

# Detecção de Patologias em Obras Civis Utilizando Redes Neurais Convolucionais.

João Victor Oliveira da Silva.<sup>1\*</sup>

Diogo Lopes da Silva.<sup>2</sup>

<sup>1\*</sup>Discente de graduação em Análise e Desenvolvimento de Sistemas - IFPE - E-mail: [jvos2@discente.ifpe.edu.br](mailto:jvos2@discente.ifpe.edu.br);

<sup>2</sup> Docente de graduação em Análise e Desenvolvimento de Sistemas - IFPE - E-mail: [diogo.lopes@palmares.ifpe.edu.br](mailto:diogo.lopes@palmares.ifpe.edu.br)

## RESUMO

Este trabalho propõe um sistema para detecção automatizada de rachaduras em estruturas civis utilizando o modelo *YOLO*, uma rede neural convolucional reconhecida pela precisão e rapidez em tempo real. Foram empregadas técnicas de *transfer learning* e *fine-tuning* sobre um *dataset* contendo 1.398 imagens anotadas da classe “rachadura”. Os resultados mostraram desempenho expressivo, alcançando *Recall@0.50* de 0,95 e *mAP@0.50* de 0,90, indicando alta sensibilidade e robustez do modelo. A solução apresenta potencial para ser aplicada em drones ou outros dispositivos, oferecendo uma alternativa escalável e de baixo custo para inspeções visuais tradicionais, embora desafios como generalização para outras patologias e limitações de hardware em campo ainda precisam ser explorados. Este estudo representa um avanço significativo no uso de inteligência artificial para monitoramento de integridade estrutural, contribuindo para maior segurança e durabilidade de edificações.

**Palavras-chave:** Inspeção automatizada. Visão computacional. Obras Civis.

## ABSTRACT

This work proposes a system for automated crack detection in civil structures using the *YOLO* model, a convolutional neural network known for its real-time accuracy and speed. Transfer learning and fine-tuning techniques were applied to a dataset containing 1,398 annotated images of the “crack” class. The results demonstrated strong performance, achieving a *Recall@0.50* of 0.95 and *mAP@0.50* of 0.90, indicating high sensitivity and robustness. The solution shows potential for deployment on drones or other devices, offering a scalable and low-cost alternative to traditional visual inspections. However, challenges such

as generalization to other pathologies and hardware limitations in the field still need to be addressed. This study represents a significant advancement in the use of artificial intelligence for structural integrity monitoring, contributing to increased safety and durability of buildings.

**Keywords:** Automated inspection. Computer vision. Civil structures.

## 1 INTRODUÇÃO

As patologias em obras civis nada mais são do que doenças que acometem estruturas em edificações, e assim como no ser humano, se não forem descobertas e tratadas com antecedência (Lima, 2019; Kim et al., 2018), podem evoluir, comprometendo parcial ou totalmente a estrutura do edifício. Isso aumenta o risco de degradação e de perda da durabilidade do material, podendo, inclusive, levar ao desabamento. Por isso, a identificação precoce é fundamental para garantir segurança, funcionalidade e durabilidade do projeto. As principais patologias são:

- Eflorescência: formação de sais que aparecem como manchas brancas, transportadas por meio da umidade;
- Corrosão da armadura de aço: exposição da armadura devido a fendilhamento ou desagregação do concreto, causada por fatores mecânicos, químicos ou físicos;
- Infiltrações: entrada de fluidos que permeiam espaços vazios em paredes, pisos e lajes;
- Rachaduras: aberturas mais profundas e divididas, consideradas perigosas por permitirem a penetração de água na estrutura.

Segundo Brandão (2007), em edificações com 101 a 500 m<sup>2</sup>, há um percentual de 41% de manifestações patológicas. Para outras construções, o aparecimento de patologias é de 42% no primeiro ano, caindo para 21% no segundo, atingindo o menor percentual, de 9%, no terceiro ano, e voltando a aumentar no quarto para 11% e, no quinto, para 17%, como mostrado na Figura 1. Considerando isso, foi notado que 58% das patologias identificadas apresentam gravidade moderada, ou seja, trata-se de um fator preocupante para os usuários.

Figura 1 – Evolução Patológicas ao Longo dos Anos.



A NBR 15575 (ABNT, 2013) é a norma de desempenho para edificações habitacionais que estabelece critérios indispensáveis para garantir a qualidade das obras. Ela deve atender às exigências dos usuários ao longo dos anos, com ênfase na habitabilidade e na durabilidade da edificação, considerando não apenas a fase construtiva, mas também todo o seu ciclo de uso. Ou seja, todos os envolvidos no processo de construção, compra e moradia estão sujeitos à norma e devem cumprir suas responsabilidades conforme ela estabelece.

A fiscalização ocorre principalmente por inspeções visuais, nas quais engenheiros e técnicos precisam realizar a verificação manualmente, muitas vezes se expondo a riscos ao acessar locais de grande altura ou de difícil acesso. Além disso, após a detecção da patologia, é necessário retornar ao local para realizar a intervenção corretiva, o que representa uma nova exposição ao risco.

Para auxiliar nesse processo vem sendo desenvolvido um *laser scanner 3D*, que permite a captura e criação de modelos tridimensionais das estruturas (MundoGEO, 2025). Porém, é um equipamento custoso e que exige a capacitação de quem for operá-lo, tanto para o manuseio quanto para a interpretação dos dados gerados, além de fornecer as coordenadas exatas daquela patologia.

Para isso, é proposto o uso de técnicas de visão computacional e inteligência artificial, no caso *CNN (Convolutional Neural Network)*, para detecção das patologias, sendo extremamente útil para lugares de difícil acesso e elevadas alturas, além de ser uma solução escalável e de baixo custo para o monitoramento contínuo da integridade estrutural em obras civis.

O estudo compromete-se a identificar, primariamente, rachaduras e, posteriormente, incluir outras patologias, como infiltrações, mofo, corrosão da armadura de aço e

eflorescência.

## **2 TRABALHOS RELACIONADOS**

Estudos recentes vêm aplicando inteligência artificial (IA) e visão computacional na detecção de anomalias em contextos industriais e na engenharia civil. Em Liu et al. (2024), é apresentada uma revisão detalhada de técnicas de detecção de falhas em imagens industriais, destacando a eficácia de redes neurais profundas, mesmo em situações com poucos dados disponíveis. Os autores ressaltam que ambientes reais, como canteiros de obras, impõem desafios adicionais devido à variabilidade e imprevisibilidade dos defeitos, exigindo modelos com alta capacidade de generalização, como as redes convolucionais

O estudo de Bergmann et al. (2019) investigou o modelo *DifferNet* com a incorporação de módulos de atenção (*attention modules*) em inspeções visuais. Os resultados mostraram melhorias significativas na detecção de anomalias em cenários com baixa incidência de falhas, condição comum na detecção de patologias em estruturas civis. A sensibilidade aumentada a padrões sutis torna essa abordagem promissora, especialmente para a identificação de microfissuras ou falhas iniciais em superfícies de concreto.

Embora voltados para ambientes industriais, os princípios dessas pesquisas são diretamente aplicáveis à construção civil. Os desafios enfrentados, como texturas irregulares, ruídos visuais e escassez de dados rotulados, também estão presentes na inspeção de edificações.

Diante disso, este trabalho propõe a aplicação do modelo *YOLO*, reconhecido por sua precisão e velocidade em tempo real, como solução adaptada à detecção automatizada de patologias em obras civis. Ao contrário de abordagens que operam em ambientes controlados, a proposta aqui busca atuar em condições reais, inicialmente com foco em rachaduras, com possibilidade de expansão para infiltrações, eflorescência e corrosão da armadura.

A proposta preenche uma lacuna prática ao aplicar a IA em campo, considerando os desafios técnicos e operacionais da engenharia civil.


### **2.1 Fundamentação Teórica**

As Redes Neurais Convolucionais (CNN) são amplamente utilizadas em visão computacional devido à sua capacidade de extrair automaticamente padrões visuais complexos. Elas funcionam aplicando filtros convolucionais sobre imagens para identificar características como bordas, texturas e formas, que são combinadas ao longo de múltiplas camadas para formar representações de alto nível.

Entre as arquiteturas de CNN para detecção de objetos, o YOLO (You Only Look Once) se destaca por realizar a detecção em tempo real com alta precisão. Diferente de métodos baseados em regiões (como R-CNN), o YOLO trata a detecção como um único problema de regressão, prevendo simultaneamente as coordenadas dos bounding boxes e as probabilidades de classe para cada região da imagem.

A abordagem proposta utiliza o modelo YOLO, ilustrado na Figura 2, uma rede neural convolucional projetada para tarefas de detecção em imagens. O YOLO destaca-se por sua rapidez, precisão e eficiência, características essenciais para aplicações em tempo real.

Figura 2 - Arquitetura do YOLO



A arquitetura do YOLO é composta por camadas convolucionais, operações de max pooling e camadas totalmente conectadas (fully connected layers), permitindo extrair e classificar características complexas das imagens. Inspirada no GoogLeNet, diferencia-se por utilizar camadas de redução 1x1 combinadas com convoluções, em vez dos módulos Inception. Essa configuração possibilita que imagens de diferentes tamanhos passem por transformações hierárquicas, capturando padrões específicos e detalhes relevantes.

### 3 METODOLOGIA

A abordagem proposta utiliza o modelo YOLO por sua eficiência em tarefas de detecção em tempo real. Foi adotada uma configuração cuidadosamente ajustada com o objetivo de equilibrar velocidade de convergência, estabilidade e capacidade de generalização. Para isso, definiu-se os hiperparâmetros de treinamento, que controlam como e

em que ritmo a rede aprende. O número de épocas (*epochs*) corresponde à quantidade de passagens completas do modelo pelo conjunto de dados, enquanto o tamanho do lote (*batch size*) indica quantas imagens são processadas antes de cada atualização dos pesos, influenciando diretamente o uso de memória e a estabilidade do aprendizado. Também foi utilizado um período de aquecimento (*warmup\_epochs*), no qual a taxa de aprendizado começa reduzida e aumenta gradualmente nas primeiras iterações, prevenindo oscilações bruscas, dentro desse processo, o *warmup\_bias\_lr* define uma taxa inicial ainda menor especificamente para os parâmetros de bias, garantindo ajustes mais controlados. A taxa de aprendizado inicial (*lr0*) estabelece o passo de atualização dos pesos no início do treino, enquanto a taxa final (*lrf*) define o menor valor que será alcançado ao término, permitindo ajustes mais finos na reta final do aprendizado. O otimizador escolhido foi o *Adam*, que ajusta dinamicamente a taxa de aprendizado de cada parâmetro com base no histórico de gradientes, favorecendo a convergência mais rápida. Para mitigar o sobreajuste, aplicou-se *weight decay*, que penaliza pesos excessivamente altos. Além disso, foi adotado o agendamento *cos\_lr*, que reduz a taxa de aprendizado ao longo das épocas seguindo uma curva de cosseno, permitindo ajustes mais rápidos no início e mais delicados no fim. Por fim, habilitou-se a técnica AMP (*Automatic Mixed Precision*), que combina cálculos em precisão simples (*float32*) e meia precisão (*float16*), reduzindo o uso de memória e acelerando o processamento sem comprometer a qualidade do treinamento.

### **3.1 Estratégia de *Transfer Learning***

Com o objetivo de acelerar o treinamento e melhorar a capacidade de generalização do modelo, adotou-se a técnica de transfer learning. Para isso, foram utilizados pesos pré-treinados no conjunto de dados *COCO*, amplamente utilizado em tarefas de detecção (Redmon et al., 2015). Essa abordagem permite que a rede já inicie o treinamento com conhecimento prévio de padrões visuais gerais, reduzindo o tempo de convergência e aumentando a acurácia em novos conjuntos de dados.

### **3.2 *Fine-Tuning* do Modelo**

Após a inicialização com os pesos pré-treinados, realizou-se o fine-tuning do modelo, ajustando-o especificamente ao conjunto de dados do presente trabalho. Nessa etapa, as camadas finais da rede foram treinadas com taxa de aprendizado diferenciada, permitindo que o modelo adaptasse suas representações para detectar as classes de interesse do estudo. Essa técnica garante que o modelo mantenha o conhecimento geral adquirido no pré-treinamento,

enquanto se especializa no domínio específico da base utilizada.

Para treinamento, foi utilizada a biblioteca Ultralytics YOLO, por sua interface intuitiva, suporte a diferentes frameworks (PyTorch, TorchScript, ONNX, TensorRT) e documentação detalhada. Essa biblioteca oferece flexibilidade para realizar tanto o transfer learning quanto o fine-tuning de forma integrada.

### 3.3 Ambiente de Desenvolvimento

Os experimentos foram conduzidos utilizando o *Google Colab Pro*, que oferece maior capacidade computacional e acesso a *GPUs*, recurso essencial para o treinamento de modelos de aprendizado profundo. Em específico, foi utilizada uma *GPU NVIDIA Tesla V100*. A linguagem de programação empregada foi *Python*, executada em ambiente *Linux*, escolhida por oferecer melhor desempenho e estabilidade em tarefas de deep learning.

### 3.4 Conjunto de Dados

O conjunto de dados utilizado para detecção de rachaduras foi obtido da plataforma *Roboflow (Roboflow Universe, 2024)*, contendo 1.398 imagens anotadas no formato *YOLO (.txt)*, todas com resolução  $640 \times 640$  *pixels* e pertencentes exclusivamente à classe “rachadura”. A divisão dos dados foi realizada da seguinte forma: 85% para treinamento, 9% para validação e 6% para teste.

### 3.5 Configuração de Treinamento

A configuração de treinamento foi definida com o objetivo de maximizar o desempenho do modelo, considerando ao mesmo tempo as limitações de memória da GPU utilizada e a necessidade de manter a capacidade de generalização. A Tabela 1 apresenta os hiperparâmetros adotados.

**Tabela 1.** Configuração dos hiperparâmetros utilizados no treinamento do modelo YOLO

Parâmetro	Valor	Descrição
epochs	15	Número total de passagens completas pelo conjunto de dados.
imgsz	$640 \times 640$	Resolução das imagens utilizadas.
batch	2	Quantidade de imagens processadas por lote.

warmup_epochs	3	Épocas iniciais de aquecimento com taxa de aprendizado reduzida.
warmup_bias_lr	$1 \times 10^{-6}$	Taxa de aprendizado inicial para parâmetros de bias.
lr0	0,0001	Taxa de aprendizado inicial.
lrf	0,00001	Taxa de aprendizado final.
optimizer	Adam	Otimizador utilizado no treinamento.
weight_decay	0,0001	Penalização para evitar sobreajuste.
cos_lr	True	Uso de agendamento cossenoidal de taxa de aprendizado.
amp	True	Utilização de Automatic Mixed Precision para otimização de desempenho.

### 3.6 Métricas De Desempenho

A avaliação do desempenho para o modelo utilizará algumas métricas padrão da área de detecção de objetos, que fornecem uma visão abrangente de sua capacidade de previsão e qualidade geral das previsões. As principais métricas de desempenho são *Recall*, que mede a proporção de detecções corretas em relação ao número total de objetos verdadeiros presentes na cena, e o *mAP* (*mean Average Precision*), que é a média da precisão média em diferentes valores de recall. Essa métrica é importante porque leva em consideração a variabilidade do recall em diferentes níveis de precisão, fornecendo uma medida mais abrangente do desempenho do modelo. As três métricas são importantes para avaliar o desempenho do modelo de detecção de rachaduras: *Recall* na equação (1), *Precisão* na equação (2) e *mAP* na equação (3) (*mean Average Precision*).

$$\text{Recall} = \frac{VP}{VP+FN} \quad (1)$$

- VP (Verdadeiros Positivos): São os casos em que o modelo detectou corretamente as rachaduras.
- FN (Falsos Negativos): São os casos em que o modelo não detectou as rachaduras

quando elas estavam presentes.

- O Recall mede a proporção de detecções corretas em relação ao número total de objetos verdadeiros presentes na cena.

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (2)$$

- VP (Verdadeiros Positivos): Mesma definição da equação do *Recall*.
- FP (Falsos Positivos): São os casos em que o modelo detectou rachaduras quando na verdade não havia.

A Precisão mede a proporção de verdadeiros positivos em relação ao número total de objetos detectados como positivos pelo modelo.

$$mAP = \frac{1}{|R|} \sum_{i=1}^{|R|} P(i) \cdot \Delta R(i) \quad (3)$$

- $|R|$  é o número total de pontos de *recall*.
- $P(i)$  é a precisão no ponto de *recall*  $i$
- $R(i)$  é a mudança no *recall* entre os pontos  $i$  e  $i - 1$ .

O *mAP* é calculado como a área sob a curva de precisão em função do recall, onde a precisão é interpolada entre os pontos de recall.

#### 4 RESULTADOS E DISCUSSÃO

O treinamento do modelo *YOLO* levou aproximadamente 50 minutos, com configuração de 15 épocas. Durante esse processo, observou-se desempenho expressivo na tarefa de detecção de rachaduras. A Tabela 2 apresenta as métricas obtidas:

**Tabela 2.** Resultados do modelo de detecção de rachaduras

Métricas	Descrição	Valor
<i>Recall@0.50</i>	Proporção de detecções corretas em relação ao total de objetos reais.	0.95
<i>mAP@0.50</i>	Média da precisão média em diferentes valores de <i>recall</i> .	0.90

Esses valores indicam que o modelo possui alta sensibilidade (Recall de 0,95), sendo capaz de identificar corretamente a maior parte das rachaduras presentes nas imagens. O mAP de 0,90 demonstra precisão e robustez em diferentes contextos, reforçando a viabilidade do sistema para aplicações práticas. As Figuras 3 e 4 mostram exemplos dos bounding boxes gerados, evidenciando a capacidade do modelo em identificar rachaduras com boa acurácia, inclusive em imagens com diferentes níveis de detalhe.

Figura 3 - Exemplo do bounding box gerado pelo YOLO para detectar rachaduras e indicar o nível de acerto.



Fonte: Base de dados pessoal.

Figura 4 - Bounding box indicando o nível de exatidão na detecção de rachaduras.



Fonte: Base dados *Roboflow*, imagem conjunto de teste.

Durante os testes, foi possível perceber que o sistema pode ser adaptado para diferentes contextos, como a identificação de falhas maiores ou até elementos arquitetônicos, o que amplia seu potencial de aplicação. A utilização em drones ou sistemas embarcados também é viável, mas depende de testes adicionais relacionados ao desempenho em tempo real, consumo energético e limitações de *hardware*.

Apesar dos bons resultados, é importante reconhecer que o dataset utilizado foi obtido de um repositório público (*Roboflow*), o que pode não representar com fidelidade as condições reais de campo, como variações de iluminação, presença de sujeira, ou desgaste estrutural. Isso pode limitar a generalização do modelo e impactar sua eficácia em ambientes não controlados.

Além disso, o modelo foi treinado apenas para rachaduras. A expansão para outras patologias estruturais, como infiltrações, eflorescências ou corrosão, exigirá ajustes no dataset, novas rotulações e possível reconfiguração dos hiperparâmetros.

Ainda assim, os resultados obtidos demonstram que o uso de visão computacional

com *YOLO* oferece uma alternativa promissora, escalável e de menor custo às inspeções visuais tradicionais, com grande potencial de aplicação no monitoramento da integridade de estruturas civis.

## 5 CONCLUSÃO

Este trabalho apresentou o desenvolvimento de um sistema automatizado para detecção de rachaduras em estruturas civis utilizando o modelo *YOLO*. Os resultados obtidos demonstraram alta sensibilidade e precisão, com *Recall@0.50* de 0,95 e *mAP@0.50* de 0,90, evidenciando o potencial da abordagem para aplicações em tempo real, como inspeções com drones ou dispositivos embarcados.

A utilização de visão computacional e técnicas de *deep learning* mostrou-se eficaz para simular a percepção humana na identificação de falhas estruturais, contribuindo diretamente para a prevenção de acidentes e o aumento da segurança em edificações, conforme discutido em Freitas (2022).

Apesar do bom desempenho, limitações como a necessidade de bases de dados mais representativas e a adaptação do sistema a diferentes condições de campo devem ser consideradas em futuros trabalhos. A expansão do modelo para outras patologias estruturais também representa uma linha promissora de pesquisa.

Espera-se que os resultados obtidos sirvam como base para o desenvolvimento de soluções práticas e escaláveis no monitoramento automatizado da integridade de estruturas civis.

## 6 REFERÊNCIAS

LIMA, J. M. C. Reconhecimento e análise de rachaduras a partir de imagens para monitoramento em regiões com atividade sísmica frequente. 2019. Dissertação (Mestrado em Informática) — Universidade Federal de Alagoas, Maceió-AL, 2019.

KIM, H.; AHN, E.; SHIN, M.; SIM, S. H. Crack and non-crack classification from concrete surface images using machine learning. *Structural Health Monitoring*, v. 18, p. 725–738, 2018.

BRANDÃO, R. M. L. Levantamento das manifestações patológicas nas edificações, com até cinco anos de idade, executadas no estado de Goiás. 2007. Dissertação (Mestrado em Engenharia Civil) — Universidade Federal de Goiás, Goiânia, 2007.

MOBUSS CONSTRUÇÃO. NBR 15575: quais são as exigências de habitabilidade? Disponível em: <https://www.mobussconstrucao.com.br/blog/nbr-15575/>. Acesso em: 26 jun.

2025.

REDMON, J. et al. You Only Look Once: Unified, Real-Time Object Detection. University of Washington; Allen Institute for AI; Facebook AI Research, 2015.

MUNDOGEO. Laser scanner 3D e tecnologias de inspeção avançada para prevenção de danos em pontes, túneis e viadutos. Disponível em: <https://mundogeo.com/2025/02/20/laser-scanner-3d-e-tecnologias-de-inspecao-avancada-para-prevencao-de-danos-em-pontes-tuneis-e-viadutos/>. Acesso em: 15 jul. 2025.

FREITAS, G. T. M. Software para identificação de defeitos na superfície de pavimentos rodoviários utilizando deep learning. 2022. Dissertação (Mestrado em Engenharia de Transportes) — Universidade Federal do Ceará, Fortaleza-CE, 2022.

ROBOFLOW UNIVERSE. Crack detection dataset. Disponível em: <https://universe.roboflow.com/core-labeling/crack-detection-gpbys>. Acesso em: 05 mai. 2024.

LIU, J. et al. Deep industrial image anomaly detection: A survey. Machine Intelligence Research, v. 21, p. 104–135, 2024.

BERGMANN, P.; FAUSER, M.; SATTLEGGGER, D.; STEGER, C. MVTec AD — A comprehensive real-world dataset for unsupervised anomaly detection. In: IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, CA, EUA, 2019. p. 9584–9592. DOI: 10.1109/CVPR.2019.00982.

**SERVIÇO PÚBLICO FEDERAL**  
**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE PERNAMBUCO**  
**BIBLIOTECA DEPOSITÁRIA – CAMPUS PALMARES**

**TERMO DE RESPONSABILIDADE DO ORIENTADOR E AUTORIZAÇÃO PARA PUBLICAÇÃO DA PRODUÇÃO INTELECTUAL NO REPOSITÓRIO INSTITUCIONAL RI-IFPE**

Eu, Diogo Lopes da Silva, CPF: 04836423473 , ORCID: 0009-0004-7649-1448 , link lattes: \_\_\_\_\_, orientador do Trabalho de Conclusão de Curso, intitulado: Detecção de Patologias em Obras Cívicas Utilizando Redes Neurais Convolucionais realizado pelo aluno João Victor Oliveira da Silva, Matrícula nº 20222ADS-PM0091, Curso: Análise e Desenvolvimento de Sistemas, autorizo o depósito obrigatório, na Biblioteca do Campus Palmares, da versão final, no modelo de: ( x ) artigo ( ) monografia ( ) dissertação ( ) .

<b>INFORMAÇÕES DA BANCA</b>			
<b>NOME</b>	<b>CPF</b>	<b>ORCID</b>	<b>LINK LATTES</b>
Rodrigo César Lira da Silva	082.015.404-09	0000-0001-6089-6214	<a href="http://lattes.cnpq.br/2442224050349612">http://lattes.cnpq.br/2442224050349612</a>
Tiago Pessoa Ferreira de Lima	059.602.304-96	<a href="https://orcid.org/0000-0002-1148-4288">https://orcid.org/0000-0002-1148-4288</a>	<a href="http://lattes.cnpq.br/4861396173974431">http://lattes.cnpq.br/4861396173974431</a>

---

Professor orientador

**SERVIÇO PÚBLICO FEDERAL**  
**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE PERNAMBUCO**  
**BIBLIOTECA DEPOSITÁRIA – CAMPUS PALMARES**

**TERMO DE AUTORIZAÇÃO PARA DISPONIBILIDADE DE LIVRO / CAPÍTULO DE LIVRO / ARTIGO  
OU REA NO REPOSITÓRIO INSTITUCIONAL IFPE**

Na qualidade de titular dos direitos de autor da publicação, autorizo ao Repositório Institucional do Instituto Federal de Educação, Ciência e Tecnologia de Pernambuco (RIIFPE) a disponibilizar, através do site <https://repositorio.ifpe.edu.br/xmlui/>, sem ressarcimento dos direitos autorais, de acordo com a Lei n. 9.610/98, o texto integral da obra abaixo citada, a título de divulgação e de preservação digital da produção científica brasileira, a partir desta data.

**Identificação:**

Autor*	João Victor Oliveira da Silva
E:mail	jvos2@discente.ifpe.edu.br
Orcid	<a href="https://orcid.org/0009-0004-0357-2327">https://orcid.org/0009-0004-0357-2327</a>
Link Lattes	<a href="http://lattes.cnpq.br/4324207468595795">http://lattes.cnpq.br/4324207468595795</a>
Título	Detecção de Patologias em Obras Civis Utilizando Redes Neurais Convolucionais.
Data de defesa	30/07/2025
ISBN	
DOI	
ODS Agenda 2030 (quando cabível)	ODS 8

\*Preenchimento individual, em caso de mais de um autor.

**LICENÇA DE DIREITO AUTORAL**

Na qualidade de titular dos direitos de autor do conteúdo supracitado, autorizo o Instituto Federal de Educação, Ciência e Tecnologia de Pernambuco a disponibilizar a obra, gratuitamente, de acordo com a licença pública *Creative Commons*, Licença 4.0 *Unported* por mim declarada sob as seguintes condições:

- Permitir uso comercial da obra? ( x ) Sim      ( ) Não  
Permitir modificações em sua obra?  
( ) Sim  
( ) Sim, contanto que outros compartilhem pela mesma licença  
( x ) Não

A obra continua protegida por direito autoral e/ou por outras leis aplicáveis, respeitando inclusive o contrato celebrado entre a editora ou periódico que veicula a mesma. Qualquer uso da obra que não o autorizado sob esta licença ou pela legislação autoral é proibido.

---

Assinatura do Autor

12/08/2025  
Data de autorização.