



ARTIGOS COMPLETOS	114
RESUMOS	127
RELATOS DE EXPERIÊNCIA	131



ARTIGOS COMPLETOS

SEGMENTAÇÃO DE VEGETAÇÃO ARBÓREA EM ÁREA URBANA UTILIZANDO O SEGMENT ANYTHING MODEL (SAM) E IMAGENS DO STREET VIEW 115

SEGMENTAÇÃO DE VEGETAÇÃO ARBÓREA EM ÁREA URBANA UTILIZANDO O SEGMENT ANYTHING MODEL (SAM) E IMAGENS DO STREET VIEW

Danielle Elis Garcia Furuya¹, Michelle Tais Garcia Furuya¹, Lucas Prado Osco¹, Ana Paula Marques Ramos²

¹Universidade do Oeste Paulista – UNOESTE, Presidente Prudente, SP. ²Universidade Estadual Paulista Júlio de Mesquita Filho – UNESP. E-mail: daniellegarciafuruya@gmail.com

RESUMO

O diagnóstico e monitoramento da vegetação arbórea são elementos importantes para o planejamento urbano. O sensoriamento remoto é uma opção viável para analisar áreas amplas e possibilita o estudo de determinada área sem a necessidade de ir até o local. As imagens do Street View podem fornecer mais detalhes na identificação de um alvo quando comparadas a imagens de satélite. A utilização de modelos e técnicas de Inteligência Artificial podem contribuir e otimizar os procedimentos ambientais. Nesse contexto, o Segment Anything Model (SAM) é um modelo de segmentação de imagens recente disponibilizado em abril de 2023 e possui diversas vantagens quando comparado aos métodos de segmentação tradicionais. O objetivo desse estudo foi analisar a capacidade do SAM em segmentar vegetação arbórea em área urbana com imagens do Street View da cidade de Presidente Prudente. Os resultados foram satisfatórios e mostraram que a utilização e aplicação de Inteligência Artificial traz vantagens para aplicações ambientais. A utilização do SAM para detectar vegetação otimiza as etapas de rotulação e facilita a segmentação de objetos na imagem.

Palavras-chave: vegetação arbórea, SAM, inteligência artificial, street view.

SEGMENTATION OF TREE VEGETATION IN URBAN AREA USING THE SEGMENT ANYTHING MODEL (SAM) AND STREET VIEW IMAGES.

ABSTRACT

The diagnosis and monitoring of tree vegetation are important elements for urban planning. Remote sensing is a viable option to analyze large areas and allows the study of a certain area without the need to go to the location. Street View imagery can provide more detail in identifying a target when compared to satellite imagery. The use of Artificial Intelligence models and techniques can contribute and optimize environmental procedures. In this context, the Segment Anything Model (SAM) is a recent image segmentation model available in April 2023 and has several advantages when compared to traditional segmentation methods. The objective of this study was to analyze the ability of SAM to segment tree vegetation in an urban area with Street View images of the city of Presidente Prudente. The results were satisfactory and showed that the use and application of Artificial Intelligence brings advantages to environmental applications. The use of SAM to detect vegetation optimizes the labeling steps and facilitates the segmentation of objects in the image.

Keywords: tree vegetation, SAM, artificial intelligence, street view.

INTRODUÇÃO

A vegetação em áreas urbanas fornece serviços ecossistêmicos que são importantes para a biodiversidade e o bem estar. As áreas verdes são consideradas essenciais na vida do ser humano (O'BRIEN et al, 2017; FERRINI et al, 2020) e é possível encontrar diferentes tipos de vegetação, como árvores, arbustos e grama, nas áreas urbanas (DRILLET et al, 2020).

Alguns dos exemplos das vantagens da vegetação arbórea nas áreas urbanas é o controle da temperatura, resfriamento do ar, produção de biomassa, absorção de poluentes do ar, redução de ruído (PAULEIT et al, 2011; GATTO et al, 2020; LIVESLEY et al, 2016) além de ser um elemento central para mitigar as mudanças climáticas (FERRINI et al, 2020).

O sensoriamento remoto tornou-se uma ferramenta importante para análises ambientais e tem potencial para ser combinado com outros métodos de monitoramento e avaliação (WELLMANN et al, 2020; DONG et al, 2019). O mapeamento da vegetação em áreas urbanas com técnicas de sensoriamento remoto pode ser útil para o planejamento e para lidar com os desafios urbanos (GAŠPAROVIĆ e DOBRINIĆ, 2020). Para determinado estudo, as imagens de satélite podem ser insuficientes para uma análise, como no caso de identificação de espécies arbóreas. Nesses casos, a visão aérea de imagens de satélite não disponibiliza o detalhamento necessário para o reconhecimento de vegetação arbórea.

As imagens do Street View fornecem uma nova opção para analisar e estudar as áreas urbanas com mais detalhes (LARKIN et al, 2021). Um estudo feito por Barbierato et al 2020, propôs um conjunto de métricas para áreas verdes urbanas com a combinação de sensoriamento remoto e sensoriamento próximo (Street View). Os autores classificaram as áreas verdes por segmentação semântica com a utilização de redes neurais profundas e obtiveram acurácia de 83%.

Outro estudo feito por LI et al, 2018, apresentou um novo método para identificar sombras de árvores nas ruas do centro da cidade de Boston com o auxílio de imagens do Street View para calcular o fator de visão do céu. De acordo com os autores, as imagens no nível da rua possibilitaram considerar obstruções sem depender de simulações do ambiente ou simplificações.

A combinação de métodos ajuda na tomada de decisão, contribui para futuros projetos de esverdeamento urbano para moderação do clima urbano e tornam o sensoriamento remoto mais acessível para planejadores urbanos e pesquisadores que necessitam de dados qualitativos (LI et al, 2018; WELLMANN et al, 2020).

A Inteligência Artificial (IA) é uma tecnologia robusta e promissora. As aplicações e desenvolvimento da IA crescem a cada ano em diversas áreas, inclusive nas áreas urbanas e ambiental (YIGITCANLAR et al, 2020; ALLAM e DHUNNY, 2019). A utilização de Inteligência Artificial na arborização urbana contribui para a tomada de decisões a fim de melhorar a qualidade das cidades, pois o bem estar dos cidadãos depende em grande parte das florestas urbanas (ARAÚJO et al, 2021).

A segmentação de imagens é uma parte importante do processamento de imagens e diversos métodos são desenvolvidos rapidamente para realizar este processo (LIU et al, 2021). A segmentação divide uma imagem inteira em diversas regiões que possam ter propriedades semelhantes, separando um alvo de interesse (LIU et al, 2021). Novas tecnologias incluindo a Inteligência Artificial contribuem para otimizar o processo de segmentação de imagens com a aplicação de um modelo, algoritmo, entre outros (LATEEF e RUICHEK, 2019; LIU et al, 2021). A segmentação de imagens com a utilização de técnicas de machine e deep learning atingiram resultados satisfatórios e mostraram que a utilização de IA auxilia na segmentação de imagens (HESAMIAN et al, 2019; BHATNAGAR, et al, 2020).

Um estudo feito por Lassiter e Darbari, 2020, avaliou três métodos não supervisionados para segmentar vegetação em área urbana, incluindo o k-means e a Convolutional Neural Network (CNN). Os autores verificaram que cada método possui um melhor desempenho na segmentação dependendo do alvo, como por exemplo a presença de sombras e vegetação secundária. Apesar de avaliarem mais de um método, os autores verificaram que são opções viáveis para segmentar vegetação urbana.

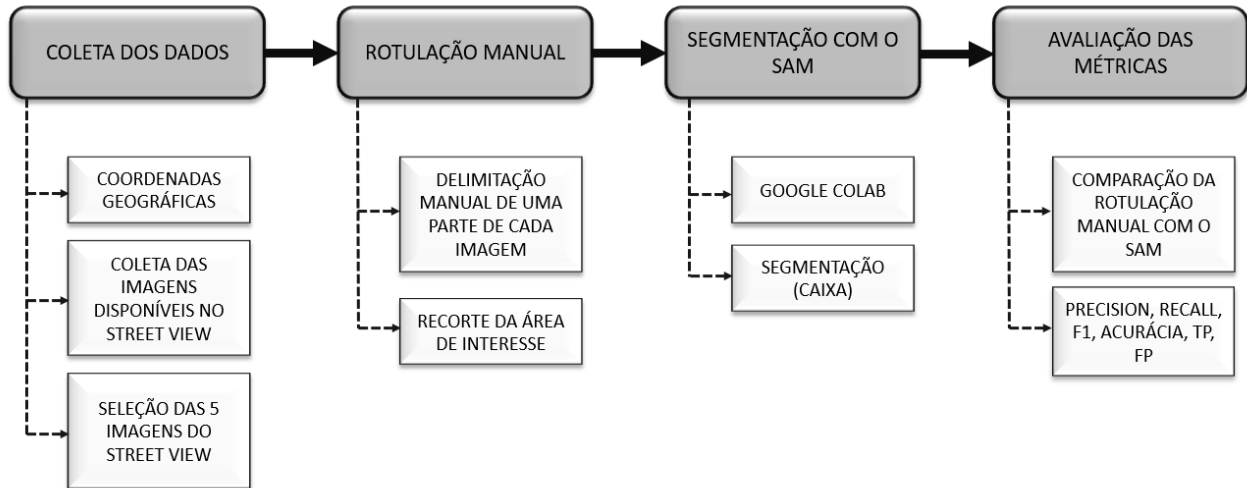
O Segment Anything Model (SAM) é uma ferramenta atual disponibilizada em abril de 2023, e foi projetado para segmentar objetos de interesse em imagens a partir de prompts fornecidos por pontos, caixas ou texto (MAZUROWSKI et al, 2023). A recente contribuição do SAM é segmentar qualquer objeto de uma imagem sem a necessidade de realizar treinamento anteriormente (Meta AI, 2023).

No contexto atual de Inteligência Artificial e segmentação de imagens, o objetivo deste estudo foi avaliar a performance do Segment Anything Model (SAM) na segmentação de vegetação arbórea em imagens do Street View da cidade de Presidente Prudente em comparação com a rotulação manual.

METODOLOGIA

A realização deste estudo foi feita em quatro etapas principais: coleta dos dados, rotulação manual, segmentação de vegetação arbórea com o SAM e avaliação das métricas. As etapas deste estudo estão descritas conforme a Figura 1.

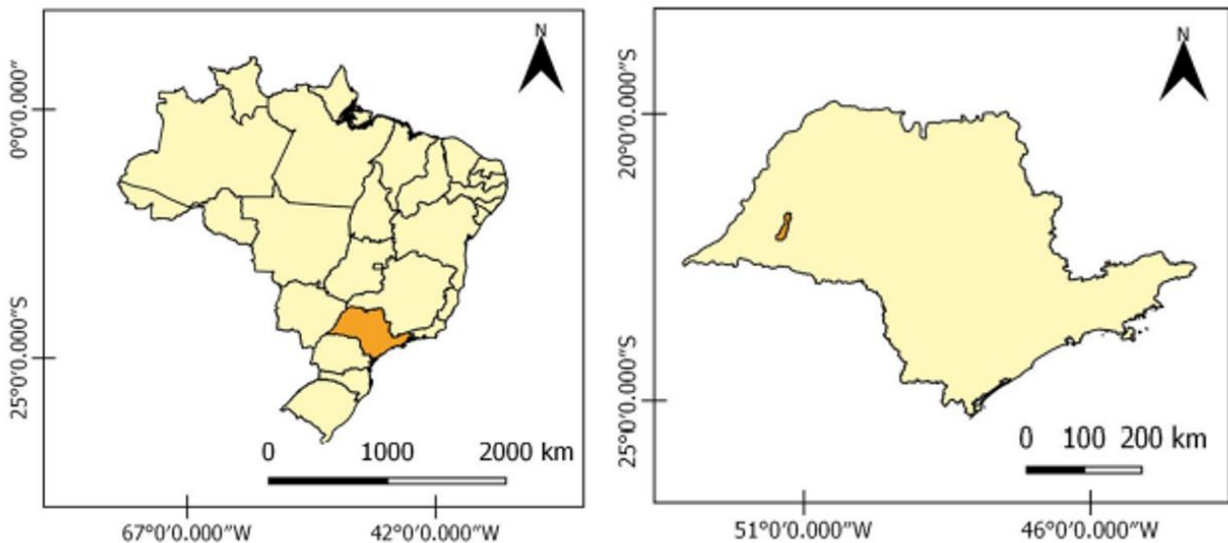
Figura 1. Fluxograma com as principais etapas da metodologia.



Fonte: (Os autores).

A área de estudo corresponde a cidade de Presidente Prudente, localizada no estado de São Paulo, Brasil. A cidade possui vegetação arbórea composta de vegetação nativa e exótica nas áreas urbanas. A Figura 2 mostra a localização da área de estudo.

Figura 2. Localização da cidade de Presidente Prudente.



Fonte: (Furuya et al, 2023).

Para a aquisição das imagens do Street View de Presidente Prudente foi selecionada uma área urbana (Figura 3) que anteriormente foi identificada a presença de espécies arbóreas nativas e exóticas. A partir da seleção, as coordenadas geográficas da área foram identificadas e posteriormente foi realizada a coleta das imagens do Street View disponíveis da área escolhida.

Para a cidade de Presidente Prudente foram encontradas 72 imagens do Street View na área urbana escolhida. Apesar da quantidade, diversas imagens correspondem a imagens com o mesmo ângulo, mas de anos diferentes, sendo visualmente similares. Portanto, para este estudo foram selecionadas 5 imagens. A Figura 4 mostra alguns exemplos das imagens do Street View encontradas para a cidade de Presidente Prudente.

Figura 3. Área urbana com presença de vegetação arbórea escolhida para o estudo.



Fonte: (Google Earth Pro, 2023).

Figura 4. Exemplos de imagens do Street View encontradas na área selecionada de Presidente Prudente com base nas coordenadas geográficas.



Fonte: (Google Street View, 2022).

Para os testes de segmentação com o SAM, foram selecionadas 5 imagens do Street View: 2 imagens do ano de 2012; 1 imagem de 2015 e 2 imagens do ano de 2017. O código e os testes utilizados foram feitos no Google Colab.

Para verificar o desempenho do SAM na segmentação de vegetação arbórea, foi realizada a rotulação manual de partes de vegetação arbórea em cada uma das imagens selecionadas para posteriormente comparar os resultados na segmentação. A rotulação manual foi realizada no GIMP e o alvo de interesse foi delimitado para cada imagem conforme a Figura 5.

Figura 5. Exemplo da delimitação de vegetação arbórea por meio da rotulação manual.




Fonte: (Os autores, adaptado do Google Street View, 2023).

Após a delimitação de uma área com vegetação arbórea, foi feito o recorte da rotulação para ser comparado com a segmentação do SAM no Google Colab.

O SAM produz uma incorporação de imagem que pode ser consultado com eficiência por uma variedade de prompts de entrada para produzir máscaras de objeto em velocidade amortizada em tempo real (KIRILLOV et al, 2023). Para prompts correspondentes a mais de um objeto, o SAM pode produzir diversas máscaras válidas e pontuações de confiança associadas (Figura 6).

Figura 6. Exemplo de segmentação feita pelo SAM.



Fonte: (KIRILLOV et al, 2023).

Para a realização dos testes é necessário inserir a imagem do Street View escolhida no código utilizado. O Segment Anything Model (SAM) permite selecionar uma área pelo formato de caixas, pontos ou texto, nesse estudo foram feitos testes com o formato de caixas.

Após inserir a imagem no Google Colab, é possível delimitar uma caixa na área escolhida, conforme a Figura 7. Nos testes realizados foi feita a delimitação de uma caixa por imagem, dessa forma, o SAM não irá segmentar toda a vegetação arbórea de cada imagem, somente a que estiver dentro da caixa. Esse procedimento foi realizado pois o objetivo é avaliar o desempenho do SAM comparado a rotulação manual. Portanto, para cada imagem foi delimitada somente uma parte para comparar os dois métodos.

Figura 7. Exemplo da delimitação da área de interesse pelo formato de caixa do SAM.



Fonte: (Os autores, 2023).

A partir da delimitação da caixa (na cor azul) no próprio código no Google Colab conforme a Figura 7, o SAM realiza a segmentação do objeto encontrado dentro da caixa. O SAM também é utilizado para segmentar uma imagem inteira sem precisar de treinamento (Figura 8), mas como o objetivo deste estudo é analisar a capacidade do SAM em segmentar um alvo específico (vegetação arbórea), o procedimento é diferente.

Figura 8. Exemplo de segmentação realizada pelo SAM em toda a imagem fornecida.



Fonte: (Meta AI, 2023).

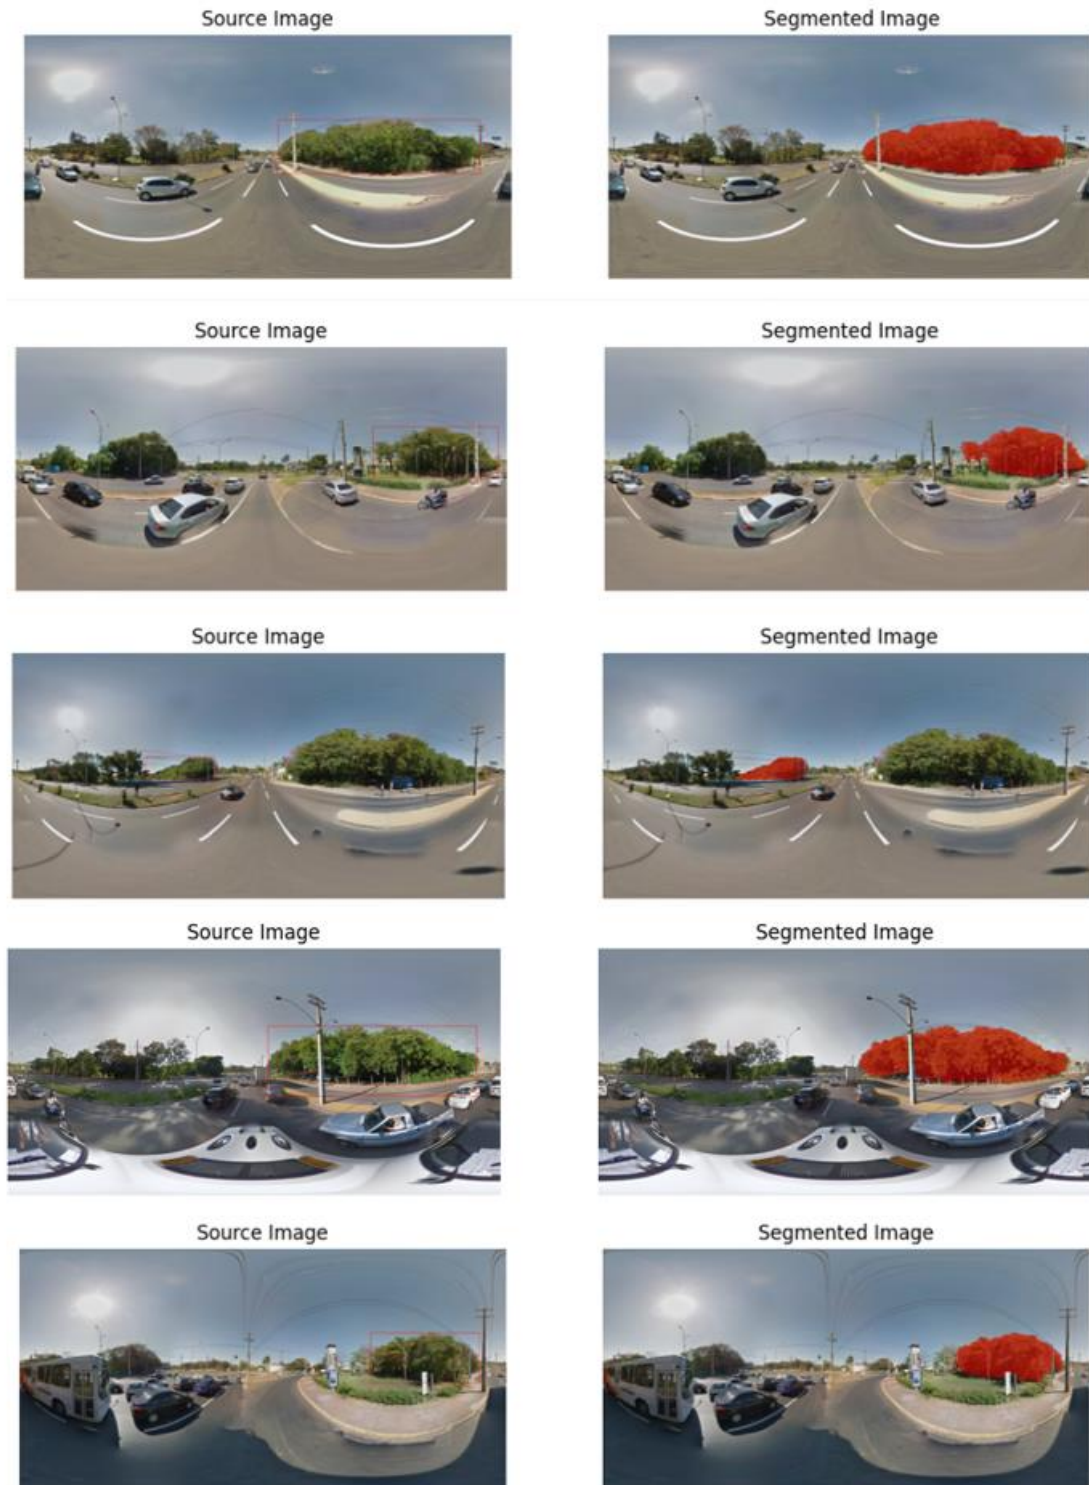
Assim que o SAM realizou a segmentação das áreas delimitadas, foi solicitado por meio do código a comparação da rotulação manual e a segmentação feita pelo SAM, os dois arquivos foram fornecidos e métricas de avaliação foram calculadas.

Neste estudo foi solicitado o cálculo das seguintes métricas: precision, recall, F-score, acurácia, verdadeiro positivo (TP) e falso positivo (FP).

RESULTADOS

Conforme descrito na metodologia, o SAM realizou a segmentação dos objetos encontrados dentro das caixas que foram selecionadas (Figura 9).

Figura 9. Segmentação realizada pelo SAM nas 5 imagens do Street View com base no formato da caixa.



Fonte: (Os autores).

Após a segmentação feita pelo SAM, foi solicitado a comparação dos dois métodos (rotulação manual e o SAM). As métricas de avaliação foram calculadas com base no recorte dos dois arquivos (Figuras 10 e 11).

Figura 10. Cálculo das métricas precision, recall, F1 e acurácia para uma das imagens.

```
# Calculate the precision, recall, F-score, and accuracy
precision = precision_score(img1_flat, img2_flat, average='weighted')
recall = recall_score(img1_flat, img2_flat, average='weighted', zero_division=1)
f1 = f1_score(img1_flat, img2_flat, average='weighted')
accuracy = accuracy_score(img1_flat, img2_flat)

print("Precision: ", precision)
print("Recall: ", recall)
print("F-score: ", f1)
print("Accuracy: ", accuracy)

Precision:  0.9917624274341269
Recall:    0.9906314646703958
F-score:   0.990940660413282
Accuracy:  0.9906314646703958
```

Fonte: (Os autores).

Figura 11. Cálculo das métricas verdadeiro positivo (TP) e falso positivo (FP) para uma das imagens.

```
# Assuming y_true and y_pred are the true and predicted labels for a binary classification problem
fpr, tpr, thresholds = roc_curve(img1_flat, img2_flat)

# Calculate the area under the ROC curve
roc_auc = auc(fpr, tpr)

print("True Positive Rate (TPR): ", tpr)
print("False Positive Rate (FPR): ", fpr)
print("Area Under the ROC Curve (AUC): ", roc_auc)

True Positive Rate (TPR):  [0.          0.98661512  1.         ]
False Positive Rate (FPR):  [0.          0.00914518  1.         ]
Area Under the ROC Curve (AUC):  0.9887349700358143
```

Fonte: (Os autores).

Este procedimento foi feito para cada uma das imagens, a Tabela 1 mostra a média de cada métrica calculada para as 5 imagens do Street View.

Tabela 1. Média das métricas obtidas nas 5 imagens com o SAM.

Métrica	Média
Precision	0.9951
Recall	0.9947
F1	0.9948
Acurácia	0.9947
Verdadeiro Positivo (TP)	0.9608
Falso Positivo (FP)	0.0298

Fonte: (Os autores, 2023).

DISCUSSÃO

A utilização de Inteligência Artificial (IA) em pesquisas e projetos está sendo aplicada em diversas áreas a fim de otimizar e facilitar a realização de uma tarefa. A Inteligência Artificial é um processo pelo qual o ser humano pode construir uma máquina inteligente que trabalha com base em aprendizados passados (JHA et al, 2019).

Dentro da área conhecida como IA, existem subgrupos como o aprendizado de máquina (machine learning) e o aprendizado profundo (deep learning) que auxiliam projetos e tarefas (BENOS et al, 2021; HELM et al, 2020). Diversos algoritmos e redes neurais são implantados em todas as áreas do conhecimento. O objetivo do aprendizado de máquina é alimentar a máquina com dados de experiências passadas e dados estatísticos para que ela possa executar uma tarefa atribuída para resolver um problema específico (JHA et al, 2019).

Estudos em diferentes áreas mostraram resultados satisfatórios com a combinação de ML/DL e segmentação de imagens (PIRALILOU et al, 2019; HAQUE e NEUBERT, 2020; RAEI et al, 2022; LEE et al, 2023). O processo de detecção de objetos a partir de uma imagem é uma etapa fundamental de qualquer técnica de processamento de imagem, pois a acurácia da classificação dependerá da qualidade dos resultados obtidos na etapa de segmentação (KHERADMANDI e MEHRANFAR, 2022).

A segmentação de imagens é importante para organizar uma imagem em pequenos números de regiões para entender “o que” e “onde” é/está o alvo na imagem (GHIASI et al, 2022). A rotulação de imagens demanda tempo e cautela para identificar corretamente o alvo de interesse. Apesar das técnicas de IA contribuírem com o avanço na classificação de imagens, novas técnicas e modelos podem acelerar as etapas anteriores de rotulação e segmentação.

Nos testes realizados neste estudo, verificou-se que o SAM foi capaz de segmentar a vegetação arbórea (alvo de interesse) com facilidade, apenas com a delimitação de uma caixa. A rotulação realizada anteriormente foi utilizada para comparar a precisão da segmentação realizada pelo SAM. A média das métricas utilizadas para as 5 imagens do Street View mostrou que a segmentação de vegetação arbórea com o SAM foi satisfatória, pois atingiu mais de 99%.

A utilização do Segment Anything Model (SAM) é promissora e tende a crescer nos próximos anos. Estudos estão iniciando os testes com a utilização do SAM pois o modelo foi disponibilizado pela META AI em abril de 2023. Até o momento, estudos que realizaram a aplicação do SAM para segmentação de imagens correspondem à área da saúde (análise de imagens médicas). Futuramente será possível comparar resultados mais amplos e complexos em diversas áreas do conhecimento.

CONSIDERAÇÕES FINAIS

A identificação e monitoramento de vegetação arbórea em áreas urbanas é de extrema importância para o planejamento urbano e para o bem estar da população. A utilização de técnicas de Inteligência Artificial na área ambiental tem crescido cada vez mais. O Segment Anything Model (SAM) é um modelo recente de segmentação de imagens disponibilizado em abril de 2023 pela Meta AI e otimiza o processo de identificação de imagens, pois não necessita de treinamento anterior. Os testes realizados nesse estudo com imagens do Street View mostraram que a segmentação de vegetação arbórea com o SAM é viável e atingiu boas acurácias (acima de 99%). A utilização do SAM ainda é pouco explorada devido ao curto tempo de lançamento desse modelo. Futuros estudos podem explorar a capacidade do modelo em segmentar espécies arbóreas e analisar as contribuições do SAM para a identificação de objetos em diferentes imagens.

AGRADECIMENTOS

Os autores agradecem o apoio financeiro da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES.

REFERÊNCIAS

- ALLAM, Z; DHUNNY, Z. A. On big data, artificial intelligence and smart cities. **Cities**, v. 89, p. 80-91, 2019. <https://doi.org/10.1016/j.cities.2019.01.032>
- ARAÚJO, H.C.L; MARTINS, F.S; CORTESE, T.T.P; LOCOSSELLI, G.M. Artificial intelligence in urban forestry—A systematic review. **Urban Forestry & Urban Greening**, v. 66, p. 127410, 2021. <https://doi.org/10.1016/j.ufug.2021.127410>
- BARBIERATO, E; BERNETTI, I; CAPECCHI, I; SARAGOSA, C. Integrating remote sensing and street view images to quantify urban forest ecosystem services. **Remote sensing**, v. 12, n. 2, p. 329, 2020. <https://doi.org/10.3390/rs12020329>
- BENOS, L; TAGARAKIS, A. C; DOLIAS, G; BERRUTO, R; KATERIS, D; BOCHTIS, D. Machine learning in agriculture: A comprehensive updated review. **Sensors**, v. 21, n. 11, p. 3758, 2021. <https://doi.org/10.3390/s21113758>
- BHATNAGAR, S; GILL, L; GHOSH, B. Drone image segmentation using machine and deep learning for mapping raised bog vegetation communities. **Remote Sensing**, v. 12, n. 16, p. 2602, 2020. <https://doi.org/10.3390/rs12162602>
- DONG, J; METTERNICHT, G.; HOSTERT, P.; FENSHOLT, R.; CHOWDHURY, R.R. Remote sensing and geospatial technologies in support of a normative land system science: Status and prospects. **Current Opinion in Environmental Sustainability**, v. 38, p. 44-52, 2019. <https://doi.org/10.1016/j.cosust.2019.05.003>
- DRILLET, Z; FUNG, T.K; LEONG, R.A.T; SACHIDHANANDAM, U; EDWARDS, P; RICHARDS, D. Urban vegetation types are not perceived equally in providing ecosystem services and disservices. **Sustainability**, v. 12, n. 5, p. 2076, 2020. <https://doi.org/10.3390/su12052076>
- FERRINI, F; FINI, A; MORI, J; GORI, A. Role of vegetation as a mitigating factor in the urban context. **Sustainability**, v. 12, n. 10, p. 4247, 2020. <https://doi.org/10.3390/su12104247>
- FURUYA, M.T.G; FURUYA, D.E.G; OLIVEIRA, L.Y.D; SILVA, P.A; CICERELLI, R.E; GONÇALVES, W.N; MARCATO JUNIOR, J; OSCO, L.P; RAMOS, A.P.M. A machine learning approach for mapping surface urban heat island using environmental and socioeconomic variables: a case study in a medium-sized Brazilian city. **Environmental Earth Sciences**, v. 82, n. 13, p. 325, 2023. <https://doi.org/10.1007/s12665-023-11017-8>
- GAŠPAROVIĆ, M; DOBRINIĆ, D. Comparative assessment of machine learning methods for urban vegetation mapping using multitemporal sentinel-1 imagery. **Remote Sensing**, v. 12, n. 12, p. 1952, 2020. <https://doi.org/10.3390/rs12121952>
- GATTO, E; BUCCOLIERI, R; AARREVAARA, E; IPPOLITO, F; EMMANUEL, R; PERRONACE, L; SANTIAGO, J.L. Impact of urban vegetation on outdoor thermal comfort: Comparison between a mediterranean city (Lecce, Italy) and a northern European city (Lahti, Finland). **Forests**, v. 11, n. 2, p. 228, 2020. <https://doi.org/10.3390/f11020228>
- GHIASI, G; GU, X; CUI, Y; LIN, T. Y. Scaling open-vocabulary image segmentation with image-level labels. In: **European Conference on Computer Vision**. Cham: Springer Nature Switzerland, 2022. p. 540-557. https://doi.org/10.1007/978-3-031-20059-5_31
- HAQUE, I. R. I; NEUBERT, J. Deep learning approaches to biomedical image segmentation. **Informatics in Medicine Unlocked**, v. 18, p. 100297, 2020. <https://doi.org/10.1016/j.imu.2020.100297>

HELM, J. M; SWIERGOSZ, A. M; HAEBERLE, H. S; KARNUTA, J. M; SCHAFFER, J. L; KREBS, V. E; SPITZER, A. I; RAMKUMAR, P. N. Machine learning and artificial intelligence: definitions, applications, and future directions. **Current reviews in musculoskeletal medicine**, v. 13, p. 69-76, 2020. <https://doi.org/10.1007/s12178-020-09600-8>

HESAMIAN, M. H; JIA, W; HE, X; KENNEDY, P. Deep learning techniques for medical image segmentation: achievements and challenges. **Journal of digital imaging**, v. 32, p. 582-596, 2019. <https://doi.org/10.1007/s10278-019-00227-x>

JHA, K; Doshi, A; Patel, P; Shah, M. A comprehensive review on automation in agriculture using artificial intelligence. **Artificial Intelligence in Agriculture**, v. 2, p. 1-12, 2019. <https://doi.org/10.1016/j.aiia.2019.05.004>

KHERADMANDI, N; MEHRANFAR, V. A critical review and comparative study on image segmentation-based techniques for pavement crack detection. **Construction and Building Materials**, v. 321, p. 126162, 2022. <https://doi.org/10.1016/j.conbuildmat.2021.126162>

KIRILLOV, A; MINTUN, E; RAVI, N; MAO, H; ROLLAND, C; GUSTAFSON, L; XIAO, T; WHITEHEAD, S; BERG, A .C; LO, W.Y; DOLLÁR, P; GIRSHICK, R. Segment anything. **arXiv preprint arXiv:2304.02643**, 2023.

LARKIN, A; GU, X; CHEN, L; HYSTAD, P. Predicting perceptions of the built environment using GIS, satellite and street view image approaches. **Landscape and urban planning**, v. 216, p. 104257, 2021. <https://doi.org/10.1016/j.landurbplan.2021.104257>

LASSITER, A; DARBARI, M. Assessing alternative methods for unsupervised segmentation of urban vegetation in very high-resolution multispectral aerial imagery. **PLoS One**, v. 15, n. 5, p. e0230856, 2020. <https://doi.org/10.1371/journal.pone.0230856>

LATEEF, F; RUICHEK, Y. Survey on semantic segmentation using deep learning techniques. **Neurocomputing**, v. 338, p. 321-348, 2019. <https://doi.org/10.1016/j.neucom.2019.02.003>

LEE, S.Y; LE, T.H. M; KIM, Y-M. Prediction and detection of potholes in urban roads: Machine learning and deep learning based image segmentation approaches. **Developments in the Built Environment**, v. 13, p. 100109, 2023. <https://doi.org/10.1016/j.dibe.2022.100109>

LI, X; RATTI, C; SEIFERLING, I. Quantifying the shade provision of street trees in urban landscape: A case study in Boston, USA, using Google Street View. **Landscape and Urban Planning**, v. 169, p. 81-91, 2018. <https://doi.org/10.1016/j.landurbplan.2017.08.011>

LIU, X; SONG, L; LIU, S; ZHANG, Y. A review of deep-learning-based medical image segmentation methods. **Sustainability**, v. 13, n. 3, p. 1224, 2021. <https://doi.org/10.3390/su13031224>

LIVESLEY, S.J.; MCPHERSON, E.G.; CALFAPIETRA, C. The urban forest and ecosystem services: Impacts on urban water, heat, and pollution cycles at the tree, street, and city scale. **Journal of Environmental Quality**, 2016, 45, 119–124. <https://doi.org/10.2134/jeq2015.11.0567>

MAZUROWSKI, M.A; DONG, H; GU, H; YANG, J; KONZ, N; ZHANG, Y. Segment anything model for medical image analysis: an experimental study. **Medical Image Analysis**, p. 102918, 2023. <https://doi.org/10.1016/j.media.2023.102918>

META AI. Segment Anything, Research by Meta AI, 2023. Disponível em: <https://segment-anything.com/>.

O'BRIEN, L; VREESE, R.D; KERN, M; SIEVÄNEN, T; STOJANOVA, B; ATMIŞ, E. Cultural ecosystem benefits of urban and peri-urban green infrastructure across different European countries. **Urban Forestry & Urban Greening**, v. 24, p. 236-248, 2017. <https://doi.org/10.1016/j.ufug.2017.03.002>

PAULEIT, S.; LIU, L.; AHERN, J.; KAZMIERCZAK, A. Multifunctional green infrastructure planning to promote ecological services in the city. In **Urban Ecology: Patterns, Processes, and Applications**; Niemela, J., Breuste, J., Guntenspergen, G., McIntyre, N., Elmqvist, T., James, P., Eds.; Oxford University Press: Oxford, UK, 2011; pp. 272–286. <https://doi.org/10.1093/acprof:oso/9780199563562.003.0033>

PIRALILOU, S. T; SHAHABI, H; JARIHANI, B GHORBANZADEH, O; BLASCHKE, T; GHOLAMNIA, K; MEENA. S.R; ARYAL, J. Landslide detection using multi-scale image segmentation and different machine learning models in the higher himalayas. **Remote Sensing**, v. 11, n. 21, p. 2575, 2019. <https://doi.org/10.3390/rs11212575>

RAEI, E; ASANJAN, A. A; NIKOO, M. R; SADEGH, M; POURSHAHABI, S; ADAMOWSKI, J. F. A deep learning image segmentation model for agricultural irrigation system classification. **Computers and Electronics in Agriculture**, v. 198, p. 106977, 2022. <https://doi.org/10.1016/j.compag.2022.106977>

WELLMANN, T; LAUSCH, A; ANDERSSON, E; KNAPP, S; CORTINOVIS, C; JACHE, J; SCHEUER, S; KREMER, P; MASCARENHAS, A; KRAEMER, R; HAASE, A; SCHUG, F; HAASE, D. Remote sensing in urban planning: Contributions towards ecologically sound policies? **Landscape and urban planning**, v. 204, p. 103921, 2020. <https://doi.org/10.1016/j.landurbplan.2020.103921>

YIGITCANLAR, T; Kankanamge, N; REGONA, M; MALDONADO, A.R; ROWAN, B; RYU, A; DESOUZA, K. C; CORCHADO, J.M; MEHMOOD, R; LI, R.Y.M. Artificial intelligence technologies and related urban planning and development concepts: How are they perceived and utilized in Australia?. **Journal of Open Innovation: Technology, Market, and Complexity**, v. 6, n. 4, p. 187, 2020. <https://doi.org/10.3390/joitmc6040187>

RESUMOS

ANÁLISE DAS CONDIÇÕES AMBIENTAIS EM TRECHOS DO CÓRREGO DO VEADO EM ÉPOCA DE CHUVAS ..	128
DIAGNÓSTICO AMBIENTAL PRELIMINAR NO CÓRREGO DA UNESP NO PERÍODO DE CHUVAS	129
TEOR DE CARBONO EM SOLO SOB INFLUÊNCIA DE BIOCÁRVÕES	130

ANÁLISE DAS CONDIÇÕES AMBIENTAIS EM TRECHOS DO CÓRREGO DO VEADO EM ÉPOCA DE
CHUVAS

BEATRIZ GARCIA ZILIOOTTO

GIULIANA COSTA

LAURA RUBIM DO MONTE JESUS

DANIELLI C. GRANADO

Os cursos d'água inseridos em zonas urbanas tem sido alvo de diversas intervenções ambientais que modificam suas características naturais. Este projeto foi desenvolvido com o objetivo de caracterizar e analisar as condições ambientais no Córrego do Veado e de seu afluente, Água Bôscoli, localizados na área urbana de Presidente Prudente, por meio de parâmetros limnológicos e da aplicação de uma ferramenta conhecida como protocolo de avaliação rápida - PAR de impactos ambientais adaptado para a bacia hidrográfica estudada. O projeto se concentrou nas seguintes frentes de trabalho: localização e delimitação da área de estudo; revisão e adaptação de um PAR já existente, utilizando como referência; aplicação do protocolo e mensuração de alguns parâmetros limnológicos nos trechos determinados. Após a aplicação do protocolo foi identificado que todos os trechos analisados apresentavam interferências antrópicas, que não permitiram sua classificação como trechos "naturais". Três trechos foram enquadrados como "impactados" e um como "alterado". Os principais fatores, em comum, que contribuíram para essa classificação foi em relação ao tipo de ocupação das margens, predominantemente ocupada por vias e outros elementos da infraestrutura urbana; extensão da vegetação ripária, em função da incipiência das Áreas de Preservação Permanente; e diversidade de habitats, pela carência de habitats disponíveis para a biota. Em relação aos parâmetros limnológicos, o que se destacou foi a condutividade elevada para alguns dos pontos, apresentando valores acima de 500, que pode ser um indicativo de poluição. Conclui-se que o PAR se apresenta como uma ferramenta de fácil utilização em que, com conhecimentos básicos, é possível realizar a caracterização física dos córregos urbanos. Por outro lado, encontra-se a dificuldade de utilizar um único PAR que abrange todas as características que podem ser encontradas em córregos urbanos, tornando-se necessário uma constante adaptação para cada local de estudo. Além disso, os trechos no qual os córregos se apresentam de forma canalizada, os resultados são inferiores aos trechos não canalizado, sendo necessário um estudo ainda mais aprofundado sobre essa forma de gestão de córregos urbanos, que está muito presente em grande parte dos municípios brasileiros. Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq

DIAGNÓSTICO AMBIENTAL PRELIMINAR NO CÓRREGO DA UNESP NO PERÍODO DE CHUVAS

GIULIANA COSTA
LAURA RUBIM DO MONTE JESUS
BEATRIZ GARCIA ZILLOTTO
DANIELLI C. GRANADO

Os Protocolos de Avaliação Rápida, também chamados de PARs, são ferramentas que têm como proposta diagnosticar de forma rápida os recursos hídricos e dessa forma contribuir para protegê-los da pressão causada pela urbanização. Eles permitem que sejam avaliadas, de forma integrada, as características de um trecho de rio, de acordo com o estado de conservação ou degradação do ambiente fluvial. O objetivo deste estudo é analisar as condições ambientais no Córrego da Unesp, afluente do Córrego do Veado, pertencente à Bacia Hidrográfica do Rio Santo Anastácio, a qual abastece abastecer 30% da cidade de Presidente Prudente. Foram efetuadas adaptações nos Protocolos de Avaliação Rápida, originalmente propostos por Callisto (2002) e Sardinha (2007), visando sua aplicação específica em córregos urbanos. O instrumento avalia aspectos como ocupação e condições das margens, presença de resíduos, características físicas da água, erosão, habitats para a biota, alterações no canal do rio, vegetação ripária e no leito, entre outras. Sua pontuação varia de 0 a 150, classificando os trechos como "impactados" (0-60), "alterados" (61-90) ou "naturais" (> 91). Em 28/03/2023, durante o período de chuvas, foram avaliados quatro trechos do Córrego da Unesp, com medições in loco de pH, condutividade elétrica, oxigênio dissolvido (OD) e temperatura. Além disso, amostras foram coletadas para análise de turbidez em laboratório. O córrego, completamente canalizado, apresenta paisagem uniforme. Perto da interseção das ruas Jorge Gushiken e Cassemiro Boscoli, a canalização começa na nascente, com sinais de influência humana por resíduos sólidos. No ponto 2, a 10 metros da margem, um imóvel irregular polui a água com efluentes domésticos. A vegetação ripária escassa no terceiro ponto indica vulnerabilidade ambiental. Próximo à rua Alberto Peters, no ponto 4, há deposições de sedimentos e manchas de óleo na seção confinada sob o Sesc Thermas. Todos os pontos receberam pontuação abaixo de 60, o que os define como "impactados". Os parâmetros limnológicos apresentaram valores dentro da normalidade, exceto a condutividade, que com valores entre 508 e 604, indica poluição. Os resultados mostram que o trecho apresenta interferências antrópicas, e que há similaridade entre os pontos analisados. A canalização, muitas vezes adotada para controle de enchentes e facilitação do escoamento urbano, resulta na perda de habitats naturais, prejudicando significativamente os ecossistemas ribeirinhos. CNPQ

TEOR DE CARBONO EM SOLO SOB INFLUÊNCIA DE BIOCARVÕES

JANARDELLY GOMES DE SOUZA
VICTOR HUGO PAES DE OLIVEIRA
D'JA ARIEL HENRIQUE GORRAO COBOS MELO
MARCELO RODRIGO ALVES

O biocarvão é um produto rico em carbono gerado durante o processo de pirólise, sua aplicação pode melhorar os atributos de solos degradados e de baixa fertilidade. O objetivo foi avaliar o teor de carbono orgânico total e as frações químicas da matéria orgânica do solo sob influência de resíduos orgânicos e biocarvões. O trabalho foi realizado no Laboratório de Solos da Universidade do Oeste Paulista - UNOESTE. O delineamento foi inteiramente casualizado (DIC), com 5 repetições, sendo que os tratamentos foram constituídos por 7 composições: controle (C); solo + 300g de biossólido (BP); solo + 100g de bagaço de cana-de-açúcar puro (BCA); solo + 150g de biossólido + 50g de bagaço de cana-de-açúcar puro (BP+BCA); solo + 300g de biocarvão de biossólido (BBP); solo + 100g de biocarvão do bagaço da cana-de-açúcar (BBCA); solo + 150g de biocarvão de biossólido + 50g de biocarvão do bagaço de cana-de-açúcar (BBP+BBCA), perfazendo um total de 35 amostras. Foram realizadas análise de fertilidade e fracionamento químico da matéria orgânica do solo (extrato alcalino (EA); ácido fúlvico (FAF); ácido húmico (FAH); humina (HUM)). Os dados foram submetidos à análise de variância pelo SISVAR. Para comparação de médias foi utilizado o teste de Scott-Knott a 5% de probabilidade. Os maiores valores de pH foram no BBP (8,02) e BP (8,0). O maior teor de matéria orgânica foi no BCA (20,28 g dm⁻³) e BBP (19,30 g dm⁻³), apresentando um médio teor. Para o carbono orgânico total observou-se que onde teve a adição de biocarvão ao solo houve um incremento desse parâmetro comparado aos demais. Em todos os tratamentos, os teores de HUM predominaram em relação as de FAH e FAF. Fato este que pode estar relacionado à uma maior recalcitrância da fração humina em relação as FAF e FAH. As relações de FAH/FAF foram superiores a 1 para a maioria dos tratamentos, sinalizando um possível predomínio do ácido húmico. Já para o EA/HUM o maior valor foi observado no solo controle. Maiores valores de EA/HUM indica maior presença de frações menos estáveis (FAF e FAH) em relação a fração de maior estabilidade química (HUM). Para a soma de bases, capacidade de troca catiônica e saturação por bases notou-se que onde havia BP e BBP apresentaram maiores valores. A aplicação de resíduos e biocarvões no solo apresentou efeitos significativos para os parâmetros avaliados, principalmente para o teor de carbono orgânico total que houve um incremento em solo com inserção de biocarvões. Unoeste (CPDI:7764)

RELATOS DE EXPERIÊNCIA

PROJETO DE EXTENSÃO DANDO VIDA AO Córrego Vale do Sol.....	132
SEMENTINHA DO BEM.....	133

Engenharia Ambiental
Extensão (ENAEXT)
Comunicação oral (on-line)

UNIVERSIDADE DO OESTE PAULISTA - UNOESTE
Engenharias
Engenharia Ambiental

PROJETO DE EXTENSÃO DANDO VIDA AO CÓRREGO VALE DO SOL

GIULIANA COSTA
BEATRIZ GARCIA ZILLOTTO
DANIELLI C. GRANADO
LAURA RUBIM DO MONTE JESUS

A harmonização das comunidades com as águas urbanas, sempre esteve no cerne desta proposta, que pode ser aplicada em diferentes localidades, em diferentes escalas e com diferentes públicos. O Jardim Vale do Sol, em Presidente Prudente, e o córrego de mesmo nome, que o atravessa, foram usados como modelo para o desenvolvimento das ferramentas de trabalho. Como objetivos elenca-se: desenvolver um protocolo de trabalho para a sensibilizar as comunidades, quanto à importância da conservação das águas urbanas; adaptar uma ferramenta conhecida como protocolo de avaliação rápida - PAR de impactos ambientais; e sensibilizar e capacitar a comunidade para conhecerem a ferramenta de avaliação para que se tornem agentes multiplicadores do conhecimento e de fiscalização dos recursos hídricos, em seu entorno. O projeto se concentrou nas seguintes frentes de trabalho: capacitação da equipe; desenvolvimento da "metodologia"; busca e adaptação de protocolos já existentes na literatura para diagnóstico ambiental; busca de trechos representativos e acessíveis no Córrego Vale do Sol; reconhecimento e caracterização dessas áreas; preparação da oficina para sensibilização e capacitação da comunidade; divulgação do projeto no bairro Vale do Sol; e realização da oficina. Após a adequação, a próxima etapa foi a divulgação das ações de sensibilização na comunidade, que foi realizada em parceria com a paróquia do bairro. As ações ocorreram após as missas aos sábados à noite e contaram com ações de divulgação e, a realização da oficina para os interessados. As ações no bairro foram prejudicadas e atingiram um público bem menor que o esperado, devido a pandemia. Ainda assim, considera-se que o objetivo de fomentar a Educação Ambiental, por meio da harmonização das comunidades com os corpos hídricos de seu entorno, foi alcançado, por meio da adaptação de uma ferramenta, que visa contribuir para o diagnóstico ambiental, a sensibilização e a capacitação dos participantes. Para que se tornem aliados no processo de monitoramento das águas urbanas e multiplicadores de conhecimento. E deste modo, passem a cobrar do poder público e da própria comunidade, ações efetivas de conservação desse recurso indispensável, que é a água.

Extensão (ENAEXT)

UNIVERSIDADE DO OESTE PAULISTA - UNOESTE

Comunicação oral
(presencial)Engenharias
Engenharia Ambiental

SEMENTINHA DO BEM

MATILDE BARGA DOS SANTOS LOPES
NOEMI DE OLIVEIRA DIAS
POLLYANA SAORI SHIMADA
ROBSON DIEGO SILVA GONCALVES
JANARDELLY GOMES DE SOUZA
SAMARA PERUZZO GUSMAN
BRUNO DE LIMA MELO
ALBA REGINA AZEVEDO ARANA

A comemoração do Dia Mundial do Meio Ambiente, 5 de junho, é uma oportunidade para semearmos boas práticas ambientais. O objetivo do presente trabalho foi estimular e promover a cultura de preservação ambiental com vistas a sensibilização dos alunos e, disseminar ações que possam ser implantadas no seu dia a dia. O presente trabalho levou para salas de aulas um bate-papo descontraído com alunos, de escolas de rede municipais e estaduais, do município de Presidente Prudente-SP e Sandovalina-SP, sobre pequenas ações que podem ser realizadas e que auxiliam com a preservação do meio ambiente. Trata-se de um trabalho de extensão produzido como parte do Programa Unoeste Sustentável em parceria com a Companhia de Saneamento Básico do Estado de São Paulo - SABESP, para engajar os alunos da Universidade, em especial os vinculados ao Programa de Pós-Graduação em Meio Ambiente e Desenvolvimento Regional, e a comunidade regional em ações relacionadas aos Objetivos de Desenvolvimento Sustentável da Agenda 2030. Assim, num primeiro momento foram realizadas apresentações de palestras, vídeos, exposições de banners e distribuição de gibis para conscientizar os alunos sobre o consumo responsável de água e descarte adequado de resíduos. Essas ações foram realizadas com alunos da Pré-Escola (5 a 6 anos de idade), Ensino Fundamental I (1° ao 5° ano - 7 a 10 anos), Ensino Fundamental II (6° ao 9° ano - 11 a 14 anos) e Ensino Médio (15 a 17 anos) e foram adequadas aos devidos níveis de ensino. E, em um segundo momento foram realizadas atividades de artesanato com tampinhas, com finalidade de promover a reciclagem, em uma ação conjunta a Polícia Ambiental. No total participaram 905 alunos nas ações realizadas em comemoração do Dia Mundial do Meio Ambiente. Levar esse trabalho a comunidade regional foi de suma importância, pois envolver e conscientizar os alunos é uma forma de contribuir com o meio ambiente.