



SANEIA: SISTEMA DE DETECÇÃO AUTOMATIZADA DE ESGOTOS A CÉU ABERTO EM IMAGENS DE SATÉLITE UTILIZANDO *DEEP LEARNING*

**Vinicius Meurer
Julian Campeão
Lucas Cruz
Valdinei Saugo**

Resumo

O saneamento básico inadequado afeta milhões de brasileiros, demandando ferramentas eficientes para monitoramento em larga escala. Este trabalho apresenta o SaneIA, um sistema automatizado para detecção de esgotos a céu aberto em imagens de satélite utilizando *deep learning*. O objetivo é desenvolver e validar um modelo baseado em *ResNet18* pré-treinada capaz de classificar automaticamente a presença ou ausência de esgoto em imagens do Sentinel-2. A metodologia envolveu coleta de 58 imagens satelitais georreferenciadas, pré-processamento com *data augmentation*, e treinamento por 20 épocas usando *PyTorch*. Os resultados demonstraram acurácia de 82,8% e *AUC* de 0,882, validando a viabilidade técnica da abordagem. O sistema desenvolvido representa uma solução promissora para apoiar políticas públicas de saneamento através do monitoramento automatizado e escalável de infraestrutura urbana.

Palavras-chave: *deep learning*; sensoriamento remoto; saneamento básico; detecção automatizada; redes neurais convolucionais.

Abstract

Inadequate basic sanitation affects millions of Brazilians, demanding efficient tools for large-scale monitoring. This work presents SaneIA, an automated system for detecting open sewers in satellite images using deep learning. The objective is to develop and validate a model based on pre-trained ResNet18 capable of automatically classifying the presence or absence of sewage in Sentinel-2 images. The methodology involved collecting 58 georeferenced satellite images, preprocessing with data augmentation, and training for 20 epochs using PyTorch. The results demonstrated 82.8% accuracy and AUC of 0.882, validating the technical feasibility of the approach. The developed system represents a promising solution to support public sanitation policies through automated and scalable monitoring of urban infrastructure.

Keywords: *deep learning*; remote sensing; basic sanitation; automated detection; convolutional neural networks.

INTRODUÇÃO

O déficit de saneamento básico no Brasil representa um dos maiores desafios de saúde pública e qualidade de vida da população. Segundo o Instituto Trata Brasil (2023), milhões de brasileiros ainda não têm acesso adequado a sistemas de coleta e tratamento de esgoto, resultando em sérios impactos ambientais e sanitários. A identificação e mapeamento de esgotos a céu aberto são etapas fundamentais para o planejamento de políticas públicas efetivas,

porém os métodos tradicionais de inspeção in loco são custosos, demorados e limitados em escala.

O avanço das tecnologias de sensoriamento remoto, combinado com técnicas de inteligência artificial, oferece novas possibilidades para o monitoramento ambiental em larga escala. As redes neurais convolucionais (CNNs) têm demonstrado eficácia significativa em tarefas de classificação de imagens, tornando-se ferramentas promissoras para análise automatizada de imagens de satélite. No contexto específico do monitoramento de saneamento, estudos recentes demonstram a viabilidade técnica de utilizar imagens de satélite para mapear condições de infraestrutura urbana (Silva et al., 2021; Liu et al., 2022).

Apesar do potencial, não existem trabalhos consolidados que estabeleçam metodologias específicas para detecção automatizada de esgotos a céu aberto utilizando *deep learning* e imagens de satélite. Esta lacuna representa tanto um desafio técnico quanto uma oportunidade para desenvolvimento de soluções inovadoras que possam contribuir efetivamente para o monitoramento de saneamento básico.

Diante deste cenário, este trabalho tem como objetivo desenvolver e validar um sistema automatizado de detecção de esgotos a céu aberto em imagens de satélite utilizando técnicas de *deep learning*. Especificamente, busca-se adaptar uma arquitetura de rede neural convolucional pré-treinada para classificação binária de presença ou ausência de esgoto, avaliar seu desempenho através de métricas consolidadas, e demonstrar a viabilidade técnica da abordagem como ferramenta de apoio ao monitoramento de saneamento.

MATERIAL E MÉTODO

Este estudo caracteriza-se como uma pesquisa aplicada de natureza experimental, focada no desenvolvimento e validação de um sistema de inteligência artificial para classificação de imagens de satélite. O sistema

desenvolvido utiliza técnicas de aprendizado profundo para identificar automaticamente a presença de esgotos a céu aberto em áreas urbanas.

CRITÉRIOS DE QUALIDADE E ACEITAÇÃO

Para estabelecer critérios de qualidade objetivos, foram definidos os seguintes limites de aceitação para um sistema em fase de prova de conceito:

- a) Acurácia mínima: 75%;
- b) AUC mínima: 0,75;
- c) $F1$ -score balanceado: $> 0,70$;
- d) Estabilidade de treinamento: Convergência sem *overfitting* significativo;
- e) Reprodutibilidade: Variação $< 5\%$ entre execuções.

COLETA E PROCESSAMENTO DE DADOS

O conjunto de dados foi construído a partir de coordenadas geográficas previamente rotuladas como uma classificação binária, sendo “esgoto” (1) ou “não esgoto” (0). Para cada coordenada foram coletadas imagens satelitais correspondentes do satélite *Sentinel-2* por meio da *API* do *Google Earth Engine*, que compuseram o *dataset* final utilizado nos experimentos. Um aspecto relevante observado foi o desbalanceamento entre as classes, característica comum em problemas ambientais e que tende a impactar o desempenho de modelos de classificação, exigindo cuidados adicionais na interpretação das métricas.

O código-fonte completo da implementação está disponível em repositório público para fins de reproduzibilidade (MEURER, 2025).

PRÉ-PROCESSAMENTO

As imagens coletadas passaram por etapas de preparação antes de serem utilizadas no treinamento. Inicialmente, os valores de *pixel* foram normalizados e as imagens foram redimensionadas para se adequarem às dimensões exigidas pelo modelo pré-treinado. Após a padronização inicial, o conjunto foi submetido a técnicas de *data augmentation* (*flip* horizontal, rotação,

variação de brilho e contraste) e, em seguida, foi dividido em dois subconjuntos: treinamento (80%) e teste (20%). Essa divisão foi escolhida para maximizar a quantidade de dados disponíveis para o aprendizado do modelo, sem comprometer a etapa de avaliação. O conjunto de teste, mantido totalmente separado do treinamento, teve o papel de fornecer uma medida imparcial da capacidade de generalização do modelo em dados não vistos.

MODELO E TREINAMENTO

O modelo adotado neste trabalho foi uma *ResNet18* pré-treinada no *ImageNet*, uma arquitetura de rede neural convolucional amplamente utilizada em visão computacional devido ao seu bom equilíbrio entre profundidade e eficiência computacional. A escolha pela *ResNet18* deve-se à sua capacidade de extrair representações hierárquicas relevantes, mesmo em bases de dados reduzidas, aproveitando o conhecimento adquirido no pré-treinamento. Para a tarefa em questão, a última camada totalmente conectada (*fully connected*) foi substituída por uma camada linear com duas saídas, correspondentes às classes “esgoto” e “não esgoto”.

O treinamento foi conduzido no framework *PyTorch*, utilizando como função de perda a *cross-entropy loss*, adequada para problemas de classificação multiclasse, e o otimizador Adam, escolhido pela sua eficiência em cenários com ajustes finos de parâmetros. A taxa de aprendizado foi fixada em 0,001, valor definido empiricamente para garantir estabilidade no processo de otimização.

As imagens foram alimentadas ao modelo em lotes (*batch size*) de 32 amostras, o que permitiu equilibrar desempenho computacional e estabilidade na atualização dos pesos. O processo de treinamento foi realizado por 20 épocas, número suficiente para observar a convergência da função de perda sem indícios relevantes de sobreajuste (*overfitting*). Uma vez concluído o treinamento, o modelo foi submetido a uma etapa de avaliação para verificar sua qualidade preditiva e capacidade de generalização.

AVALIAÇÃO

A avaliação do modelo foi realizada com base em métricas amplamente utilizadas em aprendizado de máquina, de modo a fornecer uma análise abrangente da qualidade do sistema. Entre as métricas consideradas estão: acurácia, precisão, revocação (*recall*) e *F1-score*, fundamentais para verificar o equilíbrio entre acertos e erros, especialmente em contextos de classes desbalanceadas.

Além disso, foram analisadas a matriz de confusão, as curvas *ROC* (e respectivas áreas sob a curva, *AUC*) e as curvas *precision-recall*, que fornecem uma visão detalhada da capacidade discriminativa do modelo em diferentes limiares de decisão.

Por fim, também foram utilizadas as curvas de aprendizado, representando a evolução da perda ao longo das épocas. Esse recurso permitiu acompanhar a estabilidade do treinamento e identificar possíveis indícios de *overfitting* ou *underfitting*, contribuindo para a análise da robustez do modelo.

RESULTADOS E DISCUSSÕES

DESEMPENHO DE CLASSIFICAÇÃO

O modelo treinado apresentou acurácia geral de 82,8% no conjunto de teste, demonstrando capacidade satisfatória para distinguir entre áreas com e sem presença de esgoto a céu aberto. A análise detalhada por classe revelou desempenho diferenciado: a classe "não esgoto" obteve precisão, *recall* e *F1-score* de 87,8%, enquanto a classe "esgoto" alcançou 70,6% em todas essas métricas. O *F1-score* macro médio de 79,2% evidencia equilíbrio razoável entre as classes, embora com desempenho superior para a classe de ausência de esgoto.

A matriz de confusão revelou padrão específico de classificações: 36 verdadeiros negativos (áreas sem esgoto corretamente identificadas), 12 verdadeiros positivos (esgotos corretamente detectados), 5 falsos positivos (áreas sem esgoto incorretamente classificadas como tendo esgoto), e 5 falsos negativos (esgotos não detectados). Esta distribuição indica tendência equilibrada de erros entre as classes, com o modelo demonstrando capacidade similar de identificação para ambas as categorias.

CAPACIDADE DISCRIMINATIVA

A curva *ROC* demonstrou boa capacidade discriminativa do modelo, com área sob a curva (*AUC*) de 0,882. Este valor indica que o modelo possui capacidade significativamente superior ao acaso (*AUC* = 0,5) para distinguir entre as classes em diferentes limiares de decisão. Segundo a literatura, valores de *AUC* entre 0,8 e 0,9 são considerados bons, aproximando-se de desempenho excelente (*AUC* > 0,9).

A curva *precision-recall* apresentou comportamento estável, iniciando com alta precisão próxima a 1,0 em baixos valores de recall e apresentando declínio gradual conforme o recall aumenta. Este padrão é esperado em problemas de classificação e indica que o modelo mantém precisão satisfatória mesmo quando ajustado para detectar maior número de casos positivos, característica importante para aplicações práticas de monitoramento.

ESTABILIDADE DO TREINAMENTO

A análise da evolução da função de perda ao longo das 20 épocas mostrou convergência adequada do processo de treinamento. Inicialmente, a *loss* apresentou valor elevado (aproximadamente 0,7), reduzindo consistentemente até aproximadamente a quinta época. Nas épocas finais, observaram-se oscilações em torno de valores baixos (entre 0,2 e 0,3), sugerindo estabilização do aprendizado sem indícios significativos de *overfitting*.

DISCUSSÃO DOS RESULTADOS

Os resultados obtidos demonstram que o modelo pré-treinado de ResNet18 adaptado apresenta capacidade promissora para a tarefa de detecção de esgotos a céu aberto em imagens de satélite. A acurácia de 82,8% e *AUC* de 0,882 situam o desempenho em patamar satisfatório, especialmente considerando o tamanho moderado do *dataset* e a complexidade do problema.

O sistema desenvolvido oferece vantagens significativas em relação aos métodos tradicionais de inspeção: processamento automatizado em grande escala, análise objetiva e consistente, redução de custos operacionais, e capacidade de monitoramento temporal através de imagens históricas do

Sentinel-2. Estas características posicionam a ferramenta como complemento valioso para gestores públicos no planejamento de intervenções de saneamento.

Algumas limitações devem ser consideradas. O desempenho ligeiramente inferior da classe "esgoto" (70,6%) comparado à classe "não esgoto" (87,8%) sugere que o modelo tem maior dificuldade em identificar casos positivos, possivelmente devido à variabilidade visual dos esgotos a céu aberto ou ao tamanho limitado do *dataset*. Adicionalmente, o conjunto de teste relativamente pequeno (58 amostras totais) pode limitar a generalização das conclusões sobre o desempenho em cenários diversos.

A aplicabilidade prática do sistema deve considerar validação adicional em diferentes contextos geográficos, condições climáticas e tipos de áreas urbanas. Trabalhos futuros devem focar na expansão do *dataset* com maior diversidade de amostras, exploração de arquiteturas mais complexas, implementação de técnicas de balanceamento de classes, e validação em campo com comparação direta entre detecções automatizadas e inspeções presenciais.

CONCLUSÃO

Este trabalho apresentou o desenvolvimento e validação do SaneIA, um sistema automatizado para detecção de esgotos a céu aberto em imagens de satélite utilizando *deep learning*. A abordagem baseada em *ResNet18* pré-treinada demonstrou viabilidade técnica, alcançando acurácia de 82,8% e *AUC* de 0,882 na classificação binária de presença ou ausência de esgoto.

Os resultados confirmam que técnicas de aprendizado profundo aplicadas ao sensoriamento remoto constituem ferramenta promissora para monitoramento ambiental e apoio a políticas públicas de saneamento. O sistema desenvolvido possibilita análise em larga escala, processamento automatizado e monitoramento temporal, características essenciais para enfrentar o desafio do déficit de saneamento básico no Brasil.

As principais contribuições deste estudo incluem: desenvolvimento de metodologia específica para detecção automatizada de esgotos em imagens de satélite; validação da aplicabilidade de *transfer learning* com *ResNet18* para o

problema; e demonstração da viabilidade técnica da abordagem através de métricas consolidadas de desempenho.

Como limitações, destaca-se o tamanho moderado do *dataset* e a necessidade de validação em contextos geográficos mais diversos. Trabalhos futuros devem focar na expansão da base de dados, experimentação com arquiteturas mais profundas, implementação de técnicas de explicabilidade (XAI) para interpretação das decisões do modelo, e validação em campo para confirmar a utilidade prática do sistema.

O sistema desenvolvido estabelece base sólida para futuras implementações em produção, contribuindo para o avanço de soluções tecnológicas aplicadas ao monitoramento de saneamento básico e, consequentemente, para a melhoria da qualidade de vida da população brasileira.

Referências

- AMERSHI, S. et al. Guidelines for Human-AI Interaction. In: CHI CONFERENCE ON HUMAN FACTORS IN COMPUTING SYSTEMS, 2019, Glasgow. **Anais...** Glasgow: ACM, 2019.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge: MIT Press, 2016.
- INSTITUTO TRATA BRASIL. **Relatório Anual de Saneamento**. São Paulo: Instituto Trata Brasil, 2023. Disponível em: <https://www.tratabrasil.org.br/>. Acesso em: 09 out. 2025.
- LIU, X. et al. Deep learning for environmental monitoring: A review. **Ecological Indicators**, v. 135, 2022.
- MEURER, V. F. **Open Sewer Detection v6**: sistema de detecção de esgotos a céu aberto utilizando deep learning. 2025. Código-fonte. Disponível em: <https://github.com/vinimeurer/open-sewer-detection-v6>. Acesso em: 09 out. 2025.
- POWERS, D. M. W. Evaluation: From Precision, Recall and F-measure to ROC, Informedness, Markedness & Correlation. **Journal of Machine Learning Technologies**, v. 2, n. 1, 2020.
- SILVA, T. et al. Remote sensing and machine learning applied to water quality and sanitation monitoring. **Journal of Environmental Management**, v. 293, 2021.