



## Classificação e monitoramento de áreas urbanizadas usando técnicas de visão computacional

### *Classification and monitoring of urbanized areas using computer vision techniques*

Everton Castelão TETILA<sup>1\*</sup>, Paula Martin de MORAES<sup>1,2</sup>, Michel CONSTANTINO<sup>2</sup>, Reginaldo Brito da COSTA<sup>2</sup>, Fábio Martins AYRES<sup>3</sup>, Gabriela Oshiro REYNALDO<sup>2</sup>, Neire Aparecida COLMAN<sup>2</sup>, Flávia Cristina Albuquerque Palhares MACHADO<sup>2</sup>, Karen Giuliano SOARES<sup>2</sup>, Maria Madalena Dib Mereb GRECO<sup>2</sup>, Hemerson PISTORI<sup>2</sup>

<sup>1</sup> Universidade Federal da Grande Dourados (UFGD), Dourados, MS, Brasil.

<sup>2</sup> Universidade Católica Dom Bosco (UCDB), Campo Grande, MS, Brasil.

<sup>3</sup> Universidade Estadual de Mato Grosso do Sul (UEMS), Campo Grande, MS, Brasil.

\* E-mail de contato: [evertontetila@ufgd.edu.br](mailto:evertontetila@ufgd.edu.br)

Artigo recebido em 16 de fevereiro de 2021, versão final aceita em 10 de julho de 2021, publicado em 17 de março de 2023.

#### RESUMO:

Neste artigo propomos um sistema de visão computacional para classificar áreas permeáveis e impermeáveis de uma região delimitada para estudo compreendendo a Microbacia do Segredo e microbacias adjacentes, localizada no município de Campo Grande/MS, Brasil, a fim de avaliar o aumento do adensamento urbano entre os anos de 2008 e 2016. O sistema proposto baseia-se no método de segmentação de imagens *Simple Linear Iterative Clustering* (SLIC) para particionar uma imagem em múltiplos segmentos e gerar superpixels que diferenciem as áreas permeáveis e impermeáveis; e algoritmos de extração de atributos para descrever as características visuais, como cor, gradiente, textura e forma. O desempenho de cinco métodos de aprendizado supervisionados foi avaliado para a tarefa de reconhecimento de áreas permeáveis e impermeáveis. A abordagem proposta atingiu uma acurácia de 94,6% usando o algoritmo *Support Vector Machine* (SVM). Além disso, os resultados mostraram um aumento de 7,2% na taxa de ocupação urbana da área de estudo entre os anos analisados. Os resultados indicam que a abordagem proposta pode apoiar especialistas e gestores no monitoramento do adensamento urbano e o seu impacto ambiental.

*Palavras-chave:* visão computacional; adensamento urbano; impermeabilidade; impacto ambiental.

---

**ABSTRACT:** In this paper we propose a computer vision system to classify permeable and impermeable areas of a bounded area for study including the Micro-basin of Segredo and adjacent micro-basins, located in the municipality of Campo Grande/MS, Brazil, in order to evaluate the increase in urban density between the years 2008 and 2016. The proposed system is based on the image segmentation method *Simple Linear Iterative Clustering* (SLIC) to partition an image into multiple segments and generate superpixels that differentiate the permeable and impermeable areas; and attribute extraction algorithms to describe the visual features such as color, gradient, texture, and shape. The performance of five supervised learning methods was evaluated for the task of permeable and impermeable areas recognition. The proposed approach achieved an accuracy of 94.6% using the *Support Vector Machine* (SVM) algorithm. In addition, the results showed an increase of 7.2% in the urban occupation rate of the study area between the analyzed years. The results indicate that the proposed approach can support specialists and managers in the monitoring of urban density and its environmental impact.

*Keywords:* computer vision; urban density; impermeability; environmental impact.

## 1. Introdução

A redução de áreas permeáveis, como a cobertura vegetal nativa e os mananciais de água doce, tem sido uma preocupação de escala mundial, fato que ocorre em decorrência da expansão agrícola, da extração ilegal da madeira e do aumento da urbanização. Nos últimos anos, o desmatamento das florestas brasileiras tem se mostrado crescente, sendo o Brasil considerado o primeiro no *ranking* de perda líquida de área florestal entre 2010 e 2015 (FAO, 2016). As áreas permeáveis são consideradas essenciais por vários motivos: produção de microalgas e organismos da base de cadeias alimentares; manutenção dos recursos hídricos, como áreas de recarga dos lençóis freáticos e aquíferos; auxílio do ciclo reprodutivo de peixes; aumento da umidade relativa do ar, contribuindo com a formação de nuvens e a precipitação de chuvas convectivas; entre outros.

Diante do crescimento urbano e da supressão das áreas permeáveis, busca-se por tecnologias que propiciem o monitoramento da expansão urbana e os possíveis riscos da ação antrópica ao meio ambiente. Em face a esta lacuna de pesquisa obser-

vada, uma determinada área de grande importância localizada no município de Campo Grande/MS, Brasil, foi delimitada para estudo, concebendo a confluência entre a Bacia do Alto Paraguai e a Bacia do Alto Paraná (Figura 1). A área de estudo faz parte do Zoneamento Ecológico-Econômico de Campo Grande/MS (PLANURB - ZEE/CG).

A principal característica da área escolhida é a abrangência de diversas microbacias, entre elas, a Microbacia do Segredo, que é área de recarga do Aquífero Guarani e corta áreas centrais do município passando por diversos bairros, além de compreender uma grande parte de propriedades rurais. As bacias hidrográficas, além de representarem a geomorfologia do território, permitem mensurar as características físicas e espaciais do terreno, contribuindo com a unidade de planejamento municipal das análises integradas em visões estratégicas, prevista na Lei Federal nº 9.433/97, conforme institui a Política Nacional de Recursos Hídricos.

A ocupação com novas edificações e o adensamento populacional nessa região mostraram-se em expansão nos últimos anos. Sem o devido controle do poder público, vários riscos socioambientais poderão agravar-se com a incorporação de novas áreas

ao perímetro urbano, proposta pelo Plano Diretor do município de Campo Grande, dado o potencial interesse pela ocupação da região.

Embora essa alteração no perímetro urbano seja uma legítima demanda da população ali instalada, motiva também novos estudos para avaliar os impactos que a impermeabilização do solo, decorrente do aumento da ocupação destas áreas, poderá provocar na região, tais como alterações na percolação da água no subsolo, variações no volume de água das bacias hidrográficas fronteiriças e o aumento do risco de enchentes.

Com o objetivo de identificar o melhor método de aprendizado supervisionado que possibilite avaliar a expansão da urbanização, neste artigo propomos um sistema de visão computacional para

a classificação de imagens em áreas permeáveis e impermeáveis, auxiliando especialistas e gestores no monitoramento do adensamento urbano e o seu impacto ambiental, em atenção às necessidades coletivas dos moradores das regiões que pleiteiam a inserção destas áreas ao perímetro urbano.

Este artigo está organizado da seguinte forma: a Seção 2 apresenta a abordagem proposta para avaliar o desempenho dos algoritmos utilizados na tarefa de classificação da impermeabilidade do solo em função das áreas ocupadas; a Seção 3 relata os materiais e métodos adotados na pesquisa; a Seção 4 mostra os resultados experimentais, seguidos por uma discussão; por fim, as conclusões e trabalhos futuros são apresentados na Seção 5.

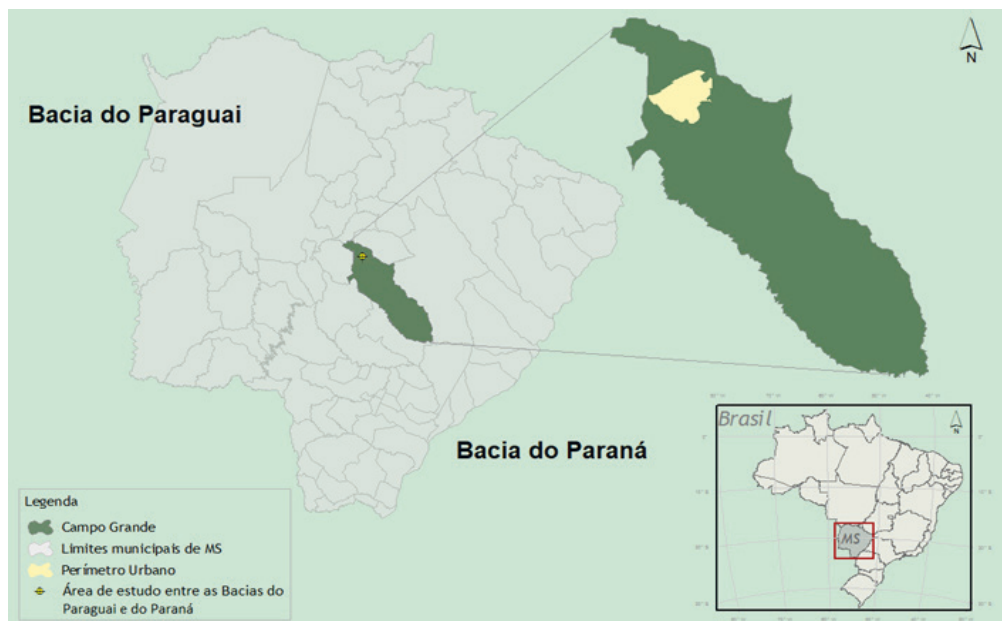


FIGURA 1 – Localização do município de Campo Grande/MS, Brasil: perímetro urbano em destaque e a área de estudo entre as Bacias do Paraguai e do Paraná.

FONTE: Adaptado de Zoneamento Ecológico-Econômico de Campo Grande/MS (PLANURB, s.d.).

## 2. Abordagem proposta

Esta seção apresenta uma abordagem de visão computacional para classificar áreas permeáveis e impermeáveis a partir de imagens aéreas. A abordagem proposta adota o algoritmo *Simple Linear Iterative Clustering* (SLIC) para segmentar as áreas permeáveis e impermeáveis na imagem. O método SLIC emprega o algoritmo *k-means* (Hartigan & Wong, 1979) para a geração de regiões semelhantes, chamadas superpixels. O parâmetro  $k$  do algoritmo refere-se ao número de superpixels na imagem e permite controlar o tamanho dos superpixels.

O algoritmo SLIC agrupa pixels em regiões atômicas de acordo com a cor dos pixels usando os componentes CIELAB:  $l$ ,  $a$ ,  $b$ , bem como as coordenadas  $x$  e  $y$  dos pixels. A imagem de entrada é segmentada em regiões regulares, definindo o número  $k$  de superpixels com aproximadamente  $N/k$  pixels, onde  $N$  é o número de pixels da imagem. Cada região compõe um superpixel inicial de

dimensões  $S \times S$ , onde  $S = \sqrt{N/k}$ . Os centros dos agrupamentos de superpixel  $C_k = [lk, ak, bk, xk, yk]$  com  $k = [1, k]$  são amostrados em uma matriz regular com espaçamento entre pixels. Os centros são movidos para a posição de menor gradiente em uma vizinhança de  $3 \times 3$  pixels, evitando a alocação de centros nas regiões de borda. No final do processo, cada pixel é associado ao centro mais próximo e uma etapa de atualização ajusta os centros para o vetor médio  $labxy$  de todos os pixels pertencentes ao agrupamento (Achanta *et al.*, 2012).

Um diagrama esquemático do sistema proposto é mostrado na Figura 2. Ela ilustra a abordagem proposta que consiste de cinco etapas: (a) coleta de imagem, (b) segmentação de imagem, (c) anotação de imagem, (d) extração de atributos e, finalmente, (e) classificação de imagem. Inicialmente, duas imagens da área de estudo foram coletadas nos anos de 2008 e 2016 (ver passo (a) na Figura 2). Essas imagens foram segmentadas usando o método SLIC superpixels, dividindo a imagem original em  $k$  segmentos de superpixels (Figura 2 (b)).

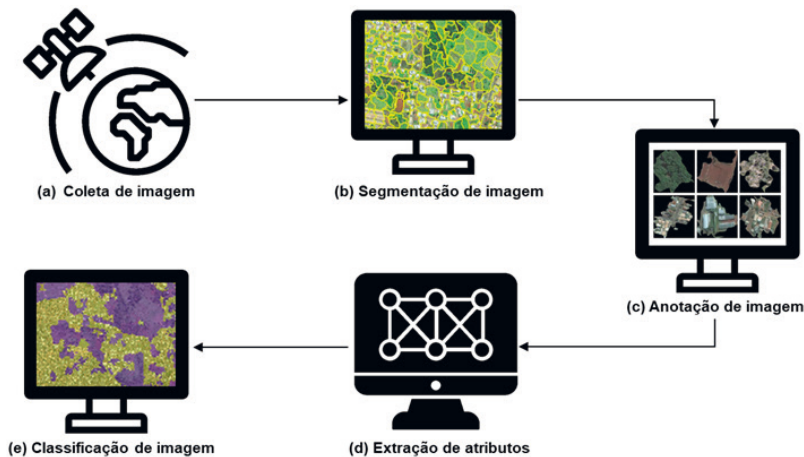


FIGURA 2 – Proposta do sistema de visão computacional para classificar áreas permeáveis e impermeáveis - etapas esquemáticas.

FONTE: Elaborada pelos autores.

Após a segmentação da imagem com o método de SLIC, cada segmento de superpixel foi anotado visualmente pelo especialista em uma das classes: “permeável” ou “impermeável”, compondo um banco de imagens de superpixels para treinamento e teste do sistema (ver etapa (c) da Figura 2). Subsequentemente, as imagens foram descritas como características baseadas na cor, gradiente, textura e forma (ver passo (d) da Figura 2) através de vetores de atributos extraídos dos superpixels. A etapa final mostra uma imagem de teste sendo classificada pelo sistema de visão computacional (Figura 2(e)). No estágio de pós-processamento, o sistema percorre a imagem da esquerda para a direita, de cima para baixo, classificando cada superpixel individualmente, enquanto fornece a cor da classe simultaneamente. Assim, um mapa colorido é gerado fornecendo uma classe por segmento.

### 3. Materiais e métodos

As próximas seções apresentam os materiais e os métodos adotados na pesquisa.

#### 3.1. Delineamento experimental

A área de estudo mostrada na Figura 3 está localizada no município de Campo Grande/MS, Brasil. As imagens da área analisada foram obtidas em 2008 e 2016, e carregam as informações do adensamento populacional entre o período analisado. A imagem de 2008 foi coletada por meio de levantamento aerofotogramétrico com resolução espacial de 10 cm, corrigida geometricamente com a ortorretificação de 90 marcos geodésicos. A imagem de 2016 é de origem do satélite *Worldview-2*, com

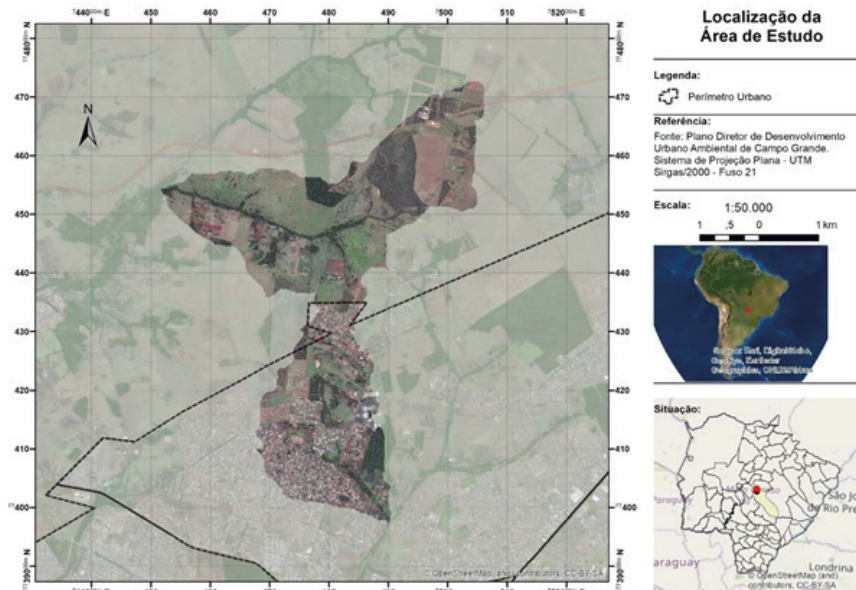


FIGURA 3 – Localização da área de estudo.

FONTE: Elaborada pelos autores.

---

resolução espacial de 50 cm, corrigida geometricamente e fundamentada com os levantamentos cartográficos das propriedades rurais certificadas no INCRA.

Para avaliar a taxa de ocupação urbana da área de estudo entre os anos analisados foi utilizado o software Pynovisão, registrado no INPI sob o número BR 51 2019 000427-2. Na identificação das áreas permeáveis e impermeáveis, cada imagem foi segmentada por meio do método baseado em superpixel, de acordo com o parâmetro  $k$  do algoritmo que permite controlar o número de superpixels na imagem. Nos experimentos, o parâmetro  $k = 10.000$  foi ajustado para segmentar as áreas de permeabilidade, definidas pela aderência aos limites de tamanho do algoritmo SLIC. Cada segmento corresponde ao tamanho aproximado de uma quadra (10.000 m<sup>2</sup>).

Nesta próxima etapa, parte dos segmentos precisam ser classificados manualmente de acordo com o olhar do especialista. Para as classes utilizadas neste estudo, os autores anotaram aleatoriamente 1.000 segmentos de superpixels, sendo 500 superpixels da classe “permeável” e 500 da classe “impermeável”; construindo assim, uma coleção de referências de superpixels para o banco de imagens. Durante a análise do especialista, considerou-se como pertencentes à classe “permeável” os segmentos em que se pode observar a prevalência de vegetação ou de solo exposto. Para a anotação dos segmentos da classe “impermeável” foi usado como critério a prevalência de construções, edificações ou pavimentação na imagem.

### 3.2. Extração de atributos e classificação

Extração ou descrição de atributos é um passo importante nos sistemas de classificação, visto que essa etapa é capaz de traduzir a informação dos padrões de conteúdos visuais e representá-los em vetores de características baseados numa representação numérica. Existem vários atributos visuais que descrevem as propriedades físicas das imagens, que dependem principalmente da cor, gradiente, textura e forma. Embora o sistema visual humano possa facilmente discriminar imagens, a descrição das características baseia-se nas propriedades físicas das superfícies dos objetos, ou seja, como elas refletem os diferentes valores de comprimento de onda.

Os atributos de textura se concentram em descrever imagens como padrões repetitivos que podem variar de acordo com o tamanho, o que produz diferentes sensações associadas à aspereza, à grosseria e à regularidade. Os atributos de forma, por sua vez, descrevem imagens dependendo do contorno dos objetos, enquanto as características de gradiente são baseadas nas derivadas direcionais, em diferentes direções da imagem. O sistema de visão computacional proposto para classificar imagens de áreas permeáveis e impermeáveis emprega de forma combinada os seguintes extratores de atributos: *cor* (estatísticas de cores (Swain & Ballard, 1991)); *gradiente* (histograma de gradientes orientados (Dalal & Triggs, 2005)); *textura* (matriz de co-ocorrência de nível de cinza (Haralick, 1979) e padrões binários locais (Ojala *et al.*, 2002)); e *forma* (momentos de Hu e momentos centrais (Hu, 1962)).

Na tarefa de classificação, as imagens capturadas foram submetidas aos algoritmos de aprendizado de máquina. Cinco algoritmos conhecidos da literatura foram comparados: máquinas de vetores de suporte, usando o algoritmo SVM (Platt, 1999); árvores de decisão, usando o algoritmo *Random*

*Forest* (Ho, 1995); *k*-vizinhos mais próximos (*k*-NN) (Altman, 1992); redes bayesianas, usando o algoritmo *Naive Bayes* (Russell & Norvig, 2009); e o algoritmo meta-heurístico *AdaBoost* (Kégl, 2013). Cinco métricas foram utilizadas para avaliar o desempenho dos algoritmos: acurácia, precisão, revocação, medida-*F* e tempo médio para construir o modelo de classificação.

Nos experimentos os algoritmos foram empregados com conjuntos de treinamento e teste, divididos de acordo com a validação cruzada estratificada de dez dobras. Neste esquema, as imagens do conjunto de dados são divididas em 10 dobras, garantindo que cada dobra tenha a mesma proporção de cada classe. Em seguida, uma dobra é usada para testar, enquanto as dobras restantes são usadas para treinar o classificador. O processo é repetido 10 vezes usando cada dobra exatamente uma única vez para o teste. Finalmente, a acurácia é dada pela média das 10 rodadas.

Para verificar se os algoritmos testados diferem estatisticamente em relação ao desempenho foi

utilizado o teste de hipóteses ANOVA no software *RStudio* (versão 1.0.136). Um nível de significância de 0,05 foi usado para descartar a hipótese nula. Por fim, realizou-se o pós-teste com o teste de *Tukey*.

#### 4. Resultados e discussão

A Figura 4 mostra os resultados para a acurácia obtidos por cinco algoritmos de aprendizagem de máquina no conjunto de teste, considerando os valores da Tabela 1. A Tabela 1 também mostra a precisão, revocação, medida-*F* e o tempo médio para construir o modelo de classificação. Nos experimentos, o classificador SVM (94,6%) obteve o maior valor para a acurácia, seguido pelos classificadores *Random Forest* (93,2%), *AdaBoost* (93,0%), *k*-NN (91,6%) e *Naive Bayes* (80,7%). O classificador *k*-NN obteve o menor tempo de processamento, seguido pelos classificadores *Naive Bayes*, SVM, *AdaBoost* e *Random Forest*.

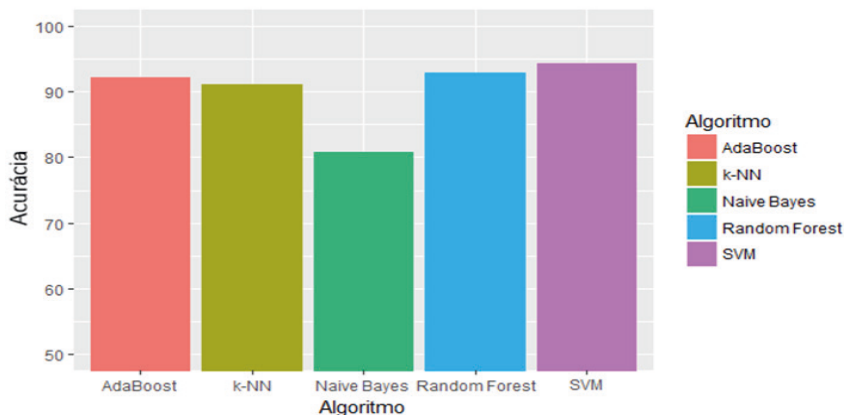


FIGURA 4 – Porcentagem de acurácia obtida por diferentes algoritmos, utilizando extratores de atributos combinados baseados em cor, gradiente, textura e forma.

FONTE: Elaborada pelos autores.

TABELA 1 – Métricas de desempenho utilizadas para avaliar a abordagem proposta.

Classificador	Acurácia (%)	Precisão (%)	Revocação (%)	Medida-F (%)	Tempo (s)
SVM	94,6	94,6	94,6	94,6	0,37
<i>Random Forest</i>	93,2	93,2	93,2	93,2	0,89
<i>AdaBoost</i>	93,0	93,0	93,0	93,0	0,52
<i>k</i> -NN	91,6	91,7	91,6	91,6	0,02
<i>Naive Bayes</i>	80,7	85,4	80,7	80,0	0,12

FONTE: Elaborada pelos autores.

Os resultados indicam que existe diferença estatisticamente significativa de acurácia entre os classificadores para um nível de significância de 0,05. Esses resultados foram confirmados pelo teste de hipóteses ANOVA (valor- $p = 3.27e-10$ ). Todavia, o teste de *Tukey* mostrou que não há diferença significativa entre os classificadores SVM e *Random Forest* (valor- $p = 0.42$ ), os quais foram os classificadores melhores avaliados para a acurácia. Destaca-se, ainda, a importância da escolha do algoritmo de aprendizado de máquina. Por exemplo, na Tabela 1 o classificador SVM obteve acurácia de 94,6% contra 80,7% utilizando *Naive Bayes*, resultando uma diferença de 13,9%.

A Figura 5 apresenta a matriz de confusão obtida por cada classificador: SVM, *Random Forest*, *AdaBoost*, *k*-NN e *Naive Bayes*. De acordo com a figura, a classe “permeável” obteve maior número de instâncias classificadas incorretamente devido à

presença de construções, edificações ou pavimentação em áreas com prevalência de vegetação ou de solo exposto.

Diante dos resultados apresentados pelos algoritmos testados, optou-se por utilizar o classificador SVM para concluir o estudo das imagens pelo sistema de visão computacional proposto.

A Figura 6(a) mostra a etapa final do sistema de visão computacional classificando os segmentos da imagem de 2008 e a Figura 6(b) mostra o resultado da classificação da imagem de 2016 da região estudada. Aqui, usamos uma abordagem objetiva com o método SLIC para a segmentação das imagens e o algoritmo SVM para a classificação dos segmentos. O resultado visual de cada classe está destacado na imagem pela cor que ela representa, e o resultado quantitativo mostra a quantidade de segmentos por classe em percentual.




FIGURA 5 – Matriz de confusão obtida pelos classificadores.

FONTE: Elaborada pelos autores.



O estágio de pós-processamento consiste em segmentar uma imagem com o método SLIC e classificar cada segmento de superpixel em uma classe: “permeável” ou “impermeável”. A complexidade computacional do processo de segmentação, baseada no algoritmo SLIC, limita o espaço de busca a uma região proporcional ao tamanho do superpixel. Isso reduz a complexidade linear ao número de  $k$  superpixels, em vez do número de  $n$  pixels. No processo de classificação, a complexidade linear também é proporcional ao número de  $k$  superpixels, o que torna a abordagem proposta muito mais rápida do que outros métodos baseados em pixels.

De acordo com a Figura 6, as classes “permeável” e “impermeável” obtiveram, em 2016, 82,52% e 17,48% do total de segmentos classifica-

dos, respectivamente, contra 89,72% e 10,28% da imagem de 2008 – um aumento de 7,2% da área impermeável entre o período avaliado. Os resultados experimentais indicam que, entre 2008 e 2016, a área de estudo sofreu adensamento na ocupação urbana com a construção de novas edificações, o que acarretou diretamente na diminuição das áreas permeáveis daquela região, confirmando a hipótese inicial da pesquisa.

Os experimentos também demonstraram que a abordagem proposta baseada no algoritmo SLIC diminui a complexidade linear ao número da quantidade de superpixels da imagem, em vez do número de pixels da imagem, podendo ser usada com sucesso para (1) apoiar gestores e especialistas no monitoramento da ocupação urbana de

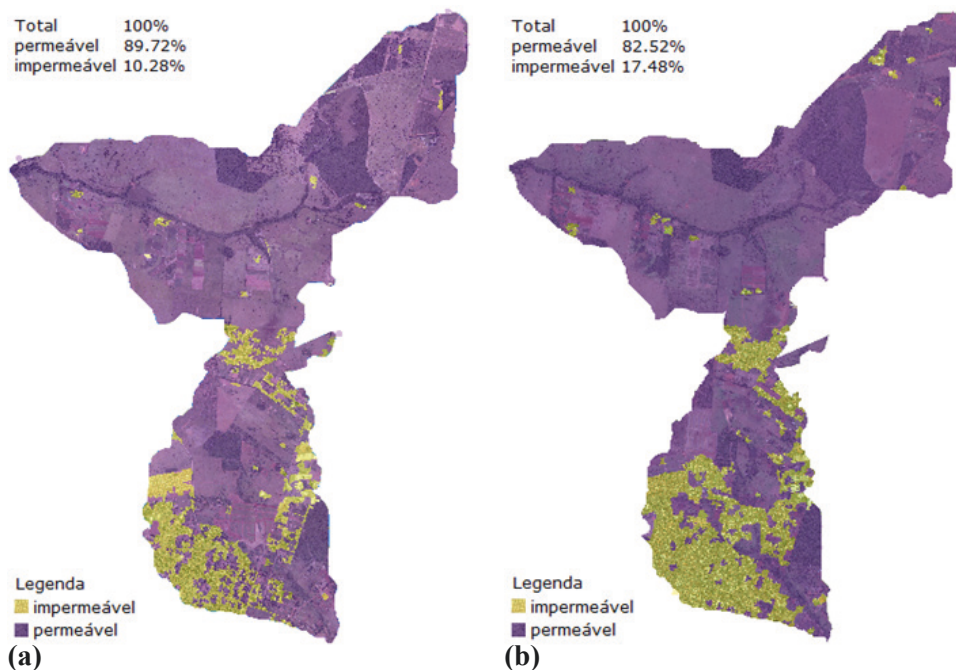


FIGURA 6 – Software Pynovisão avaliando a taxa de ocupação urbana, usando a abordagem proposta com o classificador SVM. (a) Classificação da imagem de 2008 e (b) Classificação da imagem de 2016 da área de estudo, em Campo Grande/MS.

FONTE: Elaborada pelos autores.

---

territórios, (2) subsidiar novas políticas públicas e diretrizes específicas para a ocupação destas e outras áreas do município e (3) analisar os possíveis riscos socioambientais.

## 5. Conclusões

Neste artigo foi proposta uma nova abordagem baseada no método de segmentação SLIC e algoritmos de aprendizado de máquina para a tarefa de reconhecimento de áreas permeáveis e impermeáveis. Consideramos um passo de segmentação para segmentar as imagens da área de estudo, definidas pelo especialista como “permeável” e “impermeável”. Em seguida, foi realizada a etapa de extração de atributos usando descritores de características visuais, incluindo cor, gradiente, textura e forma. Na etapa de classificação da abordagem proposta, cinco algoritmos de classificação conhecidos da literatura foram comparados. Os resultados mostraram que o classificador SVM obteve a taxa de classificação mais alta em comparação aos outros, atingindo 94,6% de amostras classificadas corretamente.

Além disso, os resultados indicaram um crescimento de 7,2% na taxa de ocupação urbana da região estudada entre o período de 2008 a 2016. O aumento da urbanização em áreas com a cobertura vegetal nativa contribuiu para a diminuição de áreas permeáveis que possibilitam a penetrabilidade de água no solo, impactando, assim, negativamente na manutenção dos recursos hídricos desta região de confluência entre as Bacias do Alto Paraguai e Alto Paraná – importantes áreas de recargas de lençóis freáticos e do Aquífero Guarani. Como parte de trabalhos futuros, pretendemos testar redes neurais convolucionais, aumentando a quantidade de amos-

tras de imagens. Também consideramos avaliar a abordagem proposta com imagens capturadas por câmeras de maior resolução e multiespectrais embarcadas no veículo aéreo não tripulado (VANT).

## Agradecimentos

Agradecemos ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e à Fundação de Apoio ao Desenvolvimento do Ensino, Ciência e Tecnologia do estado de Mato Grosso do Sul (FUNDECT).

## Referências

- Achanta, R.; Shaji, A.; Smith, K.; Lucchi, A.; Fua, P.; Susstrunk, S. Slic superpixels compared to state-of-the-art superpixel methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34(11), 2274-2282, 2012. doi: 10.1109/TPAMI.2012.120
- Altman, N. S. An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 46(3), 175-185, 1992. doi: 10.1080/00031305.1992.10475879
- Dalal, N; Triggs, B. Histograms of oriented gradients for human detection. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 886-893, 2005. doi: 10.1109/CVPR.2005.177
- FAO – Food and Agriculture Organization of the United Nations. Global Forest Resources Assessment 2015. *How are the world's forests changing?* Rome: FAO, 2 ed., 2016. Disponível em: <<http://www.fao.org/3/a-i4793e.pdf>>. Acesso em: jan. 2021.
- Haralick, R. M. Statistical and structural approaches to texture. In: *Proceedings of the IEEE*, 67(5), 786-804, 1979. doi: 10.1109/PROC.1979.11328

- 
- Hartigan, J. A.; Wong, M. A. A k-means clustering algorithm. *JSTOR: Applied Statistics*, 28(1), 100-108, 1979. doi: 10.2307/2346830
- Ho, T. K. Random decision forests. In: *Proceedings of the Third International Conference on Document Analysis and Recognition*. Washington, DC, USA: IEEE Computer Society, 278-285, 1995. doi: 10.1109/ICDAR.1995.598994
- Hu, M. K. Visual Pattern Recognition by Moment Invariants. *IRE Transactions on Information Theory*, 8(2), 179-187, 1962. doi: 10.1109/TIT.1962.1057692
- Kégl, B. The return of adaboost.mh: multi-class hamming trees. *CoRR*, 2013. Disponível em: <<http://arxiv.org/abs/1312.6086>>. Acesso em: nov. 2020.
- Ojala, T.; Pietikäinen, M.; Mäenpää T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7), 971-987, 2002. doi: 10.1109/TPAMI.2002.1017623
- PLANURB – Agência Municipal de Meio Ambiente e Planejamento Urbano. *ZEE – Zoneamento Ecológico-Econômico de Campo Grande*. Disponível em: <<https://sites.google.com/site/zecampogrande/>>. Acesso em: jan. 2021.
- Platt J. C. Fast training of support vector machines using sequential minimal optimization. In: Schölkopf, B.; Burges, C. J. C.; Smola, A. J. (Eds.). *Advances in kernel methods*. Cambridge, Massachusetts, EUA: MIT Press, p. 185-208, 1999. Disponível em: <<http://dl.acm.org/citation.cfm?id=299094.299105>>. Acesso em: nov. 2020.
- Russell, S. J.; Norvig P. *Artificial intelligence: a modern approach*. Pearson Education, 3. ed., 2009. ISBN: 978-0136042594
- Swain, M. J.; Ballard D. H. Color indexing. *International Journal of Computer Vision*, 7(1), 11-32, 1991. doi: 10.1007/BF00130487