

DOI: 10.33947/1981-741X-v20n2-4834

APLICAÇÃO DE APRENDIZADO DE MÁQUINA COM DADOS DE SENSORIAMENTO REMOTO PARA O MAPEAMENTO DE FLORESTAS URBANAS**MACHINE LEARNING APPLICATION WITH REMOTE SENSING DATA FOR MAPPING URBAN FORESTS**Priscila Lôpo Guimarães Cano¹, José Marcato Junior²

Submetido em: 21/11/2021

Aprovado em: 03/12/2021

RESUMO

As florestas urbanas fornecem vários benefícios para as cidades, incluindo redução das temperaturas, melhorias na qualidade do ar, saúde e lazer da população e proteção de bacias hidrográficas, tornando assim um dos indicadores mais importantes da qualidade ambiental e sustentabilidade urbana. Campo Grande, no Mato Grosso do Sul, possui o título de "*Tree Cities of the World*", que reconhece as cidades mais comprometidas com a preservação das florestas urbanas e o desenvolvimento sustentável, portanto o mapeamento e monitoramento servem como ferramenta de auxílio para os governos e tomadores de decisão. O presente trabalho consistiu em combinar imagens de sensoriamento remoto de alta resolução e algoritmo de aprendizado de máquina (*machine learning*) para mapear florestas urbanas. O estudo foi realizado na Bacia hidrográfica do Prosa, Campo Grande, Mato Grosso do Sul, Brazil, considerando imagens do Google Earth de 14 de maio de 2020. Para fins de classificação, adotou-se o algoritmo *Random Forest* associado com segmentação prévia da imagem com a técnica *mean shift*. Como resultado, obteve-se um percentual de 18,31% de vegetação arbórea na bacia e a métrica F1 superior a 85%, possibilitando, assim, um mapeamento acurado e atualizado de florestas urbanas.

PALAVRAS-CHAVE: Árvores. *Random forest*. Classificação supervisionada. Arcgis pro.**ABSTRACT**

Urban forests provide several benefits to cities, including lowering temperatures, improving air quality, health and leisure for the population, and protecting watersheds, thus making them one of the most important indicators of environmental quality and urban sustainability. Campo Grande, in Mato Grosso do Sul, has the title of "*Tree Cities of the World*", which recognizes the cities most committed to the preservation of urban forests and sustainable development, therefore mapping and monitoring serve as an aid tool for governments and decision makers. The present work consisted of combining high resolution remote sensing images and machine learning algorithms to map urban forests. The study was carried out in the Prosa Watershed, Campo Grande, Mato Grosso do Sul, Brazil, considering Google Earth images from May 14, 2020. For classification purposes, the *Random Forest* algorithm associated with previous image segmentation was adopted. with the mean shift technique. As a result, a percentage of 18.31% of arboreal vegetation in the watershed was obtained and the F1 metric was higher than 85%, thus enabling an accurate and updated mapping of urban forests.

KEYWORDS: Trees. *Random forest*. Supervised classification. Arcgis pro

¹ Mestranda do curso de Pós Graduação em Recursos Naturais pela Universidade Federal de Mato Grosso do Sul, Faculdade de Engenharia, Arquitetura e Urbanismo e Geografia, Campo Grande, MS, Brasil.

² Professor Doutor, na Universidade Federal de Mato Grosso do Sul, Faculdade de Engenharia, Arquitetura e Urbanismo e Geografia, Campo Grande, MS, Brasil.

INTRODUÇÃO

Os ambientes urbanos são considerados sistemas complexos e heterogêneos, pois possuem componentes ecológicos, físicos e socioeconômicos que interagem e progridem em múltiplas escalas espaciais e temporais (BLASCHKE et al., 2011). Portanto, a necessidade de mais informações e compreensão de como esses sistemas funcionam e progridem é necessária para governos e tomadores de decisão. Isso se deve, principalmente, ao fato de terem adotado a Agenda de Desenvolvimento Sustentável das Nações Unidas para 2030, com o objetivo de tornar as cidades e os assentamentos humanos inclusivos, seguros, resilientes e sustentáveis (ZHU et al., 2019).

As florestas urbanas tornaram-se áreas essenciais para a sustentabilidade das cidades, fornecendo serviços ecossistêmicos para o bem-estar humano e ecológico. Muitos estudos destacam a importância dessas áreas para a melhoria da saúde e lazer da população, mitigação do microclima, purificação do ar, proteção de bacias hidrográficas, proteção de espécies e melhorias na drenagem urbana (GÓMEZ-BAGGETHUN; BARTON, 2013; WEINBRENNER et al., 2021; NGHIEM et al., 2021; HIRABAYASHI, 2021). Essas áreas são compostas por árvores individuais espalhadas ou blocos de árvores localizadas em parques, ruas, terrenos e jardins, e estão inseridos em ecossistemas altamente alterados e extremamente complexos, onde os humanos são os principais condutores de seus tipos, quantidades e distribuição (JENSEN et al., 2009; DOBBS et al., 2011). Por caracterizar-se como áreas importantes e potencialmente substanciais, o mapeamento e o monitoramento são necessários como ferramenta de análise visando o planejamento e gestão urbana adequados.

Nos últimos anos, a classificação de imagens com base em dados de sensoriamento remoto e algoritmos de aprendizado de máquina (*machine learning*) tem fornecido bons resultados para o mapeamento de florestas urbanas (CANETTI et al., 2018; CHEȚAN et al., 2017; NOVACK et al., 2011). Os algoritmos de aprendizado de máquina são capazes de modelar dados de classe complexos para identificar padrões e aceitar uma variedade de conjuntos de dados de entrada. Além disso, apresentam a vantagem de possuírem técnicas que permitem tomar decisões com pouca intervenção humana. Alguns exemplos desses algoritmos são o *Support Vector Machine* (SVM) e o *Random Forest* (RF) (MAXWELL et al., 2018, LI; STEIN, 2020). No estudo realizado por Canetti et al. (2018) com o SVM concluíram que esta é uma estratégia eficaz para quantificar a cobertura arbórea em cidades, como a Araucária no Paraná, Brasil. Em relação ao *Random Forest*, Puissant et al. (2014) certificaram que o algoritmo não requer o ajuste de muitos parâmetros, portanto, apresenta formas mais fáceis e eficientes para identificar a vegetação no contexto urbano.

Na cidade de Campo Grande, Mato Grosso do Sul, Brasil, foram realizados alguns estudos sobre a vegetação urbana. Esses estudos usaram métodos baseados em segmentação com aprendizado profundo (*deep learning*) para identificação de espécies de árvores (LOBO TORRES et al., 2020; ARCE et al., 2021), identificação de copas de árvores (MARTINS et al., 2020) e detecção de árvores individuais (ZAMBONI et al., 2021). Cabe ressaltar que esses estudos foram realizados em

áreas relativamente pequenas, não englobando sequer uma bacia hidrográfica urbana. Outro aspecto é que os métodos de aprendizado profundo requerem conjuntos de dados de rotulagem extensos, que, em geral, não estão disponíveis para cidades ao redor do mundo. Métodos tradicionais de aprendizado de máquina combinados com segmentação de imagens surgem como uma alternativa neste cenário, pois exigem menor esforço no processo de rotulação.

Os métodos tradicionais de aprendizado de máquina podem aumentar a capacidade de monitoramento e mapeamento da cobertura do solo urbano em todo o mundo devido à sua baixa exigência de rotulação. Também cabe destacar a importância do nosso produto como insumo para os tomadores de decisão em termos de planejamento e gestão sustentável da cidade. Campo Grande tem o título de "*Tree Cities of the World*", que reconhece as cidades mais comprometidas com a preservação das florestas urbanas e o desenvolvimento sustentável pela Organização das Nações Unidas para Agricultura e Alimentação e a Fundação Dia da Árvore. Porém, existe uma lacuna de estudos e produtos relacionados ao seu mapeamento pela cidade, e o presente trabalho visa suprir parcialmente essa lacuna. Portanto, o objetivo deste estudo consiste em combinar imagens de sensoriamento remoto de alta resolução e algoritmo de aprendizado de máquina para mapear as florestas urbanas da Bacia Hidrográfica do Prosa na cidade de Campo Grande (Mato Grosso do Sul - MS / Brasil).

MATERIAL E MÉTODOS

A área de estudo está localizada no município de Campo Grande, Mato Grosso do Sul, Brasil (Figura 1). O município de Campo Grande possui 96,3% dos domicílios urbanos com arborização em vias (IBGE, 2010). Especificamente, estudamos a Bacia Hidrográfica do Prosa localizada na porção leste da área urbana da cidade. A bacia possui uma heterogeneidade de cobertura e usos do solo, incluindo prédios comerciais e residenciais e reservas de vegetação para preservação de amostras do ecossistema do Cerrado, como o Parque das Nações Indígenas e o Parque Estadual do Prosa.

A região onde se localiza a bacia também pode ser caracterizada pelo aumento do grau de impermeabilidade do solo, devido ao alto desenvolvimento urbano dos últimos anos. Assim, contribuindo para intensificar o escoamento superficial e, conseqüentemente, os processos de inundação e erosão (CAMPO GRANDE, 2015).

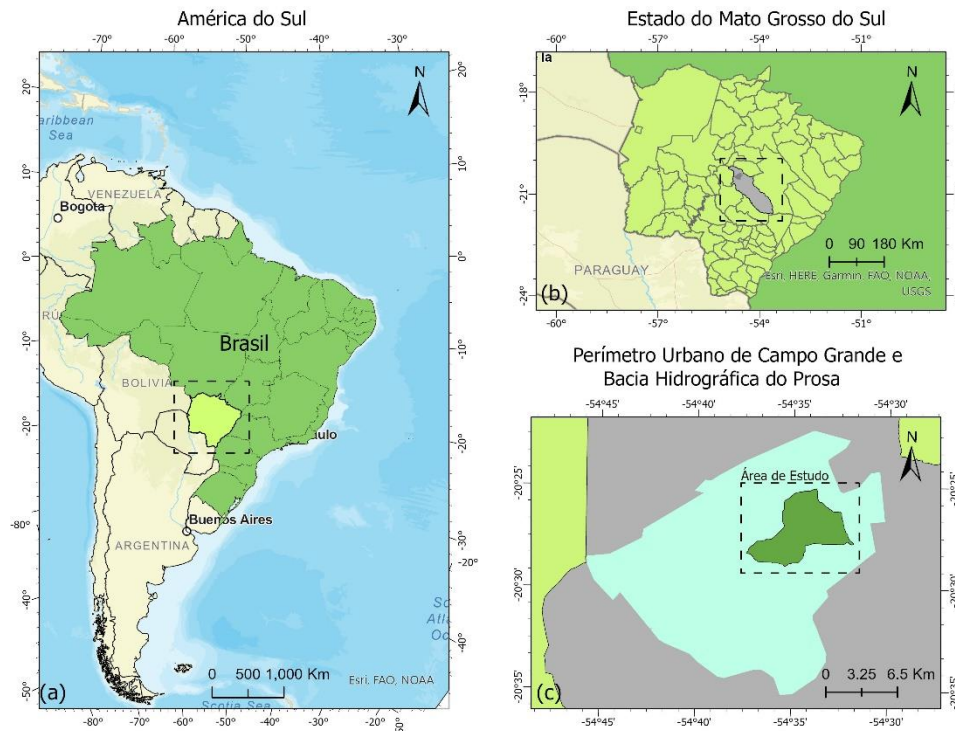


Figura 1 – Localização da área de estudo.

Figure 1 - Study area.

Fonte: Elaborada pelos autores

Para realizar o estudo, definimos um fluxo de trabalho de quatro etapas: a) seleção de amostras de treinamento para o esquema de classificação, b) segmentação da imagem de satélite, c) classificação supervisionada e d) avaliação da classificação. Todas as etapas foram realizadas no software ArcGIS Pro.

O dado raster utilizado foi um mosaico de imagens de satélite do Google Earth Pro, de 14 de maio de 2020, com resolução espacial de 0,50 metros. O sistema de projeção adotado foi o Universal Transverse Mercator (UTM), zona 21 Sul, Datum SIRGAS 2000. Os dados vetoriais relativos aos limites da cidade e da bacia foram adquiridos através do site do Instituto Brasileiro de Geografia e Estatística (IBGE) e município de Campo Grande, respectivamente.

Na primeira etapa, selecionamos as amostras de treinamento para o esquema de classificação, vetorizando duas classes para compor as amostras de treinamento denominadas: árvores e outras. A classe de árvores continha 218 amostras com árvores individuais, blocos de árvores e florestas de diferentes tons de verde, enquanto a outra classe era composta por 197 amostras que incluíam edifícios, solo exposto, grama, lagos, piscinas e asfalto, ou seja, tudo que não é caracterizado como árvore.

Para realizar a classificação selecionamos o tipo supervisionada, para tanto sendo necessário a segmentação da imagem de satélite, agrupando pixels adjacentes com características espectrais

semelhantes em objetos de imagem. As unidades de processamento são convertidas de pixels convencionais em objetos de imagem (HAN et al., 2015). Utilizou-se o algoritmo *mean shift*,

considerando-se o valor de 20 (vinte) para ambos os detalhes espectrais e espaciais, e o tamanho mínimo de 20 pixels para o segmento, visando mapear até mesmo árvores pequenas.



Figura 2 – Detalhes imagem segmentada e amostra.

Figure 2 - Detalhes imagem segmentada e amostra.

Fonte: Elaborada pelos autores.

Definidas as amostras de treinamento, o esquema de classificação e a imagem segmentada, realizamos o processo de classificação supervisionada com base em objetos. O algoritmo escolhido para realizar a classificação foi *Random Forest*, pois apresentou melhor desempenho nos testes realizados, além de possuir um histórico bem-sucedido em diversos estudos com vegetação arbórea (PUISSANT et al., 2014; MA et al., 2017; MASCHLER; ATZBERGER; IMMITZER, 2018; PERSSON; LINDBERG; REESE, 2018; HARTLING; SAGAN; MAIMAITIJIANG, 2021)

Para avaliar a precisão da classificação criamos 500 (quinhentos) pontos distribuídos aleatoriamente pela área de estudo, não coincidentes com os segmentos usados no treinamento. O dado de entrada foi a imagem classificada, e o esquema de amostragem escolhido foi o aleatório estratificado, onde cada classe possui um número de pontos proporcional à sua área. Realizada a validação manual geramos uma matriz de confusão.

A matriz de confusão contém informações sobre o número de amostras classificadas corretamente e incorretamente em comparação com os resultados reais. Através dessa matriz estimamos algumas métricas: sensibilidade, especificidade, precisão e pontuação F1. A sensibilidade é uma métrica que indica quanto o modelo classificou corretamente os padrões que eram positivos,

enquanto a especificidade indica a correta classificação em relação aos negativos. A precisão consiste em avaliar a quantidade de verdadeiros positivos em relação a todos os valores positivos, a acurácia indica a exatidão do modelo e o quanto ele detectou corretamente em todas as classificações, e a Pontuação F1 é uma média harmônica da precisão e da sensibilidade. Abaixo são apontadas as equações referentes as métricas informadas:

$$\text{Sensibilidade} = \frac{VP}{(VP + FN)}$$

$$\text{Especificidade} = \frac{VN}{(FP + VN)}$$

$$\text{Precisão} = \frac{VP}{(VP + FP)}$$

$$\text{Acurácia} = \frac{(P + N)}{(2 \times VP)}$$

$$\text{Pontuação F1} = \frac{(2 \times VP)}{[(2 \times VP) + FP + FN]}$$

RESULTADOS E DISCUSSÃO

O mapa resultante da classificação supervisionada das árvores urbanas na Bacia Hidrográfica do Prosa pode ser visualizado na Figura 3. A Bacia Hidrográfica do Prosa possui uma área de 31.9704 km², enquanto a área arbórea classificada corresponde a 5.8544 km². Portanto, a arborização urbana ocupa um total de 18,31% da bacia. Destacam-se na área de estudo o Parque das Nações Indígenas (amarelo) e a Unidade de Conservação do Estado do Prosa (vermelho), correspondentes a 1,43% e 4,03%, respectivamente.

DOI: 10.33947/1981-741X-v20n2-4834

APLICAÇÃO DE APRENDIZADO DE MÁQUINA COM DADOS DE SENSORIAMENTO REMOTO PARA O MAPEAMENTO DE FLORESTAS URBANAS
Priscila Lôpo Guimarães Cano, José Marcato Junior

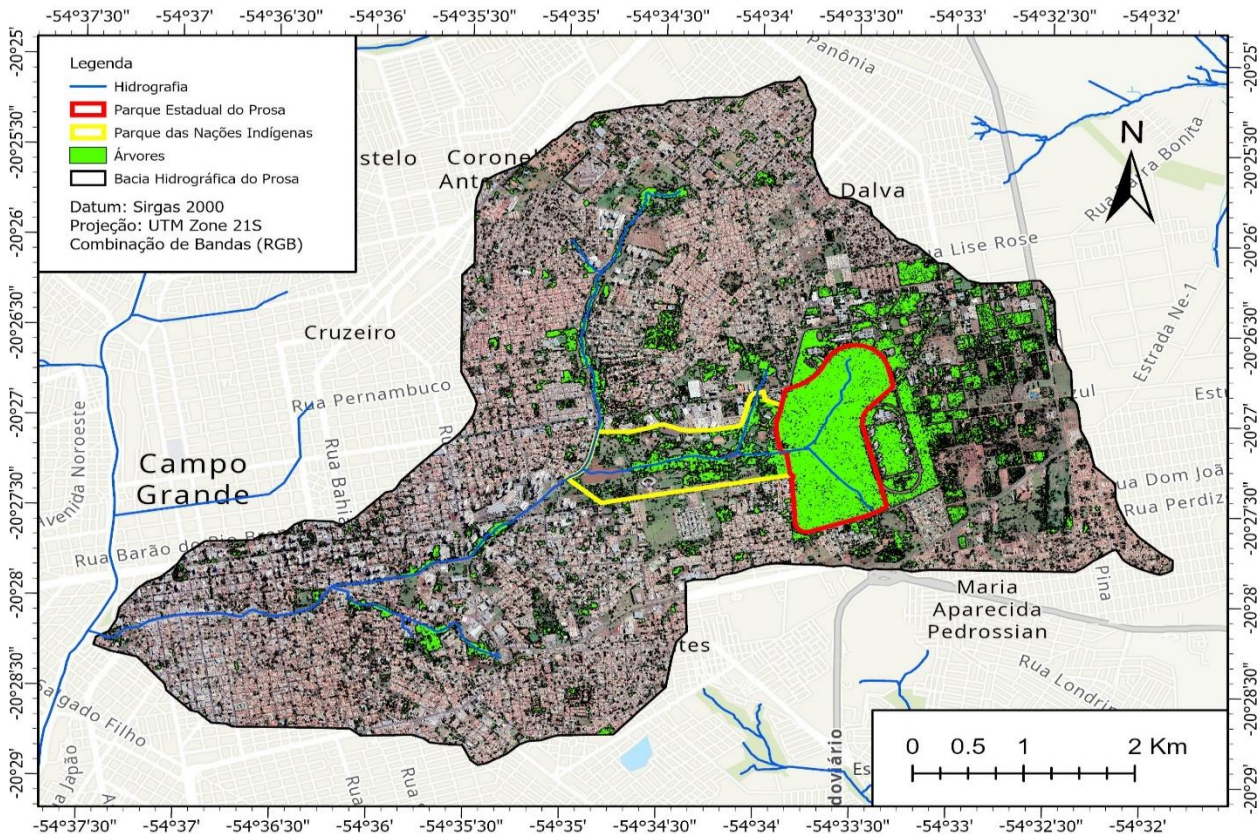


Figura 3 – Mapeamento da Floresta urbana na Bacia Hidrográfica do Prosa
Figure 3 - Urban Forest Mapping in the Prosa Hydrographic Basin.

Fonte: Elaborada pelos autores.

Segundo o Plano Diretor de Drenagem Urbana de Campo Grande (CAMPO GRANDE, 2008) a bacia hidrográfica do Prosa apresenta 21% de cobertura vegetal, enquanto neste estudo foi encontrado, para maio de 2020, um percentual de 18,31% de vegetação arbórea.

Em comparação com outras cidades brasileiras, por exemplo, Mossoró-RN com 6,90% (EDUARDO et al., 2013) e Rondonópolis-MT com 8% (PESSI et al., 2019), o percentual encontrado é superior e favorável aos demais, proporcionando aos moradores da região uma melhor qualidade de vida, servindo como barreira aos poluentes e melhorando a sensação térmica das cidades.

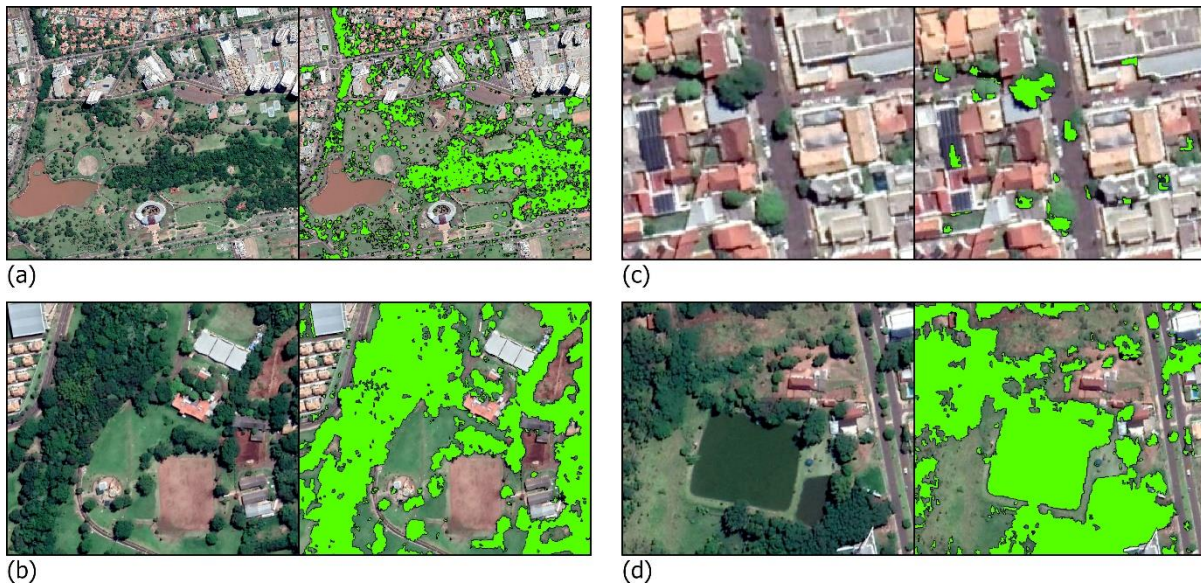


Figura 4 – Detalhes da classificação supervisionada.

Figure 4 - Details of supervised classification.

Fonte: Elaborada pelos autores

Alguns detalhes da classificação foram destacados na Figura 4. Os exemplos das Figuras 4.a e 4.b apresentam uma classificação correta, preenchendo maior parte das áreas que correspondem à classe árvores. Porém, na Fig. 4.c, verificou-se que o algoritmo não obteve uma resposta satisfatória, deixando de classificar os objetos com a cor verde mais clara. Esses objetos são árvores com folhagem mais clara, facilmente confundidas com grama, caracterizando falsos negativos. Na Fig. 4.d, há um falso positivo, a área correspondente a um lago com acúmulo de algas possui uma característica espectral semelhante à das árvores. No estudo de Feng et al. (2015), que utilizaram *Random Forest* para classificação, a mesma confusão de características foi obtida, e os autores relataram que esses erros ocorrem principalmente devido à baixa qualidade espectral das imagens ou à falta de uma banda do infravermelho próximo que reduz a separabilidade de cada tipo de cobertura do solo.

Quanto à validação da classificação das imagens (Tabela 1), o número de pixels de árvores corretamente classificados, indicando a sensibilidade do modelo, foi de 80,58% (83 verdadeiros positivos de 103 pontos para árvores de classe). Para as áreas que o classificador detectou como não arbóreas e acertou, alcançou um percentual de 97,73%. A partir da matriz de confusão obteve-se uma precisão geral de 94,20% e uma medida F1 de 85,13%.

MATRIZ DE CONFUSÃO			
Valor Verdadeiro			
		Positivo	Negativo
Valor Previsto	Positivo	83 (VP)	9 (FP)
	Negativo	20 (FN)	388 (VN)
MÉTRICAS			VALOR OBTIDO (%)
		Sensibilidade	80.58
		Especificidade	97.73
		Precisão	90.22
		Acurácia	94.20
		Pontuação F1	85.13

Tabela 1. Matriz de confusão.

Table 1. Confusion matrix.

Fonte: Elaborada pelos autores.

A precisão da classificação supervisionada está relacionada à qualidade e ao equilíbrio quantitativo de amostras de diferentes classes, onde podem ocorrer mal-entendidos humanos, bem como devido à complexidade da cobertura do solo e da variabilidade entre as classes (EGOROV et al., 2015; PELLETIER et al., 2017). Analisando a classificação, notamos que os resultados foram satisfatórios. Porém, considerando os erros encontrados, pode-se utilizar de técnicas de aprendizado profundo para melhorar o desempenho da classificação, conforme informado por Reichstein et al. (2019) que afirmam uma melhoria substancial no mapeamento e monitoramento ambiental do terreno usando dados de sensoriamento remoto e técnicas de aprendizado profundo, superando os métodos tradicionais de aprendizado de máquina. No entanto, é importante destacar que esses métodos requerem grandes conjuntos de dados rotulados.

CONCLUSÃO

As imagens disponíveis e utilizadas do Google Earth Pro, além de possuírem uma alta resolução espacial, tendem a ser mais vantajosas por permitirem uma aplicação em larga escala, envolvem uma aquisição facilitada e de investimento nulo e possuem imagens atualizadas no contexto urbano, favorecendo assim o mapeamento e monitoramento de florestas urbanas em todo o globo.

Na classificação com o algoritmo *Random Forest* ocorreu alguns erros, os quais estão relacionados à resposta de similaridade espectral dos alvos. Mesmo com essas confusões, uma pontuação F1 superior a 85% foi alcançada para a tarefa selecionada.

Por fim, este trabalho indicou que o uso de imagens do Google Earth Pro submetidas à classificação com o algoritmo *Random Forest* apresentam um bom desempenho para o mapeamento de árvores em um ambiente urbano. A ferramenta abordada auxilia no monitoramento e planejamento sustentável, possibilitando classificar, mapear e monitorar as florestas urbanas simultaneamente, e os dados obtidos podem determinar o potencial de captura de carbono dessas áreas, como também servir de informação para outros estudos. Como orientação para trabalhos futuros, prevemos aplicar a metodologia para áreas permeáveis, como também aplicar métodos de aprendizado profundo.

REFERÊNCIAS

- ARCE, L. S. D. et al. *Mauritia flexuosa* palm trees airborne mapping with deep convolutional neural network. **Scientific Reports**, v. 11, 19619, 2021.
- BLASCHKE, T. et al. Collective sensing: Integrating geospatial technologies to understand urban systems—An overview. **Remote Sensing**, v. 3, n. 8, p. 1743-1776, 2011.
- CANETTI, A. et al. Understanding multi-temporal urban forest cover using high resolution images. **Urban Forestry & Urban Greening**, v. 29, p. 106-112, 2018.
- CAMPO GRANDE. Agência Municipal de Meio Ambiente e Planejamento Urbano – PLANURB. **Relatório de Avaliação Ambiental (RAA) do Programa de Desenvolvimento Integrado do Município de Campo Grande/MS: Viva Campo Grande. 2ª Etapa.** Campo Grande: Groen, 2015.
- CAMPO GRANDE. Agência Municipal de Meio Ambiente e Planejamento Urbano – PLANURB. **Plano Diretor de Drenagem Urbana de Campo Grande: Diagnóstico Ambiental Analítico das Bacias Hidrográficas: Relatório R5.** Campo Grande, 2008.
- CHEȚAN, M. A.; DORNIK, A.; URDEA, P. Comparison of object and pixel-based land cover classification through three supervised methods. **Journal of Geodasy, Geoinformation and Land Management**, 2017.
- DOBBS, C.; ESCOBEDO, F. J.; ZIPPERER, W. C. A framework for developing urban forest ecosystem services and goods indicators. **Landscape and urban planning**, v. 99, n. 3-4, p. 196-206, 2011.
- EDUARDO, L. V. et al. Índice de área verde e de cobertura vegetal no perímetro urbano central do município de Mossoró-RN. **Revista Verde de Agroecologia e Desenvolvimento Sustentável**, v. 8, n. 2, 2013.
- EGOROV, A. V. et al. Image interpretation-guided supervised classification using nested segmentation. **Remote Sensing of Environment**, v. 165, p. 135-147. 2015.
- ESRI - Environmental Systems Research Institute. **Software ArcGIS Pro.** 2021. Version 2.8.1, student license with registration number 0330653. Disponível em:<<https://www.esri.com>>.
- FENG, Q.; LIU, J.; GONG, J. UAV remote sensing for urban vegetation mapping using random forest and texture analysis. **Remote sensing**, v. 7, n. 1, p. 1074-1094, 2015.

- GÓMEZ-BAGGETHUN, E.; BARTON, D. N. Classifying and valuing ecosystem services for urban planning. **Ecological economics**, v. 86, p. 235-245, 2013.
- HAN, N. et al. Exploring the synergistic use of multi-scale image object metrics for land-use/land-cover mapping using an object-based approach. **International Journal of Remote Sensing**, v. 36, n. 13, p. 3544-3562, 2015.
- HARTLING, S.; SAGAN, V.; MAIMAITIJIANG, M. Urban tree species classification using UAV-based multi-sensor data fusion and machine learning. **GIScience & Remote Sensing**, p. 1-26, 2021.
- HIRABAYASHI, S. Technical specifications of urban forests for air purification: A case study in Tokyo, Japan. **Trees, Forests and People**, v. 4, p. 100078, 2021.
- IBGE – Instituto Brasileiro de Geografia e Estatística. Brasil. **Censo Demográfico 2010**. Disponível em: <<https://cidades.ibge.gov.br/brasil/ms/campo-grande/panorama>>. Acesso em: 20 jul. 2021.
- JENSEN, R. R. et al. Modeling urban leaf area index with AISA+ hyperspectral data. **Applied Geography**, v. 29, n. 3, p. 320-332, 2009.
- LI, M.; STEIN, A. Mapping land use from high resolution satellite images by exploiting the spatial arrangement of land cover objects. **Remote sensing**, v. 12, n. 24, p. 4158, 2020.
- LOBO TORRES, D. et al. Applying fully convolutional architectures for semantic segmentation of a single tree species in urban environment on high resolution UAV optical imagery. **Sensors**, v. 20, n. 2, p. 563, 2020.
- MA, L. et al. A review of supervised object-based land-cover image classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 130, p. 277-293, 2017.
- MARTINS, J. et al. Aerial Image Segmentation In Urban Environment For Vegetation Monitoring. **IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS)**, p. 375-379, 2020.
- MASCHLER, J.; ATZBERGER, C.; IMMITZER, M. Individual tree crown segmentation and classification of 13 tree species using airborne hyperspectral data. **Remote Sensing**, v. 10, n. 8, p. 1218, 2018.
- MAXWELL, A. et al. Implementation of machine-learning classification in remote sensing: An applied review. **International Journal of Remote Sensing**, v. 39, n. 9, p. 2784-2817, 2018.
- NGHIEM, T. P. L. et al. Biodiverse urban forests, happy people: Experimental evidence linking perceived biodiversity, restoration, and emotional well-being. **Urban Forestry & Urban Greening**, v. 59, p. 127030, 2021.
- NOVACK, T. et al. Machine learning comparison between WorldView-2 and QuickBird-2-simulated imagery regarding object-based urban land cover classification. **Remote sensing**, v. 3, n. 10, p. 2263-2282, 2011.
- PELLETIER, C. et al. Effect of training class label noise on classification performances for land cover mapping with satellite image time series. **Remote Sensing**, v. 9, n. 2, p. 173. 2017.
- PERSSON, M.; LINDBERG, E.; REESE, H. Tree species classification with multi-temporal Sentinel-2 data. **Remote Sensing**, v. 10, n. 11, p. 1794, 2018.

DOI: 10.33947/1981-741X-v20n2-4834

APLICAÇÃO DE APRENDIZADO DE MÁQUINA COM DADOS DE SENSORIAMENTO REMOTO PARA O MAPEAMENTO DE FLORESTAS URBANAS
Priscila Lôpo Guimarães Cano, José Marcato Junior

PESSI, D. D. et al. Vegetation cover in urban microbasins: temporal analysis of the arboreal cover and temperature of Rondonópolis, Mato Grosso. **Revista Brasileira de Geografia Física**, v. 12, n. 1, p. 299-309, 2019.

PUISSANT, A. et al. Object-oriented mapping of urban trees using Random Forest classifiers. **International Journal of Applied Earth Observation and Geoinformation**, v. 26, p. 235-245, 2014.

REICHSTEIN, M. et al. Deep learning and process understanding for data-driven Earth system science. **Nature**, v. 566, n. 7743, p. 195-204, 2019.

WEINBRENNER, H. et al. "The Forest Has Become Our New Living Room"—The Critical Importance of Urban Forests During the COVID-19 Pandemic. **Frontiers in Forests and Global Change**, v. 4, p. 68, 2021.

ZAMBONI, P. et al. Benchmarking Anchor-Based and Anchor-Free State-of-the-Art Deep Learning Methods for Individual Tree Detection in RGB High-Resolution Images. **Remote Sensing**, v. 13, n. 13, p. 2482, 2021.

ZHU, Z. et al. Understanding an urbanizing planet: Strategic directions for remote sensing. **Remote Sensing of Environment**, v. 228, p. 164-182, 2019.