



# **YOLO aplicado à Infraestrutura Urbana: Detecção de Fissuras em Ciclovias com o Apoio de Drones**

**Nome do palestrante: Michele Tereza Marques  
Carvalho**



**TRIBUNAL DE CONTAS  
ESTADO DO AMAZONAS**

# SUMÁRIO

- INTRODUÇÃO
- REVISÃO BIBLIOGRÁFICA
- METODOLOGIA
- RESULTADOS
- DISCUSSÕES
- CONCLUSÕES
- REFERÊNCIAS

**Autores:** Tharlys Hikaro Pinheiro Silva  
Michele Tereza Marques Carvalho

# INTRODUÇÃO

- Importância da qualidade das ciclovias para mobilidade urbana sustentável.
- **Problema:** fissuras comprometem conforto, durabilidade e segurança.
- Inspeções visuais manuais são lentas, subjetivas e pouco padronizadas.



# INTRODUÇÃO

- **Lacuna:** poucas metodologias automatizadas específicas para ciclovias, que considerem as particularidades desses espaços.
- **Objetivo do estudo:** propor e avaliar o uso de imagens de drones combinadas com visão computacional + inteligência artificial (YOLO) para identificar automaticamente fissuras em ciclovias de pavimento rígido.

# REVISÃO BIBLIOGRÁFICA

- Fissuras são manifestações patológicas comuns em pavimentos rígidos (Hora, 2021; Silva Júnior, 2018).
- Redes neurais convolucionais vêm ganhando destaque na detecção automática de fissuras em estruturas de concreto oferecendo agilidade, padronização e redução da subjetividade na identificação de danos (Ai *et al.*, 2023; Dung; Anh, 2019).
- **YOLO**: detecção em tempo real, uso de *bounding boxes* (caixas delimitadoras), menor custo computacional que segmentação (Han; Yang; Yang, 2024).

# REVISÃO BIBLIOGRÁFICA

- ***Data augmentation*** (aumento de dados): aumenta diversidade e robustez do modelo por meio de transformações como rotações, redimensionamentos e ajustes de cores.
- ***Transfer learning***: reutiliza pesos de redes treinadas, útil em bases pequenas, pois reduz a necessidade de grandes volumes de dados rotulados e melhora a velocidade de convergência do treinamento (Philip *et al.*, 2023).

# METODOLOGIA



## 1ª ETAPA

Coleta dos dados - imagens das ciclovias  
(utilização de drone)




## 2ª ETAPA

Pré-Processamento das imagens  
(Auto-orientação e divisão em blocos)



## 3ª ETAPA

Anotação das fissuras nas imagens  
(Roboflow)



## 4ª ETAPA

Treinamento dos modelos  
(YOLOv11)



## 5ª ETAPA

Avaliação dos modelos  
(Quantitativa e Qualitativa)



# Coleta, pré-processamento e anotação de imagens das ciclovias

- Drone: DJI *Phantom 4 Advanced+*, resolução 5472×3078 px, altura 7–30 m.
- Área de estudo: Asa Sul – Brasília/DF.





# Coleta, pré-processamento e anotação de imagens das ciclovias

- Foi utilizado o **Roboflow** (Dwyer et al., 2024) para realizar as seguintes tarefas:
  - Divisão das imagens em 3×3 blocos (*tiles*);
  - Anotação: fissuras em placas diferentes → caixas diferentes; fissuras ramificadas → uma caixa por ramificação.

# Treinamento dos Modelos

- **Arquitetura:** YOLOv11m (equilíbrio entre precisão e custo computacional).
- ***Data Augmentation:***
  - Espelhamento horizontal e vertical.
  - Rotações (90°, 180°, 270°).
  - Zoom de 0% a 30%.
  - Objetivo: ampliar a diversidade e o volume do banco de dados antes do treinamento.

# Treinamento dos Modelos

- **Modelo 1** (*Transfer Learning*): pré-treinado em *dataset* (banco de dados) genérico de fissuras (7.070 imagens) + ajuste fino com banco local (656 imagens).
- **Modelo 2**: treinado apenas com banco local (656 imagens).
- **Configuração de treino**: *imgsz=1024, epochs=100, batch=8*.



# Avaliação dos Modelos

- **Métricas:**

- *Precision* (precisão): proporção de detecções corretas sobre o total de detecções feitas.
- *Recall*: proporção de fissuras detectadas sobre o total existente.
- $mAP_{50}$ : média da precisão considerando predições corretas com *Intersection over Union* (IoU)  $\geq 50\%$ .

# Avaliação dos Modelos

- As métricas foram complementadas por uma análise qualitativa de inferências geradas em imagens não utilizadas para treinamento, com o objetivo de interpretar o desempenho final do modelo.

# RESULTADOS - Quantitativo

- Tabela 1 – Comparação dos desempenhos entre o Modelo 1 e o Modelo 2

| Modelo   | <i>Precision (%)</i> | <i>Recall (%)</i> | <i>mAP<sub>50</sub> (%)</i> |
|----------|----------------------|-------------------|-----------------------------|
| Modelo 1 | 53,3                 | 45,1              | 46,3                        |
| Modelo 2 | 49,1                 | 44,3              | 43,3                        |

Fonte: Autores.




# RESULTADOS - Quantitativo

- Comparação do Resultado

| Estudo                  | Estudo / Modelo     | Nº de imagens (treino) | mAP50 (%) |
|-------------------------|---------------------|------------------------|-----------|
| Jiang, Pang e Li (2021) | YOLOv3              | 512                    | 52,43     |
|                         | Fast-YOLO           | 689                    | 55,92     |
|                         | MobileNet-SSD       | 679                    | 43,31     |
| Presente estudo         | YOLOv11m (Modelo 1) | 656                    | 46,3      |
|                         | YOLOv11m (Modelo 2) | 656                    | 43,3      |

# RESULTADOS - Qualitativo

Falha de detecção de fissura



Detecção bem-sucedida de fissura com presença de vegetação sobreposta à superfície do pavimento



# Resultados - Qualitativo



Detecção parcial de fissura em condição adversa de iluminação, com predições descontínuas

# DISCUSSÕES

- *Transfer Learning* aumentou a precisão, *recall* e  $mAP_{50}$  mesmo com mudança de domínio.
- *Dataset* limitado e variabilidade visual impactam métricas.
- Perda de detalhes em fissuras finas pode ocorrer devido ao redimensionamento.
- Necessidade de ampliar base de imagens e incluir cenários adversos.



# CONCLUSÕES

- YOLOv11m viável para detecção automática de fissuras em ciclovias, com imagens obtidas de drones.
- *Transfer learning* melhora desempenho frente ao treino apenas local.
- Potencial para inspeções mais rápidas e padronizadas.

# CONCLUSÕES

- Futuras pesquisas:
  - Ampliar banco de dados e variedade visual.
  - Testar recortes menores mantendo resolução.
  - Integrar resultados em GIS para mapeamento de manutenção.
- O estudo demonstra que, mesmo com um banco de dados reduzido, é viável empregar arquiteturas leves como YOLOv11 em aplicações práticas e reais de inspeção de infraestrutura.

# REFERÊNCIAS

- HORA, K. M. da. Metodologia Para Avaliação Do Ciclo De Vida De Ciclovias De Pavimento Rígido. Dissertação (Mestrado) – Programa de Pós-Graduação em Estruturas e Construção Civil, Universidade de Brasília, Brasília, 2021.
- SILVA JÚNIOR, A. C. Proposta de metodologia para avaliação de danos de pavimentos rígidos de ciclovia. Dissertação (Mestrado) – Programa de Pós-Graduação em Estruturas e Construção Civil, Universidade de Brasília, Brasília, 2018.
- AI, D. et al. Computer vision framework for crack detection of civil infrastructure —A review. *Engineering Applications of Artificial Intelligence*, v. 117, p. 105478, jan. 2023.
- DUNG, C. V.; ANH, L. D. Autonomous concrete crack detection using deep fully convolutional neural network. *Automation in Construction*, v. 99, p. 52–58, mar. 2019.
- HAN, C.; YANG, H.; YANG, Y. Enhancing pixel-level crack segmentation with visual mamba and convolutional networks. *Automation in Construction*, v. 168, p. 105770–105770, set. 2024.
- PHILIP, R. E. et al. A Comparative Study on Crack Detection in Concrete Walls Using Transfer Learning Techniques. *Journal Of Composites Science*, v. 7, n. 4, abr. 2023.
- Dwyer, B., Nelson, J., Hansen, T., et al., "Roboflow," (2024). Disponível em: <<https://roboflow.com>>. Acesso em: 4 mar. 2025.
- JIANG, Y.; PANG, D.; LI, C. A deep learning approach for fast detection and classification of concrete damage. *Automation in Construction*, v. 128, p. 103785, ago. 2021.