v7.n8.2026

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

USO DE APRENDIZADO PROFUNDO PARA DETECTAR POTENCIAIS CRIADOUROS DE *AEDES AEGYPTI* EM PISCINAS URBANAS

USE OF DEEP LEARNING FOR DETECTING POTENTIAL AEDES AEGYPTI BREEDING SITES IN URBAN SWIMMING POOLS

USO DEL APRENDIZAJE PROFUNDO PARA DETECTAR POTENCIALES CRIADEROS DE AEDES AEGYPTI EN PISCINAS URBANAS

Cindy Fernandes Mendes[1], Veraldo Liesenberg[2]

e788495
https://doi.org/10.47820/recima21.v7i7.8495

PUBLICADO: 08/2026

RESUMO

Doenças transmitidas por mosquitos representam um desafio crescente para a saúde pública, especialmente em áreas urbanas, onde o *Aedes aegypti* encontra condições favoráveis para a reprodução. Entre os possíveis criadouros, piscinas sem manutenção podem acumular água e contribuir para a proliferação do vetor da dengue. Neste estudo, avaliou-se o uso de imagens obtidas por aeronave remotamente pilotada e técnicas de aprendizado profundo para a detecção automática de piscinas urbanas no bairro São Sebastião, em Lages, Santa Catarina. Foi utilizado o *Segment Anything Model*, implementado por meio da ferramenta SamGeo, em seu modo de segmentação por texto. Foram testados os *prompts* "pool" e "dirty pool", e os resultados foram comparados com máscaras de referência vetorizadas manualmente em ambiente SIG. O *prompt "pool"* apresentou o melhor desempenho, com precisão de 94%, erro de omissão de 46%, erro de comissão de 6% e IoU de 52%. A omissão esteve associada principalmente às piscinas cobertas. Já o prompt *"dirty pool"* apresentou precisão de 2%, erro de omissão de 1%, erro de comissão de 98% e IoU de 2%, confundindo piscinas com córregos e estradas não pavimentadas. Os resultados indicam que o SAM Text pode auxiliar na triagem de locais prioritários para inspeções de campo, embora estudos adicionais, com maior diversidade amostral, sejam necessários.

PALAVRAS-CHAVE: *Aedes aegypti.* Dengue. Sensoriamento remoto. Aprendizado profundo. Segment Anything Model.

ABSTRACT

Mosquito-borne diseases represent a growing public health challenge, especially in urban areas, where Aedes aegypti finds favorable conditions for reproduction. Among potential breeding sites, poorly maintained swimming pools can accumulate water and contribute to the proliferation of the dengue vector. This study evaluated the use of images acquired by a remotely piloted aircraft and deep learning techniques for the automatic detection of urban swimming pools in the São Sebastião neighborhood, in Lages, Santa Catarina, Brazil. The Segment Anything Model, implemented through the SamGeo tool, was used in its text-prompt segmentation mode. The prompts "pool" and "dirty pool" were tested, and the results were compared with reference masks manually vectorized in a GIS environment. The "pool" prompt showed the best performance, with 94% precision, 46% omission error, 6% commission error, and an IoU of 52%.

[1] Doutoranda em Engenharia Florestal na Universidade do Estado de Santa Catarina – UDESC.
[2] Professor doutor na Universidades do Estado de Santa Catarina - UDESC, departamento de Engenharia Florestal.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

The omission was mainly associated with covered swimming pools. In contrast, the "dirty pool" prompt showed 2% precision, 1% omission error, 98% commission error, and an IoU of 2%, confusing swimming pools with streams and unpaved roads. The results indicate that SAM Text can support the screening of priority locations for field inspections, although additional studies with greater sample diversity are needed.

KEYWORDS: *Aedes aegypti. Dengue. Remote sensing. Deep learning. Segment Anything Model.*

RESUMEN
Las enfermedades transmitidas por mosquitos representan un desafío creciente para la salud pública, especialmente en áreas urbanas, donde Aedes aegypti encuentra condiciones favorables para su reproducción. Entre los posibles criaderos, las piscinas sin mantenimiento pueden acumular agua y contribuir a la proliferación del vector del dengue. En este estudio se evaluó el uso de imágenes obtenidas mediante una aeronave pilotada remotamente y técnicas de aprendizaje profundo para la detección automática de piscinas urbanas en el barrio São Sebastião, en Lages, Santa Catarina, Brasil. Se utilizó el Segment Anything Model, implementado mediante la herramienta SamGeo, en su modo de segmentación por texto. Se probaron los prompts "pool" y "dirty pool", y los resultados se compararon con máscaras de referencia vectorizadas manualmente en un entorno SIG. El prompt "pool" presentó el mejor desempeño, con una precisión del 94%, un error de omisión del 46%, un error de comisión del 6% y un IoU del 52%. La omisión estuvo asociada principalmente a las piscinas cubiertas. En cambio, el prompt "dirty pool" presentó una precisión del 2%, un error de omisión del 1%, un error de comisión del 98% y un IoU del 2%, confundiendo piscinas con arroyos y caminos no pavimentados. Los resultados indican que SAM Text puede apoyar la selección de lugares prioritarios para inspecciones de campo, aunque se requieren estudios adicionales con mayor diversidad de muestras.

PALABRAS CLAVE*: Aedes aegypti. Dengue. Teledetección. Aprendizaje profundo. Segment Anything Model.*

1. INTRODUÇÃO

Doenças transmitidas por mosquitos estão entre os desafios globais mais significativos para a saúde pública, com a dengue, a malária, o Zika e a chikungunya contribuindo substancialmente para problemas de saúde e mortalidade em todo o mundo. A dengue, transmitida predominantemente pelos mosquitos *Aedes aegypti* e *Aedes albopictus*, expandiu-se rapidamente nas últimas décadas e atualmente coloca mais da metade da população mundial em risco (MAHFODZ *et al*., 2026).

A dengue, em especial, é uma arbovirose cuja expansão geográfica e recorrência epidêmica constituem um desafio crescente para a saúde pública (WILDER-SMITH *et al.*, 2019). No Brasil, a doença ocorre em ciclos epidêmicos que pressionam os sistemas de saúde. O principal vetor, *Aedes aegypti*, é altamente adaptado ao meio urbano, utilizando pequenos acúmulos de água limpa para sua reprodução, com criadouros comuns em recipientes descartados incorretamente, caixas-d'água destampadas e piscinas sem manutenção.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Dependendo das condições de manutenção, caixas-d'água e piscinas podem ser caracterizadas como potenciais criadouros, pois o uso inadequado de telas de proteção ou a ausência de tampas permitem o acesso e a reprodução dos vetores nas caixas-d'água. Da mesma forma, as piscinas podem se tornar criadouros significativos para mosquitos quando não são tratadas adequadamente (CUNHA *et al*., 2021).

As abordagens convencionais de vigilância de mosquitos, que incluem levantamentos larvais, instalação de armadilhas e inspeções de rotina em domicílios, continuam sendo essenciais para o manejo integrado de vetores (MAHFODZ *et al*., 2026). No entanto, essas estratégias de vigilância e controle, baseadas em visitas domiciliares, enfrentam dificuldades logísticas em áreas urbanas extensas e complexas.

O uso de drones destaca-se como um instrumento promissor para a vigilância de vetores e o monitoramento ambiental, pois esses equipamentos são dotados de sensores de imagem de alta resolução, o que possibilita o mapeamento rápido, flexível e em escala fina das paisagens, oferecendo novas oportunidades para identificar e caracterizar criadouros de mosquitos em diferentes tipos de ambientes (MECHAN *et al.,* 2023).

A combinação de imagens capturadas por drone com estratégias de geoprocessamento constitui uma ferramenta importante, permitindo análises espaço-temporais de fatores relacionados à ocorrência da doença (NAYAK; PAI; GOVINDAN, 2025). O avanço de algoritmos de inteligência artificial, especialmente de modelos de aprendizado profundo, ampliou o potencial para o reconhecimento automatizado de objetos em imagens de alta resolução (SRUTHI *et al.*, 2025).

A detecção de padrões baseada em modelos de aprendizado profundo fornece resultados quantificáveis, oferecendo uma solução mais eficiente, precisa e escalável para identificar estruturas urbanas potencialmente associadas à formação de criadouros de *Aedes aegypti* em imagens de drones (HASSAN *et al.*, 2026). Entre esses modelos, o *Segment Anything Model* (SAM) abriu novas possibilidades ao realizar a segmentação precisa de objetos com mínima supervisão (OSCO *et al.*, 2023). A implementação do SAM por meio do SamGeo apresenta diferentes modos de segmentação de objetos, entre os quais se destaca o modo baseado em prompt textual ("text"), no qual descrições textuais são utilizadas como *prompts* para o processo de segmentação (OSCO *et al.*, 2023). Esse modo resulta da integração do SAM com o método Grounding DINO (LIU *et al.*, 2023).

Embora o SAM apresente bom potencial, é importante destacar que sua aplicação ainda possui algumas limitações devido às características das imagens aéreas, como as diferentes escalas dos objetos, a complexidade das paisagens de fundo e as diferenças inerentes em

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

relação às imagens convencionais utilizadas para o desenvolvimento do modelo, fatores que podem reduzir sua capacidade de generalização (REN *et al.*, 2024). O desempenho da segmentação também pode ser afetado pelo tamanho da imagem e por limites pouco definidos, causados pelo baixo contraste com os elementos do entorno (GUI; BHARDWAJ; SAM, 2024). Dessa forma, sua aplicação em cenários urbanos complexos torna-se um desafio.

Embora piscinas sem tratamento possam ser ambientes favoráveis à reprodução de mosquitos, sua identificação não confirma a presença das formas imaturas de *Aedes aegypti*. Portanto, os locais identificados por técnicas de sensoriamento remoto devem ser considerados pontos de atenção, os quais precisam ser verificados por meio de inspeções de campo (TEILLET *et al.*, 2024). Assim, o mapeamento automático pode complementar a vigilância convencional, sendo uma técnica auxiliar para a otimização dos trabalhos de campo (HAHM *et al.*, 2026).

Este estudo tem como objetivo aplicar e avaliar uma metodologia baseada em SIG e aprendizado profundo para a detecção automática de piscinas urbanas consideradas potenciais pontos de atenção para a vigilância de criadouros de *Aedes aegypti.* Para isso, foi avaliado o desempenho do modo de segmentação por texto do SAM utilizando diferentes *prompts* textuais. Os resultados podem contribuir para a triagem de locais prioritários para inspeções de campo e apoiar ações de vigilância e controle da dengue.

2. METODOLOGIA

A área de estudo está localizada no bairro São Sebastião (27°47′24″ S, 50°17′44″ W), em Lages, Santa Catarina (Figura 1). O bairro apresenta características predominantemente residenciais, com residências que, em sua maioria, apresentam padrão médio de construção. As imagens foram obtidas por meio de um voo realizado com uma aeronave remotamente pilotada (ARP), modelo DJI Phantom 4 Pro V2, a 120 m de altitude. O voo foi realizado em março de 2023, com sobreposição lateral de 70% e longitudinal de 80%. As imagens foram processadas no *software* Agisoft Metashape, gerando uma ortofoto georreferenciada com resolução espacial de 2,4 cm/pixel e cobertura de aproximadamente 0,4 km².

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

Figura 1. Localização da área de estudo no contexto da região sul e no município de Lages (SC) com detalhamento da localidade de São Sebastião.

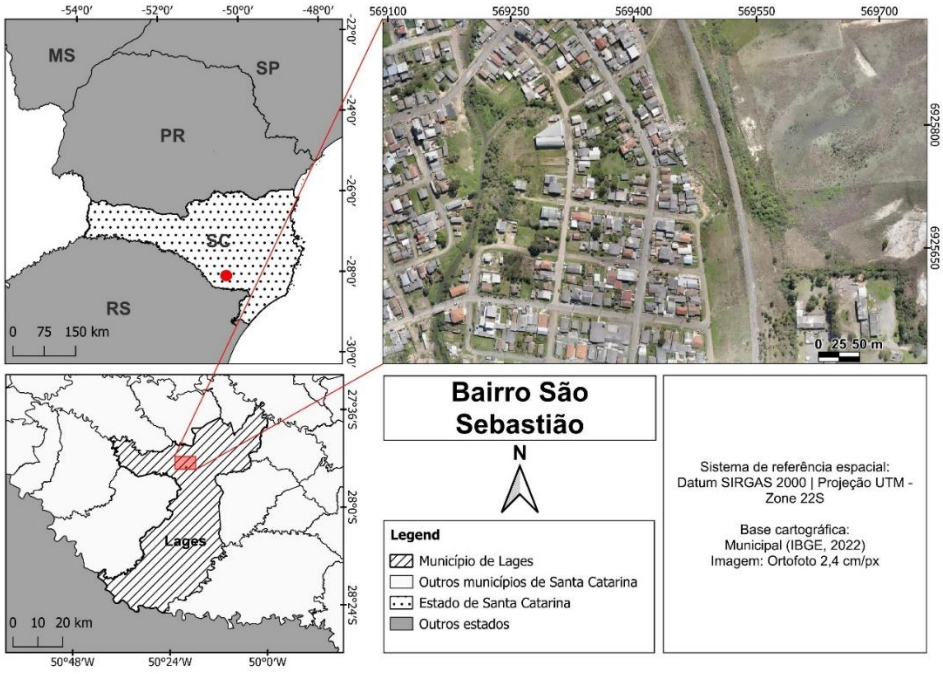

Fonte: Os autores (2026)

O objeto de nosso estudo foram as piscinas localizadas nas residências do bairro São Sebastião. Foram identificadas 17 piscinas na área abrangida pela ortofoto, todas vetorizadas manualmente para a composição da máscara de referência (*ground truth*). Para a aplicação do modelo, a ortofoto foi recortada em *tiles* de 640 × 640 pixels.

Como modelo de aprendizado profundo para a segmentação dessas piscinas, utilizou-se o SAM, cuja aplicação foi implementada em Python e executada no Visual Studio Code. Utilizou-se o pacote segment-geospatial, por meio da ferramenta SamGeo (WU; OSCO, 2023) para a implementação do modelo.

O SAM foi testado em seu modo de segmentação por texto (SAM Text), com os *prompts* “pool” e “dirty pool”. Foram utilizados os parâmetros *box threshold* e *text threshold*, ambos definidos em 0,25 após testes preliminares. O *box threshold* corresponde ao limiar mínimo de confiança para a seleção das caixas delimitadoras, enquanto o *text threshold* representa o limiar de correspondência entre o objeto identificado e o prompt textual. Para avaliar o desempenho do

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

modelo, as máscaras de referência produzidas manualmente em ambiente SIG (QGIS Desktop 3.34.11) foram comparadas com os resultados da segmentação.

Para calcular o verdadeiro positivo (VP), foi utilizada a ferramenta 'Interseção' entre o *ground truth* e o *shapefile* resultante do SAM, em ambiente SIG, sendo posteriormente calculada a área correspondente à interseção. Os demais cálculos foram realizados no aplicativo MS-Excel, considerando as seguintes definições: i) Falsos positivos (FP): diferença entre a área total do *shapefile* resultante do SAM e o VP; e ii) Falsos negativos (FN): diferença entre a área total do *ground truth* e o VP. A avaliação foi realizada com base nas áreas dos polígonos, de modo que VP, FP e FN representam áreas de concordância e discordância entre a segmentação e o *ground truth*, e não a quantidade de piscinas.

Com estes valores, foram calculados os erros de omissão (FN/(VP+FN)), de comissão (FP/(VP+FP)) e a precisão (VP/(VP+FP)) para cada prompt estudado. O erro de omissão representa a proporção da área das piscinas presentes no *ground truth* que não foi segmentada pelo modelo, enquanto o erro de comissão representa a proporção da área segmentada que não corresponde às piscinas. Também foi utilizada a métrica de Interseção sobre União (IoU) (VP/(VP+FP+FN)), amplamente aplicada na avaliação de problemas de detecção e segmentação de objetos.

3. RESULTADOS E DISCUSSÃO

O prompt "pool" apresentou precisão de 94%, erro de omissão de 46%, erro de comissão de 6% e IoU de 52%. Esses resultados indicam um comportamento conservador, pois as áreas segmentadas apresentaram elevada correspondência com as piscinas, como indicado pelo valor da precisão. No entanto, uma parcela elevada da área de referência deixou de ser identificada. Essa omissão esteve associada principalmente às piscinas cobertas, o que deve ser considerado em relação ao objetivo da aplicação do método e à finalidade da triagem e à sensibilidade necessária para as inspeções de campo. Essa diferença entre precisão e omissão resultou em um IoU moderado, o que indica que o método pode ser útil para localizar os potenciais pontos de atenção, mas apresenta limitações quando é necessária uma delimitação completa das piscinas.

Já o prompt "dirty pool" apresentou precisão de 2%, erro de omissão de 1%, erro de comissão de 98% e IoU de 2%. Embora tenha apresentado baixa omissão, esse resultado decorreu da segmentação incorreta de outros elementos da paisagem.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Figura 2. Métricas utilizadas para avaliação dos *prompts*

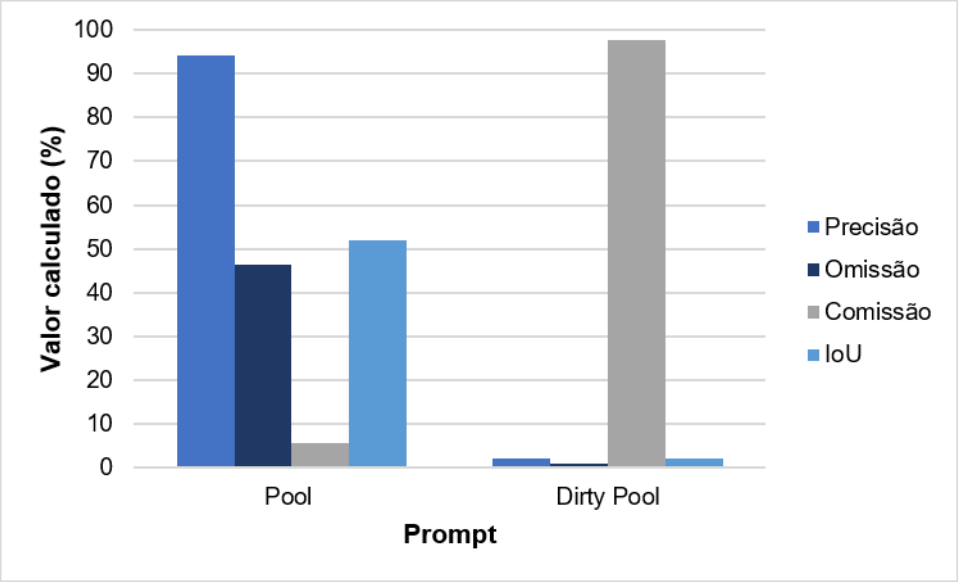

Fonte: Os autores (2026)

O prompt “pool” apresentou o melhor desempenho geral nesse cenário, combinando elevada precisão e baixo erro de comissão. Entretanto, a omissão de 46%, atribuída principalmente às piscinas cobertas (Figura 3B), demonstra uma limitação na sensibilidade do método. Em aplicações voltadas à priorização de piscinas expostas e potencialmente sem tratamento, a omissão de estruturas cobertas pode apresentar menor impacto operacional. Nesses casos, a triagem pode contribuir para direcionar as inspeções e reduzir o número de visitas presenciais necessárias para identificar edifícios, quarteirões e bairros com maior risco (LARANJEIRA *et al.*, 2024). Assim, as visitas podem ser direcionadas aos pontos que demandam maior atenção, como piscinas sem cobertura e sem tratamento adequado (JEMBERIE; DUGASSA; ANIMUT, 2025). Na Figura 3A, observa-se que o prompt “pool” detectou também uma piscina com água turva, sem que fosse necessário utilizar o prompt “dirty pool” para detectar esse tipo de piscina.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Figura 3. Segmentação das piscinas com o prompt “pool”. Em A, observam-se duas piscinas detectadas, em B, observa-se a omissão de duas piscinas cobertas.

Fonte: Os autores (2026)

O elevado erro de comissão do prompt “dirty pool” ocorreu principalmente porque o modelo classificou córregos e estradas não pavimentadas como piscinas (Figura 4). A baixa omissão observada para esse prompt não representa maior capacidade de discriminação das piscinas, pois foi acompanhada por segmentação excessiva de elementos do entorno. Dessa forma, o prompt incluiu praticamente toda a área das piscinas, mas não foi capaz de distingui-las adequadamente dos demais elementos da paisagem.

Esse é um problema recorrente em imagens de sensoriamento remoto, nas quais fundos complexos podem interferir na extração de características. Quando múltiplas categorias com características visuais sobrepostas coexistem na imagem, distingui-las torna-se um grande desafio (HE *et al.*, 2025). Esse problema poderia ser reduzido por meio da utilização de mapas de drenagem e malhas rodoviárias, que podem ser cruzados com os resultados da segmentação para excluir essas áreas dos pontos de atenção.

Entre as vantagens do uso do SAM estão a ausência da necessidade de dados previamente anotados (HE *et al.*, 2025; KIRILLOV *et al.*, 2023), o menor custo computacional em comparação com redes que precisam ser treinadas e a velocidade de processamento. Essas

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

características podem constituir um ponto de partida para estudos voltados à identificação de residências prioritárias para vistorias (LARANJEIRA *et al.*, 2024).

Figura 4. Segmentação das piscinas com o prompt “dirty pool”. Observa-se uma piscina detectada corretamente, além de estradas e córregos segmentados de forma incorreta.

Fonte: Os autores (2026)

Nesse estudo, constatou-se que a escolha do prompt textual no SAM Text influenciou a qualidade dos resultados. Dessa forma, outras palavras podem ser futuramente testadas e avaliadas para identificar a melhor escolha para cada condição ambiental da imagem. O estudo de Li *et al.* (2024) demonstra que a filtragem semântica varia conforme a palavra escolhida e que explorar terminologias diferentes é uma etapa necessária para otimizar os resultados de acordo com o alvo e o ambiente.

Entretanto, é importante ressaltar que este é um estudo preliminar, sendo necessários estudos adicionais com maior diversidade amostral e a avaliação de outros modelos de aprendizado profundo para a detecção ou segmentação de piscinas, com foco em reduzir os casos de omissão e aumentar a precisão. Essa ampliação é importante porque as imagens de

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

sensoriamento remoto apresentam alta variabilidade intraclasse, baixa separabilidade entre classes e dificuldade de transferência entre cenários (ZHANG *et al.*, 2025).

Apesar das limitações observadas, os resultados indicam que as geotecnologias podem atuar como ferramentas auxiliares para a vigilância e o controle da dengue em áreas urbanas. Cunha *et al*. (2021) destacam que a identificação automática de piscinas e caixas-d'água em imagens de sensoriamento remoto pode auxiliar na seleção de imóveis prioritários para inspeções de campo. Essa triagem pode ser complementada pela análise automática das condições de conservação das fachadas dos imóveis, conforme proposto por Laranjeira *et al*. (2024). Além disso, o mapeamento dessas informações em ambiente SIG permite organizar espacialmente os pontos de atenção e, com isso, direcionar as ações de controle para locais específicos (HAPAIRAI *et al*., 2024).

No entanto, as piscinas e demais estruturas identificadas nas imagens não devem ser consideradas diretamente como criadouros confirmados de *Aedes aegypti*, pois as condições de manutenção e tratamento precisam ser verificadas em campo. Dessa forma, os resultados representam uma etapa preliminar de triagem espacial, que pode auxiliar os agentes públicos na definição dos imóveis prioritários para inspeções de campo, fiscalização sanitária e, quando necessário, adoção de medidas de controle. Essa abordagem pode ser relevante para a saúde pública, principalmente em municípios com recursos humanos e financeiros limitados, pois a priorização das visitas pode otimizar o trabalho das equipes e aumentar a eficiência das ações de vigilância.

4. CONSIDERAÇÕES FINAIS

Os resultados indicam que o SAM Text é promissor para a identificação automática de potenciais pontos de atenção relacionados aos criadouros do vetor da dengue, embora a escolha do prompt influencie o equilíbrio entre precisão e omissão. Recomenda-se, portanto, que estudos futuros avaliem diferentes *prompts ,* técnicas de pós-processamento espacial e a integração com dados auxiliares, como mapas de drenagem e malhas rodoviárias, visando reduzir os erros e aumentar a confiabilidade da metodologia. No entanto, destaca-se o caráter preliminar deste estudo, realizado em uma única área urbana e com uma amostra de 17 piscinas. Dessa forma, a metodologia deve ser validada em áreas com diferentes características urbanas, ambientais e de aquisição das imagens.

Agradecimentos

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Os autores agradecem ao Programa de Bolsas de Monitoria de Pós-Graduação (PROMOP) pela concessão de bolsa à primeira autora e à Universidade do Estado de Santa Catarina (UDESC/CAV) pelo apoio técnico e científico. Agradecem também à FAPESC pela concessão de bolsa de pós-graduação e pelo financiamento dos projetos nº 2024TR002296 e nº 2025TR001147, bem como ao CNPq, por meio dos processos nº 421003/2025-1 e nº 312263/2025-2, e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio ao Programa de Pós-Graduação em Engenharia Florestal.

REFERÊNCIAS

CUNHA, H. S.; SCLAUSER, B. S.; WILDEMBERG, P. F.; FERNANDES, E. A. M.; SANTOS, J. A. dos; LAGE, M. de O.; LORENZ, C.; BARBOSA, G. L.; QUINTANILHA, J. A.; CHIARAVALLOTI-NETO, F. Water tank and swimming pool detection based on remote sensing and deep learning: relationship with socioeconomic level and applications in dengue control. **PLOS ONE**, v. 16, n. 12, e0258681, 2021. DOI: 10.1371/journal.pone.0258681.

GUI, B.; BHARDWAJ, A.; SAM, L. Evaluating the efficacy of Segment Anything Model for delineating agriculture and urban green spaces in multiresolution aerial and spaceborne remote sensing images. **Remote Sensing**, v. 16, n. 2, 414, 2024. DOI: 10.3390/rs16020414.

HAHM, M.; GUTHULA, V. B.; CHILAULE, R.; GOMINSKI, D.; LIMWAGU, A.; CHAKI, E.; OKUMU, F.; TINGITANA, L.; HERMUND, A.; TUSTING, L. S.; FENSHOLT, R.; RIBEIRO, G.; KNUDSEN, J. B.; MOTTELSON, J.; MLACHA, Y.; CAMERON, M.; IGEL, C. High-resolution automated mapping of potential *Aedes* larval container habitats using drone imagery and supervised machine learning in Dar es Salaam, Tanzania. **PLOS Neglected Tropical Diseases**, v. 20, n. 5, e0014361, 2026. DOI: 10.1371/journal.pntd.0014361.

HAPAIRAI, L. K.; SEERAMSINGH, R.; JAMES, L. D.; FENG, R. S.; NANDRAM, N.; MOHAMMED, A.; DUMAN-SCHEEL, M.; SEVERSON, D. W. GIS-enhanced survey of potential *Aedes aegypti* and *Aedes albopictus* artificial oviposition containers distributed across communities in Trinidad, West Indies. **Insects**, v. 15, n. 10, 779, 2024. DOI: 10.3390/insects15100779.

HASSAN, M. M.; CHAMBERLIN, A. J.; TARPENNING, M. S.; WEBER, W. C.; COOMBE, K. D.; DE LEO, G. A.; JUNAID, M.; SOMA, A. S.; ANSARIADI; ROSSER, J. I. Enhancing *Aedes aegypti* breeding site detection: a deep learning approach to tire identification in unmanned aerial vehicle imagery from urban Indonesia. **Remote Sensing Applications: Society and Environment**, v. 42, 102011, 2026. DOI: 10.1016/j.rsase.2026.102011.

HE, L.; ZHOU, Y.; LIU, L.; CAO, W.; MA, J. Research on object detection and recognition in remote sensing images based on YOLOv11. **Scientific Reports**, v. 15, 14032, 2025. DOI: 10.1038/s41598-025-96314-x.

JEMBERIE, W.; DUGASSA, S.; ANIMUT, A. Physical and chemical characteristics of *Aedes* larval habitats in Metema District, Northwest Ethiopia. **BMC Ecology and Evolution**, v. 25, 59, 2025. DOI: 10.1186/s12862-025-02368-w.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

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. In: IEEE/CVF INTERNATIONAL CONFERENCE ON COMPUTER VISION (ICCV), 2023, Paris. **2023 IEEE/CVF International Conference on Computer Vision (ICCV).** Piscataway: IEEE, 2023. p. 3992-4003. DOI: 10.1109/ICCV51070.2023.00371.

LARANJEIRA, C.; PEREIRA, M.; OLIVEIRA, R.; BARBOSA, G.; FERNANDES, C.; BERMUDI, P.; RESENDE, E.; FERNANDES, E.; NOGUEIRA, K.; ANDRADE, V.; QUINTANILHA, J. A.; SANTOS, J. A. dos; CHIARAVALLOTI-NETO, F. Automatic mapping of high-risk urban areas for *Aedes aegypti* infestation based on building facade image analysis. **PLOS Neglected Tropical Diseases**, v. 18, n. 6, e0011811, 2024. DOI: 10.1371/journal.pntd.0011811.

LI, W.; HSU, C.-Y.; WANG, S.; YANG, Y.; LEE, H.; LILJEDAHL, A.; WITHARANA, C.; YANG, Y.; ROGERS, B. M.; ARUNDEL, S. T.; JONES, M. B.; MCHENRY, K.; SOLIS, P. Segment Anything Model can not segment anything: assessing AI foundation model's generalizability in permafrost mapping. **Remote Sensing**, v. 16, n. 5, 797, 2024. DOI: 10.3390/rs16050797.

LIU, S.; ZENG, Z.; REN, T.; LI, F.; ZHANG, H.; YANG, J.; JIANG, Q.; LI, C.; YANG, J.; SU, H.; ZHU, J.; ZHANG, L. Grounding DINO: marrying DINO with grounded pre-training for open-set object detection. **arXiv**, arXiv:2303.05499, 2023. DOI: 10.48550/arXiv.2303.05499.

MAHFODZ, Z.; NABA, A.; ISAWASAN, P.; NGESOM, A. M. M.; DOM, N. C. Drone-based machine learning approaches for mosquito vector surveillance. **Discover Applied Sciences**, v. 8, 657, 2026. DOI: 10.1007/s42452-026-08700-3.

MECHAN, F.; BARTONICEK, Z.; MALONE, D.; LEES, R. S. Unmanned aerial vehicles for surveillance and control of vectors of malaria and other vector-borne diseases. **Malaria Journal**, v. 22, 23, 2023. DOI: 10.1186/s12936-022-04414-0.

NAYAK, P. P.; PAI, J. B.; GOVINDAN, S. Leveraging geographic information system for dengue surveillance: a scoping review. **Tropical Medicine and Health**, v. 53, 102, 2025. DOI: 10.1186/s41182-025-00783-9.

OSCO, L. P.; WU, Q.; LEMOS, E. L. de; GONÇALVES, W. N.; RAMOS, A. P. M.; LI, J.; MARCATO JUNIOR, J. The Segment Anything Model (SAM) for remote sensing applications: from zero to one shot. **International Journal of Applied Earth Observation and Geoinformation**, v. 124, 103540, 2023. DOI: 10.1016/j.jag.2023.103540.

REN, S.; LUZI, F.; LAHRICHI, S.; KASSAW, K.; COLLINS, L. M.; BRADBURY, K.; MALOF, J. M. Segment anything, from space? In: IEEE/CVF WINTER CONFERENCE ON APPLICATIONS OF COMPUTER VISION (WACV), 2024, Waikoloa. **2024 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)**. Piscataway: IEEE, 2024. p. 8340-8350. DOI: 10.1109/WACV57701.2024.00817.

SRUTHI, S.; SHREE, S. S.; KATARIYA, P. P.; SINGH, R. P. Small waste detection on land using fine-tuned YOLOv9 in unmanned aerial vehicle images. **Procedia Computer Science**, v. 258, p. 2258-2267, 2025. DOI: 10.1016/j.procs.2025.04.478.

TEILLET, C.; DEVILLERS, R.; TRAN, A.; CATRY, T.; MARTI, R.; DESSAY, N.; RWAGITINYWA, J.; RESTREPO, J.; ROUX, E. Exploring fine-scale urban landscapes using satellite data to predict

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

the distribution of *Aedes* mosquito breeding sites. **International Journal of Health Geographics**, v. 23, 18, 2024. DOI: 10.1186/s12942-024-00378-3.

WILDER-SMITH, A.; OOI, E.-E.; HORSTICK, O.; WILLS, B. Dengue. **The Lancet**, v. 393, n. 10169, p. 350-363, 2019. DOI: 10.1016/S0140-6736(18)32560-1.

WU, Q.; OSCO, L. P. samgeo: a Python package for segmenting geospatial data with the Segment Anything Model (SAM). **Journal of Open Source Software**, v. 8, n. 89, 5663, 2023. DOI: 10.21105/joss.05663.

ZHANG, J.; LI, Y.; YANG, X.; JIANG, R.; ZHANG, L. RSAM-Seg: a SAM-based model with prior knowledge integration for remote sensing image semantic segmentation. **Remote Sensing**, v. 17, n. 4, 590, 2025. DOI: 10.3390/rs17040590.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.