



Universidade Estadual
da Região Tocantina
do Maranhão

**UNIVERSIDADE ESTADUAL DA REGIÃO TOCANTINA MARANHÃO -
UEMASUL CAMPUS AÇAILÂNDIA
CENTRO DE CIÊNCIA HUMANAS, SOCIAIS, TECNOLÓGICAS E LETRAS
CURSO DE ENGENHARIA CIVIL BACHARELADO**

WALISSON DANILO MELO DA SILVA

**APLICAÇÃO DE REDE NEURAL CONVOLUCIONAL PARA IDENTIFICAÇÃO DE
MANIFESTAÇÕES PATOLÓGICAS EM ESTRUTURAS DE CONCRETO**

Açailândia - MA

2026



Universidade Estadual
da Região Tocantina
do Maranhão

WALISSON DANILO MELO DA SILVA

APLICAÇÃO DE REDE NEURAL CONVOLUCIONAL PARA IDENTIFICAÇÃO DE MANIFESTAÇÕES PATOLÓGICAS EM ESTRUTURAS DE CONCRETO

Trabalho de conclusão de curso apresentado ao Curso Engenharia Civil Bacharelado do Centro de Ciências Humanas, Sociais, Tecnológicas e Letras da Universidade Estadual da Região Tocantina do Maranhão, campus Açailândia, como requisito para obtenção de grau bacharelado em Engenharia Civil.

Orientadora: Prof^a. Ma. Jessica Almeida Dos Santos.

Coorientador: Prof^o. Me. Felipe Gomes Barbosa.

Açailândia – MA

2026

S586a

Silva, Walisson Danilo Melo da

Aplicação de rede neural convolucional para identificação de manifestações patológicas em estruturas de concreto / Walisson Danilo Melo da Silva. – Açaílândia: UEMASUL, 2026.
70 f. ; il.

Trabalho de Conclusão de Curso (Curso de Bacharelado em Engenharia Civil) – Universidade Estadual da Região Tocantina do Maranhão – UEMASUL, Açaílândia, MA, 2026.

Orientadora: Profa. Ma. Jessica Almeida dos Santos.
Coorientador: Prof. Me. Felipe Gomes Barbosa.

1. Visão computacional. 2. Deep learning. 3. YOLOv8. I. Título.

CDU 69.059



Universidade Estadual
da Região Tocantina
do Maranhão

**CENTRO DE CIÊNCIAS HUMANAS, SOCIAIS, TECNOLÓGICAS E LETRAS
CCHSTL/CAMPUS AÇAILÂNDIA**

WALISSON DANILO MELO DA SILVA

**APLICAÇÃO DE REDE NEURAL CONVOLUCIONAL PARA IDENTIFICAÇÃO DE
MANIFESTAÇÕES PATOLÓGICAS EM ESTRUTURAS DE CONCRETO**

Trabalho de conclusão de curso apresentado ao Curso Engenharia Civil Bacharelado do Centro de Ciências Humanas, Sociais, Tecnológicas e Letras da Universidade Estadual da Região Tocantina do Maranhão, campus Açailândia, como requisito para obtenção de grau bacharelado em Engenharia Civil.

Orientadora: Prof^a. Ma. Jessica Almeida Dos Santos.

Coorientador: Prof^o. Me. Felipe Gomes Barbosa.

Aprovado em: 18 de junho de 2026



Documento assinado digitalmente
JESSICA ALMEIDA DOS SANTOS
Data: 26/06/2026 09:20:33-0300
Verifique em <https://validar.iti.gov.br>

Orientadora Prof^a. Ma. Jessica Almeida Dos Santos
Universidade Estadual da Região Tocantina do Maranhão (UEMASUL)



Documento assinado digitalmente
ALCINEIDE DUTRA PESSOA DE SOUSA
Data: 26/06/2026 09:57:03-0300
Verifique em <https://validar.iti.gov.br>

Prof^a. Dra. Alcineide Dutra Pessoa de Sousa
Universidade Estadual da Região Tocantina do Maranhão (UEMASUL)



Documento assinado digitalmente
KALLEBE DE OLIVEIRA BRITO
Data: 30/06/2026 22:48:43-0300
Verifique em <https://validar.iti.gov.br>

Prof^o. Me. Kallebe de Oliveira Brito
Universidade Estadual da Região Tocantina do Maranhão (UEMASUL)



Universidade Estadual
da Região Tocantina
do Maranhão

AGRADECIMENTOS

Primeiramente, agradeço a Deus por ter me sustentado durante toda a caminhada até o presente momento.

Agradeço à minha família, que sempre me deu suporte e incentivo. Dedico um agradecimento especial à minha mãe, Rosileide Fernandes de Melo, que sempre esteve do meu lado, oferecendo apoio incondicional, incentivo e compreensão.

Expresso minha profunda gratidão a minha orientadora, Prof^ª. Ma. Jessica Almeida dos Santos por toda a paciência, todas as orientações e lições dadas durante todo o curso.

Agradeço ao meu coorientador, Prof. Me. Felipe Gomes Barbosa, pelas considerações e contribuições que auxiliaram no aprimoramento deste trabalho.

Agradeço aos meus amigos Gustavo Santos, Gustavo Gomes, Amailson e Luander que estiveram comigo durante a caminhada, os momentos de descontração fizeram toda a diferença.

Agradeço à Universidade Estadual da Região Tocantina do Maranhão (UEMASUL), instituição que contribuiu significativamente para minha formação acadêmica e profissional.

Por fim, agradeço a todas as pessoas que passaram pela minha vida e de alguma forma me ajudaram, seja por meio de uma palavra de incentivo, apoio financeiro ou simplesmente companhia.

Meu mais sincero obrigado a todos que fizeram parte desta trajetória!

RESUMO

As manifestações patológicas em edificações, como fissuras e corrosão, representam importantes indicadores de degradação estrutural, podendo comprometer a durabilidade, a segurança e o desempenho das construções quando não identificadas precocemente. Nesse contexto, o presente trabalho teve como objetivo desenvolver e avaliar uma Rede Neural Convolucional (RNC) baseada na arquitetura YOLOv8n para a detecção automática dessas manifestações patológicas por meio de técnicas de Visão Computacional e Aprendizado Profundo. A metodologia empregada envolveu a revisão da literatura, a preparação da base de dados, o tratamento das imagens, o treinamento da rede neural e a análise dos resultados, proporcionando uma abordagem sistemática para o desenvolvimento e validação do modelo proposto. O desempenho dos modelos foi avaliado por meio das métricas Precisão, *Recall*, *F1-score*, *Intersection over Union* (IoU) e *mean Average Precision* (mAP). Os resultados demonstraram que o conjunto DT2 apresentou desempenho superior ao DT1 em todas as métricas analisadas, evidenciando a importância da diversidade de imagens para a capacidade de generalização da rede neural. Para a classe fissura, o modelo alcançou precisão de até 95%, recall de 91%, F1-score de 92%, IoU de 85% e mAP de 97%. Para a classe corrosão, foram obtidos valores de 83% para precisão, 92% para recall, 87% para F1-score, 77% para IoU e 94% para mAP. Nos testes realizados com imagens inéditas, o sistema identificou corretamente todas as manifestações patológicas avaliadas neste trabalho, apresentando níveis de confiança entre 68% e 96%. Conclui-se que a utilização da arquitetura YOLOv8n para detecção automática de fissuras e corrosão apresentou resultados satisfatórios, demonstrando potencial para aplicação como ferramenta de apoio em inspeções prediais e monitoramento estrutural. A metodologia proposta contribui para a automatização do processo de identificação de manifestações patológicas, reduzindo a subjetividade das análises visuais e fornecendo suporte à tomada de decisão em atividades de manutenção e conservação de edificações.

Palavras-chave: Visão Computacional; Deep Learning; YOLOv8; Redes Neurais Convolucionais; Fissuras; Corrosão; Engenharia Civil.



ABSTRACT

Pathological manifestations in buildings, such as cracks and corrosion, represent important indicators of structural degradation, potentially compromising the durability, safety, and performance of constructions if not identified early. In this context, the present work aimed to develop and evaluate a Convolutional Neural Network (CNN) based on the YOLOv8n architecture for the automatic detection of these pathologies using Computer Vision and Deep Learning techniques. The methodology employed involved a literature review, database preparation, image processing, neural network training, and results analysis, providing a systematic approach for the development and validation of the proposed model. The performance of the models was evaluated using the metrics Precision, Recall, F1-score, Intersection over Union (IoU), and Mean Average Precision (mAP). The results demonstrated that the DT2 set showed superior performance to DT1 in all analyzed metrics, highlighting the importance of image diversity for the generalization capacity of the neural network. For the crack class, the model achieved accuracy up to 95%, recall of 91%, F1-score of 92%, IoU of 85%, and mAP of 97%. For the corrosion class, values of 83% for accuracy, 92% for recall, 87% for F1-score, 77% for IoU, and 94% for mAP were obtained. In tests performed with unpublished images, the system correctly identified all evaluated pathologies, presenting confidence levels between 68% and 96%. It is concluded that the use of the YOLOv8n architecture for automatic crack and corrosion detection presented satisfactory results, demonstrating potential for application as a support tool in building inspections and structural monitoring. The proposed methodology contributes to the automation of the pathology identification process, reducing the subjectivity of visual analyses and providing support for decision-making in building maintenance and conservation activities.

Keywords: Computer Vision; Deep Learning; YOLOv8; Convolutional Neural Networks; Cracks; Corrosion; Civil Engineering.

LISTA DE ILUSTRAÇÕES

Figura 1 – Fissura em parede	16
Figura 2 – Subconjunto de IA	19
Figura 3 – Tarefas da Visão Computacional	20
Figura 4 - Detecção de objetos aplicada na manifestação patológica fissura.....	21
Figura 5 - Modelo de um neurônio de McCulloch e Pitts	21
Figura 6 – Neurônio esquematizado	22
Figura 7 – Neurônio de McCulloch e Pitts com limiar explícito.....	23
Figura 8 – Estrutura de uma rede neural artificial	24
Figura 9 - Rede neural simples e rede neural profunda.....	25
Figura 10 – Imagem dividida em padrões locais	26
Figura 11 – Arquitetura de uma RNC	26
Figura 12 – Matriz de Confusão	27
Figura 13 - Matriz de confusão aplicada em imagens com e sem fissuras.....	28
Figura 14 - Ground-truth bounding box e bounding box prevista.....	29
Figura 15 - Determinação do IoU	30
Figura 16 - IoU de bounding boxes	30
Figura 17 - Etapas do TCC	32
Figura 18 – Amostra do Banco de Dados referente a fissuras.....	33
Figura 19 – Amostra do Banco de Dados referente a corrosão	33
Figura 20 – Pré-processamento das imagens.....	34
Figura 21 – Bloco de notas contendo as informações das bounding boxes	35
Figura 22 – Elementos do arquivo .txt	35
Figura 23 - Representação dos elementos do arquivo de .txt	36
Figura 24 - Exemplo de uma parte do banco de dados.....	36
Figura 25 – Resultado do melhor treino para manifestação patológica do tipo corrosão	55
Figura 26 – Resultado do melhor treino para manifestação patológica do tipo fissura.....	56
Figura 27 – Resultado de detecção para corrosão	57
Figura 28 – Resultado de detecção para fissuras	58
Figura 29 – Resultado de detecção para ambas as manifestações patológicas.....	59



Figura 30 – Ambiente virtual de testes.....	60
Figura 31 – Teste de detecção realizado remotamente pelo engenheiro 1	60
Figura 32 – Teste de detecção realizado remotamente pelo engenheiro 2	61
Figura 33 – Teste de detecção realizado remotamente pelo engenheiro 3	61



Universidade Estadual
da Região Tocantina
do Maranhão

LISTA DE TABELAS

Tabela 1 – Classificação de manifestação patológica quanto ao seu grau de abertura	17
Tabela 2 – Divisão das imagens do banco de dados.....	37



LISTA DE GRÁFICOS

Gráfico 1 - Exemplo de uma curva precisão/recall	31
Gráfico 2 – Evolução de treino e validação para Box	39
Gráfico 3 – Evolução de treino e validação para CLS loss	40
Gráfico 4 – Evolução de treino e validação para DFL loss	41
Gráfico 5 – Evolução de treino e validação para Box loss	42
Gráfico 6 – Evolução de treino e validação para Box loss	43
Gráfico 7 – Evolução de treino e validação para CLS loss	44
Gráfico 8 – Evolução de treino e validação para CLS loss	45
Gráfico 9 – Evolução de treino e validação para DFL loss	46
Gráfico 10 – Evolução de treino e validação para DFL loss	47
Gráfico 11 – Resultados para corrosão: Precisão x Épocas	48
Gráfico 12 – Resultados para fissuras: Precisão x Épocas	49
Gráfico 13 – Resultados para corrosão: Recall x Épocas	50
Gráfico 14 – Resultados para fissuras: Recall x Épocas	51
Gráfico 15 – Resultados para corrosão: F1-score x Épocas	51
Gráfico 16 – Resultados para fissuras: F1-score x Épocas	52
Gráfico 17 – Resultados para corrosão: IoU x Épocas	53
Gráfico 18 – Resultados para fissuras: IoU x Épocas	53
Gráfico 19 – Resultados para corrosão: mAP x Épocas	54
Gráfico 20 – Resultados para fissuras: mAP x Épocas	55



LISTA DE ABREVIATURAS

ABNT - Associação Brasileira de Normas Técnicas

AM - Aprendizado de Máquina

AP - Aprendizado Profundo

Box loss - Bounding Boxes

Cls loss - Classification Loss

Dfl loss – Distribution Focal Loss

DL - Deep Learning

DT1 - DataSet1

DT2 - DataSet2

FN - False Negative

FP - False Positive

GPU - Unidade de Processamento Gráfico

IA - Inteligência Artificial

IoU - Intersection over Union

ML - Machine Learning

RNA - Redes Neurais Artificiais

RNC - Rede Neural Convolucional

TN - True Negative

TP - True Positive

YOLO - You Only Look Once



Sumário

1 INTRODUÇÃO	12
1.1 Objetivos	13
1.1.1 Geral	13
1.1.2 Específicos	13
2 FUNDAMENTAÇÃO TEÓRICA	14
2.1 Estruturas de Concreto	14
2.1.1 Manifestações patológicas em estruturas	15
2.1.2 Fissuras	16
2.1.3 Corrosão	17
2.2 Inteligência Artificial (IA)	18
2.3 Visão Computacional	19
2.4 Redes Neurais	21
2.4.1 Redes Neurais Biológicas	22
2.4.2 Redes Neurais Artificiais	23
2.4.3 Redes Neurais Convolucionais	25
2.4.3.1 Treinamento de uma RNC	26
2.4.3.2 Métricas de Avaliação	27
3 METODOLOGIA	32
3.1 Desenho do Estudo	32
3.2 Montagem da Base de Dados	32
3.3 Pré-Processamento das Imagens	33
3.4 Programação da Rede Neural	37
4 RESULTADOS E DISCUSSÕES	39
4.1 Resultados do Treinamento	39
4.1.1 Resultado das Métricas de Perdas	39
4.1.2 Resultado das Métricas de Avaliação	48
4.2 Teste da RNC	56
5 CONCLUSÃO	63
REFERÊNCIAS	65

1 INTRODUÇÃO

As edificações desempenham um papel fundamental no cotidiano moderno, servindo de suporte para as mais variadas atividades humanas, atendendo tanto às necessidades comerciais e industriais quanto às de uso residencial. Deste modo, precisam satisfazer as necessidades dos usuários e corresponder às expectativas no momento da aquisição (Santos, 2014).

As manifestações patológicas construtivas acompanham a construção civil desde seus primórdios, manifestando-se de diferentes maneiras. Essas ocorrências fazem parte da realidade das edificações e surgem devido a fatores variados, que incluem desgaste natural, falhas de execução ou condições ambientais desfavoráveis (Cavalcante; Martins, 2022).

Entre os inúmeros tipos de falhas patológicas que atingem edificações, sejam residenciais, comerciais ou de outra natureza, as fissuras figuram entre as mais recorrentes. Esse tipo de anomalia se destaca por alguns fatores principais: pode representar um indício de risco à estabilidade estrutural, compromete a solidez da obra e sua resistência ao longo do tempo, além de gerar incômodo e insegurança aos usuários devido à presença evidente das aberturas nas superfícies (Dutra, 2016).

São inúmeros os fatores que podem provocar o comprometimento de uma estrutura, podendo esses problemas ter origem desde a fase inicial da construção como defeitos congênitos de projeto ou execução até serem adquiridos ao longo da vida útil da edificação (Trindade, 2015).

Edificações não possuem duração (vida útil) infinita, sendo necessária uma área específica (a engenharia diagnóstica) para cuidar desse processo e buscar a durabilidade da edificação pelo maior tempo possível. Segundo Cândido (2023), a engenharia diagnóstica tem como objetivo identificar as anomalias presentes nas edificações, investigando a causa de cada problema para, então, propor ações que possibilitem sua mitigação e solução. Conforme Pinto Filho (2021), a Engenharia Diagnóstica é caracterizada como a ciência voltada à elaboração de ações proativas fundamentadas em diagnósticos, prognósticos e recomendações técnicas, sempre com foco na garantia da qualidade total.

O aumento da demanda por intervenções de conservação e recuperação em estruturas de concreto tem estimulado pesquisas voltadas às manifestações patológicas construtivas e às técnicas eficazes para sua detecção (Munaro; Possan, 2017).

A pesquisa se justifica, pois, atualmente os métodos de inspeção tradicional normatizados demandam tempo significativo. Entretanto, com o avanço das tecnologias, surgem alternativas promissoras para aprimorar esse processo.

Nesse cenário, torna-se viável empregar recursos computacionais para aprimorar processos desse tipo, fazendo uso de técnicas como redes neurais para tornar as análises mais eficientes e precisas. Para Cunha (2025), a aplicação de técnicas computacionais para reconhecer manifestações patológicas em estruturas de concreto constitui um avanço relevante para a engenharia civil, contribuindo diretamente para maior eficiência na tomada de decisão relacionada às ações de manutenção e reabilitação das edificações.

Com base no contexto mencionado, esta pesquisa propõe a utilização de uma Rede Neural Convolucional (RNC) para a detecção manifestações patológicas em estruturas de concreto, e levanta o seguinte problema: Qual o nível de precisão da detecção feita pela rede treinada?

1.1 Objetivos

1.1.1 Geral

O trabalho visa o treinamento, o teste e a validação de uma Rede Neural Convolucional que seja capaz de detectar e classificar manifestações patológicas do tipo fissuras e corrosão em estruturas de concreto utilizando a arquitetura YOLO (You Only Look Once).

1.1.2 Específicos

- Realizar estudos sobre detecção e reconhecimento de imagens por redes neurais;
- Desenvolver e treinar um modelo baseado na arquitetura YOLO para identificar e classificar manifestações patológicas em estruturas de concreto com alta precisão;
- Avaliar o desempenho do modelo por meio de métricas como *precision*, *recall* e *F1-score*, garantindo boa capacidade de generalização e evitando *overfitting*;
- Analisar o comportamento da rede diante de diferentes tipos de manifestações patológicas e condições de captura, identificando limitações e possibilidades de melhoria;
- Verificar a aplicabilidade prática do sistema na engenharia diagnóstica, contribuindo para inspeções mais rápidas, eficientes e com menor custo.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Estruturas de Concreto

O concreto é considerado um ingrediente essencial para as construções, composto por cimento, areia, água e agregados, muitas vezes com acréscimos de aditivos para melhorar determinados aspectos. No momento em que misturados, os elementos formam uma substância que pode ser moldada, possuindo muitas aplicações. A elaboração pode ser preparada em centrais de dosagem sendo chamado de concreto usinado ou pode ser feito no canteiro de obras por meio de betoneiras ou manualmente recebendo o nome de concreto (in loco) (Couto et al., 2013).

Segundo Andrade (2016), um ponto fundamental é sua elevada maleabilidade, que permite a criação de formas variadas e soluções arquitetônicas complexas. Quando associado a um dimensionamento adequado e a um detalhamento correto das armaduras, o concreto apresenta excelente desempenho frente aos esforços estruturais, funcionando de maneira rígida, onde todos os elementos trabalham em conjunto.

A alta utilização do concreto ocorre devido ao seu desempenho em circunstâncias nas quais outros materiais não seriam tão adequados. De acordo com Lima et al. (2014), existem dois fatores que distinguem concreto de outros materiais, um deles é a resistência à água que o torna vantajoso se comparado com madeira e aço, visto que esses dois sofrem maior deterioração se exposto à água, e o segundo está no preço acessível dos seus componentes, tornando-o muito viável para construção.

O concreto como qualquer material possui desvantagens, uma delas é a baixa resistência a tração, para combater esse fator utiliza-se o concreto armado para fins estruturais. Segundo Couto et al. (2013), na utilização do concreto para fins estruturais, são adicionadas as ferragens em uma fôrma, e logo em seguida o concreto convencional para formar o concreto armado. É utilizado frequentemente para lajes, vigas, fundações e pilares, para garantir maior resistência a esforços, tendo em vista a junção de concreto e armadura.

Mesmo com a adição de materiais ou aditivos, estruturas de concreto possuem uma vida útil, esta pode ser reduzida por fatores que interferem ao longo do processo construtivo, ou mesmo pelo meio que estão. Apesar de o concreto ser um material rígido e amplamente utilizado, as estruturas possuem atributos diferentes e são expostas a ambientes variados, os

quais podem gerar deterioração da estrutura e conseqüentemente manifestações patológicas (Silva, 2019).

2.1.1 Manifestações patológicas em estruturas

As manifestações patológicas são os "sintomas" ou anomalias observáveis (como fissuras, eflorescências ou deslocamentos) que indicam que o desempenho da estrutura está insatisfatório ou comprometido (Souza; Ripper, 1998).

Os problemas patológicos estão presentes na maior parte das edificações, manifestando-se com diferentes graus de intensidade e em variados momentos da vida útil da construção. Conforme Lichtenstein (1985), essas manifestações podem surgir de maneira simples, permitindo um diagnóstico rápido e um reparo direto, ou podem apresentar-se de forma mais complexa, exigindo estudos específicos e uma análise detalhada de cada caso para identificação precisa de suas causas.

Segundo Souza e Ripper (1998), o desempenho de uma edificação está diretamente relacionado à capacidade de sua estrutura manter-se em condições plenas de uso ao longo de toda a sua vida útil, sem apresentar danos que comprometam, parcial ou totalmente, a função para a qual foi projetada.

As principais causas de manifestações patológicas em edificações estão relacionadas a deficiências de projeto, falhas de execução, má qualidade ou uso inadequado dos materiais, além da utilização indevida da estrutura e da falta de manutenção. Essas manifestações patológicas têm origem em erros que podem ocorrer em qualquer etapa do processo construtivo, entendido como um conjunto de atividades que compõem a construção civil (Ferreira; Lobão, 2018).

De acordo com Ferreira e Lobão (2018), as manifestações patológicas podem manifestar-se de diversas formas, apresentando características como fissuração, desagregação, deslocamentos e eflorescências, todas capazes de provocar danos e reduzir o valor e o desempenho do sistema construtivo. As manifestações patológicas mais recorrentes destacam-se os danos por umidade, fissuras, corrosões, deslocamentos de reboco e pisos, destacamentos ou descolamentos de revestimentos e recalques estruturais, cada um trazendo implicações específicas para a durabilidade e segurança da edificação.

2.1.2 Fissuras

Segundo Assis e Rabelo (2013), as fissuras podem ser caracterizadas como aberturas de pequena dimensão conforme mostrado na Figura 1. Essas manifestações podem ser classificadas como ativas, quando apresentam movimentação ao longo do tempo, ou passivas, quando já estão estabilizadas e não sofrem alterações em sua largura ou extensão.

Figura 1 – Fissura em parede



Fonte: Autoria própria, 2026.

As fissurações podem se manifestar nas direções horizontal, vertical, inclinada ou ainda em combinações entre essas direções (Vasconcelos de Carvalho *et al.*, 2021). Essas aberturas geralmente se formam quando as cargas atuantes ultrapassam a capacidade de resistência dos elementos estruturais, resultando em tensões de tração que excedem os limites suportáveis pelo material (Duarte, 1998).

Outro fator relevante para o surgimento de fissuras são as deformações impostas aos elementos estruturais. A flexão excessiva de vigas e lajes pode transmitir esforços para as paredes de vedação, ocasionando aberturas que geralmente acompanham as regiões de maior deformação. Em edificações com grandes vãos ou submetidas a carregamentos significativos, essas movimentações estruturais podem gerar fissuras inclinadas, verticais ou horizontais, dependendo da forma como os esforços são distribuídos e absorvidos pelos componentes construtivos (Oliveira, 2012).

Para Oliveira (2019), as fissuras constituem uma das manifestações patológicas mais recorrentes em estruturas. Essas aberturas lineares na superfície das paredes podem surgir por diversos motivos, incluindo variações térmicas, retração dos materiais, sobrecargas ou falhas de execução. Além de prejudicarem a estética da edificação, também representam um risco para

a durabilidade e o desempenho estrutural, uma vez que facilitam a entrada de umidade e podem comprometer o isolamento e a eficiência energética.

Segundo Oliveira (2012), fissuras constituem um importante indicador do estado de conservação de uma edificação, sendo frequentemente utilizadas como parâmetro inicial para inspeções e diagnósticos de estruturas. Embora muitas vezes sejam associadas apenas a problemas estéticos, sua presença pode indicar alterações no comportamento mecânico dos materiais ou da estrutura como um todo. Dessa forma, a análise criteriosa das fissuras deve considerar aspectos como localização, orientação, extensão, abertura e evolução ao longo do tempo, permitindo identificar suas possíveis causas e a gravidade dos danos associados.

A formação de fissuras está diretamente relacionada ao comportamento dos materiais de construção diante das solicitações internas e externas a que estão submetidos. O concreto, por exemplo, apresenta elevada resistência à compressão, porém possui resistência limitada à tração. Quando as tensões de tração desenvolvidas ultrapassam a capacidade resistente do material, ocorre a ruptura localizada, manifestando-se sob a forma de fissuras (Oliveira, 2012).

As fissuras podem surgir de maneira discreta e progressiva, sendo uma das manifestações patológicas mais comuns durante ou após a execução do projeto arquitetônico. Elas podem comprometer a estética, a durabilidade e até mesmo o comportamento estrutural da edificação. Em muitos casos, representam indícios de problemas mais sérios, como o desenvolvimento de trincas ou rachaduras, exigindo avaliação criteriosa para evitar danos maiores (Corsini, 2010).

De acordo com Oliveira (2012), os tipos de aberturas podem ser classificados de acordo com sua espessura, como mostrado na Tabela 1.

Tabela 1 – Classificação de manifestação patológica quanto ao seu grau de abertura.

ANOMALIAS	ESPESSURA (MM)
Fissuras	Até 0,5
Trincas	0,5 – 1,5
Rachadura	1,5 – 5,0
Fenda	5,0 – 10,0
Brecha	Acima de 10,0

Fonte: Adaptado de Oliveira, 2012.

2.1.3 Corrosão

“A corrosão pode ser definida como a interação destrutiva de um material com o meio ambiente, seja por ação física, química, eletroquímica, ou a combinação destas.” (Helene, 1993, p.17).

A deterioração provocada por processos físico-químicos entre um material e o meio em que ele opera corresponde às alterações indesejáveis sofridas por esse material, como desgaste, modificações químicas ou mudanças em sua estrutura, tornando-o inadequado para uso (Gentil, 2012). Em relação às armaduras do concreto, o processo de deterioração pode ser identificado por diferentes manifestações, como manchas na superfície causadas por produtos da corrosão, aparecimento de fissuras, deslocamento do concreto de cobertura, diminuição da seção resistente das armaduras, ocorrência de estribos expostos, além da redução e eventual perda de aderência, comprometendo a segurança da estrutura (Helene, 1993).

As armaduras de aço presentes nas estruturas de concreto possuem, inicialmente, proteção garantida pelo revestimento previsto em projeto, o qual atua como uma barreira física contra agentes externos. Quando essa proteção é comprometida, o processo corrosivo tende a se iniciar e se intensificar. A corrosão acontece quando o concreto apresenta permeabilidade suficiente para possibilitar a penetração de íons até as barras de aço, sendo esses elementos, associados à presença de água e oxigênio, responsáveis pelo desencadeamento do processo corrosivo (Nascimento, 2015).

Quando o concreto se encontra em ambiente seco, o risco de corrosão das armaduras é reduzido ou praticamente inexistente, pois a presença de água é indispensável para que o processo corrosivo ocorra. Situação semelhante acontece em ambientes com saturação total e permanente do concreto, uma vez que a ausência de oxigênio impede o avanço do processo. Esse cenário é comum em estruturas submersas e em ambientes rurais fechados, onde a concentração de agentes poluentes costuma ser baixa (Nascimento, 2015).

2.2 Inteligência Artificial (IA)

A inteligência artificial (IA) teve origem na década de 1950, quando pesquisadores da área de computação passaram a investigar a possibilidade de desenvolver máquinas capazes de simular o pensamento humano (Chollet, 2018). Consiste em um campo voltado ao desenvolvimento de sistemas capazes de reproduzir comportamentos associados à inteligência humana, para serem aplicados na resolução de problemas de alta complexidade para pessoas, mas que podem ser processados de forma eficiente por computadores (Silva; Costa, 2022).

A IA pode ser estruturada em diferentes camadas ou níveis, destacando o Aprendizado de Máquina (*Machine Learning* – ML) e o Aprendizado Profundo (*Deep Learning* – DL), conforme Figura 2.

Figura 2 – Subconjunto de IA



Fonte: Silva e Costa (2022).

O Aprendizado de Máquina (AM) constitui uma área em expansão da ciência da computação que possibilita a identificação de padrões e tendências a partir de dados históricos, favorecendo a tomada de decisões sem a necessidade de acompanhamento humano contínuo (Ghosh *et al.*, 2018). De forma complementar, Tavares *et al.* (2020), destacam que o AM proporciona às máquinas a capacidade de aprender automaticamente com grandes volumes de dados, reconhecendo relações subjacentes entre variáveis.

O Aprendizado Profundo (AP) é processo de treinamento de redes neurais artificiais capazes de extrair e aprender representações de forma hierárquica, de modo que características mais complexas, em níveis superiores, sejam construídas a partir da combinação de atributos mais simples, obtidos em níveis inferiores da rede (Schmidhuber, 2015).

2.3 Visão Computacional


A Visão Computacional é um campo interdisciplinar que atua em conjunto com a inteligência artificial, possibilitando a análise e a extração de informações visuais a partir de imagens (Szeliski, 2010).

De acordo com Patrício e Rieder (2018), a Visão Computacional envolve duas etapas fundamentais: a aquisição e o processamento de imagens. A etapa de aquisição é realizada por meio de dispositivos como câmeras de alta resolução, garantindo qualidade suficiente para

reduzir a complexidade do sistema, enquanto o processamento engloba técnicas de aprimoramento das imagens, incluindo a redução de ruídos e a correção de iluminação.

A Figura 3 mostra algumas tarefas da visão computacional: segmentação, classificação e localização, detecção e segmentação de instância.

Figura 3 – Tarefas da Visão Computacional




Fonte: Adaptado de Li *et al.*, 2017.

A tarefa de visão computacional tratada neste estudo refere-se à detecção de objetos. Segundo Sarga (2018), essa atividade envolve estimar a posição de um objeto e, simultaneamente, identificar sua classe. Para determinar tanto a localização quanto o tipo de elemento presente na imagem, são empregadas as chamadas *bounding boxes*, ou caixas delimitadoras, que indicam visualmente a área correspondente ao objeto detectado.

Uma *Bounding Box* é um retângulo utilizado para delimitar um objeto em uma imagem, indicando sua posição, classe (por exemplo: carro, pessoa, animal, etc) e o nível de confiança associado à detecção (Subramanyam, 2021). No contexto deste trabalho, as classes consideradas correspondem às fissuras e corrosão, sendo o retângulo responsável por indicar sua localização na imagem, além de apresentar a confiabilidade da detecção, conforme ilustrado na Figura 4.

Figura 4 - Detecção de objetos aplicada na manifestação patológica fissura




Fonte: Autoria própria, 2026.

2.4 Redes Neurais

Pode-se definir uma rede neural como “um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso”. (Haykin, 2001, p.28).

As discussões centrais sobre redes neurais remontam à década de 1940, quando McCulloch e Walter Pitts (1943) propuseram o primeiro modelo matemático de neurônio artificial, estabelecendo uma representação formal baseada em lógica proposicional e no princípio do “tudo ou nada” do disparo neuronal (Figura 5).

Figura 5 - Modelo de um neurônio de McCulloch e Pitts



Fonte: Rauber, 2005.

De acordo com Russell e Norvig (2016), uma rede neural é composta por múltiplos neurônios simples interconectados, cujo comportamento depende tanto da estrutura da rede quanto das características individuais de cada neurônio. Durante o processamento, cada neurônio recebe entradas ponderadas conforme a importância de cada sinal, soma esses valores

e os submete a uma função de ativação, que decide se a unidade será ativada. A saída resultante é então transmitida aos neurônios subsequentes, permitindo que a informação se propague pela rede e possibilitando a aprendizagem de padrões complexos usados em tarefas como reconhecimento, classificação e tomada de decisão.

Para Taylor (2017), as redes neurais integram o campo do aprendizado profundo, o qual constitui um subcampo do aprendizado de máquina e tem se mostrado promissor na resolução de problemas difíceis, como reconhecimento de objetos em imagens e processamento de linguagem natural.

2.4.1 Redes Neurais Biológicas

A inteligência humana é uma das mais complexas entre os seres vivos, estando associada ao funcionamento do cérebro. Suas unidades fundamentais são os neurônios, que se organizam em redes interconectadas, permitindo a troca de informações e a construção da inteligência biológica. A partir dessa compreensão, surge o interesse em reproduzir, em ambientes tecnológicos, a estrutura e o funcionamento desse sistema (Rauber, 2005).

O cérebro humano possui aproximadamente 100 bilhões (10^{11}) de neurônios, que constituem suas unidades fundamentais. Cada um desses neurônios é responsável por processar informações e estabelecer comunicação com milhares de outros simultaneamente e de forma contínua (Braga; Ludermit; Carvalho, 2000). Estruturalmente, o neurônio é composto pelo corpo celular, que abriga o núcleo e atua como centro metabólico (Figura 6), além de desempenhar papel na recepção e integração dos estímulos. Os dendritos recebem sinais e ampliam a capacidade de recepção do neurônio, enquanto o axônio conduz esses impulsos para outras células, estabelecendo o fluxo de informação no sistema nervoso (Furtado, 2019).

Figura 6 – Neurônio esquematizado



Fonte: Furtado, 2019.

Embora as redes neurais artificiais apresentem certa inspiração nesse funcionamento biológico, não têm como objetivo reproduzir fielmente o cérebro humano, cuja complexidade é significativamente superior, sendo que grande parte de seus processos cognitivos ainda não é completamente compreendida (Botero, 2018).


2.4.2 Redes Neurais Artificiais

Conforme Graupe (2013), as Redes Neurais Artificiais (RNA) são sistemas computacionais que buscam reproduzir, de maneira simplificada, o processo de tomada de decisão presente nas redes de neurônios do sistema nervoso central biológico.

Segundo Valença (2007), o modelo mais simples pode ser apresentado considerando $x_1, x_2, x_3, \dots, x_n$ como as variáveis de entrada x_i (com $j=1, \dots, n$) de um neurônio i , a entrada líquida net_i é determinada por meio de uma regra de propagação (Equação 1). W_{ij} representa o vetor de pesos sinápticos que conectam o neurônio i ao neurônio de entrada j , enquanto θ corresponde ao limiar de ativação, conforme ilustrado na Figura 7.

$$net_i = \sum_{j=1}^n W_{ij} X_j - \theta \quad (1)$$

Figura 7 – Neurônio de McCulloch e Pitts com limiar explícito




Fonte: Valença, 2007.

Grande parte das redes neurais é estruturada por meio da organização de neurônios em camadas, nas quais cada uma reúne unidades com funções ou características semelhantes; de modo geral, essas redes são divididas em três partes principais: camada de entrada, camada oculta e camada de saída (Brega, 1996). Silva, Spatti, Flauzino (2010, p.46), descrevem que “a camada de entrada é responsável pelo recebimento de informações, sinais, características ou medições advindas do meio externo”.

A camada oculta, também conhecida como intermediária e/ou escondida é responsável por grande parte do processamento e, por meio das conexões ponderadas, ela pode ser considerada como uma camada extratora de características (Finocchio, 2014, p.20), a camada de saída é responsável pela apresentação dos resultados da rede, os quais são advindos dos processamentos realizados pelos neurônios das camadas anteriores. (Silva; Spatti; Flauzino, 2010, p. 46). Na Figura 8 é possível observar a divisão de camadas.


Figura 8 – Estrutura de uma rede neural artificial



Fonte: Adaptado de Ahmadian e Khanteymoori (2015).

As redes neurais que apresentam uma grande quantidade de camadas ocultas são denominadas redes neurais profundas e, conforme Hollerweger (2019), representam um avanço significativo na área, sendo responsáveis por resultados expressivos obtidos recentemente no campo da inteligência artificial. A Figura 9 mostra a diferença de uma RNA simples e uma RNA profunda.

Figura 9 - Rede neural simples e rede neural profunda



Fonte: Adaptado de Vasquez, 2017.


2.4.3 Redes Neurais Convolucionais

Redes Neurais Convolucionais (RNC) constituem uma classe de redes neurais artificiais que se destaca como predominante em diversas aplicações de visão computacional (Yamashita et al., 2018). Estudos comprovam que esses modelos computacionais apresentam elevada eficiência na identificação de padrões visuais (Krichen, 2023). Segundo Li et al. (2021), as RNCs transformaram a área de visão computacional, impulsionando avanços expressivos em aplicações como reconhecimento facial, sistemas de vigilância inteligente e veículos autônomos.

A diferença fundamental entre uma camada oculta tradicional de uma rede neural e uma camada de convolução, conforme explica (Chollet, 2018), é que as camadas das redes profundas convencionais aprendem padrões globais no espaço de características de entrada, enquanto as camadas convolucionais aprendem padrões locais, concentrando-se em pequenas regiões da informação.

Na Figura 10 pode-se observar que as imagens são divididas em padrões locais, bordas, texturas e assim sucessivamente.


Figura 10 – Imagem dividida em padrões locais



Fonte: Chollet, 2018.

Segundo Junior *et al.* (2024), As Redes Neurais Convolucionais tradicionais são estruturadas a partir de quatro tipos principais de camadas: entrada, convolucionais, *pooling* e totalmente conectadas (Figura 11). A camada de entrada é responsável por receber os valores de pixel da imagem, constituindo a base para o processamento subsequente. As camadas convolucionais aplicam filtros sobre diferentes regiões da imagem com o objetivo de extrair padrões e características relevantes. Em seguida, a camada de *pooling* atua na redução da dimensionalidade dos dados, diminuindo a quantidade de parâmetros e, consequentemente, o custo computacional do modelo. Por fim, as camadas totalmente conectadas desempenham a etapa de classificação, operando de maneira semelhante às redes neurais tradicionais.

Figura 11 – Arquitetura de uma RNC



Fonte: Junior *et al.*, 2024.

2.4.3.1 Treinamento de uma RNC

O processo de treinamento de um algoritmo de inteligência artificial é organizado em ciclos chamados de épocas, nos quais, o modelo percorre todo o conjunto de dados de treinamento ao menos uma vez a cada ciclo (Hollerweger, 2019).

As redes neurais são, em geral, treinadas com três subconjuntos de dados: treinamento, validação e teste. Segundo Taylor (2017), o conjunto de treinamento é utilizado para ajustar os pesos da rede, o de validação auxilia no controle do *overfitting*, e o conjunto de teste é empregado na avaliação final do desempenho do modelo.

O *overfitting* ocorre quando um modelo é ajustado aos dados de forma que represente com alta precisão o conjunto de treinamento, mas não consiga generalizar adequadamente para novos dados provenientes da mesma distribuição, pois parte dos padrões aprendidos não é representativa da população (Aliferis; Simon, 2024). Para Taylor (2017, p.288) “isso geralmente ocorre porque a rede apenas parece ter aprendido com sucesso, mas na realidade apenas “memorizou” o conjunto de treinamento inicial”.

2.4.3.2 Métricas de Avaliação

As métricas de avaliação de uma rede neural são utilizadas para mensurar o desempenho do modelo em tarefas como classificação ou regressão, permitindo verificar sua capacidade de aprendizado e se existe a necessidade da rede ser treinada por mais épocas. Existem diferentes métricas utilizadas para avaliar modelos; neste trabalho, serão consideradas as seguintes: matriz de confusão, precisão, *recall*, *F1-score*, IoU (*Intersection over Union*) e mAP (*mean Average Precision*) (Souza, 2022).

Segundo Souza (2022), a matriz de confusão, conforme ilustrado na Figura 12, é estruturada como uma matriz 2x2, na qual os valores posicionados na diagonal principal correspondem às classificações corretas: positivos verdadeiros (*True Positive* - TP) e negativos verdadeiros (*True Negative* - TN). Por outro lado, os valores localizados na diagonal oposta indicam as classificações incorretas, sendo elas os falsos positivos (*False Positive* - FP) e os falsos negativos (*False Negative* - FN).


Figura 12 – Matriz de Confusão

		Valor Predito	
		Sim	Não
Real	Sim	Verdadeiro Positivo (TP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (TN)

Fonte: Nogare, 2020.

Conforme apresenta a Figura 13, o verdadeiro positivo (TP) é caracterizado quando a imagem contém uma fissura e a rede neural convolucional (RNC) realiza a identificação correta dessa condição. O falso negativo (FN), por sua vez, ocorre quando a fissura está presente na imagem, porém o modelo não consegue detectá-lo. Já o falso positivo (FP) acontece quando não existe fissura na imagem, mas a RNC indica equivocadamente a sua presença. Em relação ao verdadeiro negativo (TN), ele corresponde às situações em que não há fissura na imagem e o modelo classifica corretamente essa ausência.

Figura 13 - Matriz de confusão aplicada em imagens com e sem fissuras



Fonte: Autoria própria, 2026.

As métricas de desempenho, como precisão, *recall* e *F1-score*, são obtidas com base nos valores presentes na matriz de confusão. A precisão, conforme descrito na Equação 2, corresponde à relação entre o número de verdadeiros positivos e a soma entre verdadeiros positivos e falsos positivos. Seu valor varia no intervalo de 0 a 1, sendo que quanto mais próximo de 1, maior é a exatidão das previsões realizadas pela RNC.

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

O *recall*, conforme apresentado na Equação 3, corresponde à razão entre o número de verdadeiros positivos e a soma entre verdadeiros positivos e falsos negativos. Esse indicador

assume valores no intervalo de 0 a 1 e, quanto mais elevado, maior é a capacidade da RNC em identificar corretamente as imagens que realmente pertencem à classe de interesse.


$$Recall = \frac{TP}{TP + FN} \quad (3)$$

O *F1-score*, tem como finalidade integrar as métricas de precisão e recall em um único indicador (Korstanje, 2021). Sua formulação, apresentada na Equação 4, baseia-se na média harmônica entre essas duas medidas. O valor obtido varia de 0 a 1, sendo que resultados mais elevados indicam melhor desempenho do modelo.

$$F1 \text{ score} = 2 \times \frac{Precisão \times Recall}{Precisão + Recall} \quad (4)$$

“*Intersection over Union (IoU)* é uma métrica utilizada para avaliar o desempenho de detectores de objetos em um determinado conjunto de dados” (Rosebrock, 2016). Para o cálculo dessa métrica, são necessárias duas caixas delimitadoras (*bounding boxes*): a *ground truth* e a caixa prevista pela RNC. Na Figura 14, observa-se um exemplo da aplicação dessas duas *bounding boxes* na identificação de uma fissura.


Figura 14 - Ground-truth bounding box e bounding box prevista



Fonte: Autoria própria, 2026.

A *ground truth*, representada em verde, corresponde à *bounding box* definida manualmente por meio de uma ferramenta de anotação durante a construção da base de dados da RNC. Já a *bounding box* prevista, indicada em vermelho, refere-se à caixa gerada pelo modelo após o processo de treinamento. O IoU é calculado como a razão entre a área de interseção das duas caixas e a área total resultante da união entre elas, conforme ilustrado na Figura 15.


Figura 15 - Determinação do IoU

$$\text{IoU} = \frac{\text{Área de Sobreposição}}{\text{Área de União}}$$


Fonte: Padilla *et al.*, 2020.

A partir desse procedimento, obtém-se um valor que varia entre 0 e 1. Segundo Rosebrock (2016), é bastante improvável que as coordenadas da *bounding box* prevista coincidam exatamente com as da *ground truth*. Dessa forma, quanto mais próximo de 1 for o valor do IoU, melhor será o desempenho do modelo, conforme ilustrado na Figura 16.

Figura 16 - IoU de bounding boxes



Fonte: Adaptado de Rosebrock, 2016.


Por último, destaca-se a métrica mAP (*mean Average Precision*), que corresponde à média aritmética dos valores de AP (*Average Precision*) considerando todas as classes

avaliadas. No entanto, como neste trabalho é analisada apenas uma única classe por vez, os valores de mAP e AP coincidem, pois, os treinamentos foram realizados de forma independente para cada manifestação patológica analisada. Assim, foi desenvolvido um modelo específico para detecção de fissuras e outro modelo específico para detecção de corrosão. Conforme Padilla, Netto e Silva (2020), a AP é amplamente empregada na avaliação do desempenho de detectores de objetos. Segundo Hui (2018), essa métrica é definida, de forma geral, como a área sob a curva de precisão em função do recall, conforme expresso na Equação 5.

$$AP = \int_0^1 p(r) dr \quad (5)$$

A curva precisão/recall é representada por um gráfico composto por pares ordenados, no qual o eixo vertical corresponde à precisão e o eixo horizontal ao recall. Um exemplo dessa relação pode ser visualizado no Gráfico 1.

Gráfico 1 - Exemplo de uma curva precisão/recall




Fonte: Adaptado de Hui, 2018.

3 METODOLOGIA

3.1 Desenho do Estudo

O presente trabalho teve os métodos de pesquisa organizados em etapas lógicas e sequenciais, sendo dividido em 5 etapas, como pode ser observado na Figura 17.

Figura 17 - Etapas do TCC



Fonte: Autoria própria, 2026.


Inicialmente foi realizado o levantamento bibliográfico referente aos fatores que influenciam no surgimento de manifestações patológicas e o impacto delas nas edificações. Em seguida foi realizada a montagem do banco de dados com imagens de manifestações patológicas do tipo: fissura e corrosão. O terceiro passo consistiu no pré-processamento das imagens por meio da ferramenta online *MakeSense.ai*.

O quarto passo foi a realização do treino da Rede Neural Convolucional no ambiente de execução *Google Colab*, utilizando linguagem de programação Python, e o algoritmo YOLOv8n. Em sequência o quinto passo foi a escrita da monografia, que posteriormente pode resultar na publicação de artigos científicos.

3.2 Montagem da Base de Dados

Para montar a base de dados de fissuras foi necessária a utilização de um banco de dados amplo e sistematizado organizado por Özgenel (2018), contendo 40 mil imagens, das quais 20 mil são de fissuras. Esse banco de dados já havia sido empregado em múltiplas pesquisas relacionadas à identificação de fissuras, o que reforça a credibilidade e a consistência das informações utilizadas. A Figura 18 apresenta algumas das imagens presentes no conjunto de dados empregado.

Figura 18 – Amostra do Banco de Dados referente a fissuras




Fonte: Adaptado de Özgenel, 2018.

A montagem da base de dados foi pensada utilizando imagens do banco de dados encontrado na literatura que foi chamado de DataSet1 (DT1) e adicionalmente imagens tiradas em campo pelo autor, chamado de DataSet2 (DT2), para que a rede pudesse generalizar os padrões reconhecidos da melhor forma em várias superfícies e sobre iluminações distintas.

A base de dados referente a manifestação patológica de corrosão foi montada com 350 imagens tiradas em campo pelo autor (Figura 19), adicionadas tanto em DT1 como em DT2.

Figura 19 – Amostra do Banco de Dados referente a corrosão




Fonte: Autoria própria, 2026.

3.3 Pré-Processamento das Imagens

Após a montagem da base de dados as imagens foram organizadas em uma pasta e inseridas na ferramenta *Makesense.ai*, onde foram devidamente rotuladas (anotadas).

O *Makesense.ai* é uma ferramenta online voltada para a anotação de imagens, amplamente utilizada em projetos de visão computacional e aprendizado profundo. Sua principal finalidade é auxiliar na criação de conjuntos de dados rotulados, gerando as caixas delimitadoras (*bounding boxes*) como mostra a Figura 20.

Figura 20 – Pré-processamento das imagens




Fonte: Autoria própria, 2026.

Em abordagens de aprendizado supervisionado, como a utilizada neste trabalho, as anotações desempenham papel essencial, pois fornecem ao modelo informações detalhadas sobre a posição e a categoria das fissuras e das armaduras afetadas por corrosão.

Ao final do processo as informações das *bounding boxes* anotadas manualmente, são salvas em um arquivo de bloco de notas, em formato *.txt*, conforme o conteúdo mostrado na Figura 21, onde para cada imagem existe uma anotação.


Figura 21 – Bloco de notas contendo as informações das bounding boxes



Fonte: Autoria própria, 2026.

Podemos observar que na Figura 21 existem 2 linhas, cada uma representando uma corrosão presente na imagem anotada, que nesse caso foi a Figura 20. Nota-se também que em cada linha existem 5 elementos. Cada elemento representa um determinado parâmetro, e eles estão representados na Figura 22.

Figura 22 – Elementos do arquivo .txt




Fonte: Autoria própria, 2026.

O primeiro valor, como se observa, é igual a 0 em todas as linhas, indicando que todos os objetos pertencem à mesma classe. Nesse caso, trata-se da classe “Corrosão”, uma vez que é a única manifestação patológica considerada na imagem.

Os valores nas posições 2 e 3 correspondem às coordenadas do centro da *bounding box* nos eixos X e Y, respectivamente. Já os valores nas posições 4 e 5 representam as dimensões da *bounding box*, sendo a largura e a altura. A Figura 23 ilustra de forma clara esses parâmetros aplicados à delimitação do objeto.

Figura 23 - Representação dos elementos do arquivo de .txt




Fonte: Adaptado de Vijayvergiya, 2021.

Esse processo de criação de *bounding boxes* foi repetido para todas as imagens que contêm as manifestações patológicas estudadas, então, ao final foi obtido dois bancos de dados, um com 700 imagens sendo 350 imagens de fissuras e 350 de corrosão, e outro com um acréscimo para imagens de fissuras totalizando 800 imagens.

Na Figura 24, observa-se que para cada elemento da base de dados há sempre dois arquivos com o mesmo nome: um arquivo de imagem, no formato *.jpg*, contendo as ocorrências de fissuras, e um arquivo de texto correspondente, no formato *.txt*, que armazena as anotações referentes aos parâmetros das *bounding boxes*.

Figura 24 - Exemplo de uma parte do banco de dados



Fonte: Autoria própria, 2026.

É relevante destacar que nos bancos de dados utilizados existem algumas imagens similares, isto ocorreu por causa das imagens utilizadas nos bancos de dados terem sido padronizadas em cores e tamanhos, esse fato pode influenciar nos resultados obtidos.

3.4 Programação da Rede Neural

Para o desenvolvimento da RNC empregada neste trabalho, utilizou-se a linguagem de programação Python, por meio do ambiente *Google Colaboratory*, também conhecido como *Colab*. Essa plataforma apresenta diversas vantagens, como a execução direta no navegador, dispensando a necessidade de instalação local, além de disponibilizar gratuitamente recursos de processamento, como unidade de processamento gráfico (GPU).

Dentro do próprio *Google Colab*, é possível importar o algoritmo de detecção de objetos YOLO, cuja tradução para o português é “você olha apenas uma vez”. Essa denominação decorre do fato de que o algoritmo processa a imagem em uma única passagem, encaminhando-a diretamente para a rede neural convolucional, o que torna a detecção mais rápida e eficiente quando comparada a métodos tradicionais que realizam múltiplas etapas de análise.

De acordo com Redmon *et al.* (2016), o YOLO realiza o treinamento diretamente sobre imagens completas e otimiza de forma conjunta o desempenho da detecção. Por se tratar de um modelo unificado, ele integra em uma única etapa tarefas que, em abordagens tradicionais, são executadas separadamente, como a extração de características e a localização de objetos.

Para o treinamento da rede neural, foi necessária a importação do modelo YOLOv8n no ambiente de execução do *Google Colab*, possibilitando a utilização do banco de dados previamente estruturado e em seguida, realizados os treinamentos para DT1 e DT2.

Os bancos de dados DT1 e DT2 foram estruturados com imagens de corrosão e fissuras, sendo que DT2 possui integralmente todas as imagens de DT1, mais um acréscimo de 100 imagens de fissuras tiradas em campo sobre diferentes condições. Treino e validação foram realizados com a divisão mostrada na Tabela 2.

Tabela 2 – Divisão das imagens do banco de dados.

Banco de dados	Total de imagens	Conjunto de treino	Conjunto de validação
DT1	700	600	100
DT2	800	700	100

Fonte: Autoria própria, 2026.

Diante disso, foram realizados 2 treinamentos com 150 épocas cada, um para cada banco de dados. Em todos os casos, foi empregado, na fase inicial, o método de *Transfer Learning* (transferência de aprendizagem). Trata-se de um método empregado para transferir o

conhecimento adquirido em uma determinada tarefa para a resolução de outra. Esse procedimento pode, por exemplo, contribuir para o aumento da precisão do modelo, bem como para a redução do tempo necessário para o treinamento da rede neural (Ribani; Marengoni, 2019).

Para a RNC empregada neste trabalho, a *Transfer Learning* consistiu na utilização de um conjunto de pesos iniciais provenientes de outra RNC previamente treinada, a qual já havia aprendido características básicas presentes nas imagens, como bordas, linhas e variações de cor. Dessa forma, evitou-se que a rede precisasse aprender tais padrões desde o início, tornando o processo mais eficiente. Após essa etapa, foi necessário apenas aguardar a conclusão dos dois treinamentos, uma vez que o processo é realizado de forma automatizada pela própria rede neural convolucional.

Para a etapa de teste foram realizados dois experimentos. No primeiro, o próprio autor testou a rede com novas imagens para verificar a capacidade de generalização do modelo. No segundo, foi desenvolvido na plataforma do *Google Colab* um ambiente online para a execução do modelo treinado e compartilhamento do link de acesso, para que os testes fossem realizados remotamente e em tempo real. Salienta-se que no segundo experimento profissionais da área puderam submeter imagens diretamente na plataforma, observar as respostas e o nível de confiança do modelo fornecido.

4 RESULTADOS E DISCUSSÕES


4.1 Resultados do Treinamento

4.1.1 Resultado das Métricas de Perdas

Antes da análise das métricas de desempenho, é importante avaliar o comportamento das funções de perda (*loss*) durante o treinamento da rede neural. Essas métricas permitem verificar o processo de aprendizado do modelo e identificar sua convergência ao longo das épocas. No YOLOv8 são utilizadas diferentes funções de perda, dentre as quais destacam-se a *Box Loss*, responsável pela avaliação da precisão na localização das *bounding boxes*, a *Classification Loss* (Cls Loss), relacionada à classificação correta dos objetos, e a *Distribution Focal Loss* (DFL Loss), empregada para refinar a regressão das caixas delimitadoras.

O Gráfico 2 apresenta os valores da evolução de *Box loss* durante o treinamento e validação para manifestação patológica de corrosão.


Gráfico 2 – Evolução de treino e validação para Box loss



Fonte: Autoria própria, 2026.

Para o treino observa-se uma redução gradual dos valores ao longo das épocas, saindo de aproximadamente 1,664 na época 5 para 0,717 na época 150. Embora exista uma oscilação intermediária entre as épocas 50 e 75, a tendência geral é de queda, indicando melhoria progressiva da capacidade do modelo em localizar corretamente as manifestações patológicas presentes nas imagens. Na validação, a perda de caixa partiu de 1,95 na época 5, caiu para 0,97 na época 50, teve um pequeno pico para 1,13 na época 75, e depois voltou a cair, alcançando 0,74 na época 150. Embora tenha havido uma oscilação intermediária, a tendência geral é de redução, indicando melhoria contínua na localização.

Para *CLS loss* os resultados tanto para treino quando para validação também demonstram tendência de queda conforme mostra o Gráfico 3.




Fonte: Autoria própria, 2026.

A perda de classificação no treinamento iniciou em aproximadamente 2,26 e apresentou uma redução gradual e consistente ao longo das épocas, atingindo valores próximos de 0.5 no final do treinamento. Isso indica que o modelo aprendeu efetivamente a distinguir as classes dos objetos. Na validação começou em torno de 7,45 nas primeiras épocas, caiu

rapidamente para o valor de 1,22 e continuou descendo até cerca de 0.64 na época 150. Essa redução sustenta que o modelo está generalizando bem, sem *overfitting* severo.

Em seguida consta o Gráfico 4 que mostra os resultados de *DFL loss* para treino e validação.

Gráfico 4 – Evolução de treino e validação para DFL loss



Fonte: Autoria própria, 2026.


O DFL loss no treinamento iniciou próximo de 1,70 e caiu até cerca de 1,05 na época 150. A redução é suave e estável, sugerindo um aprendizado consistente das incertezas nas predições de borda. Na validação, o DFL loss começou em 2,30 na época 5, caiu para 1,07 na época 50, subiu ligeiramente para 1,18 na época 75, depois retomou a queda até 0,88 na época 150. Assim como na perda de caixa, houve uma pequena oscilação, mas o valor final é significativamente menor que o inicial.

Esses resultados apresentam clara tendência de queda ao longo das épocas, indicando que o modelo está aprendendo e melhorando progressivamente, mostrando que o modelo está

bem treinado e pronto para ser utilizado em tarefas de detecção de objetos, com bom equilíbrio entre precisão de classificação e localização.

Para fissuras referentes a DT1 a evolução de *Box loss* de treinamento e validação seguem abaixo no Gráfico 5.

Gráfico 5 – Evolução de treino e validação para Box loss




Fonte: Autoria própria, 2026.

A perda *Box loss* apresentou tendência geral de redução ao longo do treinamento. Inicialmente, o valor observado foi de 1,42 na época 5, diminuindo para 0,72 na época 50 e alcançando 0,61 ao final do treinamento, na época 150. Em relação à validação, a *Box loss* iniciou com valor de 3,48 na época 5 e apresentou uma redução acentuada até atingir 2,83 na época 25 e 2,21 na época 50, finalizando com 1,96 na época 150. Nota-se que a partir da época 100, os valores oscilam, mas no final o resultado é perto do valor visto na época 100, mostrando que em 50 épocas passadas não foi obtido ganho.

Para DT2 os resultados de *Box loss*, durante o treinamento e validação foram consistentes como mostra o Gráfico 6.

Gráfico 6 – Evolução de treino e validação para Box loss




Fonte: Autoria própria, 2026.

Nas primeiras 100 épocas, o modelo apresenta uma redução consistente dessa métrica, partindo de aproximadamente 1,24 na época 5 e atingindo 0,64, na época 100. Em seguida os valores sobem e a partir da época 125 caem terminando com 0,59 na época 150. Para validação existe oscilação em sentido de queda durante a maior parte das épocas partindo de 1,85 até finalizar com 0,92. Essa queda indica que, o modelo estava efetivamente aprendendo a posicionar as caixas delimitadoras sobre os objetos nas imagens de treino.

Para as métricas de CLS e DFL *loss*, DT1 e DT2 apresentaram valores bem distintos, com os valores de perdas de DT1 oscilando bastante em algumas situações não caindo como esperado, enquanto que DT2 se manteve constante em vários períodos e na maior parte do

tempo com tendência de queda. Os Gráficos 7, 8, 9 e 10 mostram os resultados pra DT1 e DT2 respectivamente.

Gráfico 7 – Evolução de treino e validação para CLS loss




Fonte: Autoria própria, 2026.

Para DT1 observa-se uma tendência geral de diminuição da perda ao longo das épocas. O valor inicial registrado na época 5 foi de aproximadamente 2,022, reduzindo para 1,300 na época 25 e 1,143 na época 50. A partir desse ponto, a curva continuou apresentando comportamento decrescente, atingindo 0,971 na época 75 e 0,643 na época 100. Embora tenha ocorrido uma elevação temporária entre as épocas 100 e 125, quando a perda alcançou 0,949, a tendência de aprendizado foi retomada, resultando em uma perda final de 0,592 na época 150.

No conjunto de validação, a perda apresentou maior variabilidade ao longo do processo. Inicialmente, verificou-se um pico elevado próximo à época 5, alcançando aproximadamente 9,383, seguido de uma rápida redução nas épocas subsequentes. Nas épocas

de referência, os valores observados foram 3,343 (época 25), 3,360 (época 50), 2,828 (época 75), 2,350 (época 100), 2,765 (época 125) e 2,405 (época 150).

Gráfico 8 – Evolução de treino e validação para CLS loss




Fonte: Autoria própria, 2026.

No caso de DT2 ocorreu uma tendência geral de redução da perda ao longo das épocas. O valor inicial registrado na época 5 foi de aproximadamente 2,217, reduzindo para 1,439 na época 25. Na época 50, a perda atingiu 0,922, representando uma diminuição significativa em relação ao início do treinamento. Posteriormente, ocorreu uma pequena elevação, alcançando 1,267 na época 75, seguida por uma nova redução para 1,119 na época 100. O comportamento decrescente foi mantido até as épocas finais, registrando 0,908 na época 125 e 0,643 na época 150. Esse resultado demonstra que o modelo aprimorou gradativamente sua capacidade de localizar os objetos durante o processo de aprendizado.

A curva de validação apresentou comportamento semelhante, porém com maior instabilidade nas primeiras épocas. Observa-se um pico elevado próximo à época 5, característica comum em estágios iniciais de treinamento, seguido por uma rápida redução da perda. Nas épocas de referência, os valores observados foram 1,567 (época 25), 1,036 (época

50), 1,402 (época 75), 0,861 (época 100), 0,777 (época 125) e 0,743 (época 150). Apesar das oscilações intermediárias, a tendência geral permaneceu decrescente, indicando melhoria progressiva do desempenho do modelo em dados não utilizados durante o treinamento.

Gráfico 9 – Evolução de treino e validação para DFL loss




Fonte: Autoria própria, 2026.

Para DFL loss, DT1 apresenta na época 5, o valor de 1,581, diminuindo para 1,394 na época 25 e 1,309 na época 50. A curva continuou apresentando comportamento decrescente, atingindo 1,259 na época 75. Embora tenha ocorrido uma pequena elevação para 1,273 na época 100 e 1,266 na época 125, a perda voltou a diminuir nas épocas finais, encerrando o treinamento com valor de 1,220 na época 150.

Para validação observa-se um pico de 3,466 próximo à época 5, seguido por uma tendência de redução progressiva. Os valores observados nas épocas de referência foram 2,477 (época 25), 2,015 (época 50), 1,878 (época 75), 1,622 (época 100), 2,020 (época 125) e 1,850 (época 150). Mesmo com oscilações verificadas entre as épocas 100 e 125, a curva de validação

manteve uma trajetória global descendente, evidenciando melhora contínua do desempenho em dados não utilizados durante o treinamento.

Gráfico 10 – Evolução de treino e validação para DFL loss



Fonte: Autoria própria, 2026.

DT2 apresenta na época 5, o valor de 1,670, diminuindo para 1,391 na época 25 e 1,256 na época 50. Embora tenha ocorrido uma pequena elevação para 1,371 na época 75, a perda voltou a diminuir nas épocas finais, encerrando o treinamento com valor de 1,195 na época 150.

Na validação ocorreu um pico de 2,269 na época 5, seguido por uma tendência de redução progressiva. Os valores observados nas épocas de referência foram 1,517 (época 25), 1,169 (época 50), 1,637 (época 75), 1,271 (época 100), 1,185 (época 125) e 1,196 (época 150).

Quando comparados os resultados dos dois conjuntos de dados, fica evidente que o DT2 apresenta um desempenho global superior e mais equilibrado do que o DT1. Na classificação em treinamento, ambos os modelos tiveram desempenhos muito próximos, com ligeira vantagem para o DT1 (0,592 contra 0,643). No DFL *loss* de treinamento, a vantagem é para o DT2 que aprendeu e reduziu sua perda para 1,195, enquanto o DT1 finalizou em 1,22.


Na validação, o DT2 obteve uma perda de classificação de aproximadamente 0,74, enquanto o DT1 ficou em cerca de 2,4. No DFL *loss* de validação, o DT2 também levou vantagem (1,196 contra 1,85). A diferença mais crítica está na perda de localização na validação: enquanto o DT2 estabilizou-se em aproximadamente 0,8 a partir da época 100 e manteve-se estável, o DT1 apresentou uma trajetória alarmante, partindo de aproximadamente 2,8 e terminando em 2,4, um sinal claro de *overfitting* severo que torna o modelo DT1 potencialmente fraco para aplicações práticas que exijam precisão na localização de objetos.

4.1.2 Resultado das Métricas de Avaliação

Baseando-se na metodologia apresentada, foram obtidos vários resultados ao longo de todo o treinamento realizado. Para melhor visualização desses resultados, os mesmos serão apresentados separados em corrosão, fissuras referentes ao DT1 e fissuras DT2, com todos os dados em forma de gráficos de acordo com as métricas de avaliação.

O primeiro resultado pode ser observado no Gráfico 11, onde é mostrado a precisão alcançada para manifestação patológica do tipo corrosão.

Gráfico 11 – Resultados para corrosão: Precisão x Épocas




Fonte: Autoria própria, 2026.

O gráfico acima expõe a precisão em função do número de épocas, mostrando que ao longo do tempo de treinamento a precisão aumentou. Inicialmente o modelo apresenta valores baixos indicando que a rede estava em fase inicial de aprendizado, mas vai aumentando ao longo do tempo. Da época 5 até a 50 percebemos um crescimento, em seguida o valor cai na época 75 e volta a subir na época 100, finalizando com 0,83 na época 150.

Nas últimas épocas a diferença é relativamente pequena, sugerindo que o modelo começou a convergir, os ganhos de desempenho tornaram-se menores à medida que o treinamento avançou. Além disso, é visível que o melhor resultado foi obtido na época 150, com precisão de 0,83, indicando que 83% das predições realizadas pelo modelo para a classe corrosão foram corretas.

Em seguida temos o comparativo entre os dois resultados de precisão das bases de dados DT1 e DT2, conforme Gráfico 12.

Gráfico 12 – Resultados para fissuras: Precisão x Épocas



Fonte: Autoria própria, 2026.


Nota-se que DT2 manteve desempenho superior durante quase todo o treinamento. De início o crescimento se deu de forma rápida com o modelo já atingindo 0,95 na época 50, mas com uma queda na época 75, que logo subiu na época 100 e se estabilizou até o final na época 150 com pouca variação, indo de 0,95 a 0,93. DT1 começou crescendo de forma constante,

porém, após a época 50 onde atingiu 0,81, os valores começaram a variar e cair, terminando na época 150 com 0,50.

Os resultados mostram que DT1 apresentou comportamento instável se comparado a DT2, além de que os valores de DT1 estão muito abaixo de DT2 em todas as épocas com exceção da época 75. O melhor resultado obtido de DT1 é de 0,81 equivalente a 81% de acertos para predições, enquanto que para DT2 ficamos com a época 100, onde o modelo apresentou 0,95, equivalente a 95% das predições corretas.

O próximo resultado diz respeito a métrica de avaliação *Recall* para corrosão, como apresentado no Gráfico 13.

Gráfico 13 – Resultados para corrosão: Recall x Épocas




Fonte: Autoria própria, 2026.

Nas primeiras etapas do treinamento, o modelo apresentou um *recall* relativamente baixo, iniciando em 0,35 na época 5. Isso indica que apenas 35% das imagens de corrosão presentes no conjunto de teste estavam sendo corretamente identificadas. Com o avanço do treinamento, houve uma evolução significativa da métrica, atingindo 0,57 na época 25 e 0,80 na época 50, demonstrando que o modelo passou a reconhecer uma parcela cada vez maior dos casos reais de corrosão.

Observa-se uma redução para 0,57 na época 75, indicando uma oscilação temporária no processo de aprendizagem. Esse comportamento pode estar relacionado a ajustes dos pesos da rede neural durante o treinamento ou à complexidade dos padrões presentes nos dados. Apesar dessa queda, o modelo voltou a apresentar melhorias expressivas a partir da época 100, alcançando 0,84, seguido de 0,91 na época 125 e 0,92 na época 150.


Em seguida no Gráfico 14 apresenta a evolução da métrica *Recall* para DT1 e DT2 ao longo de 150 épocas de treinamento.



Fonte: Autoria própria, 2026.

DT1 teve início com valor de 0,23 para a época 5 e durante todo o treinamento não conseguiu ultrapassar 0,4, ficando próximo disso apenas na época 150 com 0,39. DT2 por sua vez teve início com 0,51 na época 5, seguido de 0,83 na época 25 e 50, tendo o melhor resultado na época 125 com 0,91 e ao final terminando com 0,87 na época 150. Novamente DT2 alcança um desempenho melhor que DT1, pois, é possível visualizar que o melhor resultado de DT1 0,39 não ultrapassa o pior de DT2 0,51.

No Gráfico 15 é possível visualizar o resultado para a métrica de *F1-score*.




Fonte: Autoria própria, 2026.

A métrica avaliada no gráfico é o *F1-score*, onde pode-se notar que os valores mantiveram crescimento de forma lógica começando em 0,24 na época 5, seguindo para 0,54 e 0,78 nas épocas 25 e 50 respectivamente. A época 75 apresenta uma queda para 0,61, mas em seguida o modelo volta a apresentar crescimento e a partir da época 100 cresce de forma contínua, finalizando com 0,87 na época 150.

Percebe-se ainda que o modelo tenha apresentado instabilidade na época 75, a partir da época 100 ele começa a convergir bem, finalizando com pico na época 150 e se consolidando como o melhor valor para a métrica.

No Gráfico 16 é possível visualizar o resultado para a métrica de *F1-score* para manifestações patológicas do tipo fissura.




Fonte: Autoria própria, 2026.

Logicamente DT2 foi superior a DT1, pois a métrica avaliada consiste na média harmônica da precisão e do *recall*, onde DT2 também foi superior. Observando percebemos que todos os valores mostrados em DT1 são menores que os valores de DT2.

Para DT1 o maior valor é 0,46 na época 50, após isso o valor cai para 0,43 e se mantém até a última época onde volta a subir, mas apenas para 0,44. No DT2 inicialmente o valor é 0,36 na época 5, seguindo para 0,77 e 0,89 nas épocas 25 e 50. Assim como nos gráficos anteriores de precisão e *recall*, ocorreu uma queda na época 75 para 0,68. Analisando isoladamente percebemos que o desempenho de DT2 se mantém oscilando no final entre 0,91, 0,92 e 0,89.

No Gráfico 17 é apresentado o resultado da métrica de avaliação IoU para corrosão.




Fonte: Autoria própria, 2026.

O modelo inicialmente apresentou 14,04% na época 5, e com o avanço do treinamento obteve 37,86% na época 25 e 64,57% na época 50, o que mostra um bom crescimento, até que houve uma queda na época 75 para 44,06%. Em seguida o modelo voltou a avançar quando atingiu 70,17% na época 100 e nas épocas 125 e 150 mantiveram valores acima de 70%.

Nota-se que o melhor resultado foi obtido na época 150, com 77,41%, mas se avaliarmos de forma local a partir da época 100 os valores se mantiveram sem grande oscilação, levando acreditar que a rede aprendeu de forma adequada a capacidade de localizar as manifestações patológicas do tipo corrosão.

Abaixo segue o Gráfico 18 com os resultados obtidos para métrica de avaliação IoU para manifestação patológica do tipo fissura.




Fonte: Autoria própria, 2026.

Ao observar os valores mostrados a cima, nota-se que DT1 não conseguiu valores satisfatórios, ficando sem muitas oscilações a partir da época 50 com valores que variam de 29,97% a 28,36%. DT2 apresentou resultados muito superiores, conseguindo manter valores acima de 80% a partir da época 100.

Os melhores resultados de DT1 e DT2 são distantes, indo de 29,97% para 85,22% respectivamente, o que mostra que DT2 é muito mais eficiente do que DT1 para localizar corretamente o objeto de estudo.

O último resultado para corrosão foi o mAP, como apresenta o Gráfico 19.




Fonte: Autoria própria, 2026.

Observando o resultado de maneira geral, percebe-se que o modelo conseguiu aprender os padrões para detecção de manifestação patológica do tipo corrosão, apresentando perdas apenas na época 75. O melhor resultado se deu na época 150 alcançando desempenho de 93,86% e nota-se ainda que a partir da época 100 o modelo avançou em forma de uma linha reta crescente, mantendo acima de 85% de precisão.


Para ilustrar o desempenho do melhor treino elaborou-se a Figura 25. Essa figura mostra as manifestações patológicas do tipo corrosão sendo localizadas com precisão e certeza superiores a 90%.

Figura 25 – Resultado do melhor treino para manifestação patológica do tipo corrosão



Fonte: Autoria própria, 2026.

Para a métrica de avaliação mAP referente a fissuras, os resultados estão apresentados no Gráfico 20.




Fonte: Autoria própria, 2026.

Por fim, novamente DT2 apresentou desempenho superior a DT1, apresentando 97,09% na época 125, um resultado ótimo para um detector de objetos. As épocas 50, 100 e 150 também apresentaram bons resultados com valores superiores a 90%. DT1 por sua vez não conseguiu apresentar resultados tão satisfatórios, ficando sempre abaixo de 50% e tendo poucas oscilações a partir da época 50.

A Figura 26 busca ilustrar o desempenho do melhor resultado de treino na época 125, onde já podemos observar um modelo capaz de identificar e localizar fissuras com um percentual de certeza alto.

Figura 26 – Resultado do melhor treino para manifestação patológica do tipo fissura



Fonte: Autoria própria, 2026.

Analisando os resultados apresentados de modo geral, percebe-se que a base de dados com imagens de campo obteve um resultado melhor, mesmo com o acréscimo de poucas imagens. DT2 apresentou vantagem em um curto espaço de épocas por possuir mais imagens e por essas imagens serem retiradas de diferentes superfícies com diferentes cores e iluminações, sendo mais adequadas à tarefa de detecção de objetos, enquanto parte das imagens do DT1 foi originalmente desenvolvida para classificação.

DT1 como dito anteriormente, foi baseado em um banco de dados com imagens muito similares, além de que todas as imagens são de 227x227 px e muitas das caixas delimitadoras cobrem toda a imagem, diminuindo a capacidade do modelo de aprender a extrair aspectos em diferentes condições.

Para manifestação patológica do tipo corrosão a montagem da base de dados e treinamento foi considerado um sucesso, pois o modelo apresentou bons resultados em diversas métricas, mostrando que já é capaz de generalizar para imagens em várias condições.

4.2 Teste da RNC

Os testes iniciais foram feitos pelo autor na plataforma *google colab*, adicionando os melhores modelos treinados e sequencialmente as imagens para observar a taxa de precisão, classificação e confiança da rede. Foram adicionadas 10 imagens de fissuras e 10 de corrosão e 2 contendo ambas as manifestações patológicas, todas com diferentes iluminações, cores e tamanhos.

Para a classe Corrosão, os resultados apresentados na Figura 27 demonstram que o modelo conseguiu identificar adequadamente regiões com exposição e oxidação das armaduras, mesmo em cenários com diferentes níveis de deterioração superficial. As caixas delimitadoras destacam as áreas afetadas e os valores de confiança variam aproximadamente entre 0,78 e 0,96 (78% e 96%), indicando elevado grau de certeza na maioria das predições.


Figura 27 – Resultado de detecção para corrosão



Fonte: Adaptado de Shutterstock, 2026.

Observa-se na Figura 28 que o modelo foi capaz de detectar fissuras em diferentes condições de iluminação, texturas e revestimentos, incluindo superfícies pintadas, rebocadas e concretadas. As fissuras identificadas apresentam orientações verticais, horizontais e inclinadas, demonstrando capacidade de generalização do modelo para diferentes padrões geométricos.

Figura 28 – Resultado de detecção para fissuras



Fonte: Adaptado de Shutterstock, 2026.

Os níveis de confiança variaram aproximadamente entre 68% e 91%, indicando que a maioria das detecções foi realizada com elevada confiabilidade. As maiores confianças foram observadas em fissuras mais evidentes e com maior contraste em relação ao fundo, enquanto valores menores ocorreram em regiões onde a fissura apresenta menor abertura ou contraste reduzido.

Na Figura 29 o modelo demonstrou capacidade de detectar e classificar simultaneamente diferentes manifestações patológicas presentes em uma mesma imagem. Esse resultado evidencia que a rede neural foi capaz de extrair características discriminantes de cada classe estudada, realizando a identificação individual das manifestações patológicas mesmo quando estas ocorrem de forma concomitante.

Figura 29 – Resultado de detecção para ambas as manifestações patológicas




Fonte: Autoria própria, 2026.

De modo geral para ambas as manifestações patológicas o modelo obteve sucesso na detecção e classificação. Das 22 imagens fornecidas todas tiveram as manifestações patológicas localizadas e classificadas da forma correta.

Seguindo em frente, o ambiente para testes online (Figura 30) foi devidamente programado na plataforma *google colab* e o link foi enviado para 3 engenheiros civis para que pudesse ser testado.

Figura 30 – Ambiente virtual de testes




Fonte: Autoria própria, 2026.

Na Figura 30 pode ser visto o ambiente virtual pronto para a execução. O ambiente é intuitivo de se utilizar, pois, foi pensado para que qualquer pessoa conseguisse usar, o retângulo da esquerda é onde a imagem vai ser adicionada e o da direita onde o resultado sai. No final do teste é gerado um arquivo onde é mostrada a detecção, localização e grau de confiança.

Seguem os resultados para o engenheiro 1, engenheiro 2 e engenheiro 3 nas Figuras 31, 32 e 33, respectivamente.

Figura 31 – Teste de detecção realizado remotamente pelo engenheiro 1



Fonte: Autoria própria, 2026.

Figura 32 – Teste de detecção realizado remotamente pelo engenheiro 2



Fonte: Autoria própria, 2026.

Figura 33 – Teste de detecção realizado remotamente pelo engenheiro 3



Fonte: Autoria própria, 2026.

Os resultados demonstram que o modelo foi capaz de detectar ambas as manifestações patológicas em diferentes condições, quando solicitado. Na Figura 31 foram expostas duas imagens de fissuras verticais e a rede as detectou e localizou com sucesso, na Figura 32 as imagens mostradas foram duas fissuras com superfícies repletas de objetos no entorno, mesmo assim, a rede conseguiu detectar e localizar, para a Figura 33 o engenheiro utilizou duas

imagens diferentes, uma de fissura e outra de corrosão, e a rede conseguiu realizar a detecção correta de cada uma das classes.

De modo geral, o modelo foi capaz de aprender características visuais associadas ao processo corrosivo, como coloração ferruginosa, exposição das barras de aço e destacamento do revestimento, como também características de fissuras, como aberturas de diferentes dimensões e orientações, incluindo fissuras verticais, horizontais e inclinadas.

5 CONCLUSÃO

Através da utilização da arquitetura de detecção de objetos YOLOv8n confirmou-se que é viável desenvolver, treinar e validar uma Rede Neural Convolucional para a identificação automática de manifestações patológicas do tipo fissura e corrosão em estruturas de concreto. A metodologia proposta foi capaz de detectar e classificar ambas as manifestações patológicas com elevado nível de precisão, confirmando a viabilidade da aplicação na Engenharia Diagnóstica.

Durante o treinamento, observou-se que o banco de dados DT2, composto por imagens provenientes da literatura e por imagens coletadas em campo, apresentou desempenho significativamente superior ao DT1 em todas as métricas avaliadas. Esse resultado evidencia a importância da diversidade de imagens para o processo de aprendizagem da rede neural, contribuindo para uma maior capacidade de generalização e para o reconhecimento das manifestações patológicas em diferentes condições de iluminação, textura, coloração e estado de degradação.

Para a classe fissura, o modelo alcançou valores de precisão próximos de 95%, *recall* superior a 90%, *F1-score* acima de 90% e mAP de aproximadamente 97%, demonstrando excelente desempenho tanto na classificação quanto na localização dos objetos. Para a classe corrosão, os resultados também foram satisfatórios, atingindo precisão de 83%, *recall* de 92%, *F1-score* de 87%, IoU de 77% e mAP superior a 93%, indicando elevada capacidade de identificação das regiões afetadas.

Os testes realizados com imagens inéditas mostraram que o modelo foi capaz de detectar corretamente todas as amostras avaliadas no trabalho, apresentando níveis de confiança predominantemente entre 68% e 96%. Além disso, os testes remotos realizados por profissionais da engenharia civil confirmaram a aplicabilidade prática da ferramenta, uma vez que as manifestações patológicas foram identificadas corretamente em diferentes cenários e condições de captura.

Dessa forma, se pode concluir que a utilização de uma Rede Neural Convolucional para a identificação automática de fissuras e corrosão constitui uma alternativa promissora aos métodos tradicionais de inspeção visual, possibilitando maior rapidez na análise, redução da subjetividade das avaliações e potencial diminuição dos custos associados às inspeções técnicas. Embora a metodologia proposta não substitua a análise especializada do engenheiro,

ela pode atuar como uma importante ferramenta de apoio à tomada de decisão em processos de manutenção, monitoramento e reabilitação de estruturas.

Para trabalhos futuros, recomenda-se a ampliação da base de dados com um maior número de imagens e novas classes de manifestações patológicas, como umidade, eflorescência, deslocamento e mofo. Além da possibilidade de melhorar os resultados das métricas de avaliação a partir de técnicas como o *data augmentation*, aumento do *batch size* e a utilização de outras arquiteturas de RNC.

REFERÊNCIAS

AHMADIAN, Sajad; KHANTEYMOORI, Ali Reza. Training back propagation neural networks using asexual reproduction optimization. In: **2015 7th Conference on Information and Knowledge Technology (IKT)**. IEEE, 2015. p. 1-6.

ALIFERIS, Constantin; SIMON, Gyorgy. Overfitting, underfitting and general model overconfidence and under-performance pitfalls and best practices in machine learning and AI. In: SIMON, G. J.; ALIFERIS, C. (org.). **Artificial Intelligence and Machine Learning in Health Care and Medical Sciences**. Cham: Springer, 2024. p. 477–524.

ANDRADE, Bruno Souza Oliveira. **Concreto armado: um estudo sobre o processo histórico, características, durabilidade, proteção e recuperação de suas estruturas**. 2016. Monografia (Especialização em Construção Civil – Ênfase: Tecnologia e Produtividade das Construções) – Universidade Federal de Minas Gerais, Escola de Engenharia, Departamento de Engenharia de Materiais e Construção, Rio de Janeiro, 2016.

ASSIS, Fernando Fernandes; RABELO, Guilherme Quintino. **FISSURAS POR MOVIMENTAÇÃO TÉRMICA EM ESTRUTURAS DE CONCRETO ARMADO**. 2013. 74 f. Trabalho de conclusão de curso (Graduação em Engenharia Civil) - Universidade Federal de Goiás Escola de Engenharia Civil, Goiânia, 2013.

BOTERO, Eduardo Montoya. **Metodologia para aplicação de redes neurais artificiais para sistemas de alerta de escorregamentos deflagrados por chuvas em regiões montanhosas**. 2018. 98 f. Tese de doutorado em geotecnia (Faculdade de Tecnologia) – Universidade de Brasília, 2018.

BRAGA, Antônio de Pádua; LUDERMIR, Teresa Bernarda ; CARVALHO, André Carlos Ponce de Leon Ferreira. **Redes neurais artificiais: teoria e aplicações**. LTC editora, 2000.

BREGA, José Remo Ferreira. **A utilização de redes neurais artificiais em um sistema de gerência de pavimentos**. 1996.

CÂNDIDO, Williane Pascoal de Lima. **Laudo técnico de inspeção predial: estudo de caso em Imperatriz – MA**. 2023. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Civil) – Universidade Estadual da Região Tocantina do Maranhão, Açailândia, 2023.

CAVALCANTE, João Carlos da Silva; MARTINS, Fabiano Battemarco da Silva. **Manifestações patológicas na construção civil: estudo de caso**. TEC-USU, Rio de Janeiro, v. 5, n. 2, p. 79-100, 2022.

CHOLLET, François. **Deep learning with Python**. Manning Publications, 2018.

CORSINI, R. **Trinca ou fissura?**. São Paulo: Técnica. 160, p., jul. de 2010.

COUTO J. A. S., CARMINATTI R. L., NUNES R. R. A., MOURA R. C. A. O Concreto Como Material De Construção. 2013. Engenharia Civil ciências exatas e tecnológicas. **Cadernos de Graduação - Ciências Exatas e Tecnológicas**. Sergipe. v. 1; n.17; p. 49-58; out. 2013.

CUNHA, João Paulo Sena. **Uso de Redes Neurais Convolucionais para a identificação de manifestações patológicas no concreto armado**. 2025. 40 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Civil) – Centro de Tecnologia, Universidade Federal do Ceará, Crateús, 2025.

DO NASCIMENTO, F. B. C. Corrosão em armaduras de concreto. **Caderno de Graduação - Ciências Exatas e Tecnológicas - UNIT -ALAGOAS**, [S. l.], v. 3, n. 1, p. 177–188, 2015.

DUARTE, R. B. **Fissuras em alvenarias: causas principais, medidas preventivas e técnicas de recuperação**. Porto Alegre: CIENTEC, 1998. (Boletim técnico, 25).

DUTRA E. R.; **MANIFESTAÇÕES PATOLÓGICAS: FISSURAS Causas / Diagnóstico / Recuperação**. Belo Horizonte (MG), 2016.

FERREIRA, Jackeline Batista; LOBÃO, Victor Wandir Neves. **Manifestações patológicas na construção civil**. Cadernos de Graduação – Ciências Exatas e Tecnológicas, Aracaju, v. 5, n. 1, p. 71–80, out. 2018.

FINOCCHIO, Marco Antonio Ferreira. **Noções de redes neurais artificiais**. 2014.

FURTADO, Maria Inês Vasconcellos. **Redes neurais artificiais: uma abordagem para sala de aula**. Ponta Grossa: Atena Editora, 2019.

GENTIL. V; **Corrosão**. 6ed. Rio de Janeiro. BRASIL: LTC, 306p, 2012.

GHOSH, A.; CHAKRABORTY, D.; LAW, A. Artificial intelligence in internet of things. **CAAI Transactions on Intelligence Technology**, Wiley Online Library, v. 3, n. 4, p. 208–218, 2018.

GRAUPE, Daniel. **Principles of artificial neural networks**. World Scientific, 2013.

HAYKIN, Simon. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001.

HELENE, Paulo Roberto Do Lago. **Contribuição ao estudo da corrosão em armadura de concreto armado**. 1993. Tese – Escola Politécnica da Universidade de São Paulo. 1993.

HOLLERWEGER, Marcos Meyer. **Aplicação de Visão Computacional no Auxílio ao Levantamento de Defeitos em Pavimento Rodoviário**. 2019.

HUI, Jonathan. **mAP (mean Average Precision) for Object Detection**. Jonathan Hui Medium, 6 mar. 2018.

JUNIOR, Wanderlei Malaquias Pereira; SILVA, Sérgio Francisco; SILVA, Alessandro Rodrigues; REZIO, Luiz Henrique Ferreira; SILVA, Mateus Pereira; GUIMARÃES, Núbia Rosa da Silva; CANUTO, Sérgio Daniel Carvalho. Avaliação da presença de fissuras em imagens de estruturas de concreto através do uso de redes neurais profundas. **Revista Matéria**, v. 29, n. 4, 2024.

KRICHEN, M. Convolutional neural networks: A survey. **Computers**, MDPI, v. 12, n. 8, p. 151, 2023.

KORSTANJE, Joos. **The F1 score**. Towards Data Science, 31 ago. 2021.

LI, Fei-Fei; JOHNSON, Justin; YEUNG, Serena. **Lecture 11: Detection and Segmentation**, Stanford, 10 mai. 2017.

LI, Z.; LIU, F.; YANG, W.; PENG, S.; ZHOU, J. A survey of convolutional neural networks: analysis, applications, and prospects. **IEEE transactions on neural networks and learning systems**, v. 33, n. 12, p. 6999–7019, 2021.

LICHTENSTEIN, Norberto B. **Procedimento para formulação do diagnóstico de falhas e definição de conduta adequada à recuperação de edificações**. 1985. 191 f. Dissertação (Mestrado em Engenharia) – Escola Politécnica, Universidade de São Paulo, São Paulo, 1985.

LIMA C. I. V., COUTINHO C. O. D., AZEVEDO G. G. C., BARROS T. Y. G., TAUBER T. C., LIMA S. F. de. **Concreto E Suas Inovações**. 2014. Engenharia Civil ciências exatas e tecnológicas. Ciências exatas e tecnológicas. Maceió. v. 1; n.1; p. 31 40; maio 2014.

MCCULLOCH, W.S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, Springer, v. 5, p. 115–133, 1943.

MUNARO, R., POSSAN, E. Falha de concretagem de pilares e suas consequências na estrutura da edificação. In: **Simpósio Paranaense de Patologia das Construções**, 2017.

NOGARE, Diego. **Performance de Machine Learning – Matriz de Confusão**. Diego Nogare: Inteligência Artificial & Machine Learning, 27 Abr, 2020.

OLIVEIRA, A. M. D. **Fissuras, trincas e rachaduras causadas por recalque diferencial de fundações**. Universidade Federal de Minas Gerais. Belo Horizonte, p. 96. 2012.

OLIVEIRA, G. M. V.; CALDEIRA, P. H. A.; JUNIOR, L. A. S.; VIEIRA, A. C. Análise de fissuras em alvenaria de vedação – Estudo de caso: UEMG – Unidade de João Monlevade. **Research, Society and Development**, [S. l.], v. 8, n. 12, p. e368121617, 2019.

ÖZGENEL, Ç. F. (2018). **Concrete Crack Images for Classification**. Mendeley Data, v1. Disponível em: <https://data.mendeley.com/datasets/5y9wdsg2zt/1>.

PADILLA, Rafael; NETTO, Sergio L.; DA SILVA, Eduardo AB. A survey on performance metrics for object-detection algorithms. In: **2020 international conference on systems, signals and image processing (IWSSIP)**. IEEE, 2020. p. 237-242.

PATRÍCIO, D. I.; RIEDER, R. Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. **Computers and electronics in agriculture**, Elsevier, v. 153, p. 69–81, 2018.

PINTO FILHO, Alexandre Ricardo Fachini. **Estudo de caso: inspeção predial em residência e a importância da engenharia diagnóstica na formação dos engenheiros civis**. Universidade Estadual Paulista (Unesp), 2021.

RAUBER, Thomas Walter. **Redes neurais artificiais**. Vitória: Universidade Federal do Espírito Santo, 2005.

REDMON, Joseph et al. **You only look once**: Unified, real-time object detection. In: Proceedings of the IEEE conference on computer vision and pattern recognition. 2016. p. 779-788.

RIBANI, Ricardo; MARENGONI, Mauricio. A survey of transfer learning for convolutional neural networks. In: **2019 32nd SIBGRAPI conference on graphics, patterns and images tutorials (SIBGRAPI-T)**. IEEE, 2019. p. 47-57.

ROSEBROCK, Adrian. **Intersection over Union (IoU) for object detection**. PyImageSearch, 7 nov. 2016.

RUSSELL, S. J.; NORVIG, P. **Artificial intelligence a modern approach**. Pearson, 2016.

SANTOS, C. F. **Patologia de estruturas de concreto**. Universidade Federal de Santa Maria. Santa Maria, 2014.

SCHMIDHUBER, Jürgen. Deep learning in neural networks: An overview. **Neural Networks**, 61:85 – 117, 2015.

SHUTTERSTOCK. **Concrete wall cracks**. Shutterstock, 2025.

SHUTTERSTOCK. **Damaged concrete with rusted steel rods**. Shutterstock, 2025.

SILVA M. T. A., ROCHA J. H. A., MONTEIRO E. C. B.; Estimação da profundidade de fissuras em concreto através da velocidade de ondas ultrassônicas. 2019. **Revista Matéria**, v. 24; n. 04. Universidade de Pernambuco (UPE), Escola Politécnica de Pernambuco (POLI-UPE), Programa de Pós-Graduação em Engenharia Civil (PEC POLI).

SILVA, A. S. da; COSTA, D. B. Analise do uso de tecnologias digitais para identificação automatizada de patologias em construções. **XIX Encontro Nacional de Tecnologia do Ambiente Construído**, Canela, 2022.

SILVA, Ivan Nunes da; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes neurais artificiais para engenharia e ciências aplicadas**. 2010.

SOUZA, Átila Marconcine de. **Aplicação de redes neurais convolucionais na detecção de patologias do tipo panela em pavimentos asfálticos**. 2022. 66 f. Monografia (Bacharelado em Engenharia Civil) – Universidade Estadual da Região Tocantina do Maranhão (UEMASUL), Campus Açailândia, Açailândia, 2022.

SOUZA, Vicente Custódio Moreira de; RIPPER, Thomaz. **Patologia, recuperação e reforço de estruturas de concreto**. São Paulo: Pini, 1998.

SUBRAMANYAM, Vineeth S. **Basics of Bounding Boxes**. Analytics Vidhya, 16 jan. 2021.

SURGA, Koteswar. **Introduction to Object Detection in Deep Learning**. Koteswar Surga Medium, 5 nov. 2018.

SZELISKI, R. **Computer vision: algorithms and applications**. Springer Science & Business Media, 2010.

TAVARES, L. A.; MEIRA, M. C.; AMARAL, S. F. do. Inteligência artificial na educação: Survey. **Brazilian Journal of Development**, v. 6, n. 7, p. 48699–48714, 2020.

TAYLOR, Michael. **Neural Networks**: A visual introduction for beginners. Blue Windmill Media, 2017.

TRINDADE, D. S. **PATOLOGIA EM ESTRUTURAS DE CONCRETO ARMADO**. Engenharia Civil. Universidade Federal de Santa Maria. Santa Maria, RS, 2015.

VALENÇA, Mêuser. **Fundamentos das Redes Neurais**: exemplos em Java. Editora Livro Rápido, Recife 2007.

VASCONCELOS DE CARVALHO, Luis Henrique Duarte; MELO, José Jonas de Lima; MENDES, Henrique Ferreira; CAVALCANTE, Jonas Rafael Duarte. FISSURAS EM ALVENARIA ESTRUTURAL: CAUSAS E SOLUÇÕES. **Caderno de Graduação - Ciências Exatas e Tecnológicas - UNIT - SERGIPE**, [S. l.], v. 6, n. 3, p. 91, 2021. Disponível em: <https://periodicos.set.edu.br/cadernoexatas/article/view/7653>. Acesso em: 4 jun. 2026.

VASQUEZ, Fávio. Deep Learning made easy with Deep Cognition. **Becoming Human: Artificial Intelligence Magazine**, 21 dez. 2017.

VIJAYVERGIYA, Gaurav. **Custom Image dataset for YOLO object detection using Open image dataset**. Gaurav Vijayvergiya Medium, 5 dez. 2021.

YAMASHITA, Rikiya et al. Convolutional Neural Networks: an overview and application in radiology. **Insights into imaging**, v. 9, n. 4, p. 611-629, 2018.