

CLASSIFICAÇÃO E IDENTIFICAÇÃO DE LAGOAS UTILIZANDO GEOBIA E MINERAÇÃO DE DADOS: UM EXEMPLO APLICADO AO PANTANAL DA NHECOLÂNDIA (MS)

Adalto Moreira Braz

Universidade Federal de Goiás/Regional Jataí (UFG/REJ)

adaltobraz.geografia@gmail.com

Paola Vicentini Boni

Universidade Federal de Mato Grosso do Sul/Campus Três Lagoas (UFMS/CPTL)

paolavicentiniboni@gmail.com

Amanda Moreira Braz

Universidade Federal de Mato Grosso do Sul/Campus Três Lagoas (UFMS/CPTL).

amandabraz.geo@gmail.com

José Roberto Amaro Mantovani

Universidade Federal de Goiás/Instituto de Estudos Socioambiental (UFG/IESA)

jr.mantovani.geo@gmail.com

Ivanilton José de Oliveira

Universidade Federal de Goiás/Instituto de Estudos Socioambiental (UFG/IESA)

ivanilton.oliveira@gmail.com

Resumo

Avanços recentes com relação ao sensoriamento remoto e técnicas de mapeamento por imagens digitais, desafiam pesquisadores a buscarem novas técnicas de exploração, cada vez mais inteligentes para processamento e classificação de imagens. O artigo em questão trata da análise de imagens baseada em objetos geográficos (*GEographic-Object-Based Image Analysis* – GEOBIA) em conjunto com a técnica de mineração de dados. Foi escolhida uma área de teste, contendo 2.543,82km² no Sul do Pantanal da Nhecolândia. O trabalho, de caráter experimental, teve por objetivo avaliar parâmetros e características de atributos espectrais e espaciais para definir padrões de classificação das lagoas no Pantanal da Nhecolândia, por meio de árvore de decisão aplicando GEOBIA e mineração de dados utilizando o SIG TerraView e o módulo *Geographic Data Mining Analyst* (GeoDMA). Utilizou-se imagens do satélite Sentinel-2, sensor MSI imageadas em 22/05/2018 com resolução espacial de 10m. A classificação apresentou o rigor esperado e resultados satisfatório com relação aos elementos que compõem a paisagem. Tais resultados se mostraram igualmente importantes, de acordo com os procedimentos utilizados, para o mapeamento do uso e cobertura da terra e na identificação de lagoas no Pantanal da Nhecolândia.

Palavras-chave: Processamento Digital de Imagens (PDI); classificação orientada a objeto; GEOBIA; mineração de dados; Pantanal.

POND CLASSIFICATION AND IDENTIFICATION USING GEOBIA AND DATA MINING: AN EXAMPLE APPLIED TO THE NHECOLÂNDIA PANTANAL (MS)

Abstract

Recent advances in remote sensing and methods of digital image map production, along with ever-increasing spatial details, challenge researchers to seek out new and increasingly intelligent exploration techniques. This article deals with geographic-object-based image analysis (GEOBIA) together with the data mining technique. A test area was chosen containing 2.543,82 km² in the Southern Pantanal of Nhecolândia. The objective of this experimental work was to evaluate spectral and spatial attributes parameters and characteristics to define classification patterns of the lagoons in the Pantanal of Nhecolândia, by means of a decision tree applying GEOBIA and data mining using the TerraView GIS software and the Geographic Data Mining Analyst (GeoDMA) module. Images of the Sentinel-2 satellite, MSI sensor imaged on 05/22/2018 with 10m spatial resolution were used. The classification presented the expected rigor and satisfactory results in relation to the elements that compose the landscape. These results were equally important, according to the procedures used, for the land use and land cover mapping and for lagoons identification in the Pantanal of Nhecolândia.

Key words: Digital Image Processing (DIP); object-oriented classification; GEOBIA; data mining; Pantanal.

CLASIFICACIÓN E IDENTIFICACIÓN DE ESTANQUES USANDO GEOBIA Y MINERÍA DE DATOS: UN EJEMPLO APLICADO AL NHECOLÂNDIA PANTANAL (MS)

Resumen

Avances recientes en relación con la teledetección y las técnicas de cartografía por imágenes digitales, juntamente con detalles espaciales siempre crecientes, desafían a los investigadores a buscar nuevas técnicas de exploración, cada vez más inteligentes. El artículo científico en cuestión trata del análisis de imágenes basada en objetos geográficos (GEOBIA) juntamente con la técnica de minería de datos. Se eligió un área de prueba, teniendo 2.543,82km² en el sur del Pantanal de Nhecolândia. El trabajo experimental, tuvo por objetivo evaluar los parámetros y características de atributos espectrales y espaciales para definir patrones de clasificación de las lagunas en el Pantanal de Nhecolândia, por medio del árbol de decisiones aplicando GEOBIA y minería de datos utilizando el SIG TerraView y el módulo *Geographic Data Mining Analyst* (GeoDMA). Se utilizaron imágenes del satélite Sentinel-2, sensor MSI, con imágenes en 22/05/2018 con resolución espacial de 10m. La clasificación presentó el rigor esperado y resultados satisfactorios con relación a los elementos que componen el paisaje. Los resultados se mostraron igualmente importantes, de acuerdo con los procedimientos utilizados, para el mapeo del uso y cobertura de la tierra y en la identificación de las lagunas en el Pantanal de Nhecolândia.

Palabras-clave: Procesamiento Digital de Imágenes (PDI); clasificación orientada a objetos; GEOBIA; minería de datos; Pantanal.

Introdução

A utilização de sistemas computacionais para tratar informações geográficas teve início com o advento dos primeiros computadores, ainda em meados da década de 1960. Os primeiros Sistemas de Informações Geográficas (SIG) começaram a surgir entre as décadas 1960 a 1970. Concomitantemente, o sensoriamento remoto se desenvolvia pelas já tradicionais técnicas de fotogrametria e pelas, até então inovadoras, plataformas orbitais. Com isso, as imagens passaram a demandar processamentos e conversões em informações tangíveis para uma gama ainda maior de aplicações (BLASCHKE, 2010; NAMIKAWA,

2012; BRAZ, 2017). A crescente disponibilidade de dados de sensoriamento remoto tem incentivado a aplicação destes dados e novas tecnologias para seu processamento no estudo das paisagens naturais (BERTANI et al., 2010).

Avanços recentes com relação ao sensoriamento remoto e técnicas de mapeamento por imagens digitais, juntamente com detalhes espaciais sempre crescentes, desafiam pesquisadores a buscarem novas técnicas de exploração, cada vez mais inteligentes. A palavra inteligência, neste contexto, possui alguns aspectos como: 1) uma maneira avançada para delinear, por meio de supervisão e categorização de unidades espaciais; 2) o modo como o conhecimento é implícito ou uma experiência integrada; 3) o grau em que os dados de saída (resultados) estão contribuindo para um aumento de conhecimento e melhor compreensão dos conteúdos complexos de uma imagem (LANG, 2008).

Assim, o artigo em questão trata especificamente de um dos últimos ciclos da geoinformação, a análise de imagens baseada em objetos geográficos (*GEographic-Object-Based Image Analysis* – GEOBIA) em conjunto com a técnica de mineração de dados.

Até então, uma das abordagens mais usadas era a classificação pixel-a-pixel, atualmente tendo seus resultados questionados pelo que ficou conhecido como efeito “sal e pimenta”. Conforme o melhoramento da resolução espacial e radiométrica, as imagens passam a conter mais texturas e os pixels individuais apresentam unidades que são pouco informativas. Com a abordagem de segmentação, há uma melhoria confirmada com relação ao sinal/ruído dos pixels. A análise de objetos de imagem resulta em classificações melhores, principalmente porque deixam sofrer com o efeito “sal e pimenta” dos resultados provenientes de abordagens baseadas estritamente em pixels (PILZ e STROBL, 2007).

O paradigma do pixel está começando a mostrar rachaduras e os métodos GEOBIA estão fazendo progressos consideráveis em direção a um fluxo de trabalho de extração de informações espaciais, necessárias ao planejamento, bem como para muitos programas de monitoramento (BLASCHKE, 2010, p. 2).

Antes da GEOBIA, a tarefa principal da segmentação de imagens era produzir um conjunto de segmentos não sobrepostos (polígonos). Durante alguns anos, a etapa de segmentação foi bastante separada da etapa de classificação, por vezes, entendidas como procedimentos distintos e não complementares (BLASCHKE, 2010)

A segmentação é uma tarefa básica na análise de imagens em que estas são divididas em regiões relativamente homogêneas cujas áreas possuem propriedades similares, por exemplo, níveis de cinza, valores médios ou propriedades texturais (BINS et al., 1996)

A GEOBIA cresceu rapidamente, junto da capacidade de processamento dos SIG por volta do ano 2000 como uma alternativa às abordagens anteriormente usadas para classificação de imagens, a abordagem pixel-a-pixel e da segmentação de imagens. Foi concebida como uma técnica baseada em objetos com o objetivo de delinear alvos (objetos) em imagens, combinando sensoriamento remoto e geoprocessamento (através de SIG). A GEOBIA utiliza informações espectrais e contextuais de forma integrativa para a detecção de objetos (geoespaciais) e classificação de imagens. Ou seja, além da pura informação espectral, os objetos segmentados nas imagens são caracterizados também por vários recursos complementares, como textura e forma. Estas informações adicionais dificilmente poderiam ser exploradas usando as abordagens baseadas exclusivamente na análise dos pixels (BAATZ e SCHÄPE, 1999; BLASCHKE, 2010).

O termo GEOBIA é:

Um ramo de Ciência da Informação Geográfica (*GIScience* ou Geoinformação) dedicada ao desenvolvimento de métodos automatizados para particionar imagens de sensoriamento remoto em objetos espaciais significativos, e avaliar suas características através de escalas espaciais, espectrais, temporais e gerar novas informações geográficas (HAY e CASTILLA, 2008, p. 77).

Junto com as novas possibilidades trazidas pela GEOBIA, surgiram também novos e grandes volumes de dados a serem analisados. Esta necessidade emergiu, em muito, devido à baixa capacidade de analisar muitos dados, diversos atributos e diferentes fontes. A respeito disso, Fayyad, Shapiro e Smyth (1996) afirmam que a nossa capacidade de análise e compreensão de grandes conjuntos de dados ficam atrás da nossa capacidade de coleta e armazenamento de dados. Com isso, uma nova geração de ferramentas e técnicas computacionais se tornou necessária para extrair conhecimentos úteis de volumes de dados cada vez maiores. Dentre elas, surgiu então a mineração de dados.

A mineração de dados é uma etapa para extrair padrões (modelos) de dados [...] como preparação de dados, seleção de dados, limpeza de dados, incorporação de conhecimento prévio apropriado e interpretação adequada dos resultados da mineração, que garantem que o conhecimento útil seja derivado dos dados (FAYYAD, SHAPIRO e SMYTH, 1996, p. 29).

A mineração de dados pode aumentar o potencial da análise de dados no campo do sensoriamento remoto. As técnicas de mineração selecionam atributos representativos para classes de interesse e regras gerais para sua classificação. Técnicas de seleção de atributos de imagens se tornaram-se atraentes para classificações e mapeamentos devido a centenas de

atributos espaciais, texturais e geométricos disponíveis na GEOBIA. Assim, a mineração de dados pôde, de fato, aumentar o potencial de análise de dados espaciais e estratégicos de maior complexidade (KÖRTING et al., 2008; RIBEIRO e FONSECA, 2013).

O desenvolvimento das novas gerações de sensores nos últimos 20 anos consolidou as imagens de sensoriamento remoto como uma importante fonte de dados para estudos ambientais e fenômenos geográficos em larga escala. Cresceu a variedade de sensores (gratuitos e comerciais), suas características como as resoluções (espacial, temporal, radiométrica e espectral) e a disponibilidade das imagens de sensoriamento remoto. Apesar da grande experiência em coleta, armazenamento e distribuição de imagens e da diversidade de ferramentas computacionais para processamento e análise ainda é difícil de se encontrar sistemas que apresentem um ambiente integrado para transformar imagens em informações úteis (KÖRTING, 2012).

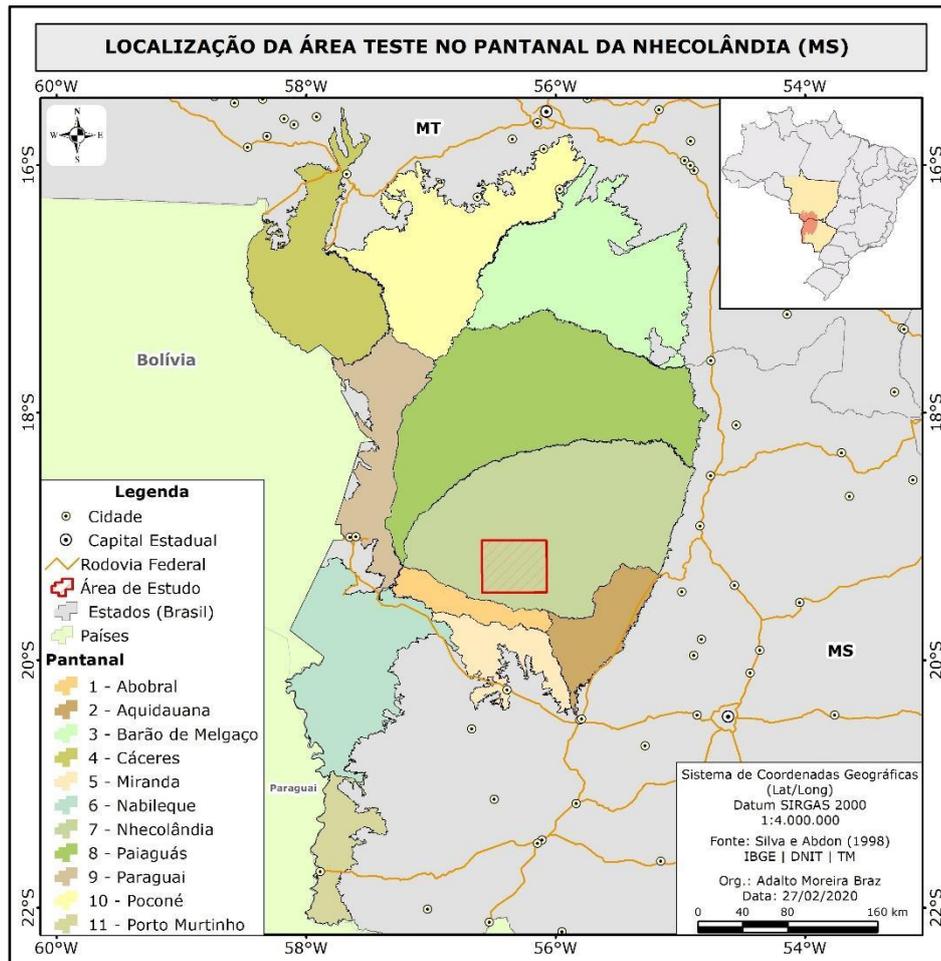
Uma das alternativas é o SIG TerraView e a extensão GeoDMA (*Geographical Data Mining Analyst*). Apesar da ampla exploração na classificação e mapeamento de elementos naturais, ainda são recentes os estudos que tem aplicado metodologias de alto desempenho para identificar padrões de distribuição de elementos naturais e definir parâmetros e características de classificação de imagens baseadas em objetos geográficos.

O objetivo deste trabalho consta na avaliação do desempenho de algoritmos de classificação, em caráter experimental, aplicando técnicas de GEOBIA e mineração de dados para classificação e identificação de lagoas em uma “área teste”, no Pantanal da Nhecolândia (MS), no Centro-Oeste do Brasil.

Área de estudo

Foi escolhida uma área de teste, contendo 2.543,82km² no Sul do Pantanal da Nhecolândia (Figura 1). A Nhecolândia é uma das 11 sub-regiões que formam o complexo do Pantanal brasileiro, definida por Silva e Abdon (1998). Esta região é bastante conhecida por compreender um sistema lacustre formado por lagoas (salinas, salitradas e baías), na qual as baías de água doce periodicamente se conectam com os rios e as salinas se encontram fora do alcance das cheias e permanecem quase sempre isoladas (ABDON, POTT e SILVA, 1995).

Figura 1. Localização da área teste no Pantanal da Nhecolândia (MS).



Fonte: Autor (2021).

É também na Nhecolândia, que o Pantanal apresenta características peculiares quanto a sua morfologia e hidrologia. A região é formada pelas lagoas, vazantes, corixos, banhados e cordilheiras, numa paisagem que apresenta formas variadas (SAKAMOTO et al., 1995).

As baías ou lagoas são porções deprimidas, com água às vezes salobras, com variadas formas interligadas por vazantes nas cheias: estas são longas depressões suaves, e que configuram um sistema de drenagem anastomosado e não hierarquizado. [...] A peculiaridade dessa paisagem, além do caráter intermitente das cheias e secas nas vazantes e baías, reside no contraste entre a qualidade das águas das lagoas permanentes e intermitentes (SAKAMOTO et al., 1995, p. 109).

Conforme Bertani et al. (2010) e Boni (2017), o Pantanal da Nhecolândia possui uma das paisagens naturais que mais estimulam estudos nesta região, influenciada pela gênese e comportamento de lagoas que ali se encontram. Assim, na região da Nhecolândia apresentam-se diversos estudos detalhados e isso se dá muito em função do interesse

científico sobre estas lagoas do Pantanal. Também por isso, o objetivo deste trabalho perpassa pela identificação das lagoas numa determinada área na Nhecolândia.

Principalmente na região da Nhecolândia, o Pantanal é um verdadeiro mosaico de lagoas, rios e corixos, canais por onde a água das lagoas escoam rumo aos rios. Essas lagoas podem ter água doce ou salobra, alcalinas. São conhecidas como baías e salinas, respectivamente. As primeiras costumam ter vegetação até sua borda, formada por brejos ou por verdadeiras matas de carandazais (*Corpenicia australis*), enquanto as outras apresentam comumente uma faixa de praia arenosa, desprovida de vegetação. As baías são ricas em peixes e outros animais, enquanto as salinas, não. A água alcalina dessas salinas parece impedir a vida de plantas e animais (COUTINHO, 2016, p. 84).

Galvão et al. (2003b) complementam a caracterização das lagoas afirmando que tanto sua origem quanto os mecanismos que controlam a concentração de íons ainda não são completamente compreendidos. Os autores afirmam que lagoas de água doce (baías) podem se juntar a corpos d'água maiores, de formas irregulares durante as enchentes ou em períodos de níveis mais alto da água (em geral, de outubro a março). No período de recuo da água (abril a junho) ou da estação seca (julho a setembro), elas podem recuperar suas formas, ou ainda, secar completamente durante secas mais severas.

Algumas lagoas apresentam grande diversidade de plantas e fauna aquática, além de contribuir para o fornecimento de água e alimentos para seres humanos e animais, tornando-se uma fonte natural de sal para o gado. Ambos os tipos de lagoas têm um papel fundamental enquanto habitats temporários ou únicos para várias espécies nativas de mamíferos, répteis e aves aquáticas (GALVÃO et al., 2003b).

As baías podem ser alimentadas tanto pela água das chuvas quanto pelas águas subterrâneas, em períodos muito úmidos. São nas baías também que frequentemente ocorrem a vegetação aquática. Já nas salinas, geralmente as águas são perenes devido à presença de depósitos de sais impermeáveis ao nível da água (BERTANI et al., 2010).

Com relação às chamadas lagoas salitradas, estas representam a transição entre as salinas de água salgada ou salobra e as baías de água doce. E a principal diferença entre os demais sistemas lacustres é por não conter área de praia no seu entorno, apenas gramíneas, seguido de vegetação arbustiva e depois cordilheira que não a circunda completamente (SILVA, 2012).

Procedimentos

A área de teste escolhida para a aplicação das técnicas de GEOBIA e mineração de dados está localizada no Sul do Pantanal da Nhecolândia, uma das regiões com a maior concentração de lagoas (salinas, salitradas e baías) do Pantanal brasileiro.

A classificação foi elaborada a partir de imagens do sensor MSI (*MultiSpectral Instrument*) acoplado ao satélite Sentinel-2A, com 10m de resolução espacial. A cena utilizada foi a 21KWU e corresponde à data de 22/05/2018. As bandas escolhidas para a composição colorida foram R8 G4 B3. A banda 8 capta energia no espectro do Infravermelho Próximo (*Near Infrared – NIR*) no comprimento de onda central de 0,842 μ m. A banda 4, do vermelho, corresponde ao espectro do visível e capta energia no comprimento de onda central de 0,665 μ m. Por último, a banda 3 capta energia também no espectro do visível, correspondente ao verde, no comprimento de onda central de 0,560 μ m.

Pelo objetivo de avaliar o potencial das técnicas e de verificar parâmetros de GEOBIA para classificação das lagoas, optou-se pela escolha de apenas três bandas de satélite (3, 4 e 8). Uma das premissas adotadas foi de que as lagoas possuem formas marcantes e que os atributos espaciais poderiam ser hierarquicamente mais importantes para discriminar as lagoas com relação aos atributos espectrais. A justificativa para a escolha das bandas supracitadas, se dá em função das características específicas dos intervalos espectrais captados pelo sensor, que são úteis para o estudo de corpos hídricos e o delineamento entre os limites de água e terra.

De acordo com Novo (1998), a água em estado líquido apresenta reflectância (menor que 10%) em comprimentos de onda na faixa do visível que vão desde 0,38 μ m a 0,70 μ m (Figura 2). Galvão et al. (2003a; 2003b) ao discutirem o uso de dados hiper espectrais no estudo do comportamento de baías e salinas no Pantanal utilizaram dados com comprimento de onda centrados em 0,667 μ m (vermelho), 0,559 μ m (verde) e 0,480 μ m (azul) do sensor *Airborne Visible/Infrared Imaging Spectrometer (AVIRIS)*. Nota-se que os autores, conforme os objetivos propostos, não utilizaram imagens no intervalo do infravermelho próximo.

Já Bertani et al. (2010), para a identificação e mapeamento de lagoas salinas e não-salinas no Pantanal da Nhecolândia por meio de GEOBIA e segmentação multiresolução, utilizaram imagens do satélite Terra, sensor *The Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER)* com resolução espacial de 15m. Para o trabalho, os autores

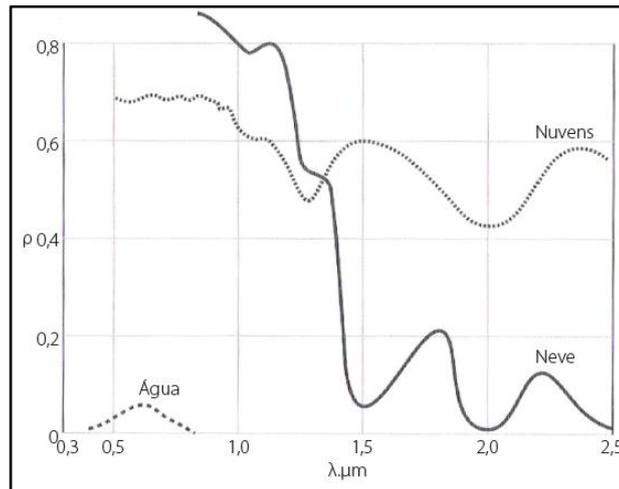
utilizaram apenas bandas no intervalo espectral do vermelho e infravermelho próximo (banda 1: 0,52-0,60 μ m; banda 2: 0,63-0,69 μ m; banda 3: 0,76-0,86 μ m).

Novack et al. (2010) apresentaram o objetivo de identificar lagoas salinas e não-salinas e utilizando imagens do mesmo satélite e bandas que Bertani et al. (2010), porém aplicando um modelo de classificação de imagens a partir de rede semântica utilizando atributos espectrais, geométricos e contextuais no *software* InterImage.

Silva, Silva e Galvão (2013) utilizaram métodos de seleção de atributos para distinguir alvos no Pantanal da Nhecolândia. Para o trabalho, os autores também utilizaram dados do sensor AVIRIS e, na ocasião, afirmaram que as bandas mais relevantes na distinção de alvos de interesse (campo de cerrado, cerrado, lagoa limpa, lagoa salgada, lagoa seca, lagoa vegetada e pastagem) se concentram na região do espectro que abrange parte do visível (0,47 a 0,77 μ m) até parte do infravermelho de ondas curtas ou *Short Wave Infrared Region* (SWIR) entre os intervalos de 1,97 a 2,27 μ m. Todavia, é importante ressaltar que o intervalo espectral mais abrangente considerado pelos autores se dá em função da necessidade de identificar um maior número de alvos e que possuem comportamentos espectrais distintos.

Em outro estudo utilizando sensoriamento remoto para o estudo de corpos hídricos, Galo et al. (2002) afirmou que o infravermelho próximo e infravermelho médio possuem forte absorção da radiação, resultando num forte contraste entre a água e os limites de terra (Figura 2). Daí, inclui-se na proposta apresentada neste artigo, a banda 8 do satélite Sentinel-2, correspondente ao NIR.

Figura 2. Comportamento espectral da água em diferentes estados.



Fonte: Novo (1998) *apud* Bias, Barbosa e Brites (2013).

Uma das diferenças essenciais da GEOBIA e da mineração de dados é a possibilidade de não depender apenas da informação espectral das imagens de satélites.

Além da pura informação espectral, essa informação muitas vezes essencial, pode ser usada junto com as características de forma e textura dos objetos da imagem para melhorar significativamente a classificação [...]. Uma parte básica do procedimento é uma nova técnica para segmentação de objetos que é capaz de encontrar objetos de imagem em qualquer resolução escolhida (estruturas finas ou grosseiras) e alta qualidade (BAATZ e SCHÄPE, 1999, p. 1).

O GeoDMA (KÖRTING et al., 2008; 2009; KÖRTING, 2012; KÖRTING, FONSECA e CÂMARA, 2010; 2013) é um sistema utilizado para mineração de dados integrado ao SIG TerraView (INPE, 2018). O TerraView é um SIG capaz de lidar com bancos de dados espaciais, imagens e regiões resultantes do processo de segmentação, além manipular outros dados geográficos, como por exemplo, dados cadastrais. Já o GeoDMA que é um sistema de mineração de dados, é usado para manipular um grande volume de dados e informações, a partir de técnicas de aprendizado por máquina, que possibilita a extração de padrões dos objetos da segmentação e, com isso, facilita a descoberta de novos conhecimentos (KÖRTING et al., 2009).

O GeoDMA integra técnicas de segmentação de imagens, extração e seleção de atributos e classificação por árvores de decisão, adaptados à mineração de dados espaciais. Ao explorar conjuntamente as características espaciais e espectrais, o sistema também explora o conceito de vizinhança que, intrínseco à análise geográfica, melhora os resultados das classificações (KÖRTING et al., 2008; KÖRTING, 2012).

Assim, após a escolha da área de estudo, recorte da área de teste e composição das bandas do satélite Sentinel-2, aplicou equalizações no histograma da imagem, deixando o ganho em 1.2 e *offset* em 10. Posteriormente, foram definidos parâmetros de segmentação da imagem a partir do algoritmo de crescimento de região médio, usando o valor 70 como tamanho mínimo de segmentos e o limiar de similaridade em 0,004. Após alguns testes de segmentação, estes parâmetros foram os que melhor atenderam às expectativas de delineamento das lagoas em vista de outros objetos na imagem. A segmentação resultou em 158.797 objetos ao longo dos 2.543,82km² da área de teste.

A extração dos atributos foi feita pelo GeoDMA, considerando a imagem de entrada (Sentinel-2A, R8 G4 B3) e as métricas espaciais e espectrais especificadas no quadro 1. Um detalhamento das descrições de cada métrica adotada é disponibilizado por Körting et al. (2013).

Quadro 1. Métricas (espaciais e espectrais) exploradas para a classificação.

Métricas Espectrais	Métricas Espaciais
Amplitude	Área
Média	Perímetro
Soma de pixels no objeto	Dimensão Fractal
<i>Skewness</i> dos pixels no objeto	Relação entre perímetro e área do objeto
Modo (nível de cinza mais comum)	Área da caixa delimitadora do objeto
Contraste de intensidade	Perímetro da caixa delimitadora do objeto
Dissimilaridade	Ângulo
Entropia	Elipse Mínima
Homogeneidade	Distância média entre vértice e centroide do objeto
Mediana	
Desvio padrão	Raio
Contagem de pixels no objeto	Círculo
Variância	

Fonte: Modificado de Körting et al. (2013); INPE (2018).

As métricas foram coletadas para todas as bandas (3, 4 e 8) e definidas de acordo com as premissas adotadas pelos autores, conforme sua possível influência para a classificação das lagoas. Observa-se que há um número maior de métricas passíveis de extração pelo sistema, mas que não foram consideradas relevantes para o objetivo deste trabalho.

Definiu-se, previamente, que a classificação se basearia em duas classes, as “lagoas”, englobando salinas, salitradas e baías e a classe “outros”, envolvendo todos os outros elementos contidos na imagem (pastagem, vegetação campestre e arbórea, praias, etc.). Como o objetivo proposto foi o de identificar e classificar as lagoas, não houve a necessidade de

criar outras classes e escolher mais métricas para discriminar outros elementos (naturais ou antrópicos). Assim, com as métricas extraídas para todos os objetos da segmentação, iniciou-se a coleta das amostras (*sample*), distribuídas entre 482 amostras coletadas para a classe “lagoa” e 573 amostras para a classe “outros”.

A classificação foi realizada pelo algoritmo C5.0 integrado ao GeoDMA, onde primeiramente criou-se a árvore de decisão e, posteriormente realizou-se a classificação. O resultado se deu por um mapa de padrões com objetos classificados entre “lagoas” e “outros”.

Com relação à mineração de dados para a criação da árvore de decisão, o algoritmo C5.0 usou os seguintes critérios para os atributos extraídos (Tabela 1):

Tabela 1. Critérios para os atributos extraídos pelo GeoDMA.

Atributo	Relevância
Mediana da Banda 8	100%
Relação entre perímetro e área do objeto	64,36%
Entropia da Banda 4	54,69%
Entropia da Banda 8	51,95%
Perímetro da caixa delimitadora do objeto	2,74%
Skewness dos pixels no objeto da Banda 4	2,60%

Fonte: Autores (2018).

A validação de qualidade da classificação foi feita por meio da exatidão global e do índice Kappa, proposto por Congalton e Green (2009), utilizando o SIG ArcGIS 10.4.1 e o *software* de planilhas Excel 2016.

para a classe “lagoa” e 248 para a classe “outros”. Para a validação, não se considerou pontos de verdade sobre as amostras de treinamento coletadas para a classificação. Os pontos de verdade terrestre foram obtidos junto da interpretação visual da imagem de entrada (Sentinel-2, R8 G4 B3). O cálculo do índice é dado pela Equação 1.

$$K = \frac{\sum_{i=1}^k ni - \sum_{i=1}^k ni + ni}{n^2 - \sum_{i=1}^k ni + ni} \quad (1)$$

A exatidão global é representada pela equação 2:

$$EG = \frac{D}{T} \quad (2)$$

Para fins de representação de um modelo de amostragem multinomial, é possível representar o cálculo pela Equação 3.

$$K = \frac{D-Q}{T-Q} \quad (3)$$

Onde: Q – é a soma da multiplicação dos totais dividido pelo total de amostras; Σ – somatório; n_i+n_i – soma das linhas da matriz de confusão somados à soma das colunas da matriz de confusão; k – número de categorias presentes na matriz de confusão; T – total de amostras; D – soma das diagonais principais da matriz de confusão; K – índice Kappa (BRAZ et al., 2017).

A matriz de confusão é dada pela tabela 2, enquanto os intervalos de aceitação para os resultados do índice Kappa, definidos por Congalton e Green (2009) é dado pela Tabela 3.

Tabela 2. Intervalo de aceitação para os resultados do índice Kappa.

Classe	Lagoa	Outros	Total Linhas
Lagoa	149	13	162
Outros	3	235	238
Total Colunas	152	248	800

Fonte: Adaptado de Congalton e Green (2009).

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

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

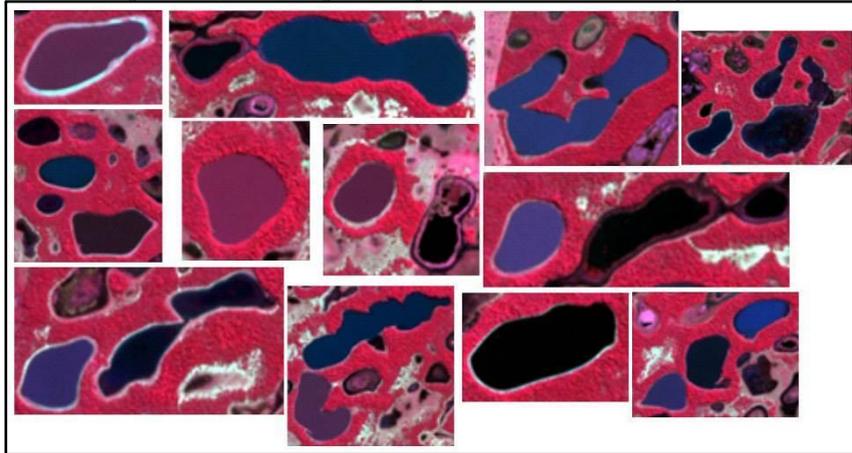
Fonte: Adaptado de Congalton e Green (2009).

Por fim, elaborou-se os mapas de localização e de uso e cobertura da terra para representar as lagoas no Pantanal da Nhecolândia. Os mapeamentos foram elaborados também pelo ArcGIS 10.4.1.

Resultados e discussão

Há algumas diferenças que distinguem as lagoas entre baías, salitradas e salinas, como a presença de praias, as suas formas, sua dinâmica hidrológica e as composições química e biológica, passíveis de interpretação por dados de sensoriamento remoto (Figura 3). O propósito adotado para a classificação de todas as lagoas se preocupou em discriminar estes elementos naturais a partir de métricas espectrais e espaciais por meio de imagem de satélite multiespectral.

Figura 3. Exemplos feições e resposta espectral de diferentes lagoas no Pantanal.



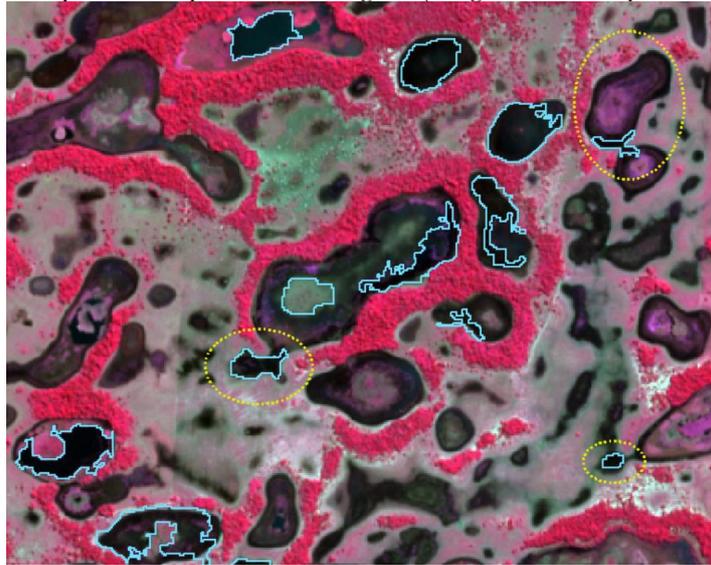
Fonte: Autores (2018).

A classificação apresentou o rigor esperado com relação aos elementos presentes na paisagem, bem como na sua representação na imagem de satélite adotada. A validação de qualidade da classificação foi considerada razoável, apresentando exatidão global de 71 (quando 0 representa a pior exatidão e 100 representa a melhor exatidão) e índice Kappa de 0,70. Há algumas hipóteses levantadas para a questão de a validação não ter sido excelente, conforme estabelecido por Congalton e Green (2009).

A primeira delas é o fato da sazonalidade das lagoas, especialmente das baías, manifestadas na imagem de satélite quando muitas estavam sem água (caracterizando-se por áreas úmidas) ou com pouca água (resultando em falsos positivos). Sakamoto et al. (1995) identificaram em seus trabalhos de campo, que durante as cheias todas as lagoas ficam inundadas e se mantêm interligadas através das vazantes ou pequenos canais rasos. Já as salinas são as últimas a secarem e por estarem numa depressão (mais baixa que o seu entorno), recebem águas do lençol freático nos períodos de estiagem, ajudando a se manterem cheias em boa parte das estações.

Acredita-se que esse foi um dos fatores que possam ter dificultado a identificação, visto que a GEOBIA considera também os atributos espaciais e várias dessas lagoas secas preservaram-se em suas formas características. Assim, os objetos da segmentação permaneceram com atributos espaciais semelhantes às das lagoas ainda cheias (Figura 4).

Figura 4. Exemplos falsos positivos em lagoas (integralmente ou parcialmente) secas.



Fonte: Autores (2018).

Aqui cabe ressaltar também, que o que se considerou para a classificação de lagoas, foram os elementos que continham água. Uma das maneiras que podem minimizar essa possível confusão é considerar incluir a classe de áreas úmidas na classificação, o que ressaltaria ainda mais os atributos espectrais para diferenciar lagoas cheias e secas. Lagoas (baías, salinas ou salitradas) sem água, não foram consideradas para a classificação.

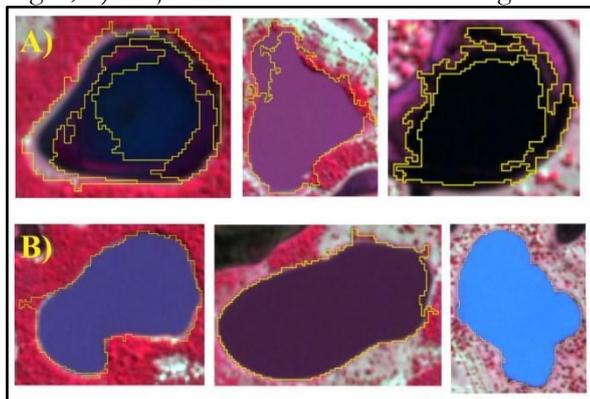
Situação semelhante foi observada por Bertani et al. (2010), quando os autores informaram que as imagens ASTER utilizadas haviam sido obtidas no período seco, quando algumas lagoas apresentavam déficit hídrico e não puderam ser identificadas. Tal situação provoca a redução do tamanho do corpo d'água e, conseqüentemente aumenta a dificuldade de segmentação das lagoas. Pois ao mesmo tempo que continuam preservando seus limites com relação aos objetos vizinhos.

Outra dificuldade mencionada pelos autores supracitados, são em relação às lagoas de alta salinidade, que tendem a ser perenes com relação às lagoas de água doce (preenchidas apenas na estação úmida). Com isso, as lagoas que secam continuam apresentando possibilidade de serem interpretadas como antigas lagoas de água doce (BERTANI et al., 2010).

Outra possível barreira encontrada na classificação foi com relação às bordas das lagoas. Mesmo com a preocupação de selecionar uma segmentação que valorizasse objetos que melhor delimitassem as lagoas, vários objetos da segmentação eram divididos entre o centro (espectralmente mais homogêneo) e as bordas (com a mistura dos pixels). Isso acaba

por influenciar nos atributos espaciais dos objetos. Os objetos do centro das lagoas possuem forma característica das lagoas, já os objetos da borda, possuem formas diversas, de acordo com a homogeneidade dos pixels que os influenciaram (Figura 5).

Figura 5. Objetos gerados para as lagoas. A) Múltiplos objetos dividindo as bordas e o centro da lagoa; B) Objetos únicos delimitando a lagoa.



Fonte: Autor (2018).

As lagoas menores em tamanho, por vezes, também participaram de confusões. Devido a escala de mapeamento proporcionada pela resolução espacial da imagem de satélite, mesmo utilizando parâmetros para uma segmentação refinada, foi possível identificar lagoas de menor porte que não foram segmentadas corretamente e, por isso, falharam também na sua classificação. Avaliar novos parâmetros podem colaborar para atenuar esta situação.

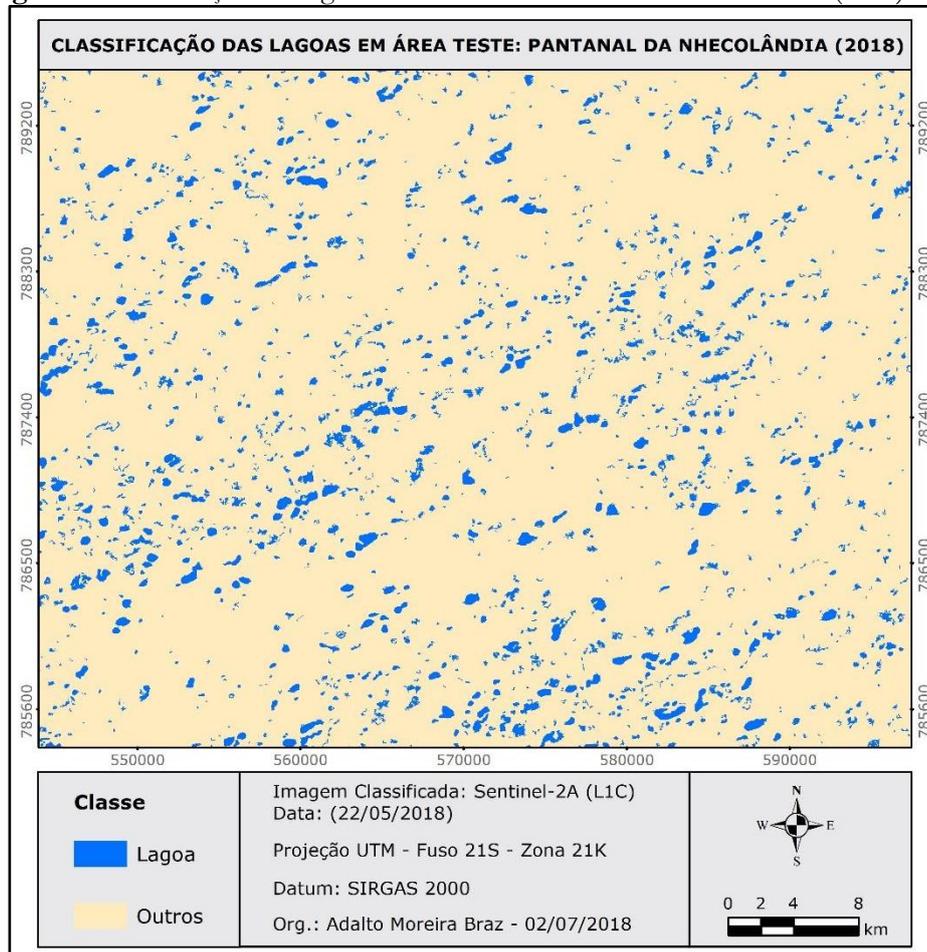
Por fim, é possível fazer um paralelo com o trabalho de Novack et al. (2010). Os autores utilizaram GEOBIA para também avaliar a classificação de lagoas no Pantanal. Salvo as diferenças entre sistemas, imagens, parâmetros, alguns dos objetivos e o não uso da mineração de dados, os autores chegaram a resultados muito semelhantes com relação à qualidade da classificação. Obtivemos um índice de 0,64 para o Kappa e 0,73 (ou 73) para a exatidão global. Mesmo assim, os resultados foram considerados muito satisfatórios pelos autores. Na ocasião, os autores atribuíram os erros de omissão e comissão entre as classes devido, principalmente às condições sazonais das lagoas.

Assim, aqui se faz o mesmo em afirmar que os índices de 0,70 para o Kappa e 71 (ou 0,71) para a exatidão global representam bons resultados para identificação por meio de GEOBIA e mineração de dados das lagoas no Pantanal.

A complexidade da área é outra questão que deve ser levada em consideração. Em alguns quilômetros quadrados há muitos elementos distintos que formam a paisagem da

região. Mesmo levando em consideração apenas as lagoas, a Figura 6, é colocada como um bom exemplo da quantidade de lagoas diferentes entre si na Nhecolândia.

Figura 6. Classificação das lagoas em área teste: Pantanal da Nhecolândia (2018).



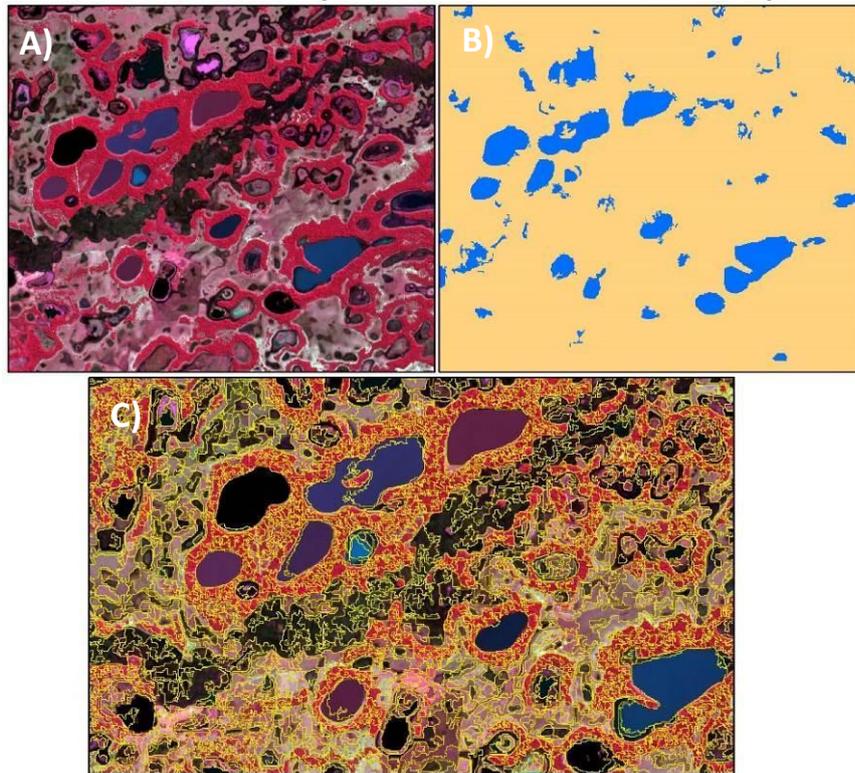
Fonte: Autor (2018).

Outrora, Galvão et al. (2003b) confirmou esta complexidade das lagoas do Pantanal, reveladas por suas distintas características espectrais e físico-químicas, sendo que as lagoas salinas apresentam uma maior reflectância global do que as lagoas de água doce, possivelmente devido ao espalhamento pela fração particulada total (partículas suspensas não vivas mais vidas ou tripton mais fitoplâncton).

Ainda assim, uma classificação razoável de acordo com o índice Kappa foi encarada como um resultado esperado. Visualmente, quando se compara a classificação junto da imagem do Sentinel-2 é possível observar uma alta correlação entre a interpretação visual e o resultado da GEOBIA (Figura 7). Na comparação visual é possível verificar que a GEOBIA e, sobretudo as métricas espaciais, contribuíram para a qualidade da classificação, principalmente no que tange ao reconhecimento de lagoas com comportamento espectral

distinto. Em experiências anteriores e, até mesmo na literatura, confirma-se que comumente técnicas baseadas estritamente em pixels ou segmentações espectrais sofrem com a confusão do comportamento espectral das lagoas. Enquanto a GEOBIA e a mineração de dados foram capazes de identificar e agrupar (baías, salitradas e salinas) em toda área de teste.

Figura 7. Correlação entre A) imagem, B) classificação e C) objetos da segmentação.

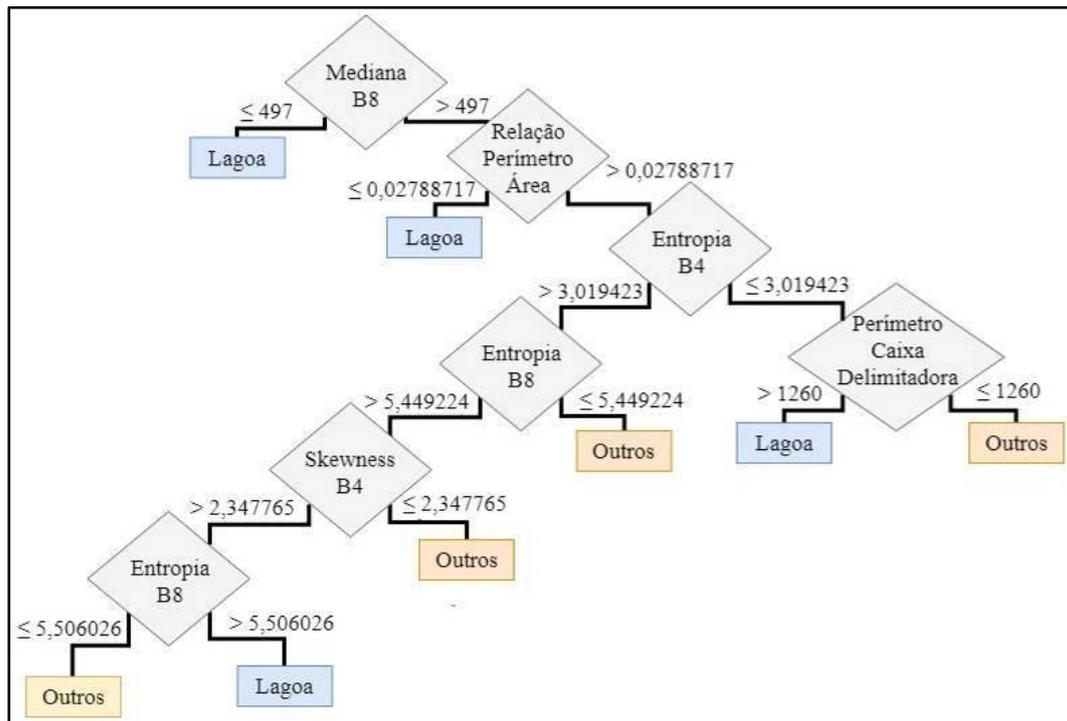


Fonte: Autor (2018).

Mesmo assim, entendemos que os erros que ainda persistem suportam novos testes, com conjuntos de dados, imagens, parâmetros de segmentação e métricas adicionais ou mesmo distintas para que a comunidade do sensoriamento remoto possa, cada vez mais, se aproximar de resultados que melhor representem a paisagem real.

Um resultado que corrobora com a necessidade de mais testes foi a árvore de decisão criada pelo GeoDMA (Figura 8). Conforme apresentado nos procedimentos, as duas métricas (espacial e espectral) mais úteis à classificação foram a mediana da banda 8 (NIR), com 100% de aproveitamento e a relação entre perímetro e área de cada objeto da segmentação, com 64,36% de aproveitamento. As outras métricas participantes e seus respectivos aproveitamentos podem ser revisados nos procedimentos deste trabalho.

Figura 8. Árvore de decisão para a classificação das lagoas.



Fonte: Autor (2018).

Apesar de usar as bandas 3 (verde), 4 (vermelho) e 8 (NIR), apenas as bandas 4 e 8 foram consideradas interessantes pelo *software* para compor a árvore de decisão da classificação. A banda 8 (NIR) responde muito bem ao delineamento de corpos d'água, apresentando uma diferenciação entre “solo *versus* água” e, por isso, justifica-se a sua mediana ser usada integralmente como um atributo espectral.

A banda 4 (vermelho), comumente usada no mapeamento da vegetação (diferenciação de espécies vegetais e contraste entre solo e vegetação) também foi considerada para a árvore de decisão, sobretudo pela métrica espectral de entropia que “mede o distúrbio em uma imagem. Quando a imagem não é uniforme, muitos elementos da matriz de coocorrência de nível de cinza (*Gray-Level Cooccurrence Matrix* – GLCM) possuem valores pequenos, resultando em grande entropia” (INPE, 2018, *online*). Isso quer dizer que, como pode ser visto na figura 7, os objetos correspondentes à classe “outros” (envolvendo a vegetação) possuem tamanhos menores com relação aos objetos correspondentes à classe das lagoas. Por isso, considerou-se que a entropia da banda 4 foi importante para distinguir os elementos da paisagem que formam a classe “outros”. Rapidamente, a GLCM é a co-ocorrência em nível de cinza (*Gray-Level Cooccurrence Matrix* – GLCM) representada por uma

matriz, grosso modo, sem grandes pormenores, envolve um determinado intervalo de valores do nível de cinza da imagem.

Curiosamente, a banda 3 (verde) que corresponde ao comprimento de onda central de 0,560 μ m e apresenta grande sensibilidade para mapeamentos envolvendo corpos d'água, ficou de fora da árvore de decisão. Este intervalo espectral correspondente ao verde (visível) há boa resposta da radiação eletromagnética na água.

Estima-se que, devido a consideração de duas classes (lagoas e outros) o algoritmo entendeu ser suficiente os atributos espaciais e os espectrais (dentre mediana, entropia e *skewness*) das bandas 8 e 4.

Assim, a utilização de atributos e da classificação por meio da árvore de decisão se mostrou interessante para classificação de paisagens de certa complexidade. Corroborando com Baatz e Schäpe (1999) e Novack, Ribeiro e Kux (2011), é possível entender que os métodos de seleção de atributos se tornaram vantajosos para o Processamento Digital de Imagens (PDI), devido à dezena e até centenas de atributos espectrais, texturais, e geométricos que podem ser incorporados às rotinas de classificação orientada a objeto ou GEOBIA. A construção de uma rede hierárquica (árvore de decisão) dos objetos em imagens também permite que cada objeto conheça seu contexto, sua vizinhança, sub-objetos e suas associações.

Todavia, definir parâmetros e escolher os atributos mais adequados para a identificação de classes de uso e cobertura da terra ou de elementos da paisagem não é tarefa das mais fáceis (NOVACK, RIBEIRO e KUX, 2011). Por isso, a realização de novos testes e criação de novos trabalhos podem contribuir para rotinas que tenham interesse na discriminação de elementos das paisagens do Pantanal e para diversos mapeamentos temáticos na região. As técnicas aqui empregadas resultaram em uma classificação satisfatória a partir dos parâmetros e atributos testados.

Considerações finais

Os objetivos do trabalho, de caráter empírico (experimental), foram alcançados com êxito. Os parâmetros adotados para a segmentação, bem como os atributos espectrais e espaciais utilizados para compor a árvore de decisão resultando numa classificação que sucedeu em resultados satisfatórios. Tais resultados se mostraram igualmente importantes,

de acordo com os procedimentos utilizados, para o mapeamento do uso e cobertura da terra e na identificação de lagoas no Pantanal da Nhecolândia.

Deste modo, considerou-se a GEOBIA e a mineração de dados como técnicas no âmbito do sensoriamento remoto, fundamentais para se obter resultados adequados à identificação das lagoas no Pantanal por meio de classificação de imagens. O bom desempenho da classificação pôde ser confirmado a partir da validação estatística e da comparação visual com a imagem do satélite Sentinel-2 usada para o trabalho, onde uma grande quantidade de lagoas pôde ser identificada e delineada pela GEOBIA.

Mesmo com algumas falhas aceitáveis (objetos criados nas bordas das lagoas, mistura de pixels, lagoas de menor porte) a validação da classificação pelos índices Kappa e de exatidão global mostrou-se substancial e que a classificação teve uma acurácia de boa qualidade. Considera-se que técnicas de classificação não representam a realidade em todas as suas dimensões e complexidades, e que não existem procedimentos exatos para as classificações. Todavia, as técnicas devem atender à maior precisão possível de acordo com o objetivo do mapeamento e que parâmetros de classificação podem ser testados e modelados para que sejam mais eficientes na discriminação de alvos de interesse. A exemplo disso, a escolha de bandas, dos parâmetros de segmentação, de métricas (espectrais e espaciais) e da árvore de decisão podem ajudar muito no processo de classificação e mapeamento do espaço.

A GEOBIA foi capaz integrar uma quantidade razoável de volume de dados (objetos) e, neste sentido, a mineração de dados também foi eficiente em processar este volume de dados, dividindo-os em atributos espectrais e espaciais, bem com a seleção dos melhores atributos para compor uma árvore de decisão e finalmente resultar em uma classificação congruente.

Outra questão importante a ser mencionada é que a GOBIA e, sobretudo as técnicas de mineração de dados são ainda recentes e pouco disseminadas, principalmente na Geografia. Considerou-se então, que a produção de novos trabalhos, bem como a discussão de parâmetros e resultados possam contribuir com a disseminação da bibliografia e o aprofundamento de futuros estudos de avaliação do potencial e limitação destas ferramentas e de estudos aplicados em outras regiões.

Por fim, este trabalho apresentou, com êxito, uma alternativa para técnicas de classificação de imagens de satélite para identificação das lagoas no Pantanal da Nhecolândia.

Tal fato se faz importante devido a facilidade em identificar a quantidade, a sazonalidade e a eficiência no delineamento de um grande volume de elementos naturais da paisagem, que em campo são difíceis e se tornam inviáveis.

Agradecimentos

O autor Adalto Moreira Braz e a autora Paola Vicentini Boni agradecem à Coordenação de Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelas bolsas de pesquisa em nível de doutorado e mestrado, respectivamente. A autora Amanda Moreira Braz agradece ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa em nível de iniciação científica.

Referências

ABDON, M. M.; POTT, V. J.; SILVA, J. S. V. Avaliação da ocupação por plantas aquáticas em lagoas da sub-região da Nhecolândia – Pantanal através de dados Landsat e SPOT. In: ENCONTRO SOBRE SENSORIAMENTO REMOTO APLICADO A ESTUDOS NO PANTANAL – GEOPANTANAL, 1., 1995, Corumbá. **Anais...** São José dos Campos: INPE, 1996. p. 119-121.

BAATZ, M.; SCHÄPE, A. Object oriented and multiscale image analysis in semantic network. In: INTERNATIONAL SYMPOSIUM ON OPERATIONAL REMOTE SENSING, 2., 1999, Enschede. **Anais...** Enschede: Faculty of Geo-information Science and Earth Observation (ITC), 1999. p. 1-7.

BERTANI, T. C. et al. Detection of saline and non-saline lakes on the Pantanal of Nhecolândia (Brazil) using object-based image analysis. In: GEOGRAPHIC OBJECT-BASED IMAGE ANALYSIS CONFERENCE, 2010, Ghent. **Proceedings...** Ghente: Ghente University, 2010, p. 1-6.

BIAS, E. S.; BARBOSA, F. L.; BRITES, R. S. Emprego de imageamento passivo na análise da variabilidade espacial da turbidez no espelho d'água do Lago Paranoá, Distrito Federal. **Revista Engenharia Sanitária e Ambiental**, Rio de Janeiro, vol. 18, n. 1, p. 55-64, jan./mar., 2013.

BINS, L. S. et al. Satellite imagery segmentation: a region growing approach. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 1996, Salvador. **Anais...** São José dos Campos: INPE, 1996. p. 677-680.

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, vol. 65, p. 2-16, 2010.

BONI, P. V. **Análise sedimentológica de uma elevação na região Leste do Pantanal da Nhecolândia-MS**. 2017. 43 f. Monografia (Licenciatura em Geografia) – Universidade Federal de Mato Grosso do Sul. Três Lagoas, 2017.

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. 286 f. Dissertação (Mestrado em Geografia) –

Classificação e identificação de lagoas utilizando Geobia e mineração de dados: um exemplo aplicado ao Pantanal da Nhecolândia (MS). Adalto Moreira Braz, Paola Vicentini Boni, Amanda Moreira Braz, José Roberto Amaro Mantovani, Ivanilton José de Oliveira.

Programa de Pós-Graduação em Geografia. Universidade Federal de Mato Grosso do Sul. Três Lagoas, 2017.

BRAZ, A. M. et al. Validação das classificações das imagens dos satélites Landsat 8 e Sentinel-2 na bacia hidrográfica do córrego Ribeirãozinho/MS. **Revista Eletrônica da Associação dos Geógrafos Brasileiros – Seção Três Lagoas/MS**, Três Lagoas, vol. 14, n. 26, nov., 2017

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

FAYYAD, U.; SHAPIRO, G. P.; SMYTH, P. The KDD process for extracting useful knowledge from volumes of data. **Communications of the ACM**, vol. 39, n. 11, p. 27-34, nov., 1996.

GALO, M. L. B. T. et al. Uso do sensoriamento remoto orbital no monitoramento da dispersão de macrófitas nos reservatórios do complexo Tietê. **Planta Daninha**, Viçosa, vol. 20, p. 7-20, 2002.

GALVÃO, L. S. et al. Spectral reflectance characterization of shallow lakes from the Brazilian Pantanal wetlands with field and airborne hyperspectral data. **International Journal of Remote Sensing**, Morgantown, vol. 24, n. 21, p. 4093-4112, 2003a.

GALVÃO, L. S. et al. Sensoriamento remoto hiperespectral no estudo de baías e salinas do Pantanal Brasileiro. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003, Belo Horizonte. **Anais...** São José dos Campos: INPE, 2003b. p. 2493-2500.

HAY, G. J.; CASTILLA, G. Geographic Object-Based Image Analysis (GEOBIA): a new name for a new discipline. In: BLASCHKE, T.; LANG, S.; HAY, G. J. (Org.). **Object-based image analysis: spatial concepts for knowledge-driven remote sensing applications**. Berlin: Springer, 2008. p. 75-89.

Instituto Nacional de Pesquisas Espaciais – INPE. **TerraLib and TerraView wiki page**. Divisão de Processamento de Imagens (DPI). Disponível em: <<http://www.dpi.inpe.br/terralib5/wiki/doku.php>>. Acesso em: 20 mai. 2018.

KÖRTING, T. S. **GeoDMA: a toolbox integrating data mining with object-based and multi-temporal analysis of satellite remotely sensed imagery**. 2012. 96 f. Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais. São José dos Campos, 2012.

KORTING, T. S.; et al. GeoDMA - Um sistema para mineração de dados de sensoriamento remoto. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 7813-7820.

KORTING, T. S.; FONSECA, L. M. G.; CAMARA, G. Interpreting Images with GeoDMA. In: GEOGRAPHIC OBJECT-BASED IMAGE ANALYSIS CONFERENCE, 2010, Ghent. **Proceedings...** Ghente: Ghente University, 2010, p. 1-5.

KORTING, T. S.; FONSECA, L. M. G.; CAMARA, G. GeoDMA - geographic data mining analyst a framework for GIScience. **Computers & Geosciences**, Laramie, v. 57, p. 133-145, 2013.

KORTING, T. S. et al. GeoDMA: a novel system for spatial data mining. In: IEEE INTERNATIONAL CONFERENCE ON DATA MINING, 2008, Pisa. **Proceedings...** Pisa: IEEE, 2008. p. 975-978.

Classificação e identificação de lagoas utilizando Geobias e mineração de dados: um exemplo aplicado ao Pantanal da Nhecolândia (MS). Adalto Moreira Braz, Paola Vicentini Boni, Amanda Moreira Braz, José Roberto Amaro Mantovani, Ivanilton José de Oliveira.

LANG, S. Object-based image analysis for remote sensing applications: modeling reality – dealing with complexity. In: BLASCHKE, T.; LANG, S.; HAY, G. J. (Org.). **Object-based image analysis: spatial concepts for knowledge-driven remote sensing applications**. Berlin: Springer, 2008. p. 3-27.

NAMIKAWA, L. M. Geoprocessamento. In: PRATINI, E. E.; SILVA JUNIOR, E. E. A. (Org.). **Criação, representação e visualização digitais: tecnologias digitais de criação, representação e visualização no processo de projeto**. Brasília: UNB, 2012, p. 91-123.

NOVACK, T.; RIBEIRO, B. M. G.; KUX, H. J. H. Análise dos dados do satélite WorldView-2 para a discriminação de alvos urbanos semelhantes com base em algoritmos de seleção de atributos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011. p. 7815-7821.

NOVACK, T. et al. Classificação de lagoas no Pantanal da Nhecolândia utilizando um sistema livre de análise de imagens orientada a objeto. **Revista Geográfica Acadêmica**, Boa Vista, vol. 4, n. 1, p. 32-45, 2010.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. 2. ed. São Paulo: Ed. Edgard Blücher, 1998.

PILZ, H.; STROBL, J. Análise da impermeabilização com base em ortofotografias aéreas coloridas digitais através de processamento de imagens orientadas a objeto. In: BLASCHKE, T.; KUX, H. (Org.). **Sensoriamento remoto e SIG avançados: novos sistemas sensores, métodos inovadores**. Traduzido por Hermann Johann Heinrich Kux. 2. ed. São Paulo: Oficina de Textos, 2007. p. 162-171.

RIBEIRO, B. M. G.; FONSECA, L. M. Urban land cover classification using WorldView-2 images and C4.5 algorithm. In: Joint Urban Remote Sensing Event – JURSE, 2013, São Paulo. **Proceedings...** São José dos Campos: INPE, 2013. p. 21-23.

SAKAMOTO, A. Y. et al. Caracterização da organização espacial de lagoas salinas e doces em uma área da fazenda Firme, Pantanal da Nhecolândia, MS. In: ENCONTRO SOBRE SENSORIAMENTO REMOTO APLICADO A ESTUDOS NO PANTANAL – GEOPANTANAL, 1., 1995, Corumbá. **Anais...** São José dos Campos: INPE, 1996. p. 109-111.

SILVA, M. H. S. **Análise da Paisagem do Pantanal da Nhecolândia: Estudo de Caso de Lagoas Salitradas Sob a Perspectiva do Modelo GTP (Geossistema, Território e Paisagem)**. 2012. Tese (Doutorado em Geografia). Universidade Estadual Paulista, Presidente Prudente, 2012.

SILVA, C. V. J.; SILVA, R. D.; GALVÃO, L. S. et al. Seleção de atributos em imagens AVIRIS para mapeamento de uma área do Pantanal Brasileiro. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2013. p. 2266-2273.

SILVA, J. S. V.; ABDON, M. M. Delimitação do Pantanal brasileiro e suas sub-regiões. **Pesquisa Agropecuária Brasileira**, Brasília, vol. 33, n. especial, p. 1703-1711, out., 1998.

Submetido em: abril de 2020.

Aceito em: março de 2021.