG *Global Mapper* 16 e imagens de radar da missão *Shuttle Radar Topography Mission* (SRTM) de 30 m. Antecedendo o processo de classificação, foram empregadas técnicas de Processamento Digital de Imagem (PDI) nas imagens, como realce e equalização de histograma, para obter uma melhor qualidade visual e propiciar uma melhor foteointerpretação. Ao analisar o desempenho dos parâmetros, nota-se que os resultados dos mapeamentos são semelhantes em todos os parâmetros estabelecidos, exceto quando aplicados na imagem CBERS-4, nos quais apresentam resultados insatisfatórios. Por fim, obtivemos resultados os quais podem ser comparados e oferecer maior seguridade e clareza na escolha dos algoritmos para os mapeamentos temáticos.

---

1 Bolsista Iniciação Científica (CNPq), discente de graduação em Geografia pela Universidade Federal de Mato Grosso do Sul – UFMS/CPTL. Membro do grupo de pesquisa DIGEAGEO (Diretrizes de Gestão Ambiental com Uso de Geotecnologias) E-mail: amandabraz.geo@gmail.com.

2 Doutorando Programa de Pós-Graduação em Geografia Universidade Federal de Goiás – UFG. Membro do grupo de pesquisa DIGEAGEO (Diretrizes de Gestão Ambiental com Uso de Geotecnologias). E-mail: adaltobraz.geografia@gmail.com.

Profa. Dra. do Programa de Pós-Graduação em Geografia Mestrado (UFMS/CPTL) e do Programa de Pós-Graduação Stricto Sensu em Ensino de Ciências (Doutorado) - Área Educação Ambiental, do Instituto de Física da Fundação Universidade Federal de Mato Grosso do Sul (UFMS-Campo Grande). Líder do grupo de pesquisa DIGEAGEO (Diretrizes de Gestão Ambiental com Uso de Geotecnologias) E-mail: patriciaufmsgeografia@gmail.com.

3 Mestrando Programa de Pós-Graduação em Geografia pela Universidade Federal de Mato Grosso do Sul – UFMS/CPTL. Membro do grupo de pesquisa DIGEAGEO (Diretrizes de Gestão Ambiental com Uso de Geotecnologias). E-mail: matheus.geo2013@gmail.com.

**Palavras-chave:** Geotecnologias. Índice Kappa. Segmentação.

**ABSTRACT:** The present work used as test area the Ribeirãozinho Watershed, located in the municipality of Selvíria (MS). The objective of this study was to compare the classifications of CBERS-4, Landsat 8 and Sentinel-2 images, according to the segmentation most appropriate for the test area, according to the interpretation of the analysts (authors of the paper), using the Geographic Information System (GIS) *SPRING*<sup>®</sup> 5.3. To validate the raw results, without post-qualifying editions, the Kappa Accuracy and Global Accuracy indices were calculated from the confusion matrices established by the *SPRING*<sup>®</sup>. The SIG Global Mapper 16 and radar images of the Shuttle Radar Topography Mission (SRTM) mission of 30 m were used to delimit the watershed automatically. Prior the classification process, Digital Image Processing (PDI) techniques were employed in the images, such as histogram enhancement and equalization, to obtain a better visual quality and provide a better photointerpretation. When analyzing the performance of the parameters, it is noticed that the results of the mappings are similar in all the established parameters, except when applied in the CBERS-4 image, in which they have unsatisfactory results. Finally, we obtained results that can be compared and offer greater security and clarity in the choice of algorithms for thematic mappings.

**Keywords:** Geotechnology. Kappa Index. Segmentation.

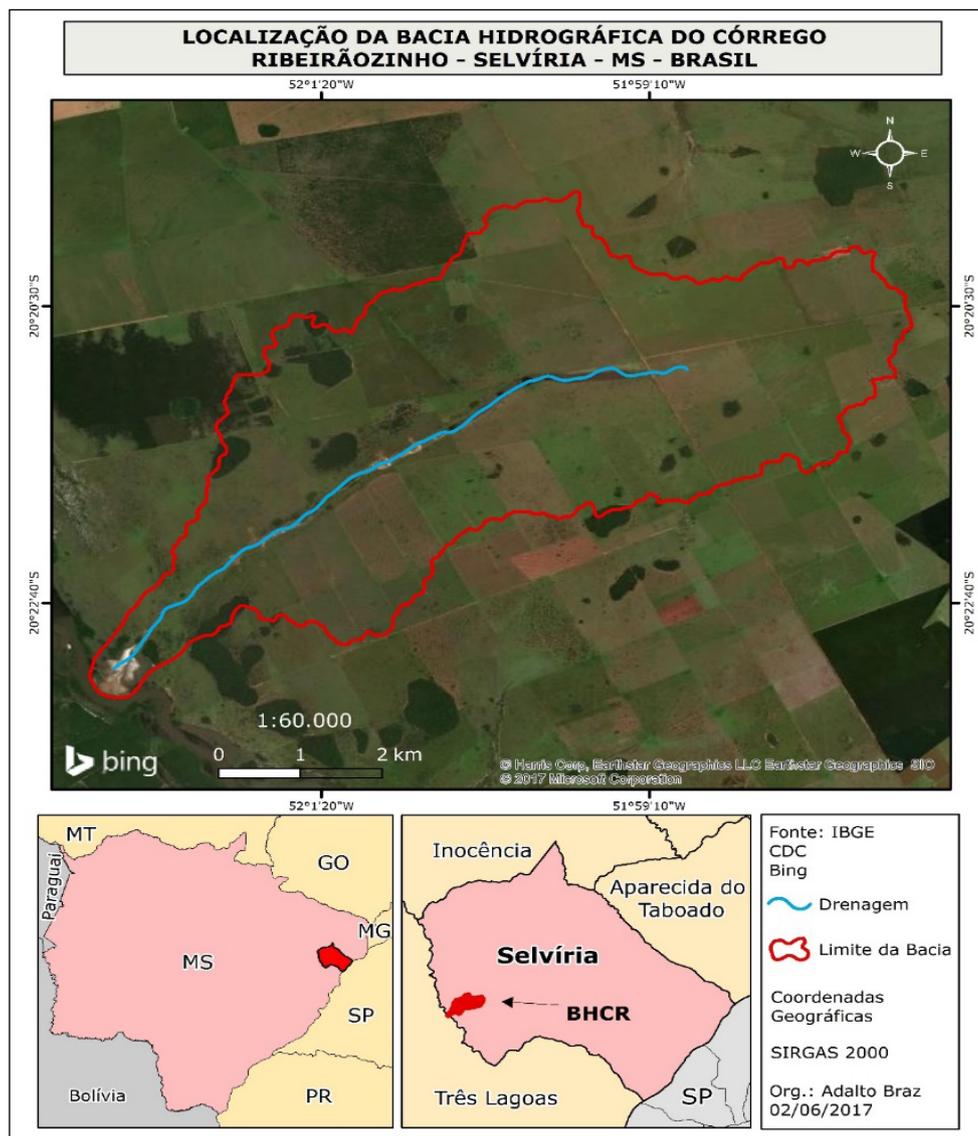
## 1 INTRODUÇÃO

Os problemas ambientais na segunda metade do século XX decorrentes do crescimento desordenado e de falta de planejamento em setores econômicos, impuseram à humanidade a necessidade de criação e desenvolvimento de metodologias e técnicas para a compreensão da dinâmica natural e ação sobre a natureza, de modo a mitigar e/ou recuperar os danos já causados pela ação humana.

Entre estas metodologias, destaca-se o planejamento ambiental, voltado para o ordenamento e monitoramento do uso e ocupação da terra, gerenciamento de recursos hídricos e bacias hidrográficas, delimitação das reservas legais, áreas de preservação permanente e proteção de áreas através dos parques e reservas, do monitoramento da cobertura vegetal.

O principal objetivo do trabalho foi comparar os resultados das classificações das imagens fornecidas pelos satélites CBERS-4 (PAN), *Landsat* 8 (OLI) e *Sentinel-2* (MSI), de acordo com a segmentação que melhor se adequa para cada imagem. Não foram realizadas edições pós-classificatórias, com o propósito de validar os resultados com o melhor potencial de classificação, de acordo com o parâmetro de segmentação julgados como mais adequados para cada imagem de satélite avaliada na área teste da Bacia Hidrográfica do Córrego Ribeirãozinho.

A pesquisa foi realizada na Bacia Hidrográfica do Córrego Ribeirãozinho, localizada no município de Selvíria (MS), sua localização geográfica está entre as coordenadas 52° 2' 53" W; 20° 19' 37" S e 51° 57' 23" W; 20° 23' 23" S (Figura 1).



Fonte: Braz (2017).

**Figura 1.** Mapa de localização da Bacia Hidrográfica do Córrego Ribeirãozinho

Vale ressaltar que a adoção de uma bacia hidrográfica para compor a área teste deu-se devido o conhecimento dos autores e de pesquisas prévias nesta região, que resultaram em trabalhos de campo, verificação *in loco* do uso e cobertura da terra e da produção de um mapa que foi usado indiretamente como “verdade de campo” (BRAZ, 2017). Estas situações facilitaram as validações e o julgamento em relação ao nível de qualidade dos parâmetros de segmentação e classificações aqui adotadas para posterior validação estatística.

No decorrer dos procedimentos optou-se por adotar três parâmetros designados como ideais, sendo cada um deles mais adequado a um satélite distinto. A partir disso, um parâmetro tido como ideal foi replicado para a segmentação em outros dois satélites e assim avaliar sua acurácia.

Por fim, para a validação das classificações aplicou-se os índices de acurácia *Kappa* e Exatidão Global, calculados para cada resultado de classificação, a partir das matrizes de confusão estabelecidas pelo *SPRING*<sup>®</sup>. Deste modo, foram geradas validações para 9 classificações, sendo 3 validações de acurácia para cada satélite, visto que foram elaboradas 3 segmentações para cada satélite (utilizando o parâmetro ideal de cada satélite).

## 2 FUNDAMENTAÇÃO TEÓRICA

As diferentes técnicas de interpretação e a escolha dos produtos (sensor, resolução, faixa espectral) influenciam nas características dos mapas produzidos. Além destes fatores, os critérios de interpretação, utilizados pelos intérpretes podem originar diferentes classificações (FERREIRA; DANTAS; MORAIS, 2007).

Imagens geradas por sensores remotos a bordo de satélites evoluíram muito desde o início da década de 70, quando foi lançado o primeiro satélite de observação da Terra. A possibilidade de se obter imagens periódicas torna o sensoriamento remoto, junto ao geoprocessamento, um conjunto de técnicas que auxiliam no gerenciamento de recursos naturais (MENDONÇA et al., 2007).

Como as paisagens são alteradas constantemente pela ação do homem, a interpretação de imagens de satélite é uma forma em tempo real de poder avaliar e determinar a dinâmica dessas alterações e sua influência nos processos econômicos, na expansão urbana, em ambiente de Geoprocessamento.

Uma metodologia bastante utilizada na elaboração de mapas de uso e ocupação da terra é a classificação digital de imagens de sensoriamento remoto.

As técnicas de classificação de imagens de satélite possuem grande potencial para extração de informações, portanto é importante analisar a confiabilidade da informação obtida via diferentes métodos de classificação em imagens de alta resolução (VIEIRA JUNIOR, 2011).

Segundo Crósta (1993), a classificação automática de imagens multiespectrais de sensoriamento remoto diz respeito a associar cada pixel da imagem a um “rótulo” descrevendo um objeto real (vegetação, solo, etc.). Dessa forma, os valores numéricos (DNs) associados a cada pixel, definidos pela reflectância dos materiais que compõem esse pixel, são identificados em termos de um tipo de cobertura da superfície terrestre imageada (água, tipo de vegetação, de solo, de rocha, etc.), chamadas então de temas.

A classificação por região se coloca como alternativa de mapeamento do uso e cobertura da terra, pois, além do nível de cinza da imagem, considera, também, a situação espacial de um conjunto de pixels semelhantes (região) em relação aos pixels que cercam esse conjunto (SILVA, 2014).

A classificação estatística é o procedimento convencional de análise digital de imagens. Constitui um processo de análise de pixels de forma isolada. Esta abordagem apresenta a limitação da análise pontual ser baseada unicamente em atributos espectrais.

Para superar estas limitações, propõe-se o uso de segmentação de imagem, anterior à fase de classificação, onde se extraem os objetos relevantes para a aplicação desejada, essa técnica é bastante difundida no meio acadêmico, diz respeito à segmentação de imagens, em vez de se envolver apenas nos aspectos de delimitação de áreas e caracterização do uso da terra.

Neste processo, divide-se a imagem em regiões que devem corresponder às áreas de interesse da aplicação. Entende-se por regiões um conjunto de “pixels” contíguos, que se espalham bidirecionalmente e que apresentam uniformidade.

A divisão em porções consiste basicamente em um processo de crescimento de regiões, de detecção de bordas ou de detecção de bacias (CÂMARA et al., 1996).

A segmentação automática, em geral, baseia-se nas características de descontinuidade e similaridade dos tons de cinza de uma imagem. O método que avalia a descontinuidade considera a mudança abrupta dos valores de cinza e o método por similaridade fundamenta-se na agregação de *pixels* em função da sua semelhança com os *pixels* vizinhos (GONZÁLES; WINTZ, 1987). A segmentação por crescimento de regiões se baseia neste segundo método.

Conforme Venturieri e Santos (1998), a operação de segmentação por crescimento de regiões consiste em agrupar *pixels* com características similares em termos tonais e texturais, formando regiões homogêneas. Desta forma, a imagem é particionada em um conjunto de regiões correspondentes às feições da superfície terrestre, que irão servir de base para a análise e cartografia temática.

Os resultados desse processo são áreas com aspecto contínuo, onde cada área possui características espectrais bem diferentes das vizinhas que a cercam.

De acordo com Coutinho (1997), a definição de valores para os limiares na segmentação de imagens depende, principalmente, do conhecimento dos padrões de repartição espacial dos objetos de cada área e da definição da generalização cartográfica ideal, em função da escala cartográfica da abordagem realizada. Contempla uma etapa que exige maior atenção devido à inexistência de valores padronizados para as variáveis do algoritmo e, também, pode influenciar diretamente na acurácia dos resultados da segmentação.

O processo de segmentação é essencialmente empírico e, em geral, ajustável aos diferentes tipos de imagens, com limiares definidos face à complexidade dos alvos investigados. O nível que esta subdivisão deve ser realizada depende do problema a ser resolvido.

Não existe modelo ideal para a segmentação. Portanto, depende de uma série de fatores, tais como a resolução do sensor que capturou a imagem e a escala aproximada das feições reconhecidas na paisagem que o analista busca identificar (LILLESAND; KIEFER; CHIPMAN, 2008 apud VIEIRA JUNIOR, 2011).

Para a validação das classificações, aplicou-se os índices de acurácia *Kappa* e Exatidão Global, calculados manualmente para cada resultado de classificação, a partir das matrizes de confusão estabelecidas pelo *SPRING*<sup>®</sup>.

### 3 MATERIAL

Foram utilizados três satélites com diferentes instrumentos imageadores, o *Landsat* 8, sensor OLI, CBERS-4, sensor PAN e o Sentinel-2, sensor MSI.

A série *Landsat* teve início na segunda metade da década de 1960, a partir de um projeto desenvolvido pela Agência Espacial Americana e dedicado exclusivamente à observação dos recursos naturais terrestres. Essa missão foi denominada *Earth Resources Technology Satellite* (ERTS) e em 1975 passou a se chamar *Landsat*.

A missão, em sua maioria, foi gerenciada pela *National Aeronautics and Space Administration* (NASA) e pela *U.S. Geological Survey* (USGS) e envolveu o lançamento de oito satélites (EMBRAPA, 2013).

O satélite *Landsat* 8 entrou em operação no ano de 2013. É o oitavo da série de satélites do Programa *Landsat*. As imagens *Landsat* estão disponíveis na plataforma online *Earth Explorer* gratuitamente.

O satélite *Landsat* 8 opera com dois instrumentos imageadores, o Operacional Terra Imager (OLI) e *Thermal Infrared Sensor* (TIRS). O sensor OLI possui nove bandas multiespectrais com resolução espacial de 30m (bandas de 1 a 7 e 9), além da banda pancromática, com 15m de resolução espacial. As faixas térmicas do instrumento TIRS fornecem dados de temperaturas de superfície mais precisas e os dados são coletados no pixel de 100m (Quadro 1).

**Quadro 1.** Características das bandas do satélite *Landsat 8*

| Sensor (OLI)<br>Bandas               | Resolução Espectral<br>( $\mu\text{m}$ ) | Resolução Espacial | Faixa Imageada                             | Resolução Radiométrica |
|--------------------------------------|--|--------------------|--|------------------------|
| B1: Ultra Blue (Coastal/<br>Aerosol) | 0,43 - 0,45                              | 30 m               | 170 km (norte-sul)<br>183 km (leste-oeste) | 16 bits/8bits          |
| B2: Blue (Azul)                      | 0,45 - 0,51                              | 30 m               |  |                        |
| B3: Green (Verde)                    | 0,53 - 0,59                              | 30 m               |  |                        |
| B4: Red Vermelho                     | 0,64 - 0,67                              | 30 m               |  |                        |
| B5: Near Infrared (NIR)              | 0,85 - 0,88                              | 30 m               |  |                        |
| B6: SWIR 1                           | 1,57 - 1,65                              | 30 m               |  |                        |
| B7: SWIR 2                           | 2,11 - 2,29                              | 30 m               |  |                        |
| B8: Pancromática                     | 0,50 - 0,68                              | 15 m               |  |                        |
| B9: Cirrus                           | 1,36 - 1,38                              | 30 m               |  |                        |
| B10: Thermal Infrared 1<br>(TIRS)    | 10,60 - 11,19                            | 100 m              |  |                        |
| Thermal Infrared 2<br>(TIRS)         | 11,50 - 12,51                            | 100 m              |  |                        |

Fonte: USGS (2017).

O Programa CBERS (*China-Brazil Earth Resources Satellite*) surgiu de uma parceria com a China. O satélite CBERS-4 foi lançado em dezembro de 2014, da base de Taiyuan e está em atividade até o presente momento. Seus produtos são distribuídos de forma gratuita pela plataforma *online* do INPE (Instituto Nacional de Pesquisas Espaciais).

O satélite CBERS-4 possui quatro sistemas imageadores (Quadro 2):

**Quadro 2.** Características dos sensores do CBERS-4

| Sensor | Resolução Espectral ( $\mu\text{m}$ ) | Resolução Espacial | Faixa Imageada | Resolução Radiométrica |
|--------|---------------------------------------|--------------------|----------------|------------------------|
| MUX    | B5: 0,45-0,52 (B)                     | 20 m               | 120 km         | 8 bits                 |
|        | B6: 0,52-0,59 (G)                     |                    |                |                        |
|        | B7: 0,63-0,69 (R)                     |                    |                |                        |
|        | B8: 0,77-0,89 (NIR)                   |                    |                |                        |
| PAN    | B1: 0,51-0,85 (Pan)                   | 5 m/10 m           | 60 km          | 8 bits                 |
|        | B2: 0,52-0,59 (G)                     |                    |                |                        |
|        | B3: 0,63-0,69 (R)                     |                    |                |                        |
|        | B4: 0,77-0,89 (NIR)                   |                    |                |                        |
| IRS    | B9: 0,50-0,90 (Pan)                   | 40 m/80 m (TIR)    | 120 km         | 8 bits                 |
|        | B10: 1,55-1,75 (SWIR)                 |                    |                |                        |
|        | B11: 2,08-2,35 (SWIR)                 |                    |                |                        |
|        | B12: 10,40-12,50 (TH)                 |                    |                |                        |
| WFI    | B13: 0,45-0,52 (B)                    | 64 m               | 866 km         | 10 bits                |
|        | B14: 0,52-0,59 (G)                    |                    |                |                        |
|        | B15: 0,63-0,69 (R)                    |                    |                |                        |
|        | B16: 0,77-0,89 (NIR)                  |                    |                |                        |

Fonte: INPE (2014); EPIPHANO (2011).

O *Sentinel-2* é uma missão imageadora multispectral do Programa *European Space Agency* (ESA) e seu lançamento ocorreu no ano de 2015. Este satélite possui o sensor MSI, com 13 faixas espectrais (Quadro 3).

**Quadro 3.** Características das faixas espectrais do satélite Sentinel-2

| Sensor (MSI) Bandas | Resolução Espectral (µm) | Resolução Espacial | Faixa Imageada | Resolução Radiométrica |
|---------------------|--------------------------|--------------------|----------------|------------------------|
| B2: Azul (B)        | 0,49                     | 10 m               | 290 km         | 12 bits por pixel      |
| B3: Verde (G)       | 0,56                     |                    |                |                        |
| B4: Vermelho        | 0,665                    |                    |                |                        |
| B8: NIR             | 0,842                    |                    |                |                        |
| B5: Red Edge 1      | 0,705                    | 20 m               | 290 km         | 12 bits por pixel      |
| B6: Red Edge 2      | 0,74                     |                    |                |                        |
| B7: Red Edge 3      | 0,783                    |                    |                |                        |
| B8A: Red Edge 4     | 0,865                    |                    |                |                        |
| B11: SWIR 1         | 1,61                     |                    |                |                        |
| B12: SWIR 2         | 2,19                     |                    |                |                        |
| B1: Aerossol        | 0,443                    | 60 m               | 290 km         | 12 bits por pixel      |
| B9: Water Vapor     | 0,94                     |                    |                |                        |
| B10: Cirrus         | 1,375                    |                    |                |                        |

Fonte: Processamento Digital (2016); *EngeSat* (2017).

As imagens do satélite *Sentinel-2* estão também disponíveis gratuitamente na plataforma *online The Copernicus Open Access Hub* (SciHub) e também na plataforma *Earth Explorer*.

#### 4 MÉTODOS

A delimitação da bacia hidrográfica foi realizada de forma automatizada no SIG *Global Mapper 16*. Foram utilizadas imagens de radar SRTM (*Shuttle Radar Topography Mission*) de 30m processadas utilizando a ferramenta *Generate Watershed*, que leva em consideração os valores altimétricos mais altos da imagem SRTM para definir os limites da bacia hidrográfica.

Foram utilizadas imagens de três sensores com diferentes características, acoplados aos satélites *Landsat 8*, *Sentinel-2* e *CBERS-4* (Tabela 1).

**Tabela 1.** Características dos sensores remotos utilizados

| Satélites  | Sensor | Resolução Radiométrica | Resolução Espacial | Faixa Imageada (km)                        |
|------------|--------|------------------------|--------------------|--|
| Landsat 8  | OLI    | 16 bits                | 30/15 m            | 170 km (norte-sul)<br>183 km (leste-oeste) |
| Sentinel-2 | MSI    | 12 bits                | 10 m               | 290 km                                     |
| CBERS-4    | PAN    | 8 bits                 | 10/5 m             | 60 km                                      |

Fonte: Braz (2018).

Para a classificação da imagem CBERS-4, foram utilizadas imagens do sensor PAN (Câmera Pancromática e Multiespectral) 5 e 10m, referente à órbita 160 e ponto 123, imageadas no dia 15/07/2016.

Para gerar a composição colorida foram utilizadas as bandas 3 (Vermelho - 0,63 $\mu$ m a 0,69 $\mu$ m), 4 (Infravermelho Próximo/NIR - 0,77 $\mu$ m a 0,89 $\mu$ m) e 2 (Verde - 0,52 $\mu$ m a 0,59 $\mu$ m), com resolução espacial de 10m.

Após a finalização da composição colorida, realizou-se a fusão com a banda 1 (Pancromática - 0,51 $\mu$ m a 0,85 $\mu$ m), com resolução espacial de 5m, gerando como produto final uma imagem multiespectral com resolução espacial de 5m.

As imagens do satélite *Landsat 8* sensor OLI (*Operation Land Imager*), órbita 223 e ponto 74, imageadas no dia 18/05/2016.

Foram utilizadas as bandas 6 (Vermelho - Infravermelho Médio/SWIR – 1,57 $\mu$ m a 1,65 $\mu$ m), 5 (Verde – Infravermelho Próximo – 0,85 $\mu$ m a 0,88 $\mu$ m) e 4 (Azul – Visível do Vermelho – 0,64 $\mu$ m a 0,67 $\mu$ m), com resolução espacial de 30 m.

Com a composição colorida finalizada, realizou-se o processo de fusão, onde as imagens multiespectrais (6R, 5G, 4B) foram transformadas em IHS (*Intensity, Hue, Saturation*), contendo os componentes intensidade, matiz e saturação. Posteriormente, o item intensidade foi substituído pela banda 8 (Pancromática – 0,50 $\mu$ m a 0,68 $\mu$ m) com resolução espacial de 15m, seguida da conversão IHS para RGB, obtendo como produto final uma imagem multiespectral com resolução espacial de 15m.

Para a imagem do satélite *Sentinel-2* sensor MSI (*MultiSpectral Instrument*), órbita 223/ponto 74, imageada em 25/07/2016, foram utilizadas bandas 4 (Vermelho – 0,665 $\mu$ m), 8 (Infravermelho Próximo/NIR – 0,842 $\mu$ m) e 3 (Azul – 0,560 $\mu$ m), com resolução espacial de 10m.

Técnicas de Processamento Digital de Imagens (PDI) foram empregadas a fim de realçar o contraste das bandas a partir da equalização do histograma RGB. A equalização do histograma de cores das imagens teve finalidade de aplicar o realce, onde os níveis de cinza das imagens foram distribuídos uniformemente pelo histograma, colaborando com melhor qualidade visual e proporcionou melhor interpretação visual e digital das informações representadas nas imagens dos satélites.

A plataforma utilizada para o PDI das imagens de satélite foi o SIG *Spring*® versão 5.3. No *SPRING*®, aplicou-se técnicas de classificações digitais de imagens, a partir de classificação supervisionada usando o algoritmo *Bhattacharya*<sup>5</sup>.

Antecedendo à classificação, foram elaboradas segmentações por crescimento de regiões, com limiar de aceitação de 95%, realizando os treinamentos com aquisição de amostras das classes pré-determinadas para a classificação supervisionada *Bhattacharya*.

O processo de segmentação de imagens exige a definição das bandas espectrais e dos limiares de similaridade e de área (*pixels*). Esses parâmetros são responsáveis pela qualidade da segmentação que servirá de base para a classificação temática posterior (LEÃO et al., 2007). A delimitação do tamanho da área considera o tamanho mínimo das regiões que serão individualizadas pelo algoritmo (OLIVEIRA, 2002).

A definição dos parâmetros para a segmentação foi determinada após alguns testes de combinações possíveis no algoritmo, até alcançarmos um resultado satisfatório (ideal) para cada imagem. A partir de uma análise visual, utilizou-se as que melhor se adequaram (Tabela 2).

**Tabela 2.** Parâmetros de segmentação ideal utilizados para as classificações

| Imagem     | Similaridade | Área ( <i>pixels</i> ) |
|------------|--------------|------------------------|
| Landsat 8  | 50           | 100                    |
| Sentinel-2 | 110          | 120                    |
| CBERS-4    | 7            | 100                    |

Fonte: Braz (2018).

Optou-se pela escolha de apenas um algoritmo de classificação, para justificar o caráter comparativo de resultados de classificação para fins de mapeamento de uso e cobertura da terra em três imagens de satélites/sensores diferentes, que são destinados à observação da terra.

Ao final da classificação das imagens, para validar o grau de concordância dos resultados da classificação supervisionada, foi gerado a exatidão global e o índice *kappa* a partir da matriz de confusão estabelecida. As matrizes foram exportadas do *Spring 5.3* para o *Microsoft Excel 2013*, onde foram realizados os cálculos estatísticos dos valores gerados.

As fórmulas utilizadas para realizar os cálculos partiram do trabalho de Santos, Peluzio e Saito (2010). A fórmula utilizada para obter os resultados da exatidão global foi:

$$EX = D/T \quad (1)$$

Onde: D: elementos da diagonal principal; T: total de *pixels* coletados.

E as fórmulas utilizadas para gerar o valor *kappa* foram:

$$Q = \frac{\sum_{i=1}^r x_{i+} x_{+i}}{T} \quad (2)$$

$$K = D - Q / T - Q \quad (3)$$

Onde: Q: soma da multiplicação dos totais dividido pelo total de *pixels*;  $\Sigma$ : somatório;  $x_{i+}$ : soma das linhas da matriz de confusão;  $x_{+i}$ : soma das colunas da matriz de confusão; r: número de categorias presentes na matriz de confusão; T: total de *pixels* coletados; K: *kappa*; D: soma da diagonal principal.

A matriz de confusão gerada pelo *Spring* representa os valores em número de *pixels* coletados por cada amostra gerada. Com as classificações geradas, os resultados foram representados em forma de mapas de uso e cobertura da terra da Bacia Hidrográfica do Córrego Ribeirãozinho e os resultados das validações estão expressos em forma de tabelas. A elaboração final do *layout* dos mapas foi feita no SIG ArcGIS 10.4, no módulo ArcMap.

## 5 RESULTADOS E DISCUSSÕES

Por se tratar de uma área considerada pequena, apenas quatro classes temáticas foram identificadas, sendo pastagem, vegetação arbórea, área úmida e solo exposto.

Optou-se por validar as classificações de modo manual, a partir da matriz de confusão gerada pelo *Spring*. Para este processo foram utilizados os parâmetros estabelecidos por Congalton e Green (1998), citado por Santos, Peluzio e Saito (2010) (Tabela 3).

Tabela 3. Intervalo de aceitação dos resultados do índice *kappa*

| ÍNDICE KAPPA ( $K$ ) | CARACTERÍSTICAS |
|----------------------|-----------------|
| $K \leq 0,4$         | Pobre           |
| $0,4 < K \leq 0,8$   | Razoável        |
| $K \geq 0,8$         | Excelente       |

Fonte: Congalton e Green (1998).

Para a classificação da imagem *Landsat 8*, o parâmetro de segmentação que melhor se adequou foi de similaridade 50 e área (*pixels*) 100 (Figura 2).

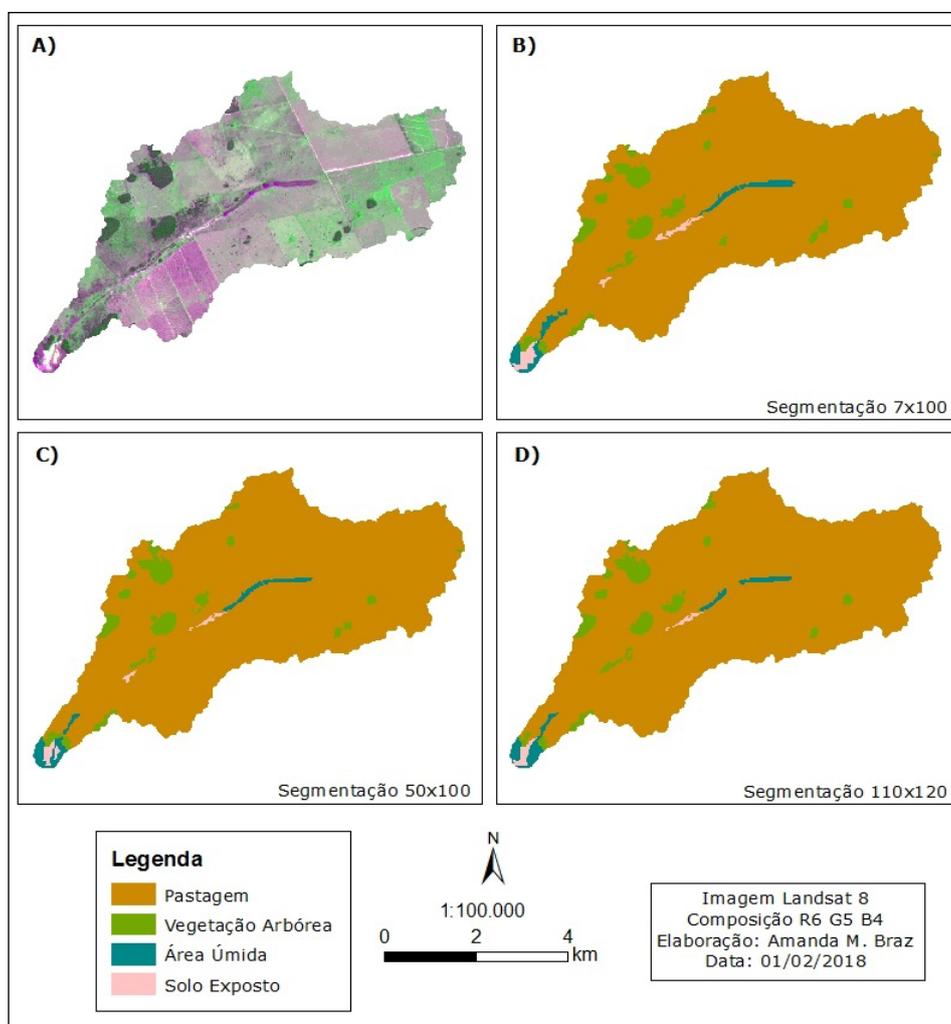


Figura 3. Mosaico das classificações da imagem Landsat 8

Os resultados das classificações também foram semelhantes, tanto visualmente quanto nos valores do *kappa*. Perante os parâmetros 7x100 e 50x100, o valor *kappa* gerado foi 0,9. Já com o parâmetro 110x120, o valor do *kappa* foi 1 (Tabela 4).

**Tabela 4.** Desempenho das classificações da imagem de satélite *Landsat 8*

| Parâmetros | Exatidão Global | Índice Kappa | Confusão Média (%) |
|------------|-----------------|--------------|--------------------|
| 7x100      | 99,65           | 0,9          | 0,35%              |
| 50x100     | 99,61           | 0,9          | 0,38%              |
| 110x120    | 1               | 1            | 0,00%              |

Fonte: Braz (2018).

As áreas úmidas e o solo exposto são as classes que sofreram alterações mais visíveis. A partir da análise quantitativa, nota-se que a segmentação 7x100 novamente foi a que gerou mais amostras, totalizando 367; a segmentação 50x100 gerou um total de 216 amostras e a 110x120 gerou 251 amostras (Tabela 5).

**Tabela 5.** Análise quantitativa das amostras geradas e coletadas da imagem *Landsat 8*

| Parâmetros | Pastagem | Vegetação Arbórea | Solo Exposto | Área Úmida | Total de Amostras |
|------------|----------|-------------------|--------------|------------|-------------------|
| 7x100      | 326      | 25                | 6            | 10         | 367               |
| 50x100     | 179      | 22                | 5            | 10         | 216               |
| 110x120    | 222      | 20                | 3            | 6          | 251               |

Fonte: Braz (2018).

Com a tabulação dos dados, nota-se que as diferenças dos valores das classes mapeadas são pequenas e no caso da pastagem, os parâmetros 7x100, ideal CBERS e 110x120, ideal Sentinel-2, geraram a mesma porcentagem (Tabela 6).

**Tabela 6.** Análise quantitativa das classes mapeadas da imagem de satélite *Landsat 8* a partir da segmentação 7x100; 50x100 e 110x120

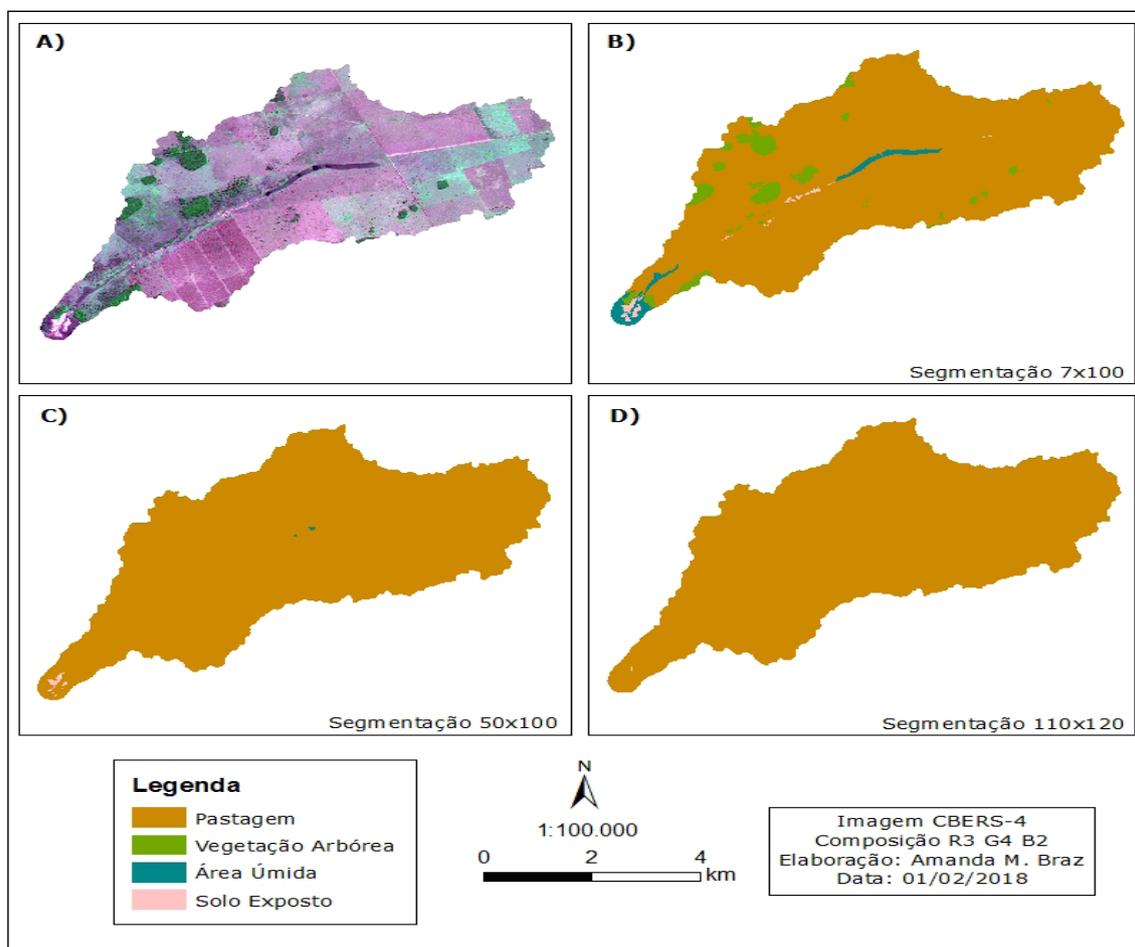
| Classes           | Porcentagem (%) |                |         |
|-------------------|-----------------|----------------|---------|
|                   | 7x100           | 50x100 (ideal) | 110x120 |
| Pastagem          | 92,2            | 93,0           | 92,2    |
| Vegetação Arbórea | 4,9             | 4,6            | 4,5     |
| Área Úmida        | 1,9             | 1,8            | 1,7     |
| Solo Exposto      | 1,0             | 0,6            | 1,6     |

Fonte: Braz (2018).

Para a classificação da imagem CBERS-4, o parâmetro de segmentação que melhor se adequou foi de similaridade 7 e área (*pixels*) 100. Visualmente, a classificação gerada apresentou boa qualidade, atingindo o índice *kappa* de 0,9, enquadrando-se na categoria excelente (Figura 3).

Com os parâmetros de similaridade 50 e área (*pixels*) 100, ideal para a imagem *Landsat 8*, a classificação apresentou um desempenho ruim, não gerando todas as classes presentes na bacia e um exagero na classe de pastagem, nota-se alto nível de conflito na

distinção das classes. Porém, o índice *kappa* atingiu o valor de 1, enquadrando-se também na categoria excelente, apesar de apresentar uma qualidade visual incorreta.



Fonte: Braz (2018).

**Figura 3.** Mosaico das classificações da imagem CBERS-4

Ao aplicar os parâmetros de similaridade 110 e área (*pixels*) 120, ideal para a imagem *Sentinel-2*, as classes de vegetação arbórea e área úmida também não geraram amostras, ocorrendo incoerência entre as classes. Porém, novamente o valor do índice *kappa* é 1, mesmo que, na realidade, a qualidade da classificação tenha sido insatisfatória e incorreta (Tabela 7).

**Tabela 7.** Desempenho das classificações da imagem de satélite CBERS-4

| Parâmetros | Exatidão Global | Índice Kappa | Confusão Média (%) |
|------------|-----------------|--------------|--------------------|
| 7x100      | 99,67           | 0,9          | 0,33%              |
| 50x100     | 1               | 1            | 0,00%              |
| 110x120    | 1               | 1            | 0,00%              |

Fonte: Braz (2018).

Ao fazer uma análise quantitativa das amostras geradas e coletadas, nota-se que a imagem CBERS-4 gerou poucas amostras ao aplicar os parâmetros de segmentação mais altos, adotados como ideais para *Landsat 8* e *Sentinel-2* e, automaticamente, uma qualidade visual ruim e com precisão temática incorreta (Tabela 8).

**Tabela 8.** Análise quantitativa das amostras geradas e coletadas da imagem CBERS-4

| Parâmetros | Pastagem | Vegetação Arbórea | Solo    |       | Total de Amostras |
|------------|----------|-------------------|---------|-------|-------------------|
|            |          |                   | Exposto | Úmida |                   |
| 7x100      | 267      | 43                | 24      | 36    | 370               |
| 50x100     | 2        | 0                 | 4       | 2     | 8                 |
| 110x120    | 1        | 0                 | 1       | 0     | 2                 |

Fonte: Braz (2018).

Para uma melhor comparação entre as classificações, foi realizada uma análise quantitativa das classes mapeadas e a tabulação dos valores, conforme a Tabela 9.

**Tabela 9.** Análise quantitativa das classes mapeadas da imagem de satélite CBERS-4 a partir das segmentações 7x100; 50x100 e 110x120

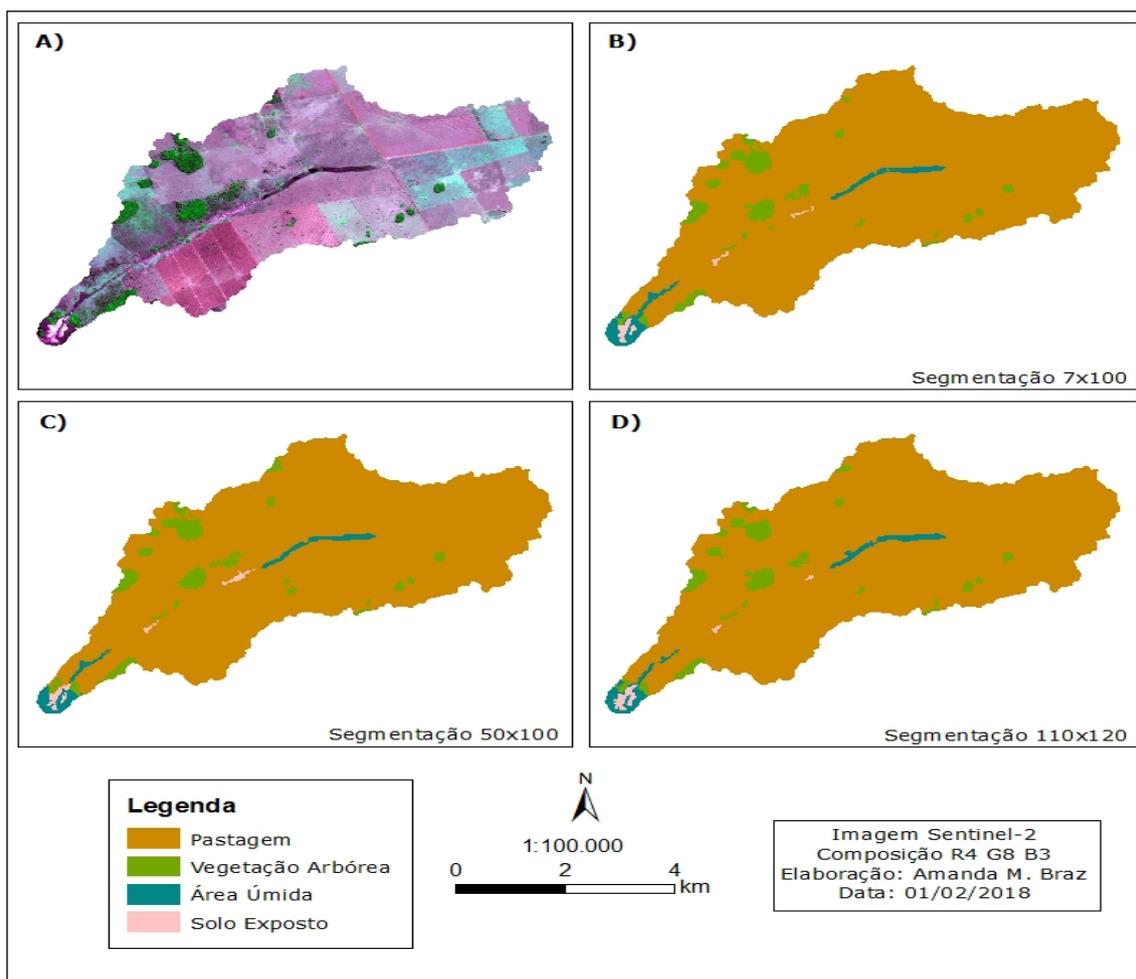
| Classes           | Porcentagem (%) |        |         |
|-------------------|-----------------|--------|---------|
|                   | 7x100 (ideal)   | 50x100 | 110x120 |
| Pastagem          | 92,9            | 99,6   | 99,9    |
| Vegetação Arbórea | 4,4             | 0      | 0       |
| Área Úmida        | 2,1             | 0,3    | 0       |
| Solo Exposto      | 0,6             | 0,1    | 0,1     |

Fonte: Braz (2018).

A classificação com os parâmetros 7x100 mostrou-se satisfatória. A pastagem ocupa grande área da bacia, sendo aproximadamente 92,9%. Em seguida vem a vegetação arbórea, com 4,4%, espalhada de forma fragmentada por todo território e em partes presente nas margens do curso d'água.

Evidentemente, as pastagens tomaram toda a área da bacia ao aplicar os parâmetros adequados para as imagens *Landsat 8* e *Sentinel-2*, totalizando 99,6% e 99,9%, respectivamente. A classe de vegetação arbórea encontra-se ausente em ambas as classificações dos parâmetros 50x100 e 110x120.

Para a classificação da imagem *Sentinel-2*, o parâmetro de segmentação que melhor se adequou foi de similaridade 110 e área (*pixels*) 120 (Figura 4).



Fonte: Braz (2018).

**Figura 4.** Mosaico das classificações da imagem *Sentinel-2*

Perante a análise visual, todas as classificações geraram um resultado semelhante, com poucas alterações e satisfatório. O parâmetro 7x100 gerou um total de 452 amostras, o 50x100 gerou 303 e, por fim, o 110x120 gerou 288 amostras (Tabela 10).

**Tabela 10.** Análise quantitativa das amostras geradas e coletadas da imagem *Sentinel-2*

| Parâmetros | Pastagem | Vegetação Arbórea | Solo Exposto | Área Úmida | Total de Amostras |
|------------|----------|-------------------|--------------|------------|-------------------|
| 7x100      | 371      | 48                | 8            | 25         | 452               |
| 50x100     | 231      | 40                | 9            | 23         | 303               |
| 110x120    | 228      | 33                | 7            | 20         | 288               |

Fonte: Autor (2018).

Ao aplicar o método *kappa*, os resultados também foram semelhantes. O *kappa* do parâmetro 7x100, ideal CBERS-4, foi 0,9, e 50x100, ideal *Landsat 8*, foi 1, enquadrando-se na qualidade excelente. Já o parâmetro 110x120, considerado neste trabalho como o parâmetro ideal para a imagem *Sentinel-2*, foi 0,9, também se enquadrando na qualidade excelente (Tabela 11).

**Tabela 11.** Desempenho das classificações da imagem de satélite Sentinel-2

| Parâmetros | Exatidão Global | Índice Kappa | Confusão Média (%) |
|------------|-----------------|--------------|--------------------|
| 7x100      | 99,28           | 0,9          | 0,71%              |
| 50x100     | 1               | 1            | 0,00%              |
| 110x120    | 99,87           | 0,9          | 0,12%              |

Fonte: Braz (2018).

Perante a análise quantitativa das amostras, o parâmetro 7x100 gerou um total de 452 amostras, o 50x100 gerou 303 e o 110x120 gerou 288 (Tabela 12).

**Tabela 12.** Análise quantitativa das amostras geradas e coletadas da imagem Sentinel-2

| Parâmetros | Pastagem | Vegetação Arbórea | Solo Exposto | Área Úmida | Total de Amostras |
|------------|----------|-------------------|--------------|------------|-------------------|
| 7x100      | 371      | 48                | 8            | 25         | 452               |
| 50x100     | 231      | 40                | 9            | 23         | 303               |
| 110x120    | 228      | 33                | 7            | 20         | 288               |

Fonte: Braz (2018).

A análise quantitativa das classes mapeadas registrou a presença da pastagem em 93,0% ao aplicar os parâmetros 110x120, ideal *Sentinel-2*, sendo o maior valor gerado entre os outros parâmetros. Em seguida vem a vegetação arbórea, com 4,4%, área úmida com 2,0% e solo exposto, menor valor, com 0,6% (Tabela 13).

**Tabela 13.** Análise quantitativa das classes mapeadas da imagem de satélite *Sentinel-2* a partir da segmentação 7x100; 50x100 e 110x120

| Classes           | Porcentagem (%) |        |                 |
|-------------------|-----------------|--------|-----------------|
|                   | 7x100           | 50x100 | 110x120 (ideal) |
| Pastagem          | 92,9            | 92,8   | 93,0            |
| Vegetação Arbórea | 4,5             | 4,6    | 4,4             |
| Área Úmida        | 2,2             | 2,1    | 2,0             |
| Solo Exposto      | 0,4             | 0,5    | 0,6             |

Fonte: Braz (2018).

Ao analisar o desempenho dos parâmetros, nota-se que os resultados quantitativos das classes mapeadas são semelhantes em todos os parâmetros estabelecidos, gerando produtos finais satisfatórios.

## CONSIDERAÇÕES FINAIS

Para os processos de segmentação e classificação, resultando em mapeamentos de uso e cobertura da terra, gerados neste trabalho, as ferramentas disponibilizadas pelo SIG *Spring* mostraram-se satisfatórias ao longo do desenvolvimento do trabalho.

Cada imagem de satélite possui suas características particulares, que se expressam em diferentes resoluções espaciais e radiométricas (principais características que influenciaram no PDI adotado neste trabalho), portanto, os parâmetros estabelecidos para o processo de segmentação devem ser tratados com atenção.

Por isso, há uma notória importância de que o analista (operador do sistema) tenha um mínimo de conhecimento a respeito do sensor escolhido, bem como dos aspectos da área que será classificada. Destaca-se neste ponto, não há um parâmetro ideal para a segmentação, portanto testes antecedentes à classificação são indispensáveis para um produto final de qualidade.

Nota-se que a imagem CBERS-4, que possui 5m de resolução espacial, demonstrou resultado insatisfatório e incorreto ao se aplicar parâmetros de segmentação altos, adequados para as outras imagens, havendo um exagero na classe de pastagem, na qual foi tomada toda a área da bacia.

A hipótese aqui apresentada é para a diferença entre resolução radiométrica e, principalmente, resolução espacial. Isso ocorre, pois, as imagens do sensor PAN do satélite CBERS-4 foram as que apresentaram maior resolução espacial (5m, contra 10m do MSI e 15m do OLI), justificado também pelos parâmetros de segmentação mais elevados nas imagens do *Landsat 8* e *Sentinel-2*.

Nota-se que o índice de acurácia *kappa* entendeu que a classificação da imagem CBERS-4 foi satisfatória, apesar de errada, pois ao aplicar os parâmetros de segmentação altos, gerou poucas amostras e não houve confusão de classes e ausência de classes que deveriam estar presentes na bacia.

Isso pode se tornar um erro ainda maior, pois sem as devidas considerações e apoiando-se apenas no teste estatístico, corre-se o risco de gerar afirmações improcedentes. Os testes estatísticos são ótimos métodos e comprovados para avaliar a qualidade de inúmeras análises, mas que devem ser realizados com os devidos cuidados, principalmente no que tange ao conhecimento do objeto de estudo. Já as imagens *Landsat 8* e *Sentinel-2* apresentaram resultados satisfatórios com todas as segmentações testadas.

Parte-se da hipótese de que os parâmetros mais altos (50x100 – *Landsat8* e 110x120 – *Sentinel-2*) se adequaram melhor entre estas imagens devido principalmente às suas resoluções radiométricas, tendo a *Landsat-8* 16bits e a *Sentinel-2* 12bits, enquanto a CBERS-4 possui o sensor PAN com apenas 8bits, tendo a menor capacidade de diferenciação de níveis de informação da imagem, ou seja, as imagens com 12bits possuem maior riqueza de informações.

Por fim, obtivemos resultados os quais podem ser comparados e oferecer maior seguridade e clareza na escolha dos algoritmos para os mapeamentos temáticos.

## NOTA

5 O classificador *Bhattacharya* é um algoritmo de classificação supervisionada por regiões onde requer a seleção de áreas de treinamento, podendo utilizar as regiões separadas durante o processo de segmentação ou polígonos representativos das regiões a serem classificadas (SANTOS, PELUZIO; SAITO, 2010).

## REFERÊNCIAS

- BRAZ, A. M. **Geotecnologias aplicadas na análise das implicações entre o uso, cobertura e manejo da terra e a qualidade das águas superficiais: bacias hidrográficas dos córregos Lajeado Amarelo e Ribeirãozinho, Três Lagoas/MS**. 2017. 287f. Dissertação (Mestrado em Geografia) - Universidade Federal do Mato Grosso do Sul, Três Lagoas, 2017.
- CAMARA, G. et al. Spring: Integrating remote sensing and GIS by object-oriented data modelling. **Computers & Graphics**, v. 20, n. 3, p. 395-403, May-Jun 1996.
- CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Lewis Publishers, 1998. 137p.
- COUTINHO, A. C. **Segmentação e classificação de imagens Landsat-TM para o mapeamento dos usos da terra na região de Campinas, SP**. 150 f. 1997. Dissertação (Mestrado em Ciências) - Pós-Graduação em Ciências, Departamento de Ecologia Geral do Instituto de Biociências, Universidade de São Paulo, São Paulo, 1997.
- CRÓSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. Campinas: IG/UNICAMP, 1993. 170 p.
- EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA, EMBRAPA. **Satélites de Monitoramento**. Campinas: Embrapa Monitoramento por Satélite, 2013. Disponível em: <<http://www.sat.cnpm.embrapa.br>>. Acesso em: 01 out. 2017.
- ENGESAT. **Engesat: soluções em imagens de satélite e geoprocessamento**. 2017. Disponível em: <<http://www.engesat.com.br/sentinel-2/>>. Acesso em: 01 out. 2017.
- EPIPHANIO, J. C. N. CBERS-3/4: características e potencialidades. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO – SBSR, 15., 2011, Curitiba/PR. **Anais [...]**. Curitiba/PR, INPE, 2011, p. 9009-9016.
- FERREIRA, E.; DANTAS, A. A. A.; MORAIS, A. R. Exatidão na classificação de fragmentos de matas em imagem do satélite Cbers-CCD, no município de Lavras, MG. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais [...]**. Florianópolis: INPE, 2007, p. 887-894.
- GONZALES, R. C.; WINTZ, P. **Digital image processing**. Boston: Prodding, Addison Wesley, 1987.
- INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS, INPE. **CBERS**. 2014. Disponível em: <[http://www.cbbers.inpe.br/sobre\\_satelite/cameras\\_imageadoras\\_cbbers3e4.php](http://www.cbbers.inpe.br/sobre_satelite/cameras_imageadoras_cbbers3e4.php)>. Acesso em: 01 out. 2017.
- LEÃO, C. et al. Avaliação de métodos de classificação em imagens TM/Landsat e CCD/CBERS para o mapeamento do uso e cobertura da terra na região costeira do extremo

- sul da Bahia. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais** [...]. Florianópolis: INPE, 2007, p. 939-946.
- MENDONÇA, L. E. R. et al. Mapeamento do uso da terra baseado em imagem Ikonos II com a utilização de algoritmos classificadores por pixels e por regiões. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais** [...]. Florianópolis: INPE, 2007, p. 603-610.
- OLIVEIRA, J. C. Índice para avaliação de segmentação (IAVAS): uma aplicação em agricultura. 2002. 160 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2002.
- PROCESSAMENTO DIGITAL. **Métodos para pesquisa e download de imagens de satélite Sentinel-2**. Sentinel-2, 29 de agosto de 2016. Disponível em: <<http://www.processamentodigital.com.br/2016/08/29/metodos-para-pesquisa-e-download-de-imagens-de-satelite-sentinel2/>>. Acesso em: 01 out. 2017.
- SANTOS, A. R.; PELUZIO, T. M. O.; SAITO, N.S. **SPRING 5.1.2**: passo a passo: aplicações práticas. Alegre: CAUFRES, 2010. 153p.
- SILVA, V. M. **Classificação de imagens por sensoriamento remoto**: análise comparativa das metodologias pixel a pixel e segmentação por região. 2014. 41 f. Trabalho (Conclusão de Curso) - XV Curso de Especialização em Geoprocessamento, Instituto de Geociências, Universidade Federal de Minas Gerais, Belo Horizonte, 2014.
- USGS. U.S. **Geological Survey**, 2017. Disponível em: <<https://landsat.usgs.gov/what-are-band-designations-landsat-satellites>>. Acesso em: 01 out. 2017.
- VENTURIERI, A.; SANTOS, J. R. dos. Técnicas de classificação de imagens para análise de cobertura vegetal. In: ASSAD, E. D.; SANO, E. E. **Sistema de informações geográficas**. 2. ed. Brasília: Embrapa-SPI; Embrapa-CPAC, 1998, p. 351-371.
- VIEIRA JUNIOR, J. A. **Análise comparativa dos métodos de classificação de imagem de alta resolução para mapeamento da cobertura do solo**. 32 f. 2011. Trabalho (Conclusão de Curso) - XIII Curso de Especialização em Geoprocessamento, Instituto de Geociências, Universidade Federal de Minas Gerais, Belo Horizonte, 2011.