



**Universidade Federal de Campina Grande**  
**Centro de Engenharia Elétrica e Informática**  
**Programa de Pós-Graduação em Engenharia Elétrica**

SAMUEL CESARINO DA NÓBREGA

**APLICAÇÃO DE TÉCNICAS DE VISÃO COMPUTACIONAL NO  
RECONHECIMENTO E NA DETECÇÃO DE DEFEITO EM  
ISOLADORES POLIMÉRICOS DE SUSPENSÃO**

Campina Grande, 12 de agosto de 2024

SAMUEL CESARINO DA NÓBREGA

APLICAÇÃO DE TÉCNICAS DE VISÃO COMPUTACIONAL NO  
RECONHECIMENTO E NA DETECÇÃO DE DEFEITO EM  
ISOLADORES POLIMÉRICOS DE SUSPENSÃO

*Dissertação apresentada à Coordenação do  
Programa de Pós-Graduação em Engenharia  
Elétrica da Universidade Federal de Campina  
Grande como parte dos requisitos necessários  
para a obtenção do grau de Mestre em Ciências  
no Domínio da Engenharia Elétrica.*

Área de Concentração: Processamento de Energia

Professor George Rossany Soares de Lira, D. Sc.

Orientador

Professor Pablo Bezerra Vilar, D. Sc.

Orientador

Campina Grande, Paraíba  
Agosto de 2024

N754a

Nóbrega, Samuel Cesarino da.

Aplicação de técnicas de visão computacional no reconhecimento e na detecção de defeito em isoladores poliméricos de suspensão / Samuel Cesarino da Nóbrega – Campina Grande, 2024.

90 f. : il. color.

Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Campina Grande, Centro de Engenharia Elétrica e Informática, 2024.

"Orientação: Prof. Dr. George Rossany Soares de Lira, Prof. Dr. Pablo Bezerra Vilar".

Referências.

1. Isolador Polimérico. 2. Fotografia. 3. You Only Look Once (YOLO). 4. Detecção de Defeitos em Isoladores. 5. Dimensão de Entrada. I. Lira, Geoge Rossany Soares de. II. Vilar, Pablo Bezerra. III. Título.

CDU 621.315.6(043)

**APLICAÇÃO DE TÉCNICAS DE VISÃO COMPUTACIONAL NO RECONHECIMENTO E  
NA DETECÇÃO DE DEFEITO EM ISOLADORES POLIMÉRICOS DE SUSPENSÃO**

**SAMUEL CESARINO DA NÓBREGA**

**DISSERTAÇÃO APROVADA EM 12/08/2024**

  
**GEORGE ROSSANY SOARES DE LIRA, D.Sc., UFCG**  
**Orientador(a)**

  
**PABLO BEZERRA VILAR, D.Sc., UFCG**  
**Orientador(a)**

  
**ELSON GUEDES DA COSTA, D.Sc., UFCG**  
**Examinador(a)**

  
**KARCIUS MARCELUS COLAÇO DANTAS, D.Sc., UFCG**  
**Examinador(a)**

**CAMPINA GRANDE - PB**

## AGRADECIMENTOS

Agradeço a Deus, em primeiro lugar, pela minha vida e por me dar sabedoria e sustento para conseguir superar todos os obstáculos que me apareceram ao longo dessa jornada árdua e difícil.

Agradeço aos meus pais, Antônio e Izabela, pelo apoio incondicional em cada fase da minha trajetória acadêmica, por acreditarem em mim e por terem me dado forças que foram essenciais para que eu chegasse até aqui.

Agradeço aos meus professores orientadores George Rossany Soares de Lira e Pablo Bezerra Vilar pela orientação cuidadosa, paciência, pelos feedbacks construtivos e todos incentivos e contribuições para o desenvolvimento desta pesquisa. Também agradeço ao professor Edson Guedes da Costa pelos conhecimentos transmitidos que contribuíram para esta pesquisa e por ter me fornecido ferramentas essenciais para o desenvolvimento deste trabalho.

Aos meus colegas da pós-graduação, especialmente a Giovanny, Igor e Breno, pelo companheirismo, pela boa convivência, ajuda diária e pelos bons momentos que tivemos ao longo desta jornada. Também agradeço a Vandilson pelos conhecimentos transmitidos, pelas boas conversas, por todo o apoio e pelos recursos fornecidos que também foram essenciais para o desenvolvimento deste trabalho.

Agradeço aos demais que fazem parte do Laboratório de Alta Tensão, em especial a Higor Costa, pelo suporte técnico, e aos funcionários José Adriano, Daniely e Evelyne, pelos serviços prestados no local.

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo auxílio financeiro.

Enfim, agradeço a todos que, de forma direta ou indireta, passaram pela minha vida e contribuíram para que eu pudesse me tornar a pessoa que eu sou hoje.

*“Ame a Verdade e seus frutos de vida, por  
você e pelos outros; consagre aos estudos  
e a seu uso o principal do seu tempo e do  
seu coração.”*

A.-D. Sertillanges.

## RESUMO

Os isoladores elétricos são equipamentos que apresentam um papel relevante na confiabilidade do sistema elétrico. Nas últimas décadas, os isoladores de vidro e de porcelana vêm sendo substituídos pelos isoladores poliméricos. Ainda que apresentem vantagens sobre os isoladores de vidro e de porcelana, os isoladores poliméricos são mais susceptíveis à ocorrência de defeitos devido à exposição à radiação solar e aos estresses elétricos. Além disso, o diagnóstico dos isoladores poliméricos é mais complexo, tendo em vista que os defeitos recorrentes são bastante pequenos e mais difíceis de serem detectados durante o processo de inspeção. Para tornar o processo de inspeção mais rápido, muitos pesquisadores estão propondo o uso de técnicas de Visão Computacional para a detecção de defeitos em cadeias de isoladores de vidro e de porcelana a partir de fotografias aéreas, porém são poucos os trabalhos que utilizam a mesma metodologia para a inspeção de isoladores poliméricos. Diante disso, o presente trabalho tem como objetivo identificar defeitos em isoladores poliméricos de suspensão a partir do uso de técnicas de Inteligência Artificial aplicadas a fotografias. Para tanto, são construídas bases de dados de fotografias de isoladores poliméricos em cinco diferentes distâncias entre câmera e isolador. Devido à necessidade de uma grande quantidade de dados para o treinamento de modelos de Visão Computacional, são utilizadas técnicas de *data augmentation* para a obtenção de novas amostras de fotografias. Em seguida, modelos *fine-tuning* de detectores YOLOv8 são treinados para realizar a detecção de quatro tipos de defeitos em isoladores: núcleo exposto, corrosão nas ferragens, rachaduras e cortes nas aletas. Por fim, é avaliado o impacto da distância entre a câmera e o isolador, da dimensão de entrada das fotografias e do tipo de modelo utilizado na detecção dos defeitos. Os resultados obtidos mostraram que a YOLOv8 é capaz de apresentar precisão, sensibilidade e AP acima de 90% na detecção de defeitos em isoladores a partir de fotografias capturadas dentro da distância de segurança entre câmera e isolador, desde que a resolução seja alta e que haja uma grande quantidade de dados para treinamento.

**Palavras-chave:** Isolador polimérico, fotografia, You Only Look Once (YOLO), defeito, distância, dimensão de entrada.

## ABSTRACT

Electrical insulators play a significant role in the reliability of the power system. In recent decades, glass and porcelain insulators have been replaced by polymeric insulators. Although they have advantages over glass and porcelain insulators, polymeric insulators are more susceptible to defects due to exposure to solar radiation and electrical stress. Additionally, the diagnosis of polymeric insulators is more complex, as the recurrent defects are quite small and more difficult to detect during the inspection process. To make the inspection process faster, many researchers are proposing the use of Computer Vision techniques to detect defects in glass and porcelain insulator strings from aerial images. However, few works have used the same methodology for to inspect polymeric insulators. Therefore, the present work aims to identify defects in polymeric suspension insulators using Artificial Intelligence techniques applied to images. To this end, datasets of polymeric insulator images at five different distances between the camera and the insulator are constructed. Due to the need for a large amount of data to train Computer Vision models, data augmentation techniques are used to obtain new samples of images. Next, fine-tuning models of YOLOv8 detectors are trained to detect four types of defects in insulators: exposed rod, end fitting corrosion, cracks, and damaged sheds. Finally, the impact of the distance between the camera and the insulator, the input size of the images, and the type of model used to detect defects is evaluated. The results showed that YOLOv8 can detect defects in polymeric insulators with precision, sensitivity, and AP above 90% from images captured within the safety distance between the camera and the insulator, as long as the input size is high and there is a large amount of data for training.

**Keywords:** Polymeric insulator, image, You Only Look Once (YOLO), defect, distance, input size.

## LISTA DE FIGURAS

Figura 1 – Imagem de um isolador (a) de vidro, (b) de porcelana e (c) polimérico. ....	6
Figura 2 – Partes Constituintes de um Isolador Polimérico.....	7
Figura 3 – Fotografias de Isoladores Poliméricos do tipo (a) pino, (b) pilar e (c) de suspensão. ....	9
Figura 4 – Fotografias de Isoladores Poliméricos com Aletas Danificadas.....	10
Figura 5 – Fotografias de Isoladores Poliméricos com Fissuras no Revestimento.....	10
Figura 6 – Fotografias de Isoladores Poliméricos com Perfuração. ....	11
Figura 7 – Fotografias de Isoladores com Erosão na Superfície Polimérica. ....	11
Figura 8 – Fotografias de Isoladores Poliméricos com Trilhamento. ....	12
Figura 9 – Fotografias de Isoladores Poliméricos com Núcleo Exposto. ....	12
Figura 10 – Fotografias de Isoladores Poliméricos com Ferragem Corroída. ....	13
Figura 11 – Fotografias de Isoladores Poliméricos Poluídos.....	13
Figura 12 – Exemplo de um modelo <i>deep learning</i> utilizado para reconhecimento facial.....	17
Figura 13 – Modelo de um neurônio artificial.....	17
Figura 14 – Estrutura de uma RNA.....	18
Figura 15 – Exemplo de uma estrutura de CNN.....	19
Figura 16 – Exemplo de operações de <i>Average Pooling</i> e <i>Max Pooling</i> .....	20
Figura 17 – Detecção de Objetos em uma Imagem.....	22
Figura 18 – Parâmetros de uma caixa delimitadora.....	22
Figura 19 – Etapas da detecção de objetos em detectores de dois estágios. ....	22
Figura 20 – Processo de detecção de objetos da YOLO.....	24
Figura 21 – Exemplo de predição de saída da YOLO com base nas <i>anchor boxes</i> .....	25
Figura 22 – Partes principais da arquitetura YOLO. ....	25
Figura 23 – Diagrama ilustrativo da função de perdas da YOLO. ....	27
Figura 24 – Exemplo de fotografia (a) original, (b) expandida por espelhamento horizontal, (c) expandida por espelhamento vertical, (d) expandida por rotação, (e) expandida por translação para a direita e para cima, (f) expandida por zoom de aproximação e (g) expandida por zoom de afastamento. ....	32
Figura 25 – Exemplo de fotografia (a) original e de amostras obtidas pela inserção de (b) borrão, (c) ruído gaussiano e (d) <i>random erasing</i> . ....	33
Figura 26 – Fluxograma que resume a metodologia proposta.....	48
Figura 27 – Fotografia do banco de isoladores poliméricos de suspensão utilizados nesta pesquisa. ....	49
Figura 28 – Cenários utilizados na etapa de captura das fotografias. ....	50
Figura 29 – Posicionamento do isolador e do conjunto câmera-tripé para a captura das fotografias na câmara de névoa. ....	50
Figura 30 – Interface do LabelImg.....	52
Figura 31 – Exemplo de rotulagem de um isolador com uma aleta cortada e duas rachaduras. ....	52
Figura 32 – Ilustração da utilização da técnica do mosaico.....	53
Figura 33 – Exemplos de fotografias capturadas.....	58
Figura 34 – Exemplos de fotografias com seus respectivos rótulos. ....	59
Figura 35 – Exemplos de fotografias obtidas na primeira parte da etapa de <i>data augmentation</i> . ....	60
Figura 36 – Exemplos de novas amostras obtidas pela inserção de (a) ruído gaussiano e condições de (b) névoa, (c) luminosidade e (d) chuva.....	61
Figura 37 – Exemplos de fotografias obtidas após a segunda parte da etapa de <i>data augmentation</i> . ....	61
Figura 38 – Gráficos de precisão para cada modelo.....	63

## LISTA DE TABELAS

Tabela 1 – Quadro sinóptico comparativo do estado da arte e da presente dissertação.....	47
Tabela 2 – Características das bases de dados obtidas após cada parte do <i>data augmentation</i> .....	53
Tabela 3 – Hiperparâmetros do treinamento dos modelos.....	54
Tabela 4 – Rótulos das classes .....	55
Tabela 5 – Quantidade de fotografias, isoladores e defeitos por base de dados. ....	59
Tabela 6 – Quantidade de fotografias, isoladores e defeitos por base de dados após a parte 1 do <i>data augmentation</i> .....	62
Tabela 7 – Quantidade de fotografias, isoladores e defeitos por base de dados após a parte 2 do <i>data augmentation</i> .....	62
Tabela 8 – Tempo de treinamento para cada modelo. ....	63
Tabela 9 – Desempenho da YOLOv8s com dimensão de entrada de 2560x2560 pixels após o treinamento com a base de dados oriunda da parte 1 do <i>data augmentation</i> .....	66
Tabela 10 – Desempenho da YOLOv8m com dimensão de entrada de 2560x2560 pixels após o treinamento com a base de dados oriunda da parte 1 do <i>data augmentation</i> .....	66
Tabela 11 – Desempenho da YOLOv8s com dimensão de entrada de 2560x2560 pixels após o treinamento com a base de dados oriunda da parte 2 do <i>data augmentation</i> .....	67
Tabela 12 – Desempenho da YOLOv8m com dimensão de entrada de 2560x2560 pixels após o treinamento com a base de dados oriunda da parte 2 do <i>data augmentation</i> .....	67
Tabela 13 – Trabalhos científicos publicados ao longo desta pesquisa. ....	71
Tabela 14 – Desempenho da YOLOv8s com dimensão de entrada de 1280x1280 pixels após o treinamento com a base de dados oriunda da parte 1 do <i>data augmentation</i> .....	79
Tabela 15 – Desempenho da YOLOv8m com dimensão de entrada de 1280x1280 pixels após o treinamento com a base de dados oriunda da parte 1 do <i>data augmentation</i> .....	79
Tabela 16 – Desempenho da YOLOv8s com dimensão de entrada de 1920x1920 pixels após o treinamento com a base de dados oriunda da parte 1 do <i>data augmentation</i> .....	79
Tabela 17 – Desempenho da YOLOv8m com dimensão de entrada de 1920x1920 pixels após o treinamento com a base de dados oriunda da parte 1 do <i>data augmentation</i> .....	79
Tabela 18 – Desempenho da YOLOv8s com dimensão de entrada de 2560x2560 pixels após o treinamento com a base de dados oriunda da parte 1 do <i>data augmentation</i> .....	80
Tabela 19 – Desempenho da YOLOv8m com dimensão de entrada de 2560x2560 pixels após o treinamento com a base de dados oriunda da parte 1 do <i>data augmentation</i> .....	80
Tabela 20 – Desempenho da YOLOv8s com dimensão de entrada de 1280x1280 pixels após o treinamento com a base de dados oriunda da parte 2 do <i>data augmentation</i> .....	80
Tabela 21 – Desempenho da YOLOv8m com dimensão de entrada de 1280x1280 pixels após o treinamento com a base de dados oriunda da parte 2 do <i>data augmentation</i> .....	80
Tabela 22 – Desempenho da YOLOv8s com dimensão de entrada de 1920x1920 pixels após o treinamento com a base de dados oriunda da parte 2 do <i>data augmentation</i> .....	80
Tabela 23 – Desempenho da YOLOv8m com dimensão de entrada de 1920x1920 pixels após o treinamento com a base de dados oriunda da parte 2 do <i>data augmentation</i> .....	81
Tabela 24 – Desempenho da YOLOv8s com dimensão de entrada de 2560x2560 pixels após o treinamento com a base de dados oriunda da parte 2 do <i>data augmentation</i> .....	81
Tabela 25 – Desempenho da YOLOv8m com dimensão de entrada de 2560x2560 pixels após o treinamento com a base de dados oriunda da parte 2 do <i>data augmentation</i> .....	81

# SUMÁRIO

1	Introdução.....	1
1.1	Objetivos.....	3
1.2	Estrutura do Trabalho.....	3
2	Fundamentação Teórica.....	5
2.1	Isoladores Elétricos.....	5
2.1.1	Defeitos Externos em Isoladores Poliméricos.....	9
2.1.2	Inspeção de Isoladores.....	13
2.2	<i>Deep Learning</i> .....	16
2.2.1	Redes Neurais Convolucionais.....	19
2.2.2	Visão Computacional.....	21
2.2.2.1	<i>You Only Look Once (YOLO)</i> .....	23
2.2.3	Métricas de Avaliação de Desempenho.....	28
2.2.4	<i>Data Augmentation</i> .....	31
3	Revisão Bibliográfica.....	35
3.1	Estado da Arte.....	35
3.1.1	Diagnóstico de isoladores a partir de modelos tradicionais.....	35
3.1.2	Diagnóstico de isoladores a partir de <i>deep learning</i> .....	37
3.1.3	Uso ou Aprimoramento das Técnicas de <i>Data Augmentation</i> .....	42
3.2	Considerações sobre o estado da arte.....	45
4	Metodologia.....	48
4.1	Desenvolvimento da Base de Dados.....	48
4.1.1	Construção da base de imagens de isoladores.....	49
4.1.2	Rotulagem das imagens e <i>Data Augmentation</i> .....	51
4.2	Treinamento dos Modelos.....	54
5	Resultados e Discussões.....	57
5.1	Bases de Dados Desenvolvidas.....	57
5.2	Desenvolvimento e Análise de Resultados de Classificador de Fotografias.....	62
5.3	Aplicação de <i>Data Augmentation</i> .....	65
6	Conclusão.....	69
6.1	Trabalhos Futuros.....	70
6.2	Publicações.....	71
	Referências.....	72
	Apêndice A – Código da YOLO.....	78
	APÊNDICE B – Resultados Obtidos para Cada Caso Analisado.....	79

# 1 INTRODUÇÃO

Falhas que ocorrem no isolamento elétrico entre os condutores das linhas de transmissão correspondem a 81,3% das intercorrências que ocorrem nos sistemas elétricos de potência (TONG, YUAN & LI, 2010). O principal componente físico utilizado para o isolamento elétrico é o isolador, que também é responsável por suportar mecanicamente os esforços produzidos pelos condutores, os efeitos da variação de temperatura, do vento e, em caso de falha de outros componentes, as consequências de um possível curto-circuito.

Os isoladores elétricos podem ser classificados de acordo com o material empregado no revestimento, que pode ser: vidro, porcelana ou polímero. Os isoladores de vidro e de porcelana são utilizados pelo setor elétrico há mais de um século, principalmente pelas boas propriedades isolantes, resistência ao calor e à degradação natural. No entanto, desde a década de 1980, os isoladores poliméricos vêm gradativamente substituindo os isoladores de vidro e de porcelana, principalmente por possuírem peso relativamente menor e baixo custo. Além disso, os isoladores poliméricos apresentam vantagens como maior resistência a impactos mecânicos e à poluição externa e melhor hidrofobicidade.

Os isoladores estão sujeitos a vários fenômenos naturais e condições ambientais, tais como campo elétrico elevado, radiação solar, ação do vento, descargas atmosféricas e depósito de contaminantes. Em isoladores poliméricos, a ocorrência destes fenômenos favorece o surgimento de defeitos, como fissuras, rachaduras, aberturas e trilhamento no revestimento, corrosão das ferragens e exposição do núcleo. Dessa forma, torna-se necessário realizar inspeções regulares, uma vez que a ocorrência de tais defeitos pode afetar a segurança e a confiabilidade dos sistemas elétricos de potência. Além disso, é importante que as inspeções sejam realizadas de forma rápida e precisa, a fim de que os isoladores sejam substituídos o mais rápido possível.

Tradicionalmente, o monitoramento de isoladores é feito através de inspeções visual, com o envio de técnicos aos locais onde os isoladores estão instalados. Neste contexto, devido ao crescimento do sistema elétrico de potência, está cada vez mais difícil monitorar os isoladores distribuídos ao longo de quilômetros de extensão de linhas de

transmissão. Destaca-se ainda que as inspeções visuais são demoradas, pois exigem que os técnicos escalem as torres de transmissão ou se desloquem por helicóptero para inspecionar os isoladores, o que aumenta o risco de acidentes e compromete a segurança humana.

Com o intuito de tornar o processo de inspeção mais rápido, confiável e barato, além de reduzir o risco de acidentes, pesquisadores estão propondo o uso técnicas de Visão Computacional para diagnosticar as condições operativas de isoladores elétricos a partir de fotografias aéreas capturadas por Veículos Aéreos Não-Tripulados (VANTs) (TAO *et al.*, 2020; ZHAO *et al.*, 2021; YANG, XU & WANG, 2022; HAO *et al.*, 2022; CHENG, 2022; ZHANG *et al.*, 2022). Embora ainda não exista um modelo que alcance, ao mesmo tempo, elevada precisão, elevada velocidade e reduzido consumo de memória, alguns trabalhos conseguiram produzir classificadores cujos resultados demonstraram compatibilidade com os requisitos para detecção em tempo real e leves o suficiente para implantação e experimentação em dispositivos móveis (CHEN *et al.*, 2023).

A partir de uma análise do estado da arte, é possível constatar que, embora as técnicas de Visão Computacional utilizadas para o reconhecimento e diagnóstico de isoladores estejam em evidência, a maioria dos trabalhos se concentrou exclusivamente na detecção de discos ausentes em cadeias de isoladores de vidro ou porcelana, sem se aprofundar em outros tipos de defeitos (TAO *et al.*, 2020; ZHAO *et al.*, 2021; HAO *et al.*, 2022; YANG, XU & WANG, 2022; ZHANG *et al.*, 2022). Destaca-se que, além de muito específico, esse tipo de defeito não costuma requerer intervenção urgente, uma vez que, cadeias de isolador podem se manter em operação mesmo que um de seus discos quebre. Além disso, é possível observar que há uma escassez de trabalhos que aplicaram técnicas de Visão Computacional no diagnóstico de isoladores poliméricos de suspensão, isso pode ser atribuído ao fato que para esses isoladores a detecção visual de defeitos é consideravelmente mais complexa, uma vez que os defeitos típicos ocupam áreas pequenas e difíceis de serem observados durante a inspeção e alguns deles, como núcleo exposto e fissuras no revestimento, exigem manutenção imediata.

Diante do exposto, este trabalho de dissertação visa contribuir para o diagnóstico de isoladores poliméricos a partir da aplicação de visão computacional, com base no que tem sido feito nos trabalhos anteriores. Para tanto, propõe-se a construção de uma base de dados de fotografias de isoladores poliméricos de suspensão e a utilização de técnicas de Visão Computacional para analisar as imagens produzidas.

## 1.1 OBJETIVOS

O objetivo geral desta pesquisa é identificar defeitos em isoladores poliméricos de suspensão a partir do uso de técnicas de Visão Computacional aplicada a fotografias.

Para atingir o objetivo geral proposto, serão necessários os seguintes objetivos específicos:

- Construir uma base de dados de fotografias de isoladores poliméricos íntegros e defeituosos;
- Avaliar e implementar técnicas expansão artificial de bases de dados de fotografias;
- Avaliar e aplicar estratégias de *fine-tuning* em modelos de Visão Computacional aptos a diagnosticar defeitos em isoladores;
- Avaliar o impacto de elevar a complexidade do modelo de classificação por meio de métricas adequadas;
- Avaliar o impacto da distância entre câmera e isolador no desempenho dos modelos propostos por meio de métricas adequadas.

## 1.2 ESTRUTURA DO TRABALHO

Este trabalho se encontra dividido em 5 capítulos, conforme descrito a seguir.

No primeiro capítulo foi apresentada uma introdução, contendo uma breve contextualização e motivação a respeito da temática abordada na pesquisa, bem como os objetivos e a estrutura deste trabalho.

No segundo capítulo será apresentada uma fundamentação teórica sobre isoladores, suas principais técnicas de inspeção, Visão Computacional e as principais técnicas utilizadas no processamento de imagens e na detecção de objetos.

No terceiro capítulo será discutido o estado da arte das principais técnicas de Visão Computacional e de *data augmentation* empregadas no reconhecimento e no diagnóstico de isoladores em geral a partir de fotografias, com o objetivo de apresentar a evolução das pesquisas nesta área.

No quarto capítulo será apresentada a metodologia utilizada nesta pesquisa, descrevendo os procedimentos para o desenvolvimento da base de dados, a utilização das

técnicas de *data augmentation* e do treinamento e avaliação dos modelos utilizados para diagnosticar os isoladores a partir de fotografias.

No quinto capítulo serão apresentados e discutidos os resultados referentes a cada modelo utilizado e uma avaliação a respeito do impacto da distância e da resolução das fotografias no desempenho da detecção dos defeitos.

Por fim, no sexto capítulo serão apresentadas as considerações finais, bem como sugestões de trabalhos futuros para a continuidade da pesquisa.

## 2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo será apresentada a Fundamentação Teórica necessária para a compreensão da pesquisa abordada no presente trabalho. Serão discutidos tópicos relacionados a isoladores elétricos, com foco na inspeção visual e nos principais tipos de defeitos, e Visão Computacional, com foco em técnicas de *data augmentation* e técnicas de *deep learning* para identificação de objetos.

### 2.1 ISOLADORES ELÉTRICOS

O isolamento elétrico de linhas aéreas de transmissão e de distribuição ocorre por meio do ar atmosférico e por meio dos isoladores elétricos. Os isoladores são componentes utilizados para suportar e fixar mecanicamente condutores nas linhas de transmissão, além de isolar eletricamente duas regiões de potenciais elétricos distintos, como, por exemplo, dois condutores ou um condutor e a torre (GORUR, CHERNEY & BURNHAM, 1999). Por isso, a disponibilidade dos isoladores elétricos tem um papel de grande relevância para o sistema elétrico de potência.

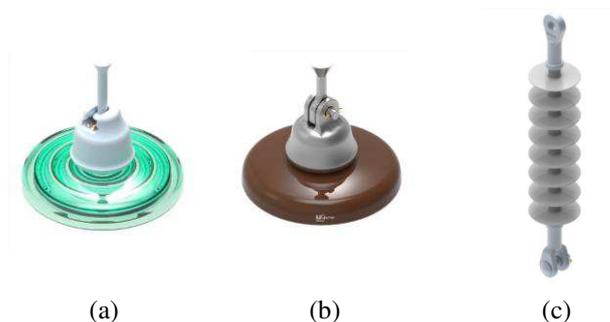
Quando em boas condições operacionais, os isoladores devem possuir as seguintes características (GORUR, CHERNEY & BURNHAM, 1999):

- Garantir uma baixa corrente de fuga em meio a diversas condições elétricas, como condições de tensão nominal e sobretensões de origem atmosférica, de manobra ou em frequência industrial;
- Garantir o isolamento elétrico em condições de intempéries naturais, como chuva, neve, gelo, poluição atmosférica e sujeira;
- Suportar mecanicamente o peso dos condutores das linhas de transmissão;
- Suportar os efeitos mecânicos resultantes da redução da temperatura ambiente, do vento e, caso outros componentes falhem, de um possível curto-circuito.

Um isolador elétrico é composto basicamente por três estruturas: o dielétrico, as ferragens e partes internas que auxiliam a conexão entre as ferragens e o dielétrico. O formato e a dimensão podem variar de acordo com as tensões nominais das linhas de

transmissão ou distribuição nos quais são empregados. De forma geral, os isoladores elétricos podem ser classificados de acordo com o tipo de dielétrico aplicado em sua construção. Dessa forma, são utilizados atualmente isoladores do tipo cerâmico, cujo dielétrico é fabricado em porcelana ou vidro, ou do tipo compósito, também conhecido como polimérico, cujo dielétrico é fabricado à base de material polimérico, como, por exemplo, borracha de silicone ou etileno-propileno-dieno. Na Figura 1 é possível observar imagens dos três tipos de isoladores elétricos.

Figura 1 – Imagem de um isolador (a) de vidro, (b) de porcelana e (c) polimérico.



Fonte: (GERMER, 2014).

Os isoladores cerâmicos são empregados pelo setor elétrico há mais de um século. O vidro e a porcelana possuem boas propriedades isolantes, resistência ao calor e à degradação natural e são inertes para a maioria dos compostos químicos. Porém, os isoladores cerâmicos são densos e frágeis, o que dificulta sua instalação, além de serem suscetíveis ao vandalismo e à quebra durante o manuseio. Devido a essas desvantagens, os isoladores cerâmicos vêm sendo gradualmente substituídos pelos isoladores poliméricos (GORUR, CHERNEY & BURNHAM, 1999).

O crescimento do uso de isoladores poliméricos a partir da década de 1980 ocorreu devido a diversas vantagens em comparação isoladores cerâmicos. Dentre elas, a principal característica é o peso reduzido, 90% menor em comparação a uma cadeia de isolador cerâmico (GUBANSKI, 2005). Consequentemente, houve uma maior facilidade de manuseio e transporte, o que contribuiu com uma redução nos custos de fabricação, transporte, instalação e manutenção e uma produção em maior escala. Além disso, os isoladores poliméricos apresentam maior resistência aos impactos mecânicos, à contaminação externa e ao vandalismo e melhores características hidrofóbicas.

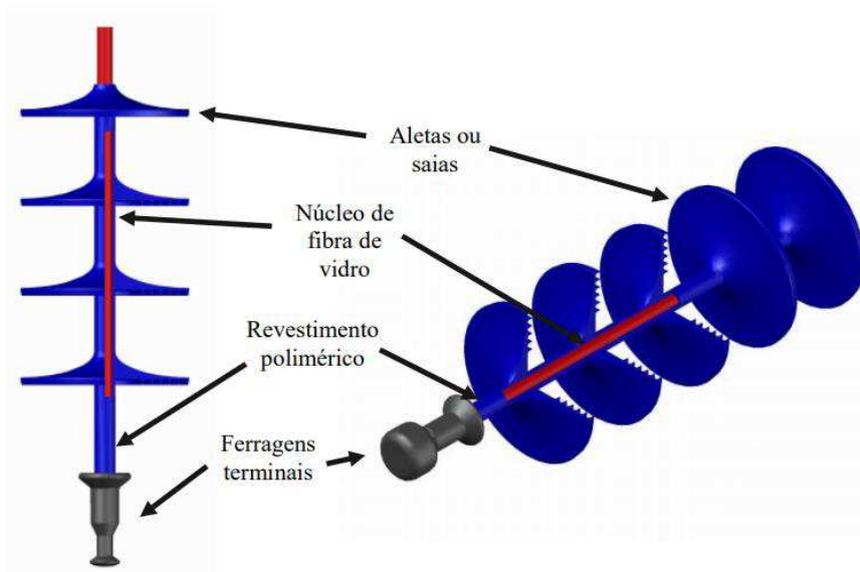
Por outro lado, os isoladores poliméricos ainda apresentam algumas desvantagens quando comparados aos isoladores cerâmicos, tais como:

- Dificuldade na identificação visual de falhas internas, como bolhas, fraturas ou desacoplamento no núcleo;
- Susceptibilidade à degradação devido à exposição à radiação ultravioleta;
- Susceptibilidade a danos elétricos causados pelo efeito corona, descargas parciais e superficiais e corrente de fuga;
- Perda da hidrofobicidade devido a influências ambientais ou atividades elétricas;
- Desempenho a longo prazo desconhecido.

Um isolador polimérico é constituído por um núcleo de fibra de vidro reforçado, revestido com material polimérico, aletas (também conhecidas como saias) e ferragens terminais. Na Figura 2 é possível observar as principais partes constituintes de um isolador polimérico.

O núcleo de um isolador polimérico é constituído de fibra de vidro reforçada (FRP – *Fiber Reinforced Plastic Rod*), formado por uma fibra de vidro e uma resina plástica impregnante, que pode ser de poliéster, vinil ou epóxi (NERI, 2005). A função do núcleo é suportar os esforços mecânicos de tração, torção e compressão provenientes do peso do cabo, vento, chuva e variações de temperatura.

Figura 2 – Partes Constituintes de um Isolador Polimérico.



Fonte: Adaptado de LAPP INSULATORS, 2019.

O revestimento polimérico do isolador tem como função proteger o núcleo contra agentes externos, como umidade, radiação ultravioleta e poluição atmosférica. Além de proteger o núcleo, o revestimento polimérico também é projetado para fornecer uma

superfície hidrofóbica capaz de impedir a formação de lâminas de água ao longo do isolador. Também fazem parte do revestimento as aletas, que têm como função aumentar a distância de escoamento entre as ferragens terminais, que é a menor distância ao longo da superfície polimérica entre as ferragens fase e terra. As aletas permitem o gotejamento em condições de névoa ou sob chuva, evitando a formação de caminhos condutivos ao longo da superfície. O formato e dimensão das aletas e o comprimento do isolador variam conforme as condições ambientais e de serviço. Por exemplo, para uma mesma classe de tensão, quanto maior a proximidade do sistema elétrico em relação ao mar ou a centros de poluição, maior deverá ser a distância de escoamento e, conseqüentemente, maior o diâmetro das aletas e o comprimento do isolador.

Por sua vez, as ferragens terminais têm como função realizar as interligações condutor/isolador e isolador/estrutura e transmitir ao núcleo os esforços mecânicos provenientes do condutor. Geralmente, são constituídas de aço, alumínio forjado ou fundido ou ferro maleável. O formato das ferragens terminais é de grande relevância, pois busca equalizar o campo elétrico em torno do isolador, evitando possíveis descargas corona ou estresse elétrico no material. Para tornar a distribuição de campo mais uniforme, anéis equalizadores são utilizados junto às ferragens, principalmente em linhas de transmissão com tensão nominal igual ou superior a 69 kV (MENDONÇA, 2016).

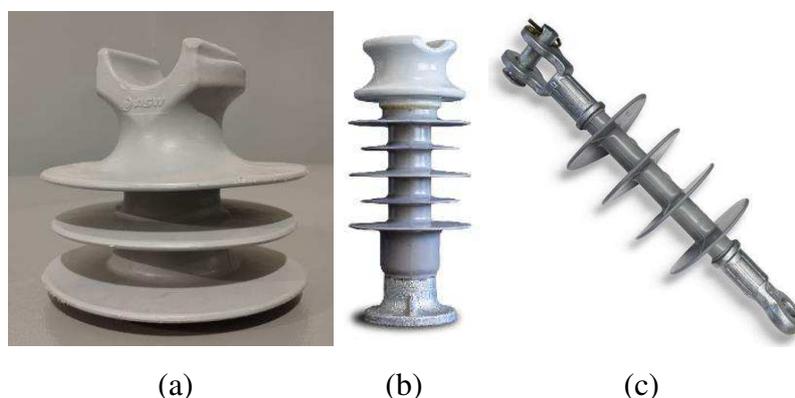
Os isoladores elétricos estão sujeitos a vários fenômenos naturais, como a ação do vento, radiação solar, variação de temperatura, poluição e descargas atmosféricas, como chuvas, neblinas, orvalhos e neve. Quando associados à ação do campo elétrico, esses fenômenos favorecem o surgimento de defeitos ao longo do isolador, como o surgimento de trincas, quebras ou até mesmo ausência de um dos discos que compõe a cadeia, no caso de isoladores cerâmicos, e degradação dos materiais do revestimento, no caso de isoladores poliméricos. A presença de falhas em isoladores elétricos pode afetar a segurança, confiabilidade e disponibilidade do fornecimento de energia elétrica pelos sistemas elétricos de potência.

Os isoladores poliméricos podem ser classificados em relação ao modo de instalação e funcionamento como:

- Isoladores de pino: são caracterizados por ser fixados à estrutura a partir de um pino. São utilizados em linhas de distribuição e de subtransmissão com tensão de até 69 kV e com condutores relativamente leves (FUCHS, 1977);

- Isoladores tipo pilar: são menos frequentes, porém são projetados para resistir a esforços mais elevados, tanto de compressão como de flexão (FUCHS, 1977);
- Isolador de suspensão: bastante utilizados em linhas de transmissão, constitui-se de peça única e possui peso reduzido comparado com as cadeias de isoladores cerâmicos. Na Figura 3 é possível observar exemplos de isoladores poliméricos de pino, tipo pilar e de suspensão da classe de tensão de 15 kV.

Figura 3 – Fotografias de Isoladores Poliméricos do tipo (a) pino, (b) pilar e (c) de suspensão.



Fonte: (a) Autoria própria, (b) BALESTRO e (c) KV LUX.

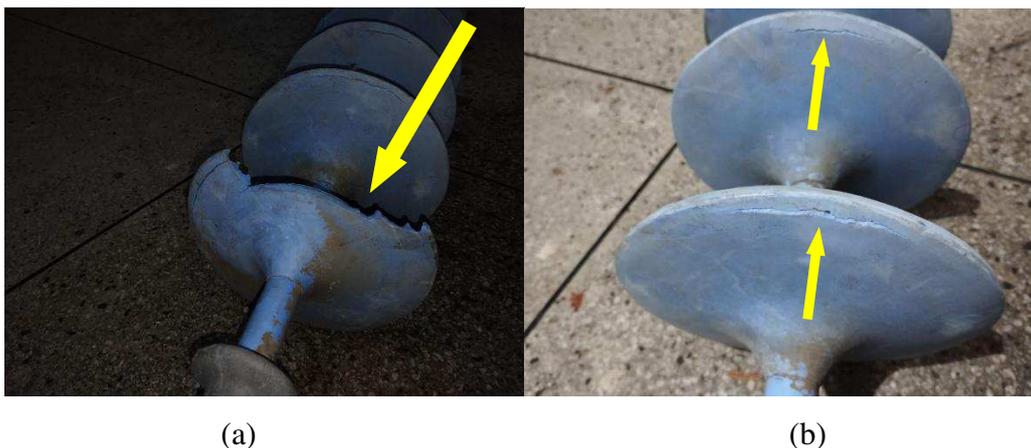
### 2.1.1 DEFEITOS EXTERNOS EM ISOLADORES POLIMÉRICOS

Os isoladores poliméricos estão sujeitos a diversos tipos de defeitos externos, que podem ocorrer por falhas no processo de fabricação, manejo durante transporte e instalação, vandalismo, estresses elétricos e contaminação química (GORUR, CHERNEY & BURNHAM, 1999; FLORENTINO, 2019). Além disso, a exposição do isolador a agentes ambientais e esforços mecânicos e elétricos pode modificar as propriedades do material polimérico, o que pode dar origem a novos defeitos ou agravar as falhas já existentes.

De acordo com guias como EPRI (2006) e STRI (2005), os defeitos externos podem ser classificados de acordo com a região do isolador que é atingida: aletas, revestimento do núcleo e ferragens terminais. Os defeitos mais frequentes em isoladores poliméricos são:

- Aleta cortada, fragmentada ou perfurada: esse tipo de defeito pode ser oriundo de ventos fortes, ação de aves de rapina, envelhecimento do material polimérico, vandalismos ou manuseio inadequado (DOMINGUES, 2012; EPRI, 2006; STRI, 2005). Na Figura 4 é possível observar exemplos de fotografias de isoladores com aletas cortadas e fragmentadas.

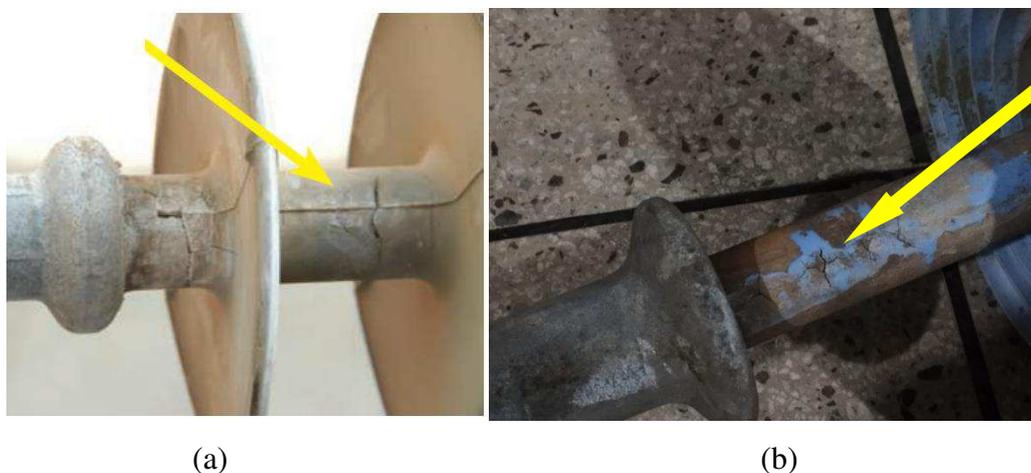
Figura 4 – Fotografias de Isoladores Poliméricos com Aletas Danificadas.



Fonte: Autoria Própria.

- Fissuras: fendas ou aberturas no revestimento polimérico oriundas do bombardeamento por elétrons em campos elétricos intensos ou defeitos de fabricação. Em alguns casos, podem expor o núcleo do isolador (DOMINGUES, 2012; STRI, 2005; EPRI, 2006). Na Figura 5 se encontram fotografias de isoladores poliméricos com fissuras no revestimento.

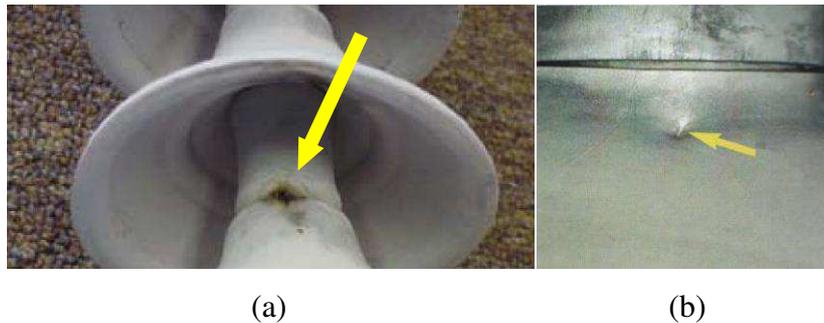
Figura 5 – Fotografias de Isoladores Poliméricos com Fissuras no Revestimento.



Fonte: (a) EPRI, 2006, (b) autoria própria.

- Perfurações no revestimento polimérico: furos ou orifícios presentes no revestimento polimérico do isolador, oriundos de descargas disruptivas. Em alguns casos, podem atingir o núcleo (DOMINGUES, 2012; STRI, 2005; EPRI, 2006). Na Figura 6 é possível observar fotografias de isoladores poliméricos com perfurações.

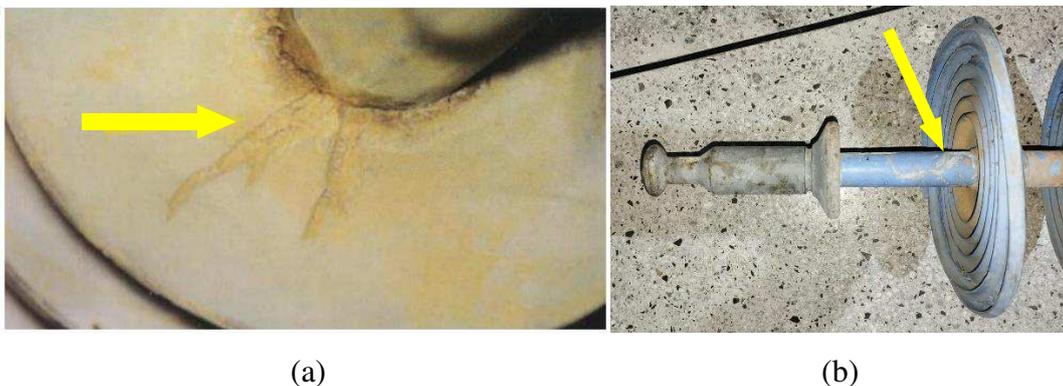
Figura 6 – Fotografias de Isoladores Poliméricos com Perfuração.



Fonte: (a) DOMINGUES, 2012, (b) EPRI, 2006.

- Erosão: perda de material na superfície polimérica do isolador, oriunda de condições severas de poluição e umidade ou até mesmo devido a erros de projeto ou fabricação (DOMINGUES, 2012; EPRI, 2006; FLORENTINO, 2019). Na Figura 7 são apresentadas fotografias de isoladores com erosão na superfície polimérica.

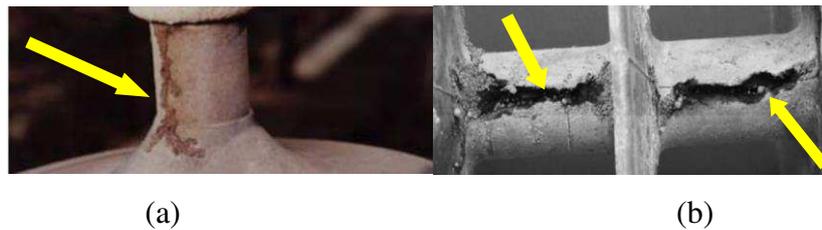
Figura 7 – Fotografias de Isoladores com Erosão na Superfície Polimérica.



Fonte: (a) DOMINGUES, 2012, (b) autoria própria.

- Trilhamento: consiste na formação de uma camada condutiva na superfície polimérica devido à circulação intensa de correntes de fuga ou alta concentração de contaminantes poluentes (DOMINGUES, 2012; EPRI, 2006; STRI, 2005). Na Figura 8 se encontram fotografias de isoladores poliméricos com trilhamento.

Figura 8 – Fotografias de Isoladores Poliméricos com Trilhamento.



Fonte: DOMINGUES, 2012.

- Núcleo exposto: exposição do núcleo do isolador ao meio ambiente devido a danos causados no revestimento polimérico, como erosão, fissuras e perfuração (DOMINGUES, 2012; EPRI, 2006). Na Figura 9 são apresentadas fotografias de isoladores poliméricos com núcleo exposto.

Figura 9 – Fotografias de Isoladores Poliméricos com Núcleo Exposto.



Fonte: (a) DOMINGUES, 2012, (b) autoria própria.

- Corrosão das ferragens: corrosão do material metálico das ferragens do isolador provocada por condições severas de umidade e poluição ou galvanização inadequada (EPRI, 2006). Na Figura 10 é possível observar fotografias de isoladores poliméricos com ferragem corroída.
- Poluição: acúmulo de contaminantes poluentes na superfície polimérica do isolador, como poeira, fuligem, névoa de sal oriunda de áreas marinhas, areia, gesso e cimento. Na Figura 11 são apresentadas fotografias de isoladores poliméricos poluídos.

Figura 10 – Fotografias de Isoladores Poliméricos com Ferragem Corroída.



(a)

(b)

Fonte: (a) EPRI, 2006, (b) autoria própria.

Figura 11 – Fotografias de Isoladores Poliméricos Poluídos.



(a)

(b)

Fonte: (a) EPRI, 2006, (b) autoria própria.

### 2.1.2 INSPEÇÃO DE ISOLADORES

Devido à importância dos isoladores elétricos e ao impacto do surgimento de defeitos nos mesmos nos sistemas elétricos de potência, é importante que inspeções sejam realizadas rotineiramente, de forma rápida e precisa. As inspeções em isoladores têm o intuito de identificar e avaliar irregularidades, a fim de determinar ações necessárias de acordo com a presença de defeitos ou poluição. Existem várias técnicas de inspeção de isoladores elétricos, incluindo inspeção visual (DENG, 2021), medição de radiação ultravioleta (LIU, QU & LI, 2021), termovisão (WANG *et al.*, 2018), medição de corrente de fuga (RAMIREZ, HERNANDEZ & MONTOYA, 2012), medição de campo elétrico (KONTARGYRI *et al.*, 2008) e medição de ruído ultrassônico (TIAN *et al.*, 2019).

- Inspeção visual: A inspeção visual é a técnica mais conhecida e utilizada no monitoramento de isoladores, principalmente devido à simplicidade e por ser considerada de baixo custo. Consiste na análise visual do isolador,

a olho nu ou por meio de binóculos, com o objetivo de identificar defeitos ao longo do mesmo. As inspeções realizadas em linhas de transmissão podem ser divididas em dois grupos: inspeções aéreas e inspeções terrestres. As inspeções terrestres são realizadas pelo envio de técnicos ao local onde os isoladores estão instalados por meio de veículos terrestres, enquanto as inspeções aéreas são realizadas em Veículos Aéreos Tripulados, como helicópteros. A qualidade da execução de inspeções visuais em isoladores depende fortemente de uma equipe devidamente treinada e experiente. Ainda assim, o diagnóstico está sujeito a erros e interpretações subjetivas por parte dos inspetores. Além disso, a necessidade de escalar a torre ou de utilizar um helicóptero torna o processo perigoso e, muitas vezes, pouco produtivo.

- Termovisão: A detecção infravermelha, também conhecida como termovisão, é uma das técnicas mais comumente utilizadas e uma das mais eficazes (LIU *et al.*, 2023). Consiste em analisar a distribuição de temperatura ao longo da superfície de um isolador a partir de uma imagem termográfica infravermelha, considerando o fato de que a concentração excessiva de campo elétrico ou uma alta corrente de fuga oriundas de defeitos são os principais motivos de anomalias de temperatura no isolador. Pode ser realizada a uma curta ou longa distância do isolador energizado, com baixa carga de trabalho e alta segurança operacional. Por meio dessa técnica, é possível identificar falhas que ocorre na superfície do isolador e também no núcleo. Porém, os termovisores são equipamentos bastante caros e o resultado da detecção pode ser afetado por fatores externos, como umidade, luz solar e temperatura.
- Medição de radiação ultravioleta (UV): A inspeção por medição de radiação UV consiste em detectar descargas parciais na superfície do isolador oriundas de descargas corona localizadas na região defeituosa do isolador. Possui como vantagens uma alta sensibilidade, baixo ruído e ampla faixa linear. No entanto, assim como o termovisor, o equipamento de medição de radiação UV é bastante caro e sensível à radiação solar e à temperatura ambiente.
- Medição de ruído ultrassônico: consiste na detecção de um sinal acústico de descargas corona localizadas na região defeituosa do isolador. Essa

técnica permite identificar a posição e a natureza do defeito que emite o sinal acústico, de acordo com a variação do sinal na área defeituosa. Possui como vantagens o fato de ser não-invasivo, rápido, inofensivo ao corpo humano e possuir baixo custo. No entanto, a medição de ruído ultrassônica é sensível a ruídos ultrassônicos externos, como os do vento e da chuva, e só é capaz de detectar defeitos associados a descargas corona.

- Medição de corrente de fuga: consiste na medição da corrente de fuga na superfície do isolador. É um método bastante utilizado na literatura para a detecção de *flashover* e do grau de deterioração ou poluição na superfície do isolador (LEITE NETO, 2022; LIU *et al.*, 2023). Porém, é um método invasivo, caro e exige a instalação de equipamento de detecção em cada cadeia, no caso de isoladores de vidro ou de porcelana, o que torna o processo ainda mais caro e arriscado para a vida humana.
- Medição de campo elétrico: consiste em identificar defeitos ao longo do isolador a partir da detecção de oriundas distorções do campo elétrico medido. Possui como vantagens o fato de ser uma técnica precisa e por ser resistente a interferências externas. Por outro lado, é uma técnica invasiva e arriscada para a vida humana.

Devido às limitações das técnicas tradicionais de monitoramento de isoladores em relação ao custo, à eficácia e ao risco de vida humana, muitas concessionárias de energia elétrica estão utilizando VANTs para realizar inspeções nas linhas de transmissão e nos equipamentos elétricos (ZHAI *et al.*, 2017; FAGHIH-ROOHI *et al.*, 2016; PEDRO, 2018). Em meio ao crescimento do sistema elétrico de potência, os VANTs tornaram-se uma opção para monitorar grandes trechos de linhas de transmissão de forma mais rápida, principalmente devido à dificuldade do envio de técnicos para inspecionar linhas que cruzam regiões montanhosas e grandes rios ou lagos.

Nesse contexto, para tornar o processo de detecção de falhas em isoladores mais rápido, confiável e seguro, pesquisadores vêm utilizando técnicas de processamento de imagens e Visão Computacional para a detecção dos defeitos contidos nas fotografias. As principais técnicas de Visão Computacional utilizadas para o reconhecimento do isolador e detecção de defeitos a partir de fotografias aéreas podem ser divididas entre técnicas tradicionais e técnicas baseadas em *deep learning*, cujas definições serão melhores detalhadas nas seções 2.2.2 e 3.1 deste trabalho.

Devido às limitações das técnicas tradicionais de Visão Computacional, os trabalhos mais recentes estão priorizando o uso de técnicas baseadas em *deep learning* para realizar o diagnóstico dos isoladores a partir de fotografias. As principais técnicas utilizadas podem ser divididas entre técnicas de dois estágios e de um estágio, cujas características serão melhores detalhadas na seção 2.2.2. Exemplos de detectores de dois estágios comumente utilizados são a *Region Based Convolutional Neural Network* (R-CNN), Fast R-CNN, Faster R-CNN e Mask R-CNN. E exemplos de detectores de um estágio comumente utilizados são *You Look Only Once* (YOLO) e *Single Shot Detector* (SSD).

## 2.2 DEEP LEARNING

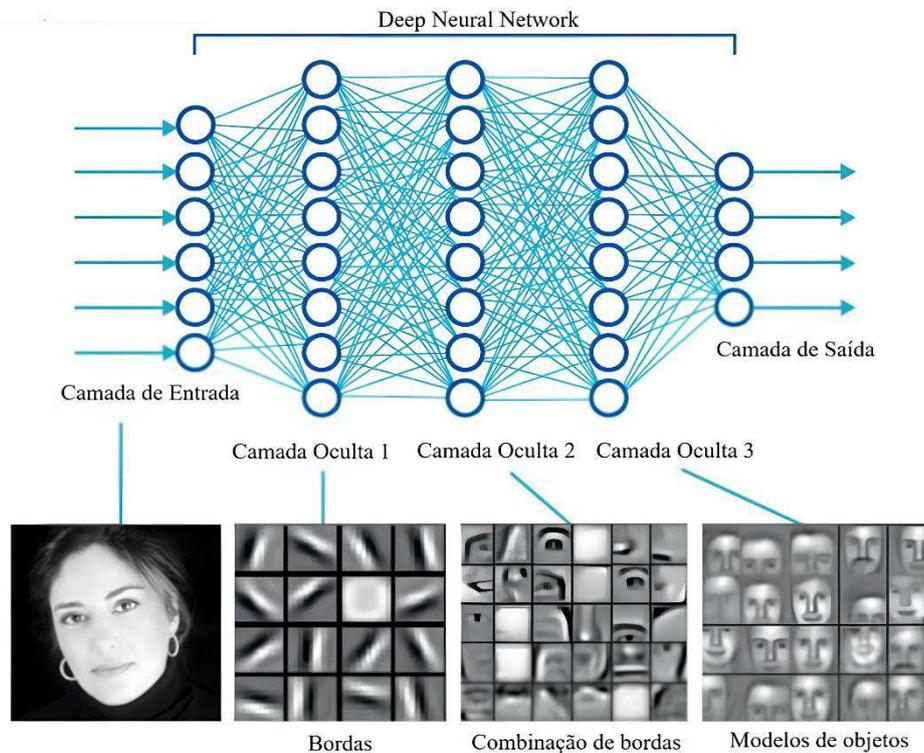
A aprendizagem profunda, também conhecida como *deep learning*, é um sub-ramo da área da inteligência artificial, no qual o aprendizado se dá por meio de sucessivas camadas com níveis crescentes de abstração (CHOLLET, 2017). O termo “profundo” refere-se ao uso de diversas camadas, permitindo que os modelos aprendam e representem informações complexas de forma mais eficiente. É importante destacar que, no contexto da inteligência artificial, a palavra “aprender” se refere a um processo iterativo de ajuste de um conjunto de parâmetros de uma dada equação, referida como “modelo”, com o objetivo de reproduzir o comportamento observado em um conjunto de dados.

A principal característica do *deep learning* é a capacidade de aprendizado hierárquico, o que significa que os modelos começam por aprender representações de atributos simples e de baixo nível nos dados de entrada e, em seguida, utilizam essas representações para construir gradualmente características mais complexas e abstratas. Um exemplo de aprendizado hierárquico está ilustrado na Figura 12, no qual a camada de entrada recebe uma imagem para reconhecimento facial, enquanto as camadas ocultas aprendem a representar características de baixo nível, como os contornos e formatos de rosto, bem como características de alto nível, como os olhos e o comprimento do cabelo.

Os neurônios artificiais são as unidades processadoras de um modelo de IA. Seu funcionamento consiste em receber sinais de entrada e multiplicar pelos seus respectivos pesos sinápticos. Os resultados obtidos serão a soma ponderada de suas entradas, por meio de uma combinação linear entre os pesos e a entrada. A estrutura de um neurônio artificial constituinte das múltiplas camadas de um modelo de *deep learning* é composta

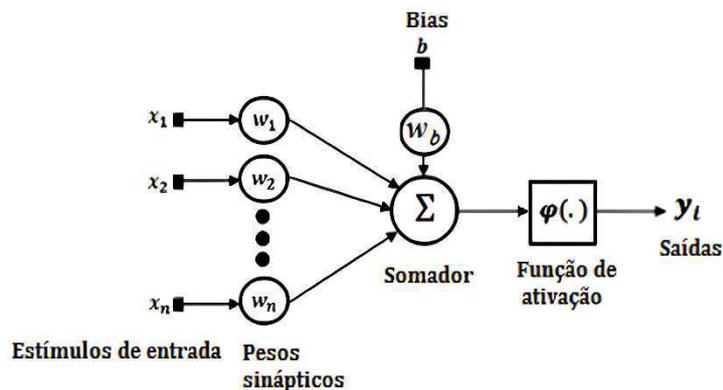
por diferentes componentes, dentre eles os estímulos de entrada, o conjunto de sinapses, o somador, o *bias* e a função de ativação (HAYKIN, 2001). Na Figura 13 se encontra um modelo de processamento de um neurônio artificial.

Figura 12 – Exemplo de um modelo *deep learning* utilizado para reconhecimento facial.



Fonte: Adaptado de NIE *et al.*, 2018.

Figura 13 – Modelo de um neurônio artificial.



Fonte: Adaptado de HAYKIN, 2001.

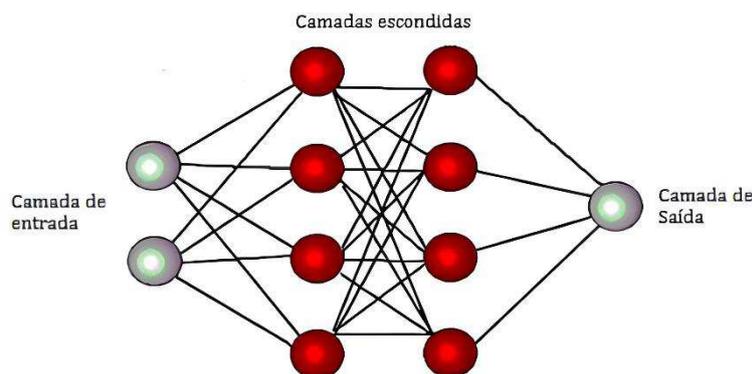
Os estímulos de entrada correspondem aos sinais de entrada. O conjunto de sinapses corresponde às conexões entre os neurônios e as conexões entre os neurônios artificiais, as quais possuem pesos sinápticos. O somador é responsável por realizar a soma dos sinais propagados ao longo da estrutura, ponderados pelos pesos sinápticos. O

*bias* tem por objetivo fornecer um ajuste aos valores obtidos na saída do somador. Por fim, a função de ativação tem por objetivo redefinir os valores de saída do neurônio a partir do resultado obtido pelo somador. Existem diversas funções de ativação, das quais as mais populares são as funções tangente hiperbólica, sigmóide e *Rectified Linear Unit* (ReLU).

As Redes Neurais Artificiais (RNA) são um tipo de IA, cuja estrutura é baseada no sistema nervoso biológico do próprio cérebro humano em dois aspectos: o conhecimento é adquirido pelo ambiente, por meio do processo de aprendizagem, e são utilizadas forças de conexão entre neurônios, ou seja, os pesos sinápticos citados anteriormente, para o armazenamento do conhecimento e reconhecimento de padrões. A forma mais simples de configuração de uma RNA é o modelo de rede *perceptron*, que consiste em um único neurônio artificial.

Um dos tipos de RNA é a *Multilayer Perceptron* (MLP), que consiste em um conjunto de neurônios *perceptron* agrupados em camadas, sem realimentação ou conexões entre neurônios da mesma camada. As camadas das redes MLP podem ser divididas em três grupos: a camada de entrada, onde os valores de entrada são apresentados à rede, as camadas ocultas, que correspondem aos neurônios artificiais e seus respectivos pesos, onde o processamento dos valores de entrada será feito, e a camada de saída, onde o resultado final é concluído e apresentado. Na Figura 14 se encontra um modelo de estrutura de uma RNA.

Figura 14 – Estrutura de uma RNA.



Fonte: ABDALLA e VOLATÃO 2013.

A estrutura mais simples de um modelo de *deep learning*, conhecida como *Deep Neural Network* (DNN), consiste em uma estrutura MLP com múltiplas camadas ocultas. As principais características presentes nas estruturas DNN que não constituem uma MLP são o aprendizado hierárquico dos dados de entrada, de forma que cada camada oculta

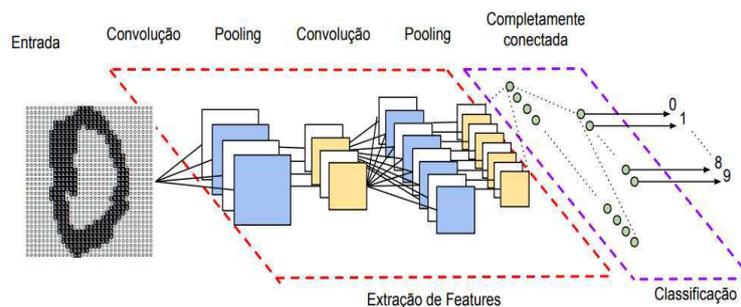
aprende a representar uma respectiva característica de baixo nível, e o processo de treinamento, o qual ocorre de forma paralela em cada camada.

### 2.2.1 REDES NEURAIAS CONVOLUCIONAIS

Redes Neurais Convolucionais, em inglês *Convolutional Neural Network* (CNN), são um tipo de rede neural baseada em *deep learning* amplamente utilizadas em tarefas de visão computacional. As CNN possuem arquitetura inspirada na hierarquia do córtex visual humano. São bastante usadas em tarefas de classificação, identificação e detecção de elementos em imagens.

Uma CNN é composta por três tipos de camadas: convolução, agrupamento (*pooling*) e totalmente conectada (*fully connected*), conforme é possível observar no exemplo ilustrado na Figura 15, sendo a entrada do sistema, geralmente, uma matriz multidimensional que representa os pixels da imagem.

Figura 15 – Exemplo de uma estrutura de CNN.



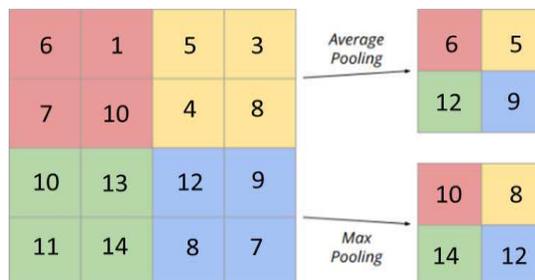
Fonte: Adaptado de VARGAS, PAES e VASCONCELOS, 2016.

O primeiro tipo de camada de uma CNN é a camada de convolução, composta por vários neurônios que possuem como finalidade aplicar um filtro ao longo da imagem de entrada. Esses filtros, conhecidos como Kernel ou máscara, são responsáveis por realizar o processo de convolução para transformar as imagens em mapas de característica (*feature map*). Cada neurônio se conecta a um conjunto de pixels, cujas conexões são representadas por pesos sinápticos que representam a matriz de convolução dos Kernels. Após a convolução, uma função de ativação não-linear é aplicada aos resultados, de forma limitá-los entre 0 e 1 ou -1 e 1.

Após a camada de convolução, existe a camada *pooling*, que é inserida entre camadas de convoluções sucessivas. Estas camadas são responsáveis pela redução da dimensão dos mapas de características extraídos pelas camadas de convolução, os quais

serão parâmetros de entrada para a camada seguinte. As funções mais comumente utilizadas na camada de *pooling* são a *average pooling*, que retorna a média dos valores dentro da região específica, e a *max pooling*, que retorna o maior valor dentro da região. Na Figura 16 é possível observar exemplos de operações na camada *pooling*.

Figura 16 – Exemplo de operações de *Average Pooling* e *Max Pooling*.



Fonte: Autoria Própria.

Por fim, as camadas *fully connected* são responsáveis por realizar a classificação a partir do mapa de característica extraído pelas camadas de convolução e *pooling*. Uma CNN pode conter uma ou mais camadas *fully connected*. Estas camadas possuem arquitetura semelhante a uma rede neural do tipo MLP. Funções de ativação também são utilizadas na saída destas camadas. A quantidade de neurônios da camada de saída de uma CNN, ou seja, a última camada *fully connected*, deve ser igual à quantidade de classes do problema.

O processo de treinamento de uma CNN é baseado na minimização da função de perdas, ou seja, o erro médio entre os valores reais e os valores preditos. Existem várias funções de perdas que calculam de diversas formas o erro médio entre os valores reais e preditos, como, por exemplo, as funções *Mean Squared Error*, *Mean Squared Logarithmic Error*, *Log Cosh* e *Sparse Categorical Cossentropy*. Inicialmente todos os valores dos filtros das camadas convolucionais e dos pesos das camadas *fully connected* são inicializados a partir de algum método ou aleatoriamente. Em seguida, realiza-se o processo de propagação, no qual as imagens do conjunto de dados de treinamento são propagadas através das camadas em direção à camada de saída, obtendo-se os valores preditos. Na sequência, realiza-se o processo de retropropagação, na qual se calcula o erro entre os valores esperados e preditos e os pesos das camadas *fully connected* e os filtros das camadas convolucionais são ajustados, de forma que se obtenha uma minimização da função de custo. O ajuste de ambos os tipos de parâmetros é realizado por uma função de otimização, como, por exemplo, a RMSprop (TIELEMAN & HINTON, 2012), Adam (KINGMA & BA, 2014) ou SGD (ROBBINS & MONRO, 1951). Por fim, todo esse

processo se repete até que se obtenha o valor mínimo desejado para a função de custo ou a quantidade máxima de iterações seja atingida.

### 2.2.2 VISÃO COMPUTACIONAL

Visão Computacional é o campo da Inteligência Artificial responsável por treinar computadores para que sejam capazes de analisar automaticamente e extrair informações de imagens, vídeos e outros tipos de dados visuais. A partir das informações extraídas das imagens, os computadores podem reconhecer, manipular e identificar objetos que compõem a imagem (BALLARD & BROWN, 1982), de forma que consigam executar tarefas inteligentes, aproximando-se da inteligência humana.

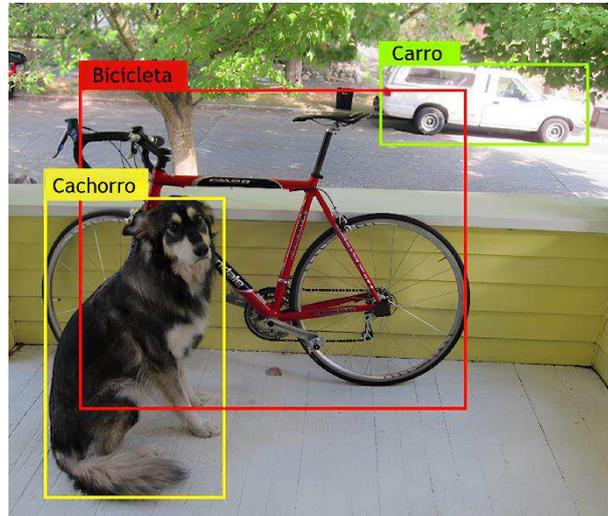
A Visão Computacional consiste basicamente em capturar imagens, melhorá-las, separar as regiões de interesse e, finalmente, relacionar as imagens com outras vistas previamente (BACKES & SÁ JUNIOR, 2016). Nos últimos anos, a Visão Computacional está sendo utilizada em uma ampla variedade de aplicações, dentre as quais: reconhecimento óptico de caracteres, inspeção de máquinas e equipamentos, imagiologia médica, segurança automotiva, reconhecimento biométrico e detecção de objetos (SZELISKI, 2022).

A detecção de objetos em uma imagem consiste em determinar onde os mesmos estão localizados na imagem, especificar caixas delimitadoras contendo cada objeto e determinar qual categoria ou classe cada um deles pertence. Na Figura 17 é apresentado um exemplo resultante da etapa de reconhecimento de objetos propriamente dita. Uma caixa delimitadora é caracterizada por seis parâmetros: as coordenadas do centro ( $b_x, b_y$ ), altura ( $b_h$ ) e largura ( $b_w$ ), a confiabilidade, ou seja, a probabilidade de existência de um objeto dentro da caixa ( $p_c$ ) e a classe do objeto detectado ( $c$ ). Na Figura 18 é apresentada uma ilustração dos parâmetros de uma caixa delimitadora. Os principais detectores de objetos baseados em *deep learning* consistem na utilização de CNNs para a extração dos atributos das imagens, a identificação das regiões de interesse e a classificação. No momento, existem dois principais tipos de detectores de objetos baseados em *deep learning*: os detectores de dois estágios e os detectores de um estágio.

Os detectores de dois estágios são caracterizados pela utilização de duas etapas no processo de detecção. A primeira etapa consiste na geração de Regiões de Interesse (RoI), que são as regiões candidatas que possam conter os objetos de interesse da imagem. Para tanto, a maioria dos detectores de dois estágios utilizam uma Rede de Propostas Regionais

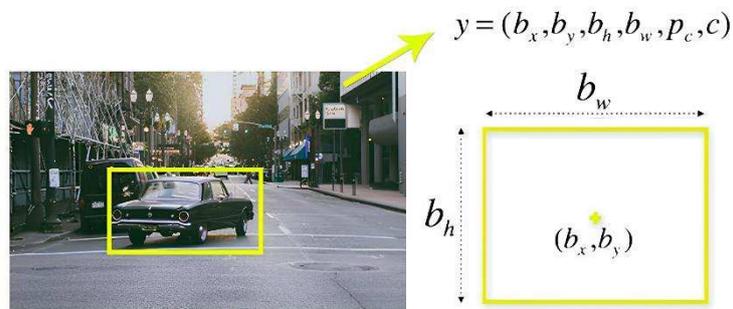
(RPN) (REN *et al.*, 2015). A segunda etapa, por sua vez, consiste no refinamento das RoIs para a obtenção da localização exata dos objetos e suas respectivas classes. Na Figura 19 é possível observar uma ilustração das etapas de detecção de objetos nos detectores de dois estágios.

Figura 17 – Detecção de Objetos em uma Imagem.



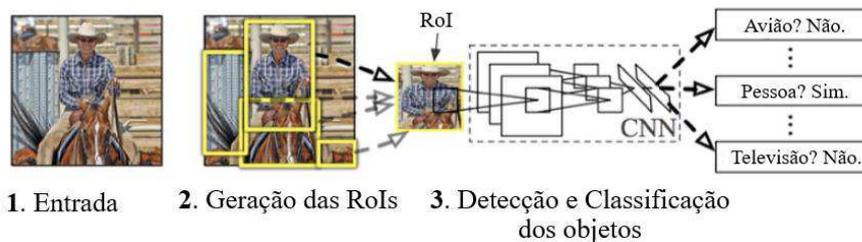
Fonte: Adaptado de REDMON, 2018.

Figura 18 – Parâmetros de uma caixa delimitadora.



Fonte: Adaptado de GOUR e KANSKAR, 2019.

Figura 19 – Etapas da detecção de objetos em detectores de dois estágios.



Fonte: Girshick *et al.*, 2014.

Os detectores de dois estágios apresentam bons resultados na acurácia e na precisão, porém normalmente apresentam baixa velocidade na detecção dos objetos.

Exemplos de detectores de dois estágios são a *Region Based Convolutional Neural Network* (R-CNN) (GIRSHICK *et al.*, 2014), Fast R-CNN (GIRSHICK, 2015), Faster R-CNN (REN *et al.*, 2015) e Mask R-CNN (HE, GKIOXARI & DOLLAR, 2017).

Por outro lado, os detectores de um estágio realizam a localização e classificação dos objetos presentes na imagem em uma única etapa e sem a utilização de uma RPN. Além disso, apresentam melhores velocidades na detecção em comparação aos detectores de dois estágios, principalmente pelo fato de suprimir a etapa da geração de RoIs. Exemplos de detectores de um estágio são a *You Look Only Once* (YOLO) (REDMON *et al.*, 2016), *Single Shot Detector* (SSD) (LIU *et al.*, 2016) e *Deeply Supervised Object Detector* (DSOD) (SHEN *et al.*, 2017).

### 2.2.2.1 YOU ONLY LOOK ONCE (YOLO)

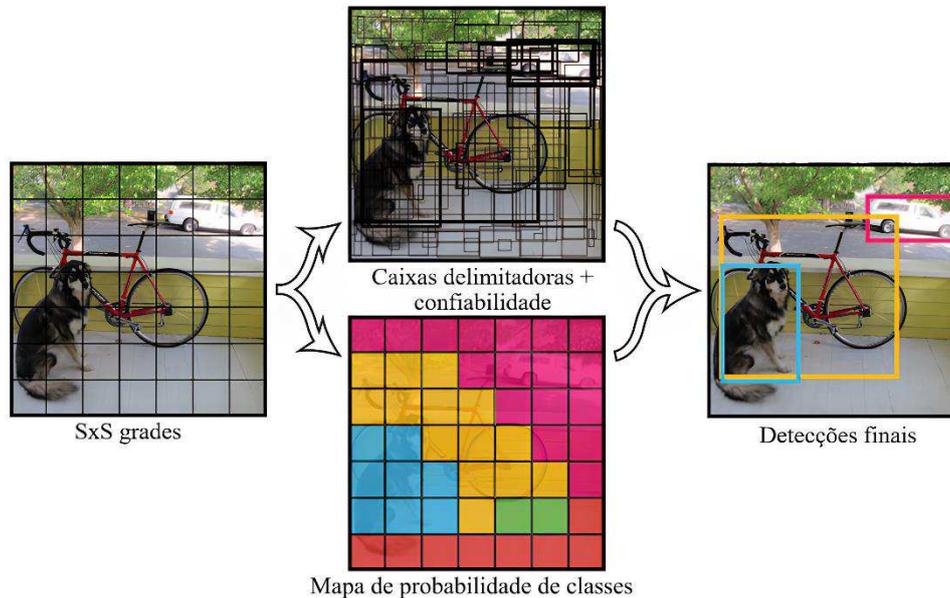
A YOLO é um algoritmo baseado em redes convolucionais, proposto em 2015 por Joseph Redmon e Ali Farhadi para a detecção de objetos. Sua principal característica é a capacidade de localizar e classificar objetos em imagens em uma única etapa, a uma velocidade que permite aplicações em dispositivos móveis e em tempo real, diferentemente dos algoritmos tradicionais de CNN que exigem mais etapas que tornam o processo mais demorado (REDMON *et al.*, 2016).

A arquitetura da YOLO consiste em uma rede de múltiplas camadas convolucionais, que divide a imagem em regiões e prevê as caixas delimitadoras e probabilidades para cada região. Primeiramente, a imagem de entrada é dividida em uma grade de  $S \times S$  células, de forma que se o centro do objeto estiver em uma célula, a mesma será responsável por detectá-lo. Em seguida, cada célula prevê  $B$  possíveis caixas delimitadoras e suas respectivas confiabilidades e probabilidade de classes. A confiabilidade diz respeito à probabilidade de a caixa delimitadora conter um objeto, enquanto as probabilidades de classes representam as probabilidade de o objeto contido pertencer a cada classe. As quantidades  $S \times S$  de células e  $B$  de caixas delimitadoras variam de acordo com a versão da YOLO.

Na sequência, com base nos valores obtidos de probabilidade de classes, obtém-se um mapa de probabilidade de classes para cada uma das células, de forma que cada célula contenha apenas uma classe, independentemente do número de caixas delimitadoras. Logo após, realiza-se um processo de supressão, denominado *Non-Maximum Suppression* (NMS), de forma a eliminar as caixas duplicadas e as que

apresentam confiabilidade inferior a um limiar estabelecido, cujo valor normalmente utilizado é de 50%. Por fim, as caixas delimitadoras definitivas são obtidas a partir das extremidades das células do mapa de probabilidade. Um diagrama esquemático do processo de detecção de objetos é apresentado na Figura 20.

Figura 20 – Processo de detecção de objetos da YOLO.



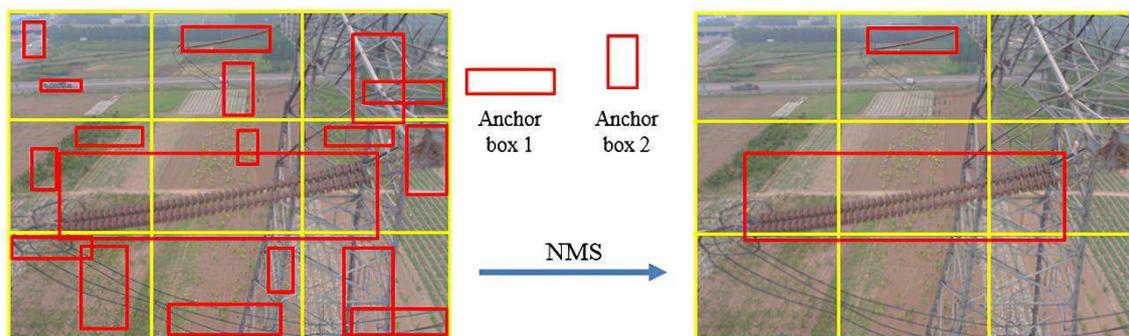
Fonte: REDMON *et al.*, 2016.

Para lidar com a grande quantidade de caixas delimitadoras, durante o processo de supressão, a YOLO utiliza a técnica das âncoras, em inglês *anchor boxes*. As âncoras são dimensões de comprimento e largura de caixas delimitadoras predefinidos, com diferentes formas e tamanhos, e são utilizadas para facilitar a detecção de objetos em diferentes escalas na imagem. Durante o processo de detecção, as células ajustam o tamanho e dimensão das caixas delimitadoras com base nas âncoras, de forma que a quantidade  $B$  de caixas preditas por cada célula é igual à quantidade de âncoras predefinidas na implementação da YOLO. Na Figura 21 é mostrado um exemplo da geração de caixas delimitadoras por grade de células com base nas *anchor boxes* e do processo de NMS para eliminar as caixas geradas com baixa confiabilidade, voltado para a detecção de cadeias de isoladores em uma fotografia. Para a cadeia de isolador que possui maior tamanho de caixa delimitadora, embora a caixa ocupe três células de grade, o centro ocupa a grade do meio. Logo, ela não deve ser considerada como predição de outras células de grade.

A arquitetura da YOLO é composta por três partes principais: *backbone*, *neck* e *head*, conforme a representação mostrada na Figura 22. A primeira parte da YOLO é o

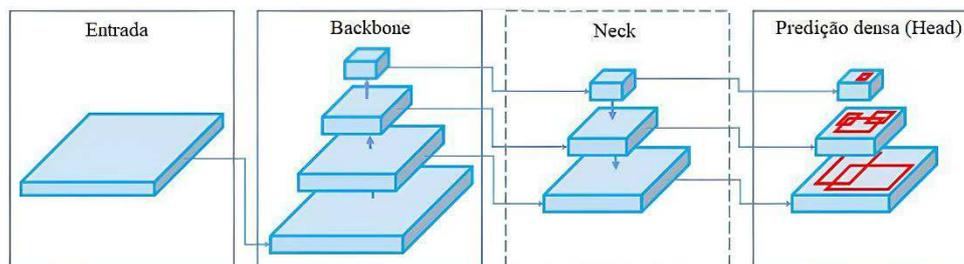
*backbone*, o qual é composto predominantemente por camadas de convolução e é responsável pela extração de atributos necessários para a detecção de objetos. Em seguida, os atributos extraídos passam para a segunda parte da YOLO, o *neck*, responsável por montar o mapa de característica de diferentes escalas de tamanhos de objetos e produzir características de alto nível mais robustas e relevantes, para que a detecção seja mais eficaz.

Figura 21 – Exemplo de predição de saída da YOLO com base nas *anchor boxes*.



Fonte: Autoria Própria.

Figura 22 – Partes principais da arquitetura YOLO.



Fonte: Adaptado de BOCHKOVSKIY, 2020.

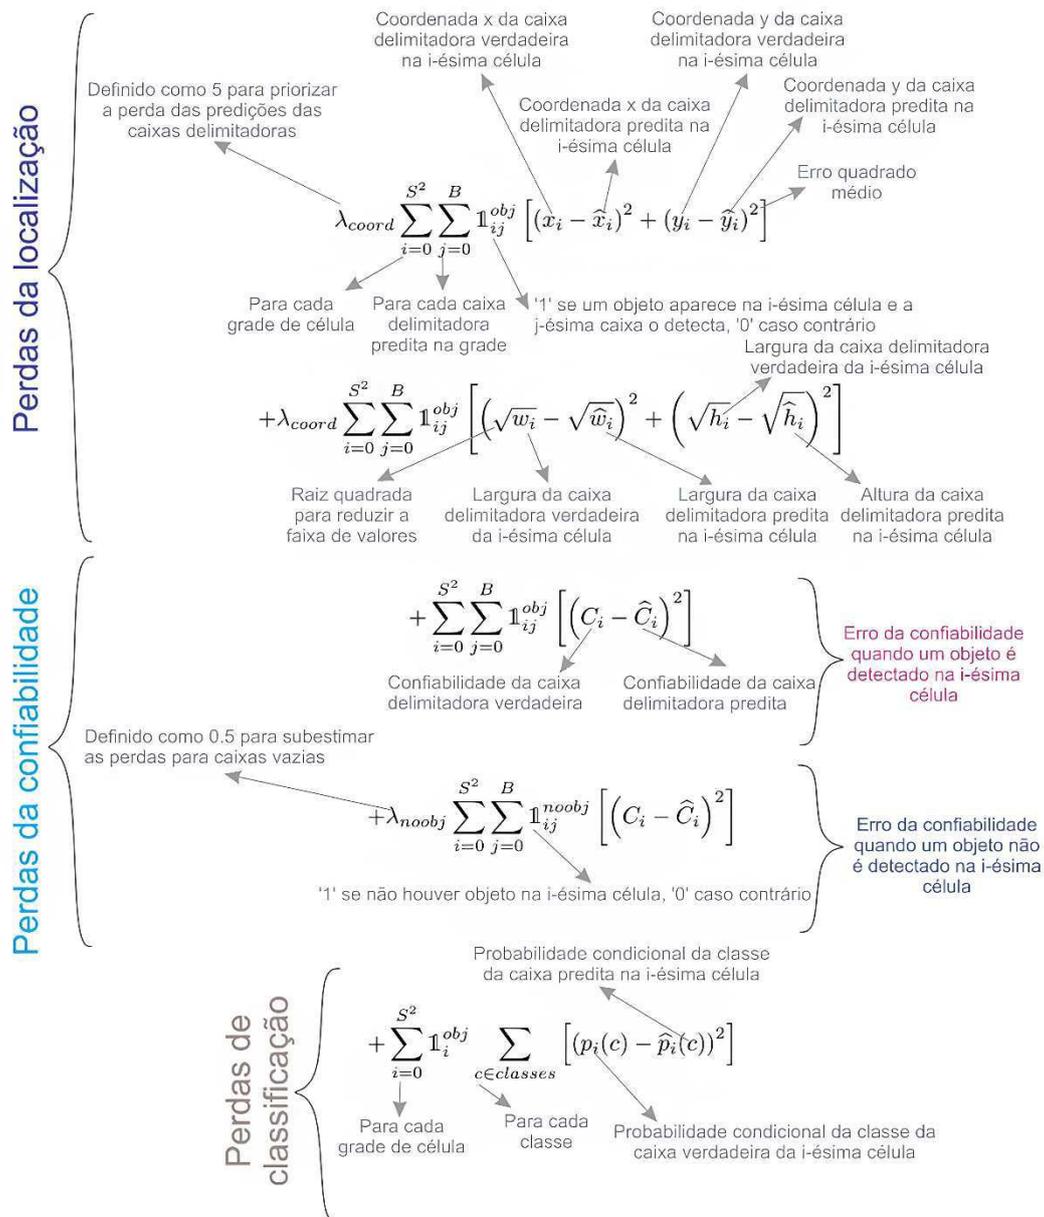
Por fim, a terceira parte da arquitetura YOLO é o *head* (em português, cabeça), que é responsável por realizar a detecção dos objetos a partir dos mapas de características gerados pelo *neck*. O *head* possui três ramos de previsões diferentes, sendo cada um deles para a detecção de objetos em pequena, média e grande escala. O ramo de detecção de objetos em pequena escala recebe o mapa de característica de baixa resolução, enquanto os ramos de detecção de objetos de média e grande escala recebem, respectivamente, os mapas de características de média e de alta resolução. Cada ramo prevê as caixas delimitadoras, a confiabilidade e as probabilidades da classe para cada caixa gerada.

As arquiteturas YOLO continuaram a evoluir em diferentes versões desde o lançamento inicial em 2015. As quatro primeiras versões, da YOLOv1 até YOLOv4, foram desenvolvidas pelos próprios autores, com a colaboração de terceiros, entre os anos

de 2016 e 2020. As quatro versões mais recentes até a presente data, da YOLOv5 até YOLOv8, foram desenvolvidas por uma organização chamada Ultralytics LLC, entre os anos de 2021 e 2022. Um grande avanço ocorrido a partir da YOLOv5 foi a eliminação da necessidade de passar como hiperparâmetro valores pré-definidos de *anchor boxes*. para treinamento. A partir dela, os valores de *anchor boxes* passaram a ser calculados de forma interna a partir dos tamanhos e proporções das caixas delimitadoras dos objetos existentes na base de dados de treinamento, utilizando o algoritmo de regressão *k-means*. A versão mais recente, a YOLOv8, englobou uma série de melhorias em relação às versões anteriores, como o aumento de precisão na detecção de objetos em diferentes escalas e o aumento da velocidade de detecção. Além disso, diversos trabalhos propuseram aperfeiçoamentos nas arquiteturas internas da YOLO com a finalidade de se obter melhores resultados para a detecção de objetos em específico, como é o caso dos defeitos em isoladores, cujos trabalhos serão mencionados no capítulo da Revisão Bibliográfica.

O processo de treinamento de uma YOLO ocorre de forma semelhante ao treinamento de uma CNN convencional. No entanto, a YOLO diferencia-se de uma CNN convencional pelo fato de a saída não apresentar apenas os valores correspondentes às classes, como também os valores das coordenadas de centro das caixas delimitadoras, a altura e a largura, além da confiabilidade. Dessa forma, a função de perdas de uma YOLO pode ser dividida em três partes: perdas da confiabilidade, perdas da classe e perdas das caixas delimitadoras. As perdas da classe de uma YOLO são calculadas da mesma forma que as perdas de uma CNN convencional, ou seja, com base no erro médio entre os valores de classe reais e preditos. De forma semelhante, as perdas da confiabilidade podem ser calculadas com base no erro médio entre a confiabilidade real (0 ou 1) e a confiabilidade das caixas delimitadoras preditas. Por fim, as perdas de localização podem ser calculadas com base no erro entre as coordenadas de centro, o comprimento e largura das caixas delimitadoras reais e preditas. Na Figura 23, é possível observar um esquema de como são calculadas as perdas de um classificador YOLO, onde  $\lambda_{coord}$  é um fator de escala que dá mais importância às predições das caixas delimitadoras e  $\lambda_{noobj}$  é um fator de escala que diminui a importância das caixas que não contém objetos.

Figura 23 – Diagrama ilustrativo da função de perdas da YOLO.



Fonte: Adaptado de TERVEN, CÓRDOVA-ESPARZA & ROMERO-GONZÁLEZ, 2023.

Existem três formas de treinamento comumente utilizadas para treinar uma arquitetura YOLO: *from-scratch*, *fine-tuning* e *transfer learning*. O treinamento *from-scratch* consiste em treinar a YOLO do zero, ou seja, inicializando os pesos das camadas internas de convolução com valores aleatórios e muito próximos de zero. O treinamento *fine-tuning* consiste em utilizar a rede YOLO pré-treinada em um grande conjunto de dados e ajustá-la para uma nova tarefa, com um novo conjunto de dados. No treinamento *fine-tuning*, as primeiras camadas da rede mantêm seus pesos fixos e apenas as últimas camadas são ajustadas com o novo conjunto de dados. Por fim, o treinamento *transfer*

*learning*, de forma semelhante ao treinamento *fine-tuning*, utiliza a rede YOLO pré-treinada. Porém, os pesos de toda a rede são mantidos fixos e novas camadas treináveis são adicionadas, as quais serão treinadas com o novo conjunto de dados. A base de dados utilizada nos cálculos da rede pré-treinada da YOLO foi a *Microsoft Common Objects in Context (COCO)*, a qual contém fotografias de 80 categorias de objetos, que abrangem uma ampla variedade de itens encontrados em cenários do mundo real.

Os principais hiperparâmetros que devem ser configurados para o treinamento de uma arquitetura YOLO são:

- Dimensão de entrada: dimensão da fotografia de entrada da YOLO. Caso a fotografia de entrada apresente dimensão maior que a configurada, o próprio algoritmo realiza o redimensionamento da mesma.
- Tamanho das *anchor boxes*: tamanho das *anchor boxes* da YOLO. A partir da YOLOv5, o tamanho das *anchor boxes* passou a ser calculado automaticamente pelo algoritmo, sem necessidade de o usuário configurar.
- Quantidade de épocas: número de vezes em que o modelo passa por todo o conjunto de dados de treinamento e ajusta os pesos.
- Tamanho do lote: número de dados de treinamento que o modelo passa em uma única iteração, antes de atualizar os pesos. Quanto maior o tamanho do lote, maior é a quantidade de memória necessária e menor é o tempo de treinamento.
- Otimizador: algoritmo responsável por ajustar os parâmetros do modelo para minimizar a função de perda.
- Taxa de aprendizado: taxa que controla a magnitude das atualizações dos parâmetros do modelo durante o treinamento.
- Momentum: termo que ajuda a acelerar o otimizador nas direções relevantes e suavizar as oscilações nas atualizações dos pesos.
- Decaimento de peso: termo que adiciona uma penalidade à função de perda para evitar que os pesos se tornem excessivamente grandes.

### 2.2.3 MÉTRICAS DE AVALIAÇÃO DE DESEMPENHO

A avaliação do desempenho de um classificador pode ser realizada a partir da comparação entre os resultados preditos e os resultados esperados. Os resultados preditos são aqueles obtidos na saída do classificador, enquanto os resultados esperados são os

resultados verdadeiros dos dados passados como parâmetro na avaliação. Ao comparar ambos os resultados, existem quatro possíveis situações:

- **Verdadeiro Positivo (VP):** ocorre quando o resultado esperado para determinado dado é positivo e o resultado predito também é positivo para uma determinada classe. Por exemplo, uma YOLO detectou uma parte de núcleo exposto, por meio de uma fotografia, em um isolador que de fato possui esse tipo de defeito. Nesse caso, o resultado é VP para a classe “núcleo exposto”.
- **Verdadeiro Negativo (VN):** ocorre quando o resultado esperado para determinado dado é negativo e o resultado predito também é negativo para uma determinada classe. Por exemplo, uma YOLO não detecta nenhum tipo de defeito de um isolador íntegro a partir de uma fotografia. Nesse caso, o resultado é VN para todas as classes que representam os defeitos em que a YOLO dada como exemplo consegue detectar em fotografias de isoladores.
- **Falso Positivo (FP):** ocorre quando o resultado esperado para determinado dado é negativo e o resultado predito é positivo para uma determinada classe. Por exemplo, uma YOLO previu uma região do isolador com núcleo exposto em uma fotografia, porém essa região não apresenta exposição de núcleo. Nesse caso, o resultado é FP para a classe “núcleo exposto”.
- **Falso Negativo (FN):** ocorre quando o resultado esperado para determinado dado é positivo e o resultado predito é negativo para uma determinada classe. Por exemplo, uma YOLO não consegue detectar uma região do isolador com núcleo exposto em uma fotografia. Nesse caso, o resultado é FN para a classe “núcleo exposto”.

Uma das formas mais simples de avaliar o desempenho de um classificador é por meio da acurácia, que é dada pela razão entre a quantidade de VP e a quantidade total de dados utilizados na avaliação, conforme mostrado em (1). Apesar de ser uma métrica simples e fácil de implementar, muitas vezes a acurácia pode não ser eficaz na avaliação do desempenho. Por exemplo, considere uma YOLO desenvolvida para a detecção de poluição em isoladores a partir de fotografias e uma base de dados teste com 990 fotografias de isoladores sem poluição e apenas 10 fotografias de isoladores com

poluição. Se a YOLO for impetuosa e classificar todos os isoladores como “sem poluição”, sua acurácia será de 99%, parecendo ser um bom resultado. Porém, a acurácia não apresentou boa eficácia ao avaliar a YOLO. Por isso, outras métricas também devem ser utilizadas para avaliar classificadores de objetos, como, por exemplo, precisão, sensibilidade, *Average Precision* (AP) e *mean Average Precision* (mAP).

A precisão de um classificador para uma determinada classe de objeto consiste na razão entre a quantidade de caixas delimitadoras geradas corretamente e a quantidade total de caixas delimitadoras geradas para aquela classe, conforme mostrado na equação (2). Por outro lado, a sensibilidade, também conhecida como *recall*, é a razão entre a quantidade de caixas delimitadoras geradas corretamente e a quantidade total de caixas delimitadoras que deveriam ser geradas corretamente para aquela classe, conforme expresso na equação (3).

$$acurácia = \frac{VP + VN}{VP + VN + FP + FN} \quad (1)$$

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

$$sensibilidade = \frac{VP}{VP + FN} \quad (3)$$

A *Average Precision* (AP) é uma métrica que combina a precisão e a sensibilidade ao longo de diferentes *thresholds* de confiabilidade de caixas delimitadoras. Diferentes valores de precisão e sensibilidade podem ser obtidos para diferentes valores de *threshold*. Por exemplo, se um modelo detectar uma ocorrência de núcleo exposto com uma confiabilidade de 51%, a detecção será considerada VP para *thresholds* abaixo de 51% e FP para *thresholds* acima de 51%, impactando valores de precisão e sensibilidade. Esses diferentes valores tornam possível a obtenção de uma curva precisão versus sensibilidade (PR), na qual o eixo das ordenadas representa a sensibilidade e o eixo das abcissas representa a precisão. A AP é calculada a partir da integral da curva PR para uma determinada classe, conforme mostrado em (4). Por sua vez, a *mean Average Precision* (mAP) é a média dos valores de AP para cada uma das classes, conforme mostrado em (5), levando em conta uma análise geral do classificador, compreendendo todas as classes.

$$AP = \int_0^1 p(r)dr, \quad (4)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (5)$$

#### 2.2.4 DATA AUGMENTATION

Devido à complexidade dos métodos baseados em *deep learning*, é necessária uma grande quantidade de dados para a obtenção de um modelo adequado no reconhecimento de objetos em uma imagem (SHORTEN & KHOSHGOFTAAR, 2019). No entanto, muitas vezes não é possível obter uma quantidade de imagens suficiente para treinar e reajustar os parâmetros de um modelo para que se possa obter uma boa precisão no reconhecimento de determinados objetos. Como consequência, os modelos treinados com pequenas bases de dados tendem a se sobreajustar aos dados da etapa de treinamento, o que é conhecido como *overfitting*, e, conseqüentemente, não apresentar uma boa qualidade no reconhecimento de objetos em outras imagens que não estejam contidas na base de dados de treinamento.

Uma das formas mais utilizadas para reduzir o *overfitting* causado pela quantidade limitada de dados é o *data augmentation*, que consiste em técnicas sintéticas para aumentar a quantidade de amostras em uma base de dados, tornando-a mais robusta. As principais técnicas de *data augmentation* utilizadas em imagens são: transformações geométricas, também conhecidas como *affine transformation*, transformação de espaço de cores, *random erasing* e inserção de ruídos eletromagnéticos e borrões.

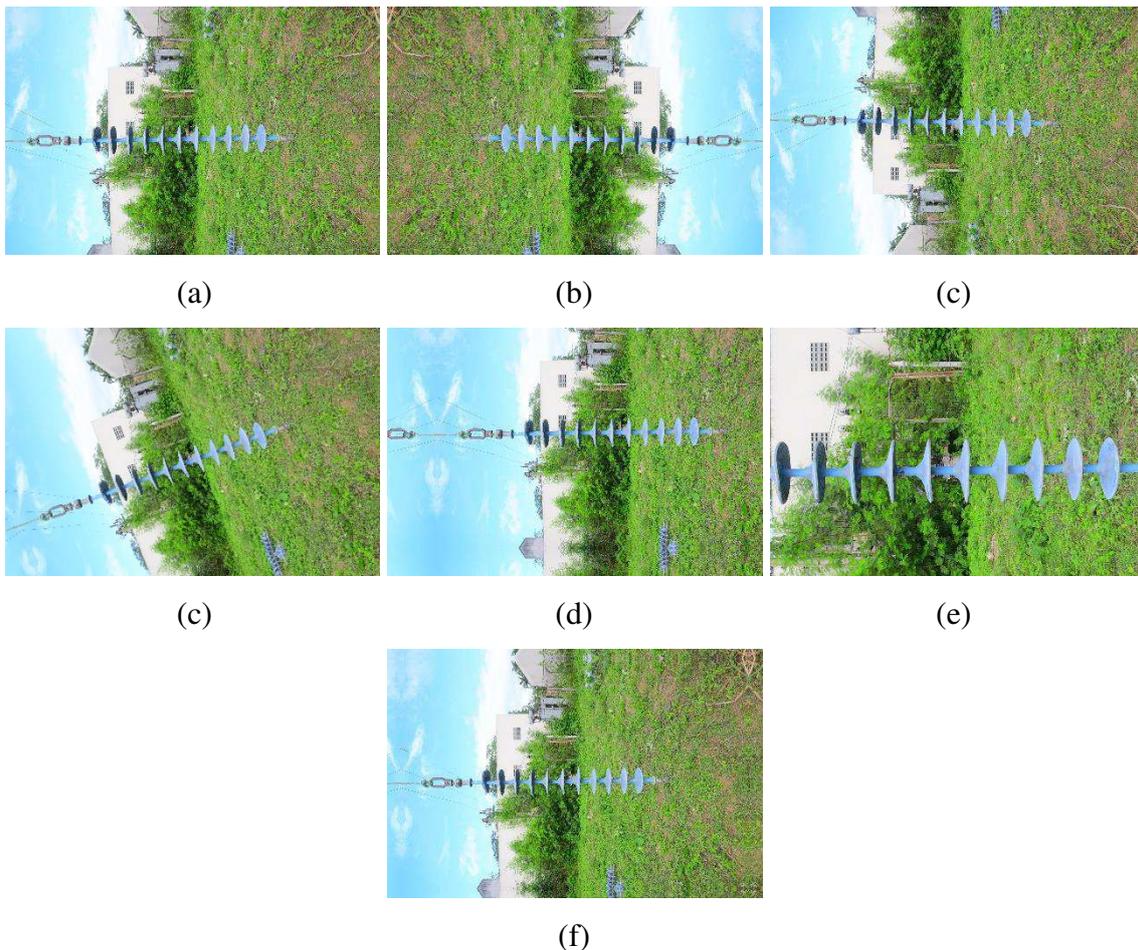
A técnica mais simples de *data augmentation* utilizada em imagens é a *affine transformation*, também conhecida como transformação geométrica, principalmente devido à sua facilidade de implementação. Existem várias formas de realizar transformação geométrica em imagens, dentre elas as mais comuns são:

- Espelhamento: também conhecido como *flipping*, consiste em espelhar a imagem, de forma horizontal ou vertical.

- Rotação: consiste em rotacionar a imagem para a direita ou esquerda em um eixo entre  $1^\circ$  e  $359^\circ$ . Uma desvantagem da rotação é a distorção dos rótulos dos dados.
- Translação: consiste em deslocar a imagens a uma certa quantidade de pixels para a direita, esquerda, para cima ou para baixo.
- Zoom: também conhecida como *scale*, consiste em aplicar ou reduzir a imagem. O zoom pode ser aplicado em apenas um dos eixos, como também em ambos os eixos da imagem.

Na Figura 24 é possível observar uma das fotografias capturadas ao longo desta pesquisa expandida por algumas das técnicas de transformada geométrica.

Figura 24 – Exemplo de fotografia (a) original, (b) expandida por espelhamento horizontal, (c) expandida por espelhamento vertical, (d) expandida por rotação, (e) expandida por translação para a direita e para cima, (f) expandida por zoom de aproximação e (g) expandida por zoom de afastamento.



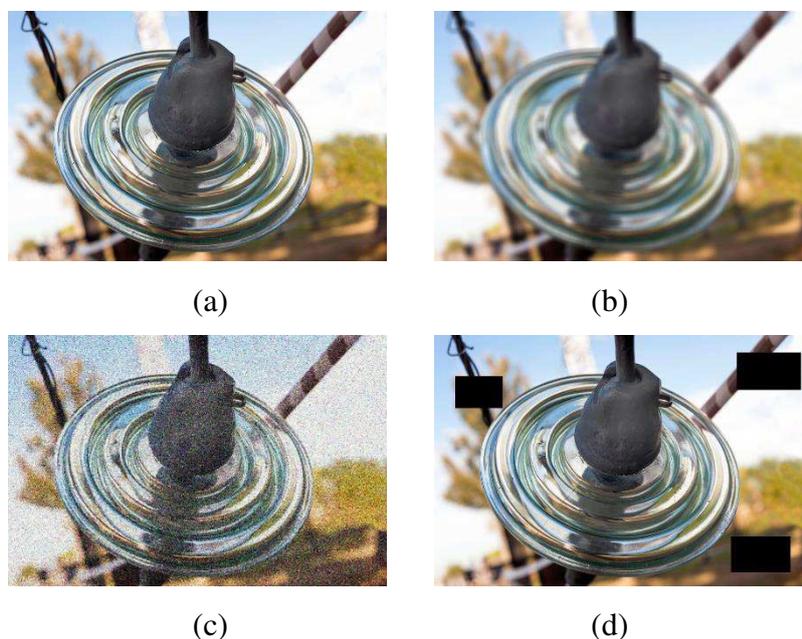
Fonte: Autoria Própria.

Em trabalhos que utilizaram *data augmentation* para expandir bases de dados de isoladores, outras técnicas bastante frequentes são a inserção de ruído gaussiano, borrões

ou *random erasing* (VIEIRA E SILVA *et al.*, 2020; SONG *et al.*, 2020; QIU *et al.*, 2022). A inserção de ruídos gaussiano consiste em criar novas amostras ao adicionar à imagem original ruídos estatisticamente distribuídos de acordo com uma distribuição gaussiana, com média zero e desvio padrão controlável. A inclusão desse tipo de ruído pode simular condições adversas, como interferência eletromagnética, condições atmosféricas ou até mesmo distorções introduzidas pelo próprio sistema de câmera dos VANTs.

Por sua vez, a inserção de borrões consiste em produzir novas amostras a partir da suavização de imagem original, a partir da redução da nitidez, a fim de simular efeitos de desfoque causados por movimento rápido do VANT, vibrações ou condições atmosféricas desfavoráveis. Por fim, a *random erasing* consiste em apagar de forma aleatória uma determinada parte da imagem original, podendo simular condições em que parte do cenário da imagem é obscurecido por algum objeto que bloqueie a visão da linha de transmissão. A aplicação de *random erasing* em imagens requer atenção, pois a região removida pode conter informações importantes, como, por exemplo, uma região defeituosa do isolador. Na Figura 25 é possível observar exemplos de obtenção de novas amostras de imagens a partir da inserção de ruído gaussiano, borrões e *random erasing*.

Figura 25 – Exemplo de fotografia (a) original e de amostras obtidas pela inserção de (b) borrão, (c) ruído gaussiano e (d) *random erasing*.



Fonte: FREEPIK, 2024.

Neste capítulo foram apresentados os principais conceitos teóricos relacionados a isoladores elétricos, com uma breve descrição sobre os principais defeitos e as principais técnicas de inspeção utilizadas, bem como embasamentos teóricos de *deep learning*,

técnicas de Visão Computacional e *data augmentation*. No próximo capítulo será apresentado um levantamento bibliográfico a respeito de trabalhos que utilizaram técnicas de Visão Computacional para realizar o diagnóstico de isoladores elétricos.

## 3 REVISÃO BIBLIOGRÁFICA

Neste capítulo será apresentado um levantamento do estado da arte das principais técnicas de Visão Computacional utilizadas na detecção de isoladores em fotografias e na identificação de defeitos no mesmo, com o objetivo de apresentar a evolução das pesquisas desta área.

### 3.1 ESTADO DA ARTE

O advento de modelos baseados em *deep learning* representou um grande avanço na área de visão computacional, tanto que, em geral, modelos que não utilizam *deep learning* costumam ser referidos como modelos tradicionais (HAO *et al.*, 2022). Tipicamente, modelos tradicionais são fundamentados em filtragens e segmentações visando extrair algum atributo que seja adequado para classificação da imagem.

#### 3.1.1 DIAGNÓSTICO DE ISOLADORES A PARTIR DE MODELOS TRADICIONAIS

Os primeiros trabalhos que buscaram diagnosticar a condição operacional de isoladores utilizando imagens empregaram métodos tradicionais para reconhecimento e detecção de defeitos em fotografias de isoladores. As principais técnicas utilizadas foram: *threshold segmentation* (ZHAI *et al.*, 2017; LV *et al.*, 2017; CHEN, YAO & LI, 2019), *texture feature* (ZHANG, AN & CHEN, 2010; WU & AN, 2012; JABID & AHSAN, 2018) e detecção de contorno (IRUANSI, TAPAMO & DAVIDSON, 2015; WANG, DU & ZHANG, 2015; ZHAI *et al.*, 2018).

Além disso, alguns pesquisadores utilizaram técnicas tradicionais para extração de atributos de isoladores a partir de fotografias, a exemplo da classificação da hidrofobicidade (ALVES, 2018), extração de atributos de imagens termográficas (SOUZA, 2016; OLIVEIRA, 2017; RIBEIRO, 2017) e níveis de descargas corona, a partir de medições de radiação UV (RIBEIRO, 2017; FLORENTINO, 2019; BRITO, 2021).

Souza (2016) propôs uma metodologia de classificação do estado de degradação de isoladores poliméricos a partir de imagens termográficas. A metodologia consiste em

segmentar o isolador das fotografias, realizar um tratamento matemático na imagem segmentada do isolador para se obter o vetor de perfil térmico do núcleo do isolador com base nas intensidades de pixels e utilizar uma MLP para classificar o estado de degradação do isolador com base no perfil térmico extraído. Os resultados obtidos mostraram que a MLP apresentou 100% de acurácia ao identificar o perfil térmico de isoladores defeituosos. No entanto, a segmentação dos isoladores da imagem termográfica foi realizada manualmente, de forma a avaliar apenas o tratamento dos pixels da imagem segmentada do isolador para obter o perfil térmico. Técnicas baseadas em *deep learning* poderiam ser incluídas na metodologia do autor para realizar a segmentação do isolador.

Oliveira (2017) desenvolveu uma técnica semiautomática de processamento de imagens para auxiliar na inspeção de isoladores poliméricos a partir de imagens termográficas. A técnica consistiu em, primeiramente, realizar a equalização dos pixels das imagens termográficas, seguida da segmentação do isolador das imagens e, a partir das imagens segmentadas, extrair o perfil térmico do isolador. A etapa da segmentação foi realizada a partir da técnica do processo de crescimento de regiões, que consiste em definir um pixel semente pertencente à região da imagem que representa o isolador e determinar as regiões correspondentes ao contorno a partir de um critério de similaridade. Por fim, realizou-se a extração do perfil térmico do isolador, a partir da imagem segmentada, com base na utilização de métodos estatísticos. A técnica desenvolvida contemplou apenas a segmentação do isolador e a extração do perfil térmico, sem realizar nenhum tipo de diagnóstico. Além disso, a segmentação do isolador ainda depende da intervenção humana para a determinação do pixel semente pertencente à região delimitada pelo isolador.

Alves (2018) propôs um método para a classificação da hidrofobicidade de isoladores poliméricos a partir de fotografias. Para tanto, a autora realizou um processamento das fotografias, a fim de prepará-las para que fosse possível extrair os atributos desejados. As técnicas de processamento de imagens aplicadas nas fotografias, em sequência, foram: limiarização multiespectral dos pixels, uniformização e binarização. Após a aplicação das técnicas, foram extraídos 8 atributos das fotografias: número de regiões molhadas, área individual máxima, área total molhada, distâncias média e máxima das regiões, maior fator de forma e excentricidades mínima e máxima. Por fim, uma MLP que recebe os 8 parâmetros foi criada e treinada para realizar a predição do nível de hidrofobicidade. Os resultados obtidos mostraram uma taxa de acerto

de 87%. No entanto, a extração dos atributos ocorreu de forma manual, o que torna o processo demorado e sujeito a erros e à subjetividade humana.

Outros trabalhos, como o de Ribeiro (2017), Florentino (2019) e Brito (2021), utilizaram a técnica de Zhang *et al.* (2016) para segmentar fâculas de imagens UV para permitir a extração de atributos essenciais para o diagnóstico de isoladores poliméricos, como densidade de pixels, mapa de persistência, número de fâculas, área da região principal e fator de forma. A técnica de Zhang *et al.* (2016) consiste em converter a imagem UV no formato RGB para escala de cinza, em seguida binarizar a imagem, de forma que seja convertida em preto e branco, e, por fim, aplicar operadores morfológicos para a remoção de ruídos. A imagem resultante contém apenas as fâculas em branco e o restante em preto, de forma que os atributos necessários para o diagnóstico dos isoladores desejados sejam extraídos. Os resultados obtidos mostraram que a utilização técnica de Zhang *et al.* (2016) para processar as imagens UV e segmentar as fâculas facilita o processo de extração dos atributos desejados.

Observa-se, portanto, que técnicas tradicionais de classificação de imagens de isoladores foram desenvolvidas com sucesso, contudo, majoritariamente foram aplicadas ao processamento de imagens do espectro visível, ou seja, termográficas e UV, o que implica necessariamente na necessidade de sensores aptos a captar esse tipo de imagem. Quando aplicadas a fotografias, técnicas tradicionais requerem extração de atributos de forma manual e não apresentam bom desempenho quando o isolador está localizado em cenários com fundo complexo. Para contornar os problemas oriundos dos métodos tradicionais, muitos trabalhos estão propondo a utilização de métodos *deep learning* para a detecção de defeitos em isoladores a partir de fotografias.

### 3.1.2 DIAGNÓSTICO DE ISOLADORES A PARTIR DE *DEEP LEARNING*

Sampedro *et al.* (2019) desenvolveram um sistema para reconhecimento e diagnóstico de cadeias de isoladores a partir de fotografias. Para tanto, os autores utilizaram uma arquitetura de Rede Full Convolutiva (FCN) para realizar a segmentação dos discos dos isoladores da imagem e uma combinação entre uma CNN de 10 camadas e uma arquitetura de Rede Convolutiva Siamesa (SCNN) para a detecção de discos ausentes ou danos nos discos da cadeia. Para treinamento e teste do sistema, os autores utilizaram uma base de dados composta por 160 isoladores cerâmicos. Devido à quantidade reduzida de imagens, os autores utilizaram duas técnicas de *data*

*augmentation* para quadruplicar a base de dados: espelhamento horizontal e ajuste dos valores dos pixels por *gamma correction*. Os resultados obtidos mostraram que o sistema desenvolvido apresentou acurácias de 95,16% na segmentação dos discos, 99,36% na detecção de discos ausentes e 95,51% na detecção de danos nos discos. Destaca-se que uma acurácia tão elevada em um modelo desenvolvido com base em poucas amostras pode indicar *overfitting* e os autores não exploraram tal possibilidade, indicando que é necessário treinar e testar o sistema com outras imagens para que se possa obter um resultado mais confiável. Além disso, a utilização de arquiteturas separadas torna o processo de segmentação e classificação mais demorado, além de tornar a estrutura muito complexa e, conseqüentemente, apresentar um elevado esforço computacional.

Tao *et al.* (2020) desenvolveram um sistema para reconhecimento de cadeias de isoladores e detecção de ausência de discos a partir de fotografias capturadas por VANTs. Para tanto, os autores desenvolveram uma base de dados de fotografias de cadeias de isoladores cerâmicos com revestimento polimérico localizados em linhas de transmissão chinesas, denominada *Chinese Power Line Insulator Dataset (CPLID)*, a qual se encontra publicada na plataforma GitHub (WANG, 2021). Os autores capturaram 900 fotografias de cadeias de isoladores íntegras e apenas 60 fotografias de cadeias com ausência de um dos discos. Devido à quantidade desproporcional de dados de cadeias íntegras e defeituosas, os autores produziram 996 fotografias sintéticas de cadeias de isoladores defeituosas a partir das 60 fotografias originais. Para tanto, os autores utilizaram técnicas de *data augmentation*, tais como *affine transformation*, segmentação e fusão de fundo, *gaussian blur* e *brightness transformation*. Para o processo de classificação da imagem, os autores desenvolveram duas arquiteturas em cascata, sendo a primeira para o reconhecimento das cadeias de isoladores na fotografia e a segunda para a detecção de discos faltantes nas mesmas. A primeira arquitetura era composta por um módulo VGG-16, seguida de uma Region Proposal Network (RPN), uma camada ROI Pooling e pelas camadas totalmente conectadas. Por sua vez, a segunda arquitetura era composta por dois módulos ResNet-101 e, entre eles, uma RPN e uma camada ROI Pooling. Os resultados mostraram precisão e sensibilidade de 90,4% e 96,6% no reconhecimento das cadeias de isoladores e uma precisão e sensibilidade de 91,0% e 95,8% na detecção de discos ausentes. No entanto, a base de dados apresenta um desbalanceamento entre a quantidade de cadeias de isoladores íntegras e defeituosas, o que pode ter provocado uma redução da precisão na detecção de discos ausentes. Além disso, utilizaram arquiteturas que demandam elevado tempo de detecção, de 359 ms/imagem, e, assim como Sampedro *et*

*al.* (2019), diferentes arquiteturas foram utilizadas no processo de reconhecimento e classificação da cadeia de isoladores na imagem.

Kulkarni, Shaw e Lewis (2020) construíram uma base de dados de fotografias de isoladores poliméricos, denominada Insulator Defect Image Dataset (IDID) e disponibilizada no IEEE Dataport (LEWIS & KULKARNI, 2021). A IDID foi construída a partir de fotografias divulgadas pelo EPRI para uso em aplicações de Visão Computacional. A base de dados é composta por imagens de alta qualidade de isoladores cerâmicos em linhas de transmissão e as correspondentes anotações de caixas delimitadoras para a cadeia de isoladores como um todo e cada disco da cadeia. Por sua vez, os discos presentes nas fotografias da base de dados podem ser classificados como: íntegros, quebrados ou com danos oriundos do *flashover*. Ao todo, a IDID é composta por 1596 imagens de cadeias de isoladores e por 7568 objetos, dentre eles 1788 cadeias de isoladores como um todo, 2636 discos íntegros, 1140 discos quebrados e 2004 discos com danos oriundos do *flashover*. Vários trabalhos utilizaram a IDID para treinar arquiteturas para detecção de defeitos em cadeias de isoladores e obtiveram resultados relevantes, dentre eles os trabalhos de Zhang, Xu e Cui (2023), que implementaram uma arquitetura *Faster RCNN*, e os trabalhos de Hong, Wang e Ma (2022) e Chen *et al.* (2023), que implementaram arquiteturas da família YOLO.

Após a publicação da base de dados CPLID, muitos trabalhos a utilizaram para desenvolver classificadores para identificar defeitos em isoladores a partir de fotografias aéreas. Um destes trabalhos é o de Zhao *et al.* (2021), que desenvolveram um sistema para reconhecimento do isolador e detecção de defeitos, baseado na melhoria da arquitetura *Faster R-CNN*, a qual é um método *deep learning* de dois estágios. Para o treinamento do sistema desenvolvido, que utilizou uma única arquitetura para o reconhecimento e a detecção de defeito, foi utilizada a base de dados CPLID. Além da arquitetura desenvolvida, os autores também compararam os resultados obtidos após o treinamento com outras arquiteturas, como a YOLOv2, SSD e a *Faster R-CNN* original. Os resultados obtidos mostraram que o sistema desenvolvido apresentou AP de 93% na identificação da cadeia de isoladores e de 91,7% na identificação de defeitos nos discos, cujos resultados foram superiores às demais arquiteturas. A utilização de uma única arquitetura para o reconhecimento e detecção de defeitos apresentou um avanço no estado da arte. No entanto, o consumo de memória foi de 9,3 GB e tempo de detecção de 197 ms/imagem, os quais foram superiores aos trabalhos anteriores.

Outros trabalhos também utilizaram classificadores baseados em métodos de dois estágios no diagnóstico de isoladores a partir de fotografias, como os trabalhos de Kang *et al.* (2018), Ling *et al.* (2019), Lei e Sui (2019) e Zhang, Xu e Cui (2023), também utilizando uma única arquitetura para as etapas de reconhecimento e detecção de discos ausentes. Embora tenham apresentado elevadas acurácias, os classificadores baseados em métodos de dois estágios apresentam baixa velocidade de detecção quando comparados com os baseados em métodos de um estágio. Por isso, muitos pesquisadores vêm utilizando classificadores baseados em métodos de um estágio para diagnosticar isoladores, propondo melhorias no que diz respeito às limitações existentes, como é o caso dos trabalhos de Yang *et al.* (2022), Hao *et al.* (2022), Xia *et al.* (2022) e Zhang *et al.* (2022).

Yang *et al.* (2022) propuseram uma modificação na arquitetura YOLOv3 para o reconhecimento de cadeias de isoladores em fotografias aéreas capturadas por VANTs e diagnóstico de discos ausentes. Os autores inseriram um bloco adicional do neck da YOLOv3, com o intuito de melhorar a velocidade de execução do classificador e as acurácias no reconhecimento e na classificação da cadeia, tendo em vista que a região do defeito é extremamente pequena comparada com o tamanho da imagem. Além disso, os autores alteraram a função de perdas original da YOLOv3 pela Smooth-EIoU Loss, com o objetivo de reduzir a quantidade de épocas necessárias para a convergência na etapa de treinamento. A base de dados utilizada no treinamento do sistema foi a CPLID. Por fim, os autores compararam o desempenho do sistema com a arquitetura original, com outras arquiteturas da família YOLO e com outros trabalhos. Os resultados obtidos foram AP de 94,0% no reconhecimento das cadeias de isoladores e de 89,0% na detecção dos defeitos e tempo de detecção de 90,5 ms/imagem. No entanto, a YOLOv4 apresentou precisão no reconhecimento de 94,6% e a YOLOv3 original apresentou melhor tempo de detecção, 80 ms/imagem.

Xia *et al.* (2022) propuseram uma melhoria na arquitetura CenterNet para obter melhores acurácias no reconhecimento de isoladores e na detecção de discos ausentes a partir de fotografias aéreas, além de melhores resultados na velocidade de detecção e no consumo de memória. Para o treinamento, os autores utilizaram a CPLID, além de outra base de dados de autoria própria. Os resultados mostraram um consumo de memória inferior a outros tipos de arquitetura, bem como uma melhoria na detecção de isoladores em pequena escala na imagem. O sistema desenvolvido apresentou AP de 97,9% na detecção do isolador e de 83,7% na detecção de defeitos, mAP de 90,8%, consumo de

memória de 87,8 MB e tempo de detecção de 32,8 ms/imagem. No entanto, a mAP do sistema implementado foi inferior aos sistemas baseados em arquiteturas da família YOLO, como, por exemplo, o sistema desenvolvido por Hao *et al.* (2022), que será apresentado na seção seguinte.

He *et al.* (2023) propuseram uma melhoria na arquitetura YOLOv8, visando também a melhoria da precisão da detecção dos defeitos nos isoladores a partir de fotografias aéreas, principalmente em cenários com fundo complexo. Para tanto, os autores desenvolveram uma própria base de dados de fotografias de isoladores de vidro e de porcelana instalados em linhas de transmissões chinesas. A base de dados desenvolvida contemplou três tipos de defeitos: discos ausentes, discos quebrados e danos por *flashover*. A arquitetura melhorada apresentou AP de 98,4% na detecção do isolador na fotografia, 94,2% na detecção de discos ausentes, 93,6% na detecção de discos quebrados e 89,5% na detecção de danos por *flashover*, além de um consumo de memória de apenas 2,53 MB, o que mostra que a arquitetura YOLOv8 apresenta bom desempenho ao detectar mais de um tipo de defeito. Além disso, os resultados apresentaram uma melhoria significativa em relação à arquitetura YOLOv8 original, como também em comparação com outros tipos de classificadores.

Ao analisar os trabalhos que utilizaram técnicas de *deep learning* para realizar o diagnóstico de imagens de isoladores, é possível constatar um foco claro no diagnóstico de isoladores de vidro ou porcelana, sendo que, na maioria dos casos o modelo de classificação é capaz apenas de determinar se existem ou não discos quebrados, o que não é um defeito considerado grave a menos que o número de discos quebrados seja bastante significativo. Observa-se também que diferentes estruturas de modelagem foram analisadas e comparadas entre si e conclui-se que a arquitetura YOLO apresenta os melhores resultados.

Destaca-se um foco em reduzir o consumo de memória e melhorar o tempo de detecção dos modelos, contudo, do ponto de vista prático o esforço computacional só é relevante durante o treinamento dos modelos, não impactando seu uso em campo, por sua vez, o tempo de reconhecimento já alcançado, que é da ordem de milissegundos já é suficientemente rápido para uso dos modelos em campo.

Não se observa em nenhum dos trabalhos uma análise de sensibilidade do desempenho dos modelos em função de parâmetros das imagens, isso ocorre em grande parte porque a maior parte dos trabalhos foi desenvolvida com dados públicos e pouco representativos. Assim, não é possível quantificar como esses modelos seriam afetados

caso a resolução da imagem fosse alterada ou a distância da câmera em relação ao isolador fosse aumentada. Tais análises seriam fundamentais para estabelecer os limites operacionais dos modelos, permitindo assim sua utilização confiável em campo.

### 3.1.3 USO OU APRIMORAMENTO DAS TÉCNICAS DE *DATA AUGMENTATION*

Devido à quantidade de imagens pouco representativa nas bases de dados CPLID e IDID, muitos trabalhos buscaram a utilização ou até mesmo o aprimoramento de técnicas de *data augmentation* dos sistemas classificadores. Ao mesmo tempo, continuaram a busca pela melhoria das arquiteturas da família YOLO, com o intuito de melhorar a velocidade de execução, o consumo de memória e a precisão na detecção de objetos em pequena escala, tanto para os isoladores, como para os próprios defeitos.

Vieira e Silva *et al.* (2020) publicaram uma nova base de dados de fotografias aéreas de isoladores cerâmicos, que agrega duas bases de dados públicas: a CPLID e algumas imagens presentes na base de dados desenvolvida por Tomaszewski *et al.* (2018), a qual contém imagens de isoladores de porcelana íntegros. Para a obtenção da nova base de dados, denominada *Unifying Public Datasets for Insulator* (UPID), os autores realizaram o *data augmentation* a partir da *affine transformation*, *gaussian blur*, ajuste de contraste e brilho, além de outros métodos descritos por Buslaev *et al.* (2020). Ao todo, a UPID é composta por 6860 imagens de isoladores cerâmicos, dentre elas 4800 são de isoladores íntegros e 1980 de isoladores defeituosos. No entanto, a UPID ainda apresenta um desbalanceamento da quantidade de imagens de isoladores íntegros e defeituosos. Além disso, os autores não avaliaram o desempenho da nova base de dados no treinamento de um classificador.

Song *et al.* (2020) realizaram a aplicação das principais técnicas de *data augmentation* na melhoria do desempenho do treinamento de um sistema para reconhecimento de isoladores em fotografias. Para tanto, foi utilizada a base de dados CPLID. As principais técnicas de *data augmentation* utilizadas no estudo foram: equalização, inserção de ruído gaussiano, *random erasing* e algumas formas de *affine transformation*, como translação, rotação e zoom por aproximação ou afastamento. Para o reconhecimento do isolador, foi utilizada uma arquitetura do tipo *Faster RCNN*. Os resultados obtidos mostraram que a expansão da base de dados por ruído gaussiano, rotação e zoom apresentaram melhor impacto na melhoria do desempenho do treinamento

do sistema. Porém, não se observa no trabalho uma análise do impacto destas técnicas na detecção dos defeitos.

Hao *et al.* (2022) propuseram uma melhoria na arquitetura YOLOv4, também para a detecção de discos ausentes em cadeias de isoladores, destacando a dificuldade na detecção de pequenos objetos nas imagens e no reconhecimento da cadeia de isoladores em fotografias com fundo complexo. Para tanto, os autores realizaram modificações na arquitetura interna, com o intuito de melhorar a detecção da cadeia em imagens com fundo complexos, a detecção de cadeias em pequena escala e o processo de extração de atributos. Para o treinamento do classificador, os autores utilizaram o CPLID e uma outra base de dados de isoladores de vidro, disponibilizada pela 8th “TipDM Cup” Data Mining Challenge, em 2020, dando origem ao *Chinese Power Line Multitype Insulator Dataset* (CPLMID). Ainda mais, os autores utilizaram técnicas de *data augmentation* para aumentar a quantidade de dados em ambas as bases de dados, dentre elas o espelhamento horizontal e vertical, adição de ruídos aleatórios e melhoramento de contraste. Os resultados obtidos mostraram uma melhoria das precisões no reconhecimento e na classificação das cadeias de isoladores em relação a trabalhos anteriores, principalmente na detecção de isoladores em pequena escala e nas imagens com fundo complexo. O sistema desenvolvido apresentou AP de 92,14% na detecção do isolador e de 99,13% na detecção de discos ausentes, tempo de detecção de 15,9 ms/imagem e consumo de memória de 227 MB.

Zhang *et al.* (2022) propuseram a expansão das fotografias da base de dados UPID e a melhoria da arquitetura YOLOv5 para o reconhecimento de cadeias de isoladores e detecção de discos ausentes a partir de fotografias aéreas capturadas por VANTs. A construção da nova base de dados, denominada *Synthetic Foggy Insulator Dataset* (SFID), foi realizada por meio do *synthetic foggy algorithm*, que consiste na inserção de uma camada sintética de névoa e variar a luminosidade do ambiente em imagens RGB. Por sua vez, a melhoria da YOLOv5 consistiu na introdução de um módulo interno para eliminar a equalidade dos pesos de cada canal oriunda da arquitetura original. Quando treinado apenas com a UPID, o sistema apresentou mAP de 96,6% e f1-score, ou seja, a média harmônica entre a precisão e a sensibilidade, de 91,1%. Após o treinamento com a SFID, a mAP subiu para 99,3% e a f1-score subiu para 93,8%. Os autores também avaliaram o sistema utilizando apenas fotografias da base de dados da UPID, a fim de verificar se as variações de luminosidade e inserção de camadas de névoa de forma artificial de fato melhora o desempenho do sistema ao classificar fotografias que não

apresentam essas condições. Os resultados mostraram que a f1-score subiu para 94,3%, o que mostra que a obtenção de novas amostras pelo synthetic foggy algorithm melhorou o desempenho do sistema desenvolvido. No entanto, o tempo de detecção foi de 200,9 ms/imagem, o qual foi bastante superior aos trabalhos citados anteriormente.

Chen *et al.* (2023) propuseram uma melhoria na arquitetura da YOLOv8, a mais recente até a publicação do trabalho, também para a detecção de discos ausentes em cadeias de isoladores, destacando a necessidade de diminuir o número de parâmetros e a complexidade computacional, além da melhoria na detecção de pequenos objetos. Para tanto, foram adicionados e substituídos módulos e uma camada de detecção de objetos. Para treinamento e teste da nova arquitetura, denominada Insu-YOLO, foram utilizadas as bases de dados CPLID e IDID. Devido à pequena quantidade de fotografias em ambas as bases de dados, os autores expandiram os dados de treinamento por algumas técnicas de *data augmentation*, como melhoramento do brilho e do contraste e aprofundamento das cores. Os resultados obtidos mostraram que houve uma melhoria da AP e mAP em relação aos modelos anteriores. O sistema desenvolvido apresentou AP de 99,5% na detecção de cadeias de isoladores e de 99,5% na detecção de defeitos, mAP de 95,9%, tempo de detecção de 11,5 ms/imagem e consumo de memória de apenas 9,2 MB, cujos valores atendem aos requisitos para detecção em tempo real e modelo leve para implantação e experimentação em dispositivos móveis. Ainda assim, a YOLOv8n apresentou melhores resultados no tempo de detecção e no consumo de memória.

Quanto às técnicas de *data augmentation*, existem ainda outras abordagens que foram utilizadas em outras bases de dados de fotografias de isoladores. Uma delas é a Generation Adversarial Network (GAN), proposta por Goodfellow *et al.* (2014). A metodologia baseada em GAN consiste em um sistema capaz de gerar um conjunto de dados imagens artificiais o mais realista possível. Alguns trabalhos, como o de Luo, Hsu e Wang (2020), propuseram melhorias ao algoritmo GAN para obter imagens artificiais mais realistas de isoladores elétricos. Embora esta metodologia tenha funcionado ao gerar imagens artificiais de outros tipos de dados, como rostos humanos, utensílios domésticos, roupas e acessórios, a GAN não tem apresentado bons resultados ao obter novas amostras de fotografias de isoladores elétricos. Além disso, em virtude de os defeitos serem objetos anexados aos isoladores, não é possível gerar novas fotografias artificiais de isoladores com defeitos. Só é possível gerar defeitos em regiões isoladas da fotografia, sem estar diretamente em cima do isolador.

Qiu *et al.* (2022) propuseram uma metodologia de *data augmentation* para a expansão de base de dados de fotografias de isoladores de vidro. Na metodologia proposta, primeiramente é utilizada uma arquitetura YOLOv3 para reconhecer os isoladores e, em seguida, separá-los do fundo da fotografia. Na sequência, técnicas de *data augmentation* são aplicadas a ambas as partes: espelhamentos horizontal e vertical e *perspective transformation* na caixa do isolador, e *random erasing* no fundo, evitando atingir o isolador ou defeito. Em seguida, realizou-se a junção entre os isoladores e os fundos, com possibilidade de troca de fundo, e adicionados ruídos e efeitos climáticos, como tremor de VANT, variação de iluminação, nevoeiro, chuva, neblina, e ruídos de sal e pimenta, ou seja, manchas brancas nas regiões mais escuras e manchas pretas nas regiões mais claras. Por fim, a base de dados expandida foi utilizada para treinar modelos CNN convencionais, mostrando que ResNet50 e VGG16-bn apresentam melhor desempenho com a base expandida. No entanto, para uma melhor avaliação da metodologia proposta, seria relevante utilizá-la para o treinamento das arquiteturas mais utilizadas pelos pesquisadores para o diagnóstico de fotografias de isoladores obtidas por VANTs, como, por exemplo, a YOLO.

### 3.2 CONSIDERAÇÕES SOBRE O ESTADO DA ARTE

Neste capítulo, foi apresentada uma revisão bibliográfica dos principais trabalhos que utilizaram técnicas de Visão Computacional no diagnóstico de isoladores a partir de fotografias.

O resultado da revisão realizada aponta que as arquiteturas baseadas em métodos *deep learning* de um estágio apresenta melhores condições para utilização em VANTs, principalmente por apresentar velocidades de detecção e consumo de memória compatíveis, além da possibilidade de utilizar uma única arquitetura das mesmas tanto para a detecção do isolador como também para o diagnóstico. Dentre as arquiteturas de um estágio utilizadas em trabalhos anteriores, constatou-se que a YOLO apresentou boa precisão ao classificar discos ausentes em cadeias de isoladores e que certas modificações internas em sua arquitetura podem melhorar a velocidade de detecção e o consumo de memória. Além disso, foi possível observar técnicas de *data augmentation* tradicionais, como a rotação, zoom e ruído gaussiano, e as técnicas aprimoradas, como aquelas

apresentadas nos trabalhos de Zhang *et al.* (2022) e Qiu *et al.* (2022), mostraram-se eficientes ao melhorar o treinamento dos classificadores desenvolvidos.

Constatou-se que a maioria dos trabalhos anteriores focou apenas na detecção de discos ausentes em cadeias de isoladores de vidro ou porcelana e na melhoria da velocidade de detecção e consumo de memória ao detectar defeitos a partir de fotografias. No entanto, outros defeitos mais relevantes poderiam ser abordados, como corrosão nas ferragens, presença de fissuras ou trincas, deterioração da cimentação e indícios de poluição, tendo em vista que a ausência de um dos discos não implica em uma intervenção imediata na cadeia de isoladores. Além disso, embora ainda haja um esforço para melhorar a velocidade de detecção e consumo de memória, as arquiteturas desenvolvidas já atingiram resultados suficientes para a detecção em tempo real e modelo leve para implantação e experimentação em dispositivos móveis. Ainda mais, há uma escassez de trabalhos que aplicaram arquiteturas de Visão Computacional na detecção de defeitos em isoladores poliméricos de suspensão a partir de fotografias. Embora alguns trabalhos citados tenham utilizado imagens de isoladores poliméricos para o treinamento dos sistemas classificadores, realizou-se apenas a detecção, sem diagnóstico de nenhum tipo de defeito em isoladores poliméricos.

Dessa forma, uma possível contribuição para o estado da arte seria ir além da detecção de discos ausentes e explorar a detecção de defeitos mais relevantes que são difíceis de ser observados a olho nu ou que requeiram ação imediata. Além disso, o diagnóstico de defeitos em isoladores poliméricos, como a presença de fissuras, rachaduras e exposição do núcleo, a partir de fotografias também seria uma contribuição significativa, dada a complexidade envolvida na identificação de defeitos dessa natureza em inspeções visuais.

Nesse contexto, o presente trabalho propõe o desenvolvimento uma base de dados de fotografias de isoladores poliméricos e sua utilização no desenvolvimento de um sistema para o reconhecimento de defeitos, tendo em vista que danos e degradações em isoladores poliméricos são mais difíceis de serem notados durante inspeções visuais e que detecção de discos ausentes em cadeias de isoladores de vidro não apresenta relevância significativa. Além disso, propõe-se a construção do sistema com base em arquiteturas da família YOLO, as quais já atingiram bons resultados na precisão, na velocidade de detecção e no esforço computacional. Na Tabela 1 são apresentadas as principais contribuições dos trabalhos anteriores na revisão bibliográfica, bem como a contribuição

proposta nesta pesquisa. No próximo capítulo será apresentada a metodologia utilizada nesta pesquisa.

Tabela 1 – Quadro sinóptico comparativo do estado da arte e da presente dissertação.

Pesquisa	1	2	3	4	5	6	7	8	9
Oliveira (2017)	•			•					•
Alves (2018)	•			•					•
Florentino (2019)	•			•					•
Sampedro <i>et al.</i> (2019)	•	•	•	•				•	
Tao <i>et al.</i> (2020)	•	•	•	•			•		
Song <i>et al.</i> (2020)	•		•		•		•		
Vieira e Silva <i>et al.</i> (2020)	•						•		
Zhao <i>et al.</i> (2021)	•	•	•		•				
Hao <i>et al.</i> (2022)	•	•	•		•	•	•		
Zhang <i>et al.</i> (2022)	•	•	•		•	•	•		
Chen <i>et al.</i> (2023)	•	•	•		•	•	•	•	
He <i>et al.</i> (2023)	•	•	•	•	•	•	•	•	
Esta dissertação	•		•	•	•	•	•	•	•

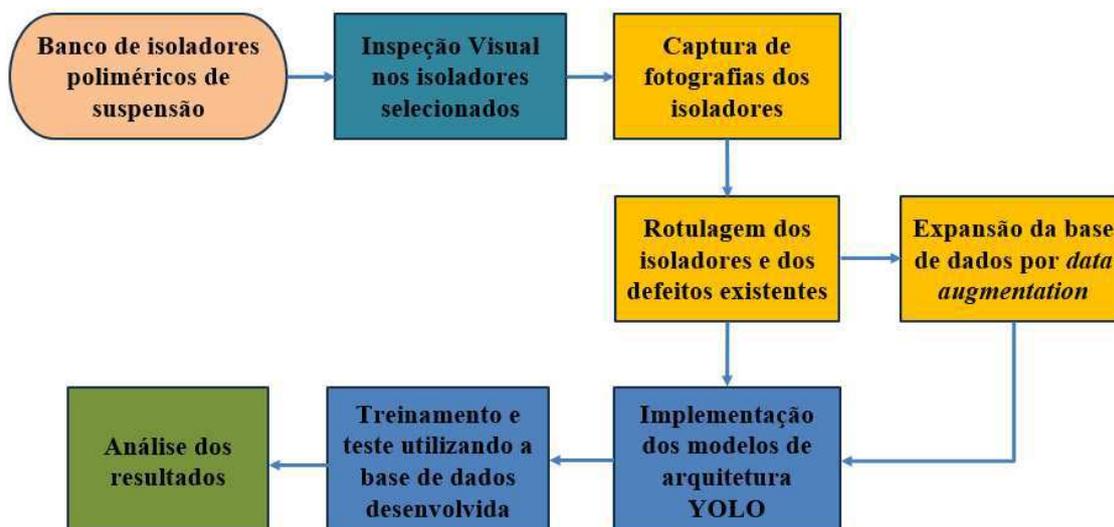
1. Inspeção de isoladores elétricos;
2. Detecção de discos ausentes;
3. Utilização de técnicas de Visão Computacional baseadas em *deep learning*;
4. Desenvolvimento da própria base de dados de fotografias de isoladores;
5. Utilização de uma única arquitetura para o reconhecimento e o diagnóstico dos isoladores;
6. Utilização de arquiteturas baseadas em métodos *deep learning* de um estágio;
7. Uso de *data augmentation*;
8. Diagnóstico de mais de um tipo de defeito;
9. Diagnóstico de isoladores poliméricos.

Fonte: Autoria Própria.

## 4 METODOLOGIA

Neste capítulo é apresentada a metodologia utilizada para atingir os objetivos propostos. Primeiramente, são discutidos os procedimentos utilizados para desenvolver a base de dados original de fotografias de isoladores poliméricos de suspensão e as principais técnicas de *data augmentation* que serão utilizadas para a produção de novas amostras. Em seguida, será discutida a metodologia de desenvolvimento dos modelos para diagnóstico das imagens dos isoladores. Na Figura 26 é apresentado um fluxograma que resume a metodologia proposta neste trabalho.

Figura 26 – Fluxograma que resume a metodologia proposta.



Fonte: Autoria Própria.

### 4.1 DESENVOLVIMENTO DA BASE DE DADOS

Para a construção da base de dados de fotografias para o treinamento dos modelos, foram utilizados 30 isoladores poliméricos de suspensão da classe de 138 kV de um mesmo fabricante e retirados de operação em diversos estados de degradação. Na Figura 27 podem ser observadas as amostras de isoladores poliméricos utilizadas para o desenvolvimento da base de dados. Após uma inspeção visual em cada isolador, constatou-se que os defeitos mais recorrentes eram: núcleo exposto, corrosão nas ferragens e presença de rachaduras e cortes nas aletas.

Figura 27 – Fotografia do banco de isoladores poliméricos de suspensão utilizados nesta pesquisa.



Fonte: Autoria Própria.

A produção da base de dados envolveu duas etapas: a captura das fotografias dos isoladores e a rotulagem das imagens produzidas, ou seja, a definição das coordenadas do isolador na imagem e da posição e natureza dos defeitos presentes na imagem.

#### 4.1.1 CONSTRUÇÃO DA BASE DE IMAGENS DE ISOLADORES

Para a etapa de captura das fotografias, foi utilizada uma câmera fotográfica modelo Nikon D7500. A fim de proporcionar uma melhor estabilidade e evitar trepidações que comprometam a qualidade das imagens, a câmera foi fixada a um tripé para a realização das capturas.

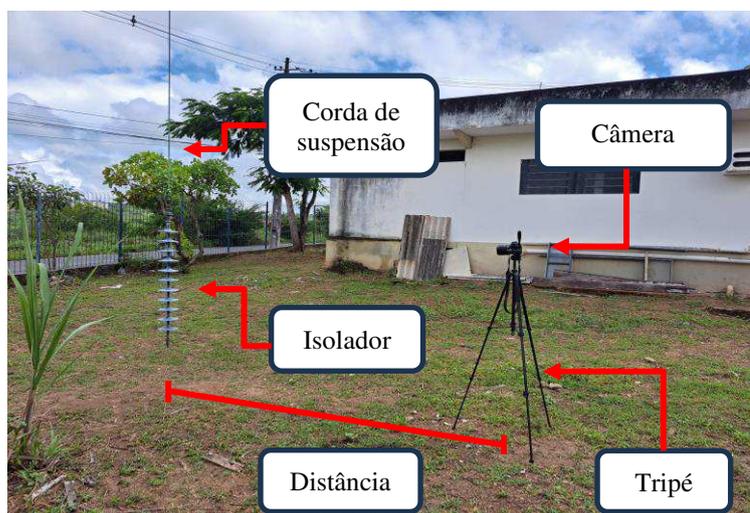
Durante a etapa de captura das fotografias, o isolador foi suspenso por uma estrutura de suporte em três ambientes distintos, a fim de contemplar diversos cenários e posições. Na Figura 28, é possível observar os três ambientes distintos, sendo o primeiro localizado na câmara de névoa os demais no ambiente de entorno do Laboratório de Alta Tensão (LAT). A câmara de névoa apresenta fundo branco e alta luminosidade, enquanto o ambiente de entorno apresenta condições mais próximas da realidade no que diz respeito à complexidade do fundo da imagem e variações de luminosidade. A câmara de névoa foi escolhida por ser um ambiente de fundo simples, que deve facilitar o processo de reconhecimento dos isoladores e seus defeitos. Por sua vez, os ambientes externos representam situações de fundo mais complexo e próximo a realidade. Na Figura 29 é possível observar uma imagem de um isolador suspenso na área de entorno, bem como o posicionamento da câmera fotográfica e do tripé para a etapa de captura das fotografias.

Figura 28 – Cenários utilizados na etapa de captura das fotografias.



Fonte: Autoria Própria.

Figura 29 – Posicionamento do isolador e do conjunto câmera-tripé para a captura das fotografias na câmara de névoa.



Fonte: Autoria Própria.

A construção das imagens seguiu a seguinte metodologia:

- Inicialmente, foram realizadas fotografias com uma distância de 1 m entre a câmera e o isolador;
- A distância foi progressivamente aumentada em passos de 1 m, até atingir uma distância máxima de 5 m, exceto na câmara de névoa, onde o espaço permitiu uma distância máxima de apenas 2 m;
- Após cada fotografia, o isolador era rotacionado de 90° e uma nova fotografia foi feita até que o isolador tenha sido fotografado por todos os ângulos.

O objetivo de rotacionar um isolador é o de ocultar alguma rachadura ou exposição do núcleo e, assim, obter uma outra amostra. Assim, para cada isolador é possível obter diversas amostras de fotografias distintas.

Para avaliar o impacto da distância entre a câmera e o isolador na detecção de defeitos, as capturas das fotografias foram realizadas em diferentes distâncias, variando de 1 a 5 m. A distância de 1 m foi utilizada como referência inicial, devido à capacidade de capturar detalhes dos defeitos com alta nitidez. No entanto, considerando as limitações operacionais de VANTs e as recomendações da literatura que sugerem uma distância entre 3 e 5 m para a inspeção de isoladores (LIN & LIU, 2021), esse intervalo também foi explorado.

#### 4.1.2 ROTULAGEM DAS IMAGENS E *DATA AUGMENTATION*

Após a conclusão da captura das fotografias dos isoladores, realizou-se o processo de atribuição de rótulos. A etapa de rotulagem dos dados é fundamental para o processo de construção de um modelo, pois é a partir dela que é possível definir as respostas esperadas para o modelo em cada situação, o que viabilizará seu treinamento e validação.

Assim, esta etapa consistiu em atribuir os rótulos das caixas delimitadoras correspondentes ao isolador e, em caso de ocorrência, aos respectivos defeitos, os quais serão utilizados para o treinamento dos modelos para a detecção de defeitos nos isoladores a partir das fotografias. Para a realização da rotulagem dos objetos das imagens, foi utilizado o *software open source* LabelImg, disponível no GitHub (TZUTALIN, 2015). Na Figura 30 é apresentada a interface do *software* utilizado para a rotulagem das imagens. Na Figura 31 é possível observar um exemplo de rotulagem de uma das fotografias da base de dados, cujo isolador apresenta duas rachaduras e uma aleta com corte.

Após a rotulagem das fotografias de isoladores poliméricos, foram utilizadas técnicas de *data augmentation* para a obtenção de novas amostras. Assim espera-se tornar as bases de dados mais robustas, obter melhores resultados no treinamento do sistema e evitar *overfitting*. Durante a análise dos classificadores deste trabalho será realizada uma análise do impacto do uso do *data augmentation* sobre a qualidade dos classificadores.

Com base na revisão bibliográfica realizada, foram utilizadas as técnicas de *data augmentation* que obtiveram maior sucesso em trabalhos com isoladores. Assim, o processo de *data augmentation* das bases de dados foi dividido em duas partes. Na

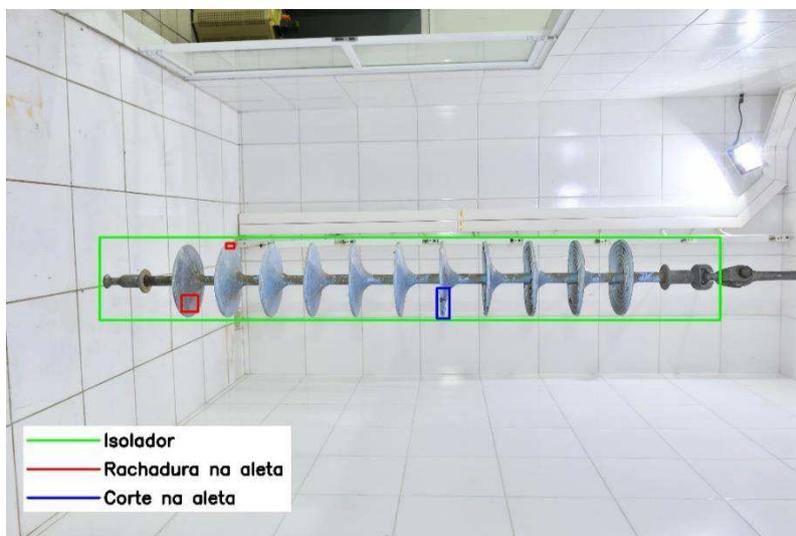
primeira parte, foram obtidas novas amostras pelos espelhamentos horizontal e vertical e por rotação das fotografias.

Figura 30 – Interface do LabelImg.



Fonte: Autoria própria.

Figura 31 – Exemplo de rotulagem de um isolador com uma aleta cortada e duas rachaduras.



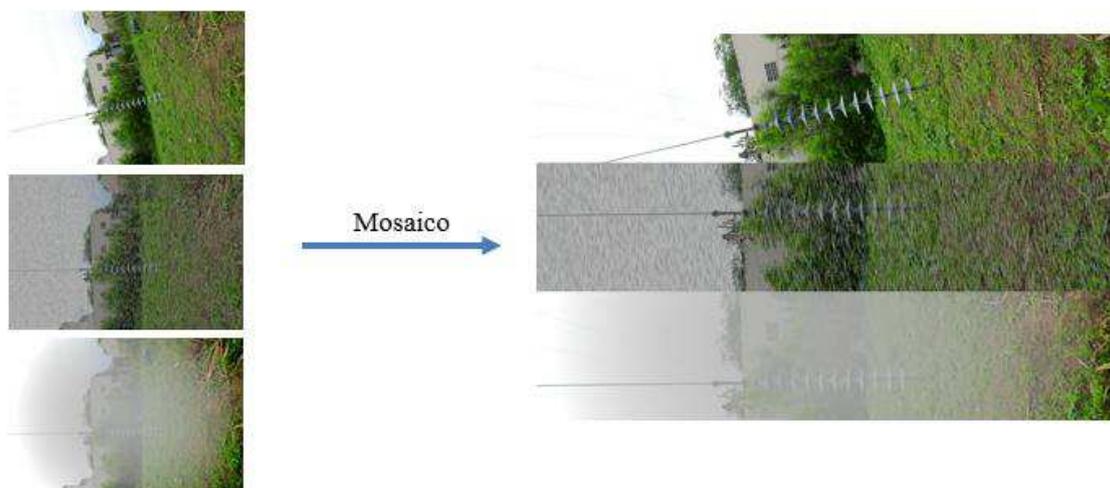
Fonte: Autoria própria.

Na segunda parte, foram obtidas novas amostras a partir da inserção de ruído gaussiano e condições atmosféricas de chuva, nevoeiro e luminosidade. A obtenção de novas amostras por inserção de condições atmosféricas de iluminação e nevoeiro foi realizada utilizando o algoritmo proposto por Zhang *et al.* (2022), enquanto as novas amostras obtidas por inserção de chuva e ruído gaussiano foram produzidas utilizando a

biblioteca *Albumentations*, tal biblioteca é *open source* e disponível para a linguagem de programação Python.

Em seguida, foi utilizada a técnica do mosaico para juntar partes de duas fotografias contendo isoladores em uma só, com a mesma dimensão e preservando os tamanhos dos isoladores nas fotografias. Decidiu-se combinar diferentes amostras de isoladores em uma única fotografia, com o intuito de manter a mesma quantidade de fotografias que foi obtida na primeira parte e, conseqüentemente, evitar o uso de uma quantidade elevada de memória RAM para realizar o treinamento dos modelos. A partir da técnica do mosaico, foram obtidas fotografias com o mosaico de duas amostras de isoladores para a base de dados de 1 m e de três amostras para as demais bases de dados. Na Figura 32 é possível observar uma ilustração de como a técnica do mosaico foi utilizada e na Tabela 2 é possível observar as características das bases de dados obtidas após cada uma das partes da etapa de *data augmentation*.

Figura 32 – Ilustração da utilização da técnica do mosaico.



Fonte: Autoria Própria.

Tabela 2 – Características das bases de dados obtidas após cada parte do data augmentation.

Base de dados	Quantidade de fotografias	Data Augmentation	Data Augmentation
		Parte 1	Parte 2
		Isoladores por fotografia	Isoladores por fotografia
1 m	1308	1	2
2 m	1236	1	3
3 m	1309	1	3
4 m	1274	1	3
5 m	1281	1	3

Fonte: Autoria Própria.

## 4.2 TREINAMENTO DOS MODELOS

Para realizar o treinamento dos modelos para diagnosticar defeitos em isoladores poliméricos a partir de fotografias, foi utilizado o ambiente virtual *Google Colaboratory Pro+*, mais conhecido como *Colab Pro+*. O *Google Colaboratory* é um serviço de armazenamento em nuvens de notebooks destinados à criação e execução de códigos em *Python* diretamente de um navegador web com acesso à internet. As vantagens de utilizar o *Colab* para o desenvolvimento do sistema proposto dizem respeito à não necessidade de instalação de um *software*, à existência de bibliotecas pré-instaladas, e principalmente, o acesso a GPUs com *hardware* acelerado, uma vez que o *Colab Pro+* disponibiliza GPUs Nvidia T4, L4, V100 e A100.

De acordo com a revisão bibliográfica apresentada, a estrutura mais promissora para o reconhecimento de defeitos em isoladores é a YOLO. Contudo, por se tratar de uma estrutura baseada em *deep learning*, existem muitas variantes e com diferentes graus de complexidade. Assim, neste trabalho optou-se por desenvolver dois classificadores com estruturas YOLO distintas como forma de avaliar o impacto do aumento da complexidade do classificador sobre seu desempenho.

Assim, para o diagnóstico dos isoladores a partir das fotografias, foram utilizados dois modelos *fine-tuning* de detectores YOLO: o YOLOv8s e o YOLOv8m. Para realizar o treinamento, foi instalada a biblioteca Ultralytics, a qual disponibiliza os modelos *fine-tuning* da YOLOv8s e da YOLOv8m. Na Tabela 3 são apresentadas as configurações de treinamento dos modelos e na Tabela 4 são apresentados os rótulos das classes dos objetos que os modelos conseguem detectar, correspondentes ao isolador e a cada tipo de defeito.

Tabela 3 – Hiperparâmetros do treinamento dos modelos.

Item	Valor
Dimensão de entrada	1280x1280, 1920x1920 e 2560x2560 pixels
Quantidade de épocas	100
Tamanho do lote	Autoajustado entre 1 e 16
Otimizador	AdamW
Taxa de aprendizado	0,001
Momentum	0,9
Decaimento de peso	0,0005

Fonte: Autoria Própria.

Tabela 4 – Rótulos das classes

Rótulo	Classes
0	Isolador
1	Núcleo exposto
2	Corrosão nas ferragens
3	Rachadura na aleta
4	Corte na aleta

Fonte: Autoria Própria.

O código desenvolvido no Google Colab para o treinamento dos modelos pode ser encontrado no APÊNDICE A. Primeiramente é criado um arquivo no formato .yaml com os diretórios da bases de dados de treinamento e teste. Posteriormente, é feita uma cópia da base de dados, localizada no Google Drive, para o diretório local do Google Colab e, em seguida, a mesma é descompactada. Após isso, é importado o modelo *fine-tuning* da YOLO e, por fim, é realizado o treinamento dos modelos, passando como parâmetros o arquivo .yaml, a quantidade de épocas, o tamanho das imagens, o tamanho do lote e outros cuja explicação detalhada se encontra no próprio código. Assim como nos trabalhos anteriores, foram utilizados os hiperparâmetros padrões da biblioteca para o otimizador e os valores de taxa de aprendizado, momentum e decaimento de peso.

Durante o treinamento, foram variadas as dimensões da imagem de entrada, a fim de avaliar o impacto da qualidade da imagem no desempenho dos modelos na detecção dos defeitos, dado que há uma maior dificuldade na identificação de defeitos pequenos em fotografias de resolução mais baixa. Foram analisadas três diferentes dimensões de entrada: 1280x1280, 1920x1920 e 2560x2560 pixels. O redimensionamento dos tamanhos das fotografias das bases de dados foi realizado utilizando a biblioteca Utralytics, a partir da técnica de redimensionamento por preenchimento. Além disso, o tamanho do lote foi ajustado automaticamente pela biblioteca, entre 2 e 16, de forma a equilibrar a velocidade e o consumo de memória RAM do treinamento, principalmente para o tamanho de entrada de 2560x2560 pixels.

Inicialmente, os modelos foram treinados com as bases de dados provenientes da primeira parte da etapa de *data augmentation*, variando-se as dimensões de entrada. Em seguida, os modelos foram treinados com as bases de dados oriundas da segunda e da terceira etapa, a fim de avaliar o impacto da quantidade de dados de treinamento e das condições de névoa, chuva e luminosidade no desempenho dos modelos na detecção de defeitos nos isoladores. Por fim, o desempenho dos modelos para cada configuração de dimensão das fotografias e para cada distância entre câmera e isolador foi avaliado, com

base na precisão, sensibilidade, AP e mAP, utilizando um *threshold* de confiabilidade de 0,5.

Neste capítulo foi apresentada a metodologia proposta neste trabalho para a avaliação do desempenho de modelos YOLO na detecção de defeitos em isoladores poliméricos a partir de fotografias e para a avaliação do impacto de aumentar a distância entre a câmera e o isolador, elevar a complexidade do modelo no desempenho da detecção dos defeitos e de aumentar a quantidade de dados para treinamento a partir de técnicas de *data augmentation*. No próximo capítulo serão apresentados os resultados obtidos por meio da metodologia proposta.

## 5 RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados os resultados obtidos no treinamento dos modelos para a identificação dos defeitos em isoladores poliméricos a partir de fotografias, com uma análise do impacto de elevar a complexidade do modelos, da distância entre a câmera e o isolador e da expansão das bases de dados. Primeiramente, são apresentados os resultados obtidos nos processos de captura das fotografias, rotulagem e *data augmentation*, além das características gerais dos dados obtidos. Em seguida, são apresentados os resultados obtidos com o treinamento a partir das bases de dados oriundas da primeira parte da etapa de *data augmentation* e, por fim, para os modelos que apresentaram melhores resultados, será feita uma análise comparativa entre os resultados obtidos após o treinamento antes e após a segunda parte da etapa de *data augmentation*, na qual foram obtidas novas de fotografias, com condições de chuva, névoa, luminosidade e ruído gaussiano.

### 5.1 BASES DE DADOS DESENVOLVIDAS

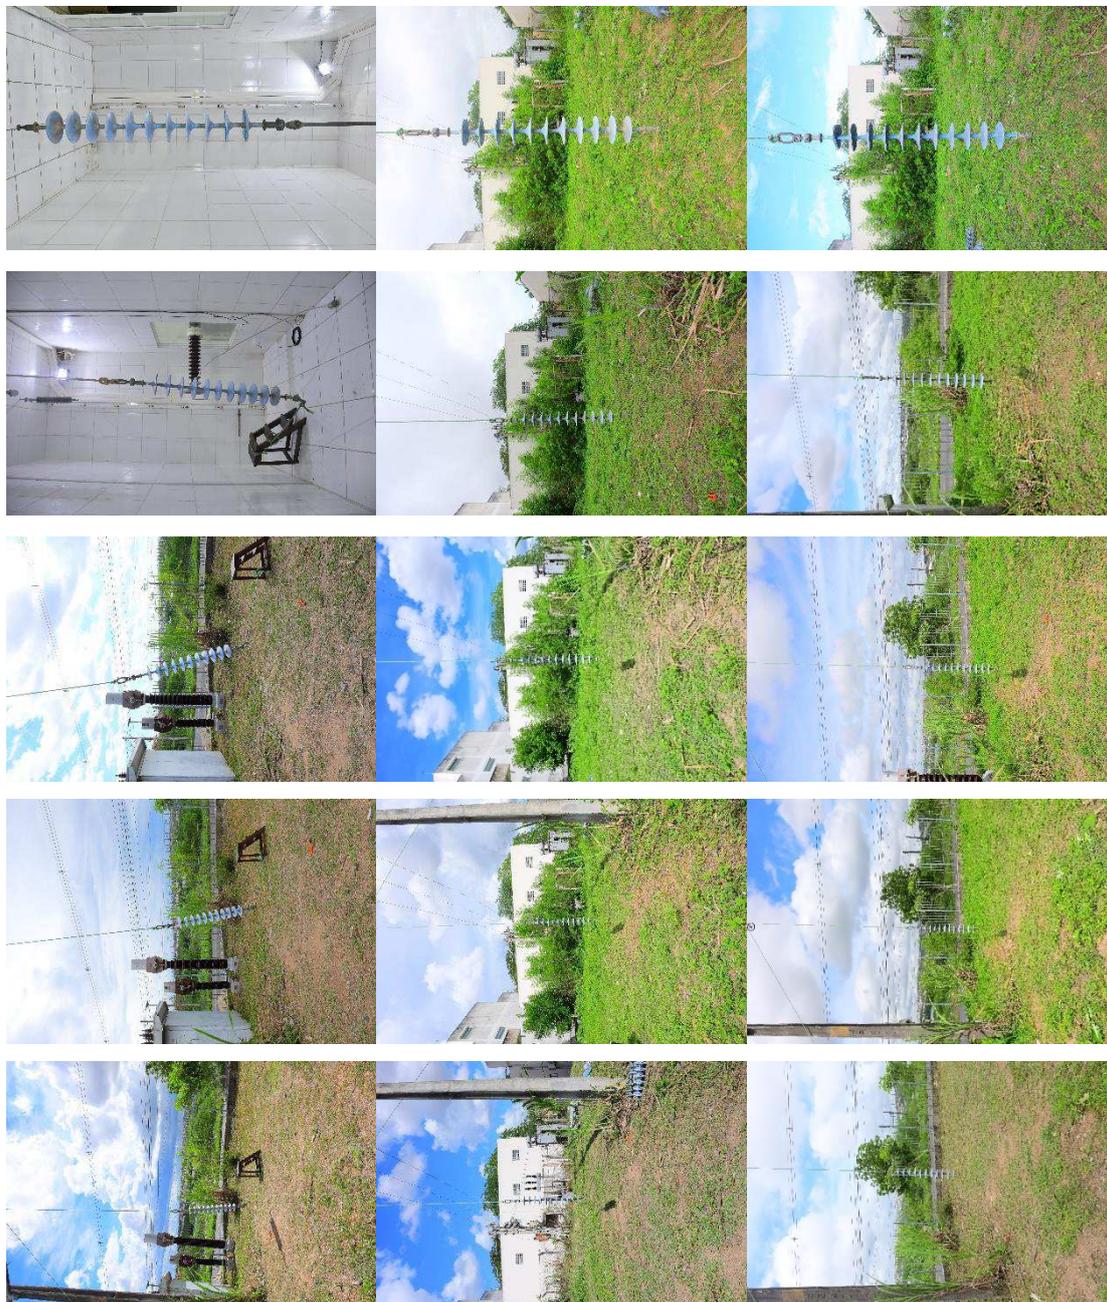
Na Figura 33 são apresentados exemplos de fotografias capturadas dos isoladores durante o processo de captura das fotografias dos isoladores, para cada distância e para cada cenário possível.

Após o processo de captura das fotografias, foi realizada a etapa de rotulagem do isolador e, em caso de ocorrência, dos respectivos defeitos. Na Figura 34 são apresentados exemplos de rótulos obtidos para cada base de dados e na Tabela 5 são apresentadas as quantidades de fotografias capturadas, isoladores e defeitos para cada base de dados desenvolvida.

Após a rotulagem, deu-se início à etapa de *data augmentation*. Primeiramente, foram obtidas novas amostras de fotografias por espelhamento horizontal e vertical, de forma a quadruplicar as bases de dados de 1 m e 2 m. Para as demais bases de dados, também foram obtidas novas de fotografias por rotação, de forma que a quantidade de fotografias de cada base de dados se tornasse o mais próximo possível, a fim de que os resultados obtidos treinamento dos modelos para o diagnóstico de isoladores a distâncias

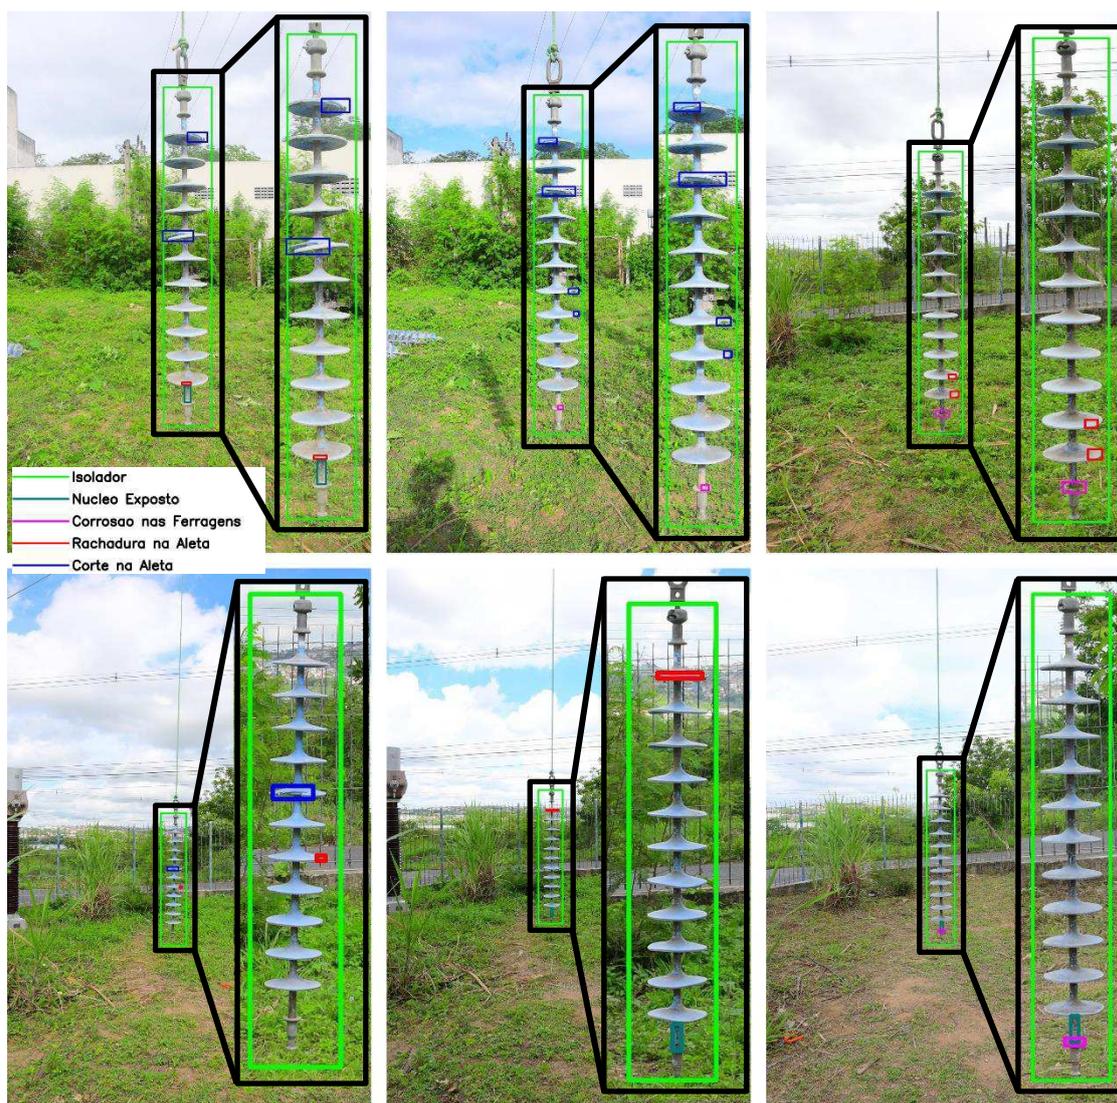
de 3 m, 4 m e 5 m não fossem prejudicados devido a uma quantidade menor de dados para treinamento. Na Figura 35 são apresentados exemplos de novas amostras obtidas para as bases de dados de 1 m e de 3 m.

Figura 33 – Exemplos de fotografias capturadas.



Fonte: Autoria Própria.

Figura 34 – Exemplos de fotografias com seus respectivos rótulos.



Fonte: Autoria Própria.

Tabela 5 – Quantidade de fotografias, isoladores e defeitos por base de dados.

Distância	Quantidade de fotografias	Isolador	Núcleo exposto	Corrosão nas ferragens	Rachadura na aleta	Corte na aleta
1 m	327	327	143	143	459	151
2 m	309	309	124	65	639	188
3 m	187	187	78	27	354	115
4 m	182	182	78	17	287	116
5 m	183	183	75	19	216	125

Fonte: Autoria Própria.

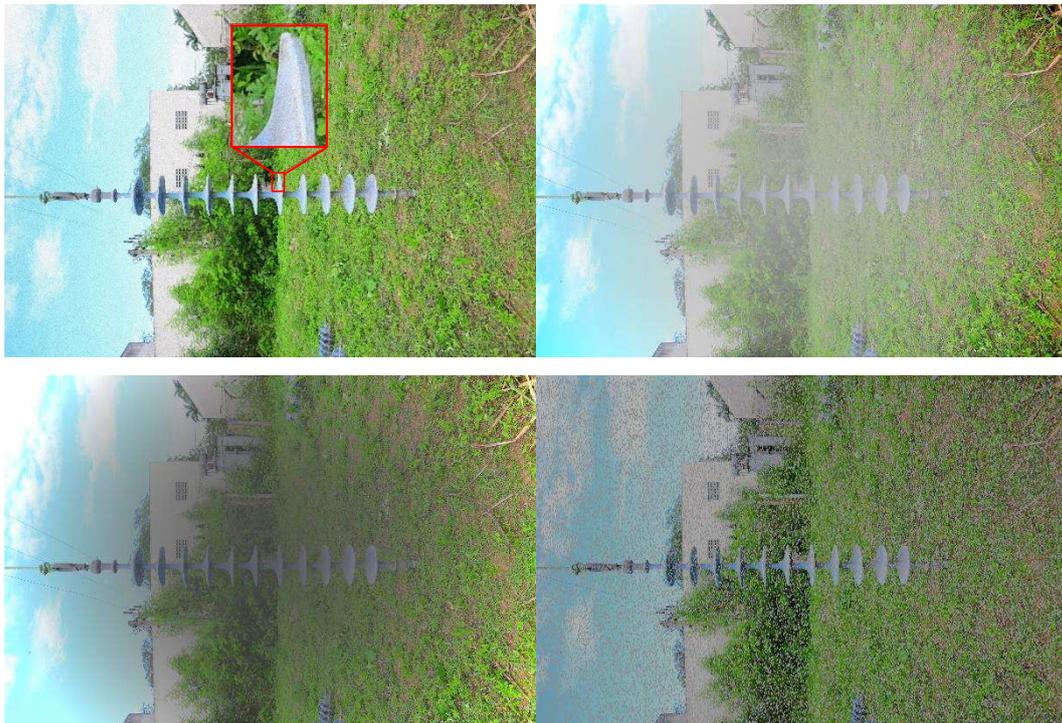
Figura 35 – Exemplos de fotografias obtidas na primeira parte da etapa de *data augmentation*.



Fonte: Autoria Própria.

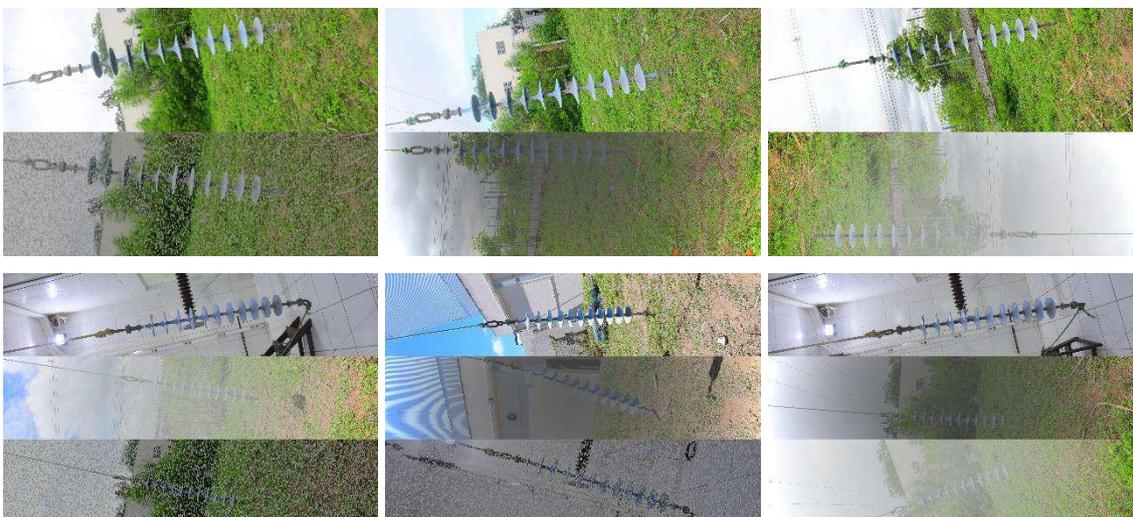
Por fim, na segunda parte da etapa de *data augmentation*, foram obtidas novas amostras de fotografias pela inserção de condições de chuva, névoa, luminosidade e ruído gaussiano, de forma a se obter quatro novas amostras, compreendendo cada uma das quatro condições, para cada fotografia das bases de dados obtidas após a primeira etapa. Na Figura 36 são apresentados exemplos de novas amostras obtidas para um exemplo de fotografia da base de dados de 1 m. Em seguida, a fim de evitar uma quantidade de fotografias que excedesse a quantidade de memória RAM disponível para realizar o treinamento dos modelos, utilizou-se a técnica do mosaico para combinar cortes das imagens de duas ou três amostras obtidas em uma única fotografia, preservando as dimensões dos isoladores e a quantidade de fotografias em relação à etapa anterior. Na Figura 37, são apresentados exemplos de amostras finais das bases de dados de 1 m e de 2 m após a segunda parte da etapa de *data augmentation* e nas Tabelas 7 e 8 são apresentadas as quantidades de fotografias e rótulos para cada base de dados após a primeira e a segunda parte do *data augmentation*.

Figura 36 – Exemplos de novas amostras obtidas pela inserção de (a) ruído gaussiano e condições de (b) névoa, (c) luminosidade e (d) chuva.



Fonte: Autoria Própria.

Figura 37 – Exemplos de fotografias obtidas após a segunda parte da etapa de data augmentation.



Fonte: Autoria Própria.

Tabela 6 – Quantidade de fotografias, isoladores e defeitos por base de dados após a parte 1 do *data augmentation*.

Distância	Quantidade de fotografias	Isolador	Núcleo exposto	Corrosão nas ferragens	Rachadura na aleta	Corte na aleta
1 m	1308	1308	572	388	1836	604
2 m	1236	1236	496	260	2556	752
3 m	1309	1309	546	189	2478	805
4 m	1274	1274	546	119	2009	812
5 m	1281	1281	525	133	1512	875

Fonte: Autoria Própria.

Tabela 7 – Quantidade de fotografias, isoladores e defeitos por base de dados após a parte 2 do *data augmentation*.

Distância	Quantidade de fotografias	Isolador	Núcleo exposto	Corrosão nas ferragens	Rachadura na aleta	Corte na aleta
1 m	1308	2616	1144	776	3672	1208
2 m	1236	3708	1488	780	7668	2256
3 m	1309	3927	1638	567	7434	2415
4 m	1274	3822	1638	357	6027	2436
5 m	1281	3843	1575	399	4536	2625

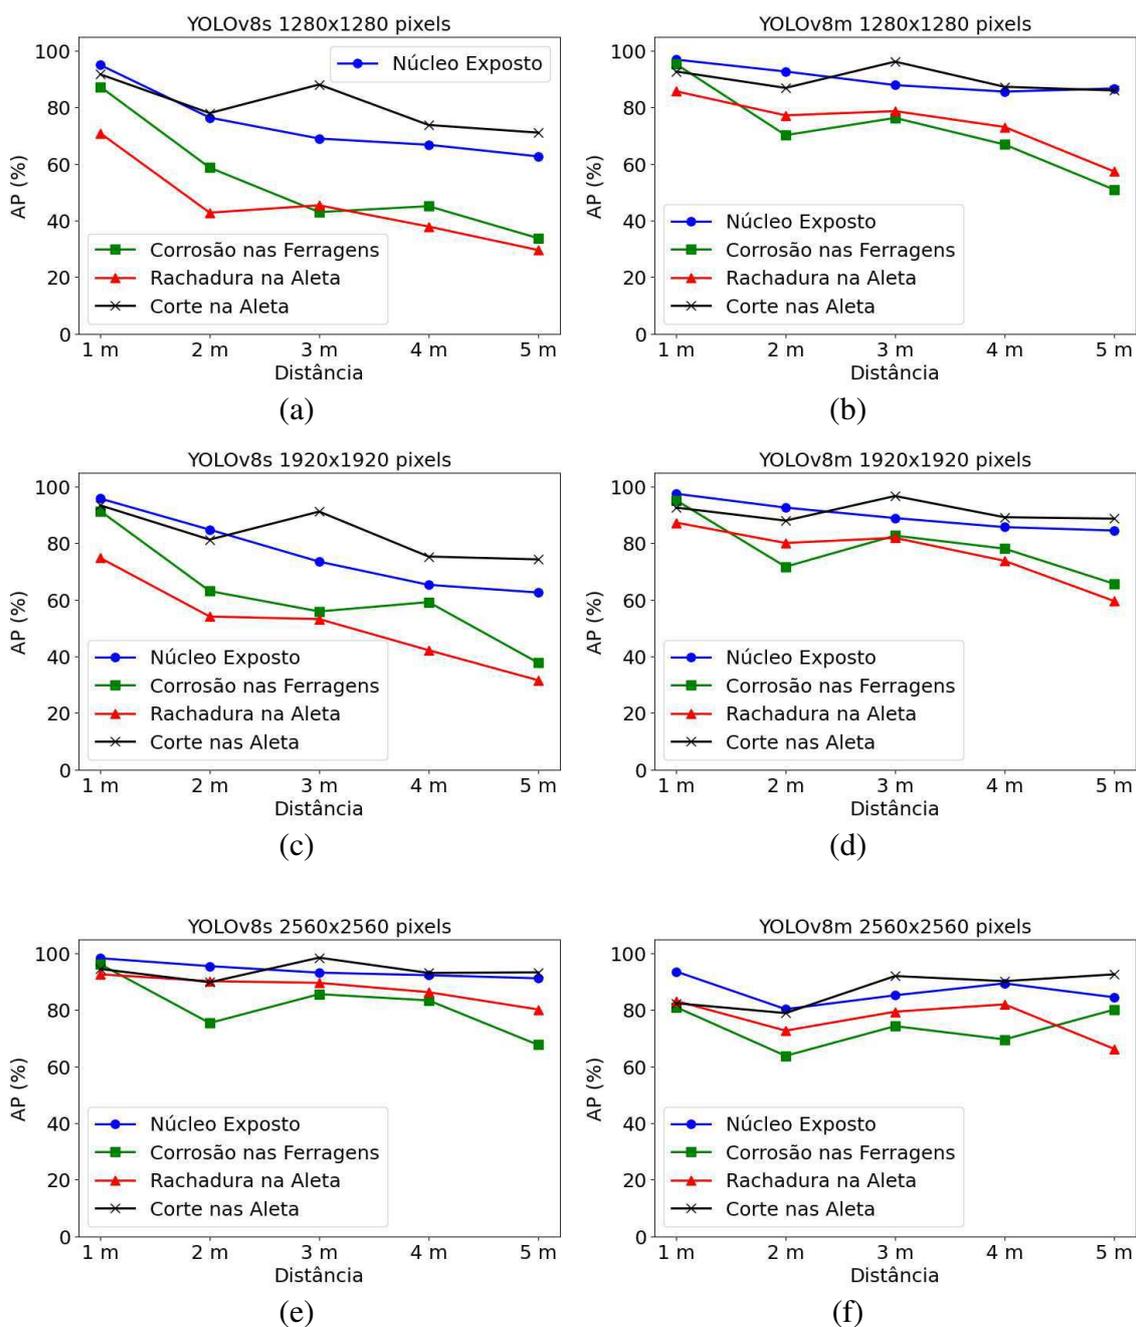
Fonte: Autoria Própria.

## 5.2 DESENVOLVIMENTO E ANÁLISE DE RESULTADOS DE CLASSIFICADOR DE FOTOGRAFIAS

A partir do código mostrado no APÊNDICE A, dois modelos YOLO distintos foram treinados inicialmente utilizando a partir das bases de dados oriundas da primeira parte da etapa de *data augmentation*, com base na AP e no tempo de treinamento. Neste capítulo, são apresentados apenas os resultados para as métricas AP e mAP. Os resultados de precisão e sensibilidade, serão apresentados em tabelas no APÊNDICE B.

Na Figura 38 é possível observar a evolução dos valores de AP na detecção de cada tipo de defeito nos isoladores poliméricos em função da distância entre câmera e isolador para cada modelo desenvolvido. Na Tabela 8 são apresentados os tempos médios de treinamento de cada modelo, para cada configuração de resolução de entrada.

Figura 38 – Gráficos de precisão para cada modelo.



Fonte: Autoria Própria.

Tabela 8 – Tempo de treinamento para cada modelo.

	1280x1280 pixels		1920x1920 pixels		2560x2560 pixels	
	YOLOv8s	YOLOv8m	YOLOv8s	YOLOv8m	YOLOv8s	YOLOv8m
GPU	T4	T4	T4	T4	T4	V100
Tempo de treinamento	2,80 h	3,94 h	4,28 h	7,92 h	6,79 h	5,70 h

Fonte: Autoria Própria.

Inicialmente, com base nos resultados apresentados nos gráficos da Figura 38 e nas tabelas do APÊNDICE B, é possível observar uma tendência natural: os resultados

melhoram para resoluções de imagens mais altas e pioram em função do crescimento da distância. Assim, a maioria dos valores de AP dos modelos que apresentaram dimensões de entrada de 1280x1280 e 1920x1920 pixels foi entre 30% e 80%, o que indica um baixo desempenho ao diagnosticar isoladores poliméricos a partir de fotografias que apresentam resoluções mais baixas. Isso pode ser atribuído ao fato de que defeitos em isoladores poliméricos ocupam uma pequena área da fotografia, podendo não ser bem representados em baixas resoluções. Por outro lado, os modelos com dimensão de entrada de 2560x2560 pixels apresentaram maior parte dos resultados de AP acima de 80%.

Conforme observado na Tabela 8, quanto maior a dimensão de entrada, maior o tempo de treinamento, a potência e o consumo de memória da GPU necessários. Destaca-se que, para a YOLOv8m com 2560x2560 pixels, foi necessário utilizar a GPU V100 para realizar o treinamento, que é mais potente e cara do que a GPU T4. Assim, melhorar o desempenho dos modelos utilizando resoluções ainda mais elevadas provavelmente seria possível, contudo, o esforço computacional e o custo a ele associado inviabilizaram este tipo de análise durante esta pesquisa.

Por outro lado, ao comparar a YOLOv8s e YOLOv8m, os resultados são de certa forma contraintuitivos. O esperado a priori seria que o modelo mais complexo apresentasse resultados sempre melhores. No entanto, para uma dimensão de entrada de 2560x2560 pixels, os melhores resultados ocorreram para o modelo YOLOv8s.

Uma hipótese para explicar a queda no desempenho da YOLOv8m é o fato de que, por ser mais complexo, o modelo precisaria de uma quantidade maior de dados para apresentar um bom desempenho ao trabalhar com fotografias de alta resolução. Por isso, para uma análise mais aprofundada, serão avaliados os desempenhos de ambos os modelos, com dimensão de entrada de 2560x2560 pixels após o treinamento com as bases de dados obtidas na segunda parte do *data augmentation*.

Ao analisar comparativamente os diferentes defeitos presentes na base de dados, é possível observar que, no geral, os modelos apresentaram melhor desempenho na detecção de núcleo exposto, o defeito considerado mais crítico, e corte nas aletas. Para a YOLOv8s com dimensão de entrada de 2560x2560 pixels e para todos os modelos de YOLOv8m desenvolvidos, a AP da detecção de núcleo exposto e corte nas aletas foi acima de 80% para todas as distâncias, exceto para a distância de 2 m na YOLOv8m com dimensão de entrada de 2560x2560 pixels. Por outro lado, para corrosão nas ferragens e rachadura nas aletas, os modelos apresentaram resultados valores de AP entre 60% e 80% para todos os casos em que as distâncias eram superiores a 1 m e as dimensões de entrada

eram de 1280x1280 ou 1920x1920 pixels, indicando que estes defeitos são particularmente difíceis de detectar, isso é corroborado pelo fato de que no modelo YOLOv8s com dimensão de entrada de 2560x2560 pixels, as detecções de rachadura nas aletas e de corrosão nas ferragens foram as únicas que apresentaram AP abaixo de 90% para distâncias maiores que 1 m, na faixa de 60% a 90%.

O baixo desempenho na detecção de corrosão nas ferragens pode estar vinculado à sua baixa ocorrência nas bases de dados. Por outro lado, a dificuldade em detectar rachaduras nas aletas, apesar de ser o defeito mais recorrente, pode ser explicado por apresentar uma espessura bastante pequena e, conseqüentemente, ocupar uma área proporcionalmente pequena na fotografia.

Por fim, é possível observar que a distância entre a câmera e o isolador é fator de maior impacto sobre o desempenho dos classificadores. Os melhores resultados ocorreram para uma distância de 1 m, os quais apresentaram AP acima de 80% em todos os modelos e acima de 90% na detecção dos defeitos utilizando a YOLOv8s com dimensão de entrada de 2560x2560 pixels. Com o aumento da distância, os valores de AP reduziram significativamente em todos os modelos e na detecção de quase todos os tipos de defeitos. Em alguns casos, os modelos apresentaram melhoria nos resultados ao variar a distância de 2 m para 3 m. Para as distâncias de 4 m e 5 m, os resultados não foram satisfatórios, uma vez que as detecções de corrosão nas ferragens e rachadura nas aletas apresentaram valores de precisão, sensibilidade e AP na faixa de 60% a 90% em ao menos um dos modelos. Considerando que os drones comerciais devem trabalhar com distâncias entre 3 e 5 m, pode-se concluir que estes modelos não são ainda adequados para as condições operacionais. Na próxima seção, este desempenho será melhor avaliado e comparado com os resultados obtidos após o treinamento com a base de dados oriunda da segunda parte da etapa de *data augmentation*.

### 5.3 APLICAÇÃO DE *DATA AUGMENTATION*

Para uma análise mais aprofundada dos resultados, primeiramente são analisados numericamente os valores das métricas AP e mAP da YOLOv8s e YOLOv8m com dimensão de entrada de 2560x2560 pixels, treinadas com a base de dados oriunda da primeira parte da etapa de *data augmentation*, considerando também a identificação do isolador nas fotografias. Na Tabela 9 são apresentados os resultados para a YOLOv8s,

enquanto na Tabela 10 são apresentados os resultados para a YOLOv8m. Em seguida, são analisados os resultados para ambos os modelos após o treinamento com a base de dados oriunda da segunda parte da etapa de *data augmentation*. Na Tabela 11 são apresentados os resultados para a YOLOv8s treinada com a base de dados da segunda parte, enquanto na Tabela 12 são apresentados os resultados para a YOLOv8m.

Tabela 9 – Desempenho da YOLOv8s com dimensão de entrada de 2560x2560 pixels após o treinamento com a base de dados oriunda da parte 1 do *data augmentation*.

	AP(%)					mAP (%)
	Isolador	Núcleo Exposto	Corrosão nas Ferragens	Rachadura nas Aletas	Corte nas Aletas	
1m	57,5	98,3	96,2	92,6	94,5	87,8
2m	99,5	95,5	75,4	90,2	89,8	90,1
3m	99,5	93,2	85,6	89,6	98,5	93,3
4m	99,5	92,3	83,4	86,3	93,1	90,9
5m	99,5	91,2	67,7	80,2	93,3	86,4

Fonte: Autoria Própria.

Tabela 10 – Desempenho da YOLOv8m com dimensão de entrada de 2560x2560 pixels após o treinamento com a base de dados oriunda da parte 1 do *data augmentation*.

	AP(%)					mAP (%)
	Isolador	Núcleo Exposto	Corrosão nas Ferragens	Rachadura nas Aletas	Corte nas Aletas	
1 m	30,7	93,6	81,0	83,2	82,4	74,2
2 m	83,3	80,3	63,8	72,7	78,9	75,8
3 m	90,9	85,2	74,3	79,4	92,0	84,3
4 m	92,9	89,4	69,6	82,0	90,2	84,8
5 m	90,5	84,5	80,1	66,3	92,6	82,8

Fonte: Autoria Própria.

Ao analisar as Tabelas 9 e 10 e as Tabelas 18 e 19 do APÊNDICE B, que contêm os resultados da AP do reconhecimento do isolador polimérico nas fotografias, é possível constatar que, embora ambos os modelos tenham apresentado melhores resultados na detecção de defeitos a uma distância de 1 m, o reconhecimento do isolador na fotografia apresentou desempenho bastante baixo para esta distância. Porém, para distâncias maiores, ambos os modelos apresentaram melhoras significativas no desempenho. Isso indica que a YOLOv8 pode apresentar dificuldades em identificar grandes objetos em fotografias de grande resolução.

Além disso, é possível constatar nos resultados apresentados nas Tabelas 9 e 10 e nas Tabelas 18 e 19 do APÊNDICE B que, embora a YOLOv8m seja o modelo mais complexo, novamente é a YOLOv8s que apresenta os melhores resultados na detecção de

defeitos. Novamente, a hipótese é que isso pode ser atribuído a uma quantidade insuficiente de dados de treinamento. Por isso, para uma melhor compreensão do que pode estar acontecendo, nas Tabelas 11 e 12 são apresentados os resultados obtidos após a segunda parte do *data augmentation*.

Tabela 11 – Desempenho da YOLOv8s com dimensão de entrada de 2560x2560 pixels após o treinamento com a base de dados oriunda da parte 2 do *data augmentation*.

	AP(%)					mAP (%)
	Isolador	Núcleo Exposto	Corrosão nas Ferragens	Rachadura nas Aletas	Corte nas Aletas	
1 m	54,9	98,8	97,4	95,0	98,3	88,9
2 m	99,5	99,4	94,8	96,0	99,1	97,7
3 m	99,5	99,5	99,3	98,7	99,3	99,2
4 m	99,5	98,7	91,8	97,8	98,4	97,2
5 m	99,5	99,5	95,1	97,9	98,8	98,2

Fonte: Autoria Própria.

Tabela 12 – Desempenho da YOLOv8m com dimensão de entrada de 2560x2560 pixels após o treinamento com a base de dados oriunda da parte 2 do *data augmentation*.

	AP(%)					mAP (%)
	Isolador	Núcleo Exposto	Corrosão nas Ferragens	Rachadura nas Aletas	Corte nas Aletas	
1 m	55,1	97,3	95,6	93,2	97,1	87,8
2 m	99,5	99,3	93,7	95,4	98,6	97,3
3 m	99,6	99,6	98,9	98,6	99,4	99,2
4 m	99,6	98,8	94,3	98,4	98,3	97,9
5 m	99,6	99,4	90,7	98,4	98,8	97,3

Fonte: Autoria Própria.

Com base nos resultados apresentados nas Tabelas 11 e 12, é possível observar que o aumento da quantidade de dados de treinamento proporcionou uma melhoria significativa no desempenho dos modelos, principalmente para a YOLOv8m. Os resultados do treinamento com a base de dados de 1 m, que possui 2 isoladores por fotografias, melhorou o desempenho da detecção de todos os tipos de defeitos, principalmente as detecções de corrosão nas ferragens e rachadura nas aletas. Por outro lado, mesmo com o aumento dos dados, os modelos ainda apresentam baixa AP na detecção do isolador nas fotografias, o que reforça a dificuldade da YOLOv8 em detectar grandes objetos em fotografias de alta resolução.

Para as demais distâncias, por apresentarem 3 isoladores por fotografias, os resultados foram melhores em relação ao treinamento com a base de dados de 1 m, que

possuía 2 isoladores por fotografia. A detecção de quase todos os tipos de defeitos apresentou todas as métricas acima de 90% para distâncias entre 3 e 5 m para ambos os modelos, exceto para a sensibilidade da detecção de corrosão nas ferragens, conforme mostrado nas Tabelas 23 e 24 do APÊNDICE B.

No geral, a metodologia de *data augmentation* empregada resultou na melhoria da detecção de todos os tipos de defeitos, principalmente para rachaduras nas aletas e corrosão nas ferragens. Quanto aos modelos utilizados, embora com uma melhoria significativa nos resultados da YOLOv8m, a YOLOv8s apresentou resultados melhores, o que mostra que, embora a YOLOv8m apresente uma estrutura mais complexa, apresenta desempenho mais baixo na detecção de objetos em fotografias de alta resolução. Contudo, com base nos resultados aqui apresentados, se a base de dados for continuamente expandida com imagens de alta resolução é possível que o modelo YOLOv8m supere o YOLOv8s.

Os resultados obtidos neste trabalho mostram que a YOLOv8 apresenta um desempenho promissor na detecção de defeitos em isoladores poliméricos e que a ocorrência de rachadura nas aletas é bastante desafiadora, tendo que vista que, embora seja o defeito mais recorrente nas bases de dados, apresentou um dos desempenhos mais baixos.

Destaca-se que foi possível produzir um classificador com desempenho superior a 90% em todos os casos, mesmos para distâncias superiores a 3 m, o que indica que a técnica é promissora para ser utilizada em campo. Além disso, a YOLOv8 apresentou alto desempenho na detecção de núcleo exposto, que é o defeito considerado mais crítico e que exige manutenção imediata. Assim, a YOLOv8 é considerada promissora para futura implantação e experimentação em VANTs para o monitoramento em isoladores poliméricos.

Neste capítulo foram apresentados e discutidos os resultados obtidos nesta pesquisa. Foram apresentados os resultados a respeito do treinamento de modelos de arquitetura YOLO para a detecção de defeitos em isoladores poliméricos a partir de fotografias. Além disso, foi feita uma análise do impacto de aumentar a distância entre a câmera e o isolador, a resolução de entrada das fotografias, a complexidade do modelo e a quantidade de dados de treinamento. No capítulo seguinte serão apresentados a conclusão deste trabalho, as sugestões de trabalhos a serem desenvolvidos para dar continuidade à pesquisa e as publicações relacionadas ao desenvolvimento desta dissertação.

## 6 CONCLUSÃO

Neste trabalho, foram empregados modelos de Visão Computacional para a detecção de defeitos em isoladores poliméricos a partir de fotografias. Para tanto, foram construídas bases de dados de fotografias de isoladores poliméricos de suspensão da classe de 138 kV, compreendendo cinco diferentes distâncias entre câmera e isolador e quatro tipos de defeitos: núcleo exposto, corrosão nas ferragens, rachaduras e cortes nas aletas. Em seguida, foram treinados modelos *fine-tuning* de YOLOv8s e YOLOv8m com as bases de dados desenvolvidas. Por fim, foi feita uma análise de como a variação da dimensão de entrada, o tipo de modelo e a distância entre a câmera e o isolador afetam o desempenho na detecção de defeitos.

Os resultados obtidos mostraram que os modelos que configurados com baixa dimensão de entrada de fotografias, como 1280x1280 e 1920x1920 pixels apresentam desempenhos insuficientes na detecção de defeitos nos isoladores. Por outro lado, o aumento da dimensão de entrada para 2560x2560 pixels elevou o desempenho na detecção de defeitos para a YOLOv8s, porém, para a distância de 1 m, a AP da detecção do isolador na fotografia reduziu significativamente. Além disso, o aumento da dimensão de entrada elevou o tempo de treinamento dos modelos e, dependendo do modelo utilizado, exigiu o uso de uma GPU mais potente.

Quanto à distância, os resultados obtidos para o treinamento com uma quantidade mais baixa de dados mostraram que, embora com uma alta resolução, os modelos apresentaram baixo desempenho na detecção de corrosão nas ferragens e de rachaduras nas aletas. Com o aumento dos dados a partir da simulação de condições de chuva, névoa, baixa luminosidade e ruído gaussiano, o desempenho dos modelos melhorou significativamente para distâncias no intervalo recomendado de 3 a 5 m, o que indica que a YOLOv8 apresenta potencial para ser utilizada na detecção dos defeitos em isoladores poliméricos instalados no sistema elétrico. Por outro lado, é necessária uma grande quantidade de fotografias ou de isoladores por fotografia para se atingir um bom desempenho, o que torna o processo mais desafiador.

Quanto à complexidade do modelo, os resultados para resoluções mais baixas mostraram melhor desempenho da YOLOv8m, principalmente por possuir uma maior quantidade de parâmetros. Por outro lado, para resoluções mais altas, a YOLOv8m

apresentou desempenho mais baixo do que a YOLOv8s na detecção dos defeitos nos isoladores para o treinamento com uma quantidade menor de dados. Porém, com o aumento dos dados, ambos os modelos apresentaram excelentes resultados na detecção de todos os tipos de defeitos, o que indica que a YOLOv8 pode apresentar potencial para utilização no diagnóstico de isoladores poliméricos no sistema elétrico a partir de fotografias.

Assim, os resultados apontam que é possível, até certo ponto, melhorar o desempenho dos classificadores a partir de melhorias na resolução de entrada da fotografia ou pelo uso de modelos mais complexos. Além disso, para produzir sistemas de classificação de imagens de fato confiáveis, o esforço deve se concentrar na produção de uma base de dados mais robusta, tendo em vista que a expansão artificial das bases de dados desenvolvidas neste trabalho elevou o desempenho da detecção dos defeitos nos isoladores.

Os resultados da pesquisa evidenciaram que o uso de técnicas de Visão Computacional para aprimorar o processo de inspeção dos isoladores é de suma importância para o sistema elétrico, tendo em vista que a detecção rápida e eficaz de defeitos em isoladores poliméricos é crucial para garantir a segurança e a confiabilidade das redes de distribuição e transmissão de energia elétrica. A utilização do algoritmo YOLOv8 para o diagnóstico de isoladores, cujo desempenho demonstrou um potencial para futuras utilizações, pode permitir um avanço significativo no monitoramento dos isoladores, tornar o processo mais rápido e reduzir o custo e o risco de vida humana durante as inspeções.

## 6.1 TRABALHOS FUTUROS

Algumas sugestões de trabalhos a serem realizados no futuro que podem dar continuidade à pesquisa realizada são:

- Avaliar o desempenho da YOLOv8 e de versões mais recentes utilizando uma base de dados com maior quantidade de fotografias reais de isoladores poliméricos com diferentes tipos e formatos;
- Avaliar o desempenho da YOLO com base no tempo de detecção e do consumo de memória, a fim de analisar melhor a viabilidade da futura implantação em VANTs;

- Implementar melhorias na arquitetura interna da YOLOv8, a fim de melhorar o desempenho ao detectar isoladores com grande tamanho na fotografia, considerando a possibilidade de o VANT dar zoom durante a captura dentro do intervalo recomendado;
- Avaliar o desempenho de outras técnicas de Visão Computacional, como a SSD e a DSOD, na detecção de defeitos em isoladores poliméricos a partir de fotografias;
- Empregar técnicas de Visão Computacional para estimar o nível de poluição em isoladores poliméricos;
- Avaliar o desempenho da YOLO na detecção de defeitos em isoladores poliméricos a partir de vídeos e em tempo real.

## 6.2 PUBLICAÇÕES

Na Tabela 13 são apresentados os trabalhos científicos publicados ao longo do desenvolvimento desta dissertação.

Tabela 13 – Trabalhos científicos publicados ao longo desta pesquisa.

<b>Autores</b>	<b>Título</b>	<b>Evento/periódico</b>	<b>Ano</b>
<b>Samuel C. Nóbrega,</b> Matheus R. Alves, George R. S. Lira	Development of a Classification System for Visual Images of Electrical Insulators Using Convolutional Neural Networks	International Symposium on High Voltage Engineering	2023
<b>Samuel C. Nóbrega,</b> George R. S. Lira, Pablo B. Vilar	Detection of Polymeric Insulator Defects based on YOLOv8	International Conference on High Voltage Engineering and Application	2024

Fonte: Autoria Própria.

## REFERÊNCIAS

ABDALLA, L. S.; VOLATÃO, C. F. D. S. Estudo da configuração de diferentes arquiteturas de redes neurais artificiais MLP para classificação de imagens ópticas. **Anais XVI Simpósio Brasileiro de Sensoriamento Remoto-SBSR, Foz do Iguaçu, PR, Brasil, 2013.** 8200-8207.

ALVES, L. N. T. **Aprimoramento da Classificação de Isoladores Poliméricos por Medições.** Universidade Federal de Campina Grande. Campina Grande. 2018.

BACKES, A. R.; SÁ JUNIOR, J. J. D. M. **Introdução à Visão Computacional usando MATLAB.**

BALESTRO. **Isolador Pilar.** Disponível em: <<https://balestro.com.br/isolador-pilar/>>. Acesso em: 26 Setembro 2023.

BALLARD, D. H.; BROWN, C. M. **Computer Vision.**

BOCHKOVSKIY, A.; WANG, C.-Y.; LIAO, H.-Y. M. Yolov4: Optimal speed and accuracy of object detection. **arXiv preprint arXiv:2004.10934**, 2020.

BRITO, K. B. **Desenvolvimento de um Algoritmo Baseado em PDI para a Extração de Atributos de Descargas Corona em Isoladores Poliméricos.** Universidade Federal de Campina Grande. Campina Grande. 2021.

BUSLAEV, A.; IGLOVIKOV, V. I.; KHVEDCHENYA, E.; PARINOV, A.; DRUZHININ, M.; KALININ, A. A. Albumentations: fast and flexible image augmentations. **Information**, 11, 2020.

CHEN, W. H.; YAO, L. N.; LI, F. Z. Insulator defect detection and localization in drone grid inspection. **Computer Applications**, n. A01, 2019. 210-214.

CHEN, Y.; LIU, H.; CHEN, J.; HU, J.; ZHENG, E. Insu-YOLO: An Insulator Defect Detection Algorithm Based on Multiscale Feature Fusion. **Electronics**, 12, n. 15, 2023. 3210.

CHENG, Y. Detection of Power Line Insulator Based on Enhanced YOLO Model. **2022 IEEE Asia-Pacific Conference on Image Processing, Electronics and Computers (IPEC)**, 2022. 626-632.

CHOLLET, F. **Deep learning with Python.**

DENG, C. The method of insulator defect recognition based on group theory. **IEEE Access**, 9, 2021. 96380--96389.

DOMINGUES, E. S. **Improved Condition Monitoring of Composite Insulators.** University of Manchester. Manchester. 2012.

EPRI. **Field Guide: Visual inspection of polymer insulators.** Electric Power Research Institute - EPRI. Palo Alto, CA,1013283. 2006.

FAGHIH-ROOHI, S.; HAJIZADEH, S.; NÚÑEZ, A.; BABUSKA, R.; DE SCHUTTER, B. Deep convolutional neural networks for detection of rail surface defects. **2016 International Joint Conference on Neural Networks (IJCNN)**, 2016. 2584-2589.

FLORENTINO, M. T. B. **Caracterização das Condições Operacionais de Isoladores Poliméricos usando Atributos das Descargas Corona**. Universidade Federal de Campina Grande. Campina Grande. 2019.

FREEPIK. Isolador de vidro para linhas de alta tensão, 2024. Disponível em: <[https://br.freepik.com/fotos-premium/isolador-de-vidro-para-linhas-de-alta-tensao\\_29511035.htm](https://br.freepik.com/fotos-premium/isolador-de-vidro-para-linhas-de-alta-tensao_29511035.htm)>. Acesso em: 25 Junho 2024.

FUCHS, R. D. **Transmissão de Energia Elétrica: Linhas Aéreas**. 1. ed.

GAO, Z.; YANG, G.; LI, E.; LIANG, Z. Novel Feature Fusion Module-Based Detector for Small Insulator Defect Detection. **IEEE Sensors Journal**, 21, 2021. 16807-16814.

GERMER. Catálogo Técnico de Isoladores Germer, 2014. Disponível em: <<https://www.germerisoladores.com.br/catalogo/>>. Acesso em: 19 novembro 2022.

GIRSHICK, R. Fast R-CNN. **Proceedings of the IEEE International Conference on Computer Vision**, Santiago, Chile, 7-13 Dezembro 2015. 1440-1448.

GIRSHICK, R.; DONAHUE, J.; DARRELL, T.; MALIK, J. Rich feature hierarchies for accurate object detection and semantic segmentation. **Proceedings of the IEEE conference on computer vision and pattern recognition**, 2014. 580-587.

GORUR, R. S.; CHERNEY, E. A.; BURNHAM, J. T. **Outdoor Insulators**.

GUBANSKI, S. Modern Outdoor Insulation - Concerns and Challenges. **IEEE Electrical Insulation Magazine**, 21, n. 6, 2005. 9-11.

HAO, K.; CHEN, G.; ZHAO, L.; LI, Z.; LIU, Y.; WANG, C. An Insulator Defect Detection Model in Aerial Images Based on Multiscale Feature Pyramid Network. **IEEE Transactions on Instrumentation and Measurement**, 71, 2022. 1-12.

HAYKIN, S. **Redes neurais: princípios e prática**.

HE, K.; GKIOXARI, G.; DOLLAR, P. G. R. Mask r-cnn. **Proceedings of the IEEE international conference on computer vision**, 2017. 2961-2969.

IRUANSI, U.; TAPAMO, J.-R.; DAVIDSON, I. E. An active contour approach to insulator segmentation. **AFRICON 2015**, 2015. 1-5.

JABID, T.; AHSAN, T. Insulator detection and defect classification using rotation invariant local directional pattern. **International Journal of Advanced Computer Science and Applications**, 9, n. 2, 2018.

KANG, G.; GAO, S.; YU, L.; ZHANG, D. Deep architecture for high-speed railway insulator surface defect detection: Denoising autoencoder with multitask learning. **IEEE Transactions on Instrumentation and Measurement**, 68, n. 8, 2018. 2679-2690.

KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. **arXiv preprint arXiv:1412.6980**, 2014.

KONTARGYRI, V.; PLATI, L.; GONOS, I.; STATHOPULOS, I. Measurement and simulation of the voltage distribution and the electric field on a glass insulator string. **Measurement**, 41, n. 5, 2008. 471-480.

KULKARNI, P.; SHAW, T.; LEWIS, D. **Insulator defect image dataset - version 1.2: Documentation EPRI**. Palo Alto, CA. 2020. (3002017949).

KV LUX. **Isolador Polimérico Bastão Âncoragem 15kV | KV LUX Distribuidor de Fábrica**. Disponível em: <<https://www.kvlux.com.br/isolador-polimerico-bastao-ancoragem-15kv.html>>. Acesso em: 26 Setembro 2023.

LAPP INSULATORS. **Company Profile and Product Overview**.

LEI, X.; SUI, Z. Intelligent fault detection of high voltage line based on the Faster R-CNN. **Measurement**, 138, 2019. 0263-2241.

LEITE NETO, A. F. **Análise comparativa da aplicabilidade das técnicas de monitoramento em isoladores poliméricos submetidos às tensões alternada e contínuas**. Universidade Federal de Campina Grande. Campina Grande. 2022.

LEWIS, D.; KULKARNI, P. Insulator Defect Detection, 2021. Disponível em: <<https://iee-dataport.org/competitions/insulator-defect-detection>>. Acesso em: 06 out. 2023.

LIN, T.; LIU, X. An intelligent recognition system for insulator string defects based on dimension correction and optimized faster R-CNN. **Electrical Engineering**, 103, 2021. 541-549.

LING, Z.; ZHANG, D.; QIU, R. C.; JIN, Z.; ZHANG, Y.; HE, X.; LIU, H. An accurate and real-time method of self-blast glass insulator location based on faster R-CNN and U-net with aerial images. **CSEE Journal of Power and Energy Systems**, 5, n. 4, 2019. 474-482.

LIU, J.; HU, M.; DONG, J.; LU, X. Summary of insulator defect detection based on deep learning. **Electric Power Systems Research**, 2024, 2023. 109688.

LIU, T.; QU, B.; LI, G. Insulator filth monitoring and situation awareness based on ultraviolet pulse and least square method. **Journal of Physics: Conference Series**, 2108, n. 1, 2021. 012056.

LIU, W.; ANGUELOV, D.; ERHAN, D.; SZEGEDY, C.; REED, S.; FU, C.-Y.; BERG, A. C. SSD: Single shot multibox detector. **Computer Vision-ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11-14, 2016, Proceedings, Part I 14**, 2016. 21-37.

LUO, L.; HSU, W.; WANG, S. Data augmentation using generative adversarial networks for electrical insulator anomaly detection. **Proceedings of the 2020 2nd International Conference on Management Science and Industrial Engineering**, 2020. 231-236.

LV, L.-J.; LI, S.-Q.; WANG, H.; JIN, L.-J. An approach for fault monitoring of insulators based on image tracking. **2017 24th International Conference on Mechatronics and Machine Vision in Practice (M2VIP)**, 2017. 1-6.

MENDONÇA, Y. A. **Análise da Corrente de Fuga de Isoladores Poliméricos para Classificação das Condições de Degradação com Auxílio de Lógica Fuzzy**. Universidade Federal de Campina Grande. Campina Grande. 2016.

MONTICELLI, A.; GARCIA, A. **Introdução aos Sistemas de Energia Elétrica**.

NERI, M. G. G. **Avaliação de Técnicas de Monitoramento de Isoladores Poliméricos**. Universidade Federal de Campina Grande. Campina Grande. 2005.

NIE, Y.; LEE, J.; YOON, S.; PARK, D. S. A multi-stage convolution machine with scaling and dilation for human pose estimation. **KSII Transactions on Internet and Information Systems (TIIS)**, 13, n. 6, 2019. 3182-3198.

OLIVEIRA, R. G. D. **Aprimoramento da Classificação de Isoladores Poliméricos por Medições**. Universidade Federal de Campina Grande. Campina Grande. 2017.

PEDRO, A. T. Uso de drones melhora inspeções da Energisa, 2018. Disponível em: <<https://www.canalenergia.com.br/noticias/53058475/uso-de-drones-melhorainspecoes-da-energisa>>. Acesso em: 17 Julho 2024.

QIU, K.; CAO, Y.; JIANG, D.; YANG, Q.; LI, Q.; XU, L. Data Augmentation of Insulator Aerial Images for Intelligent Inspection of Electric Transmission Systems. **2022 IEEE 6th Conference on Energy Internet and Energy System Integration (EI2)**, 2022. 2225-2230.

RAMIREZ, I.; HERNANDEZ, R.; MONTOYA, G. Measurement of leakage current for monitoring the performance of outdoor insulators in polluted environments. **IEEE Electrical Insulation Magazine**, 28, n. 4, 2012. 29-34.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You only look once: Unified, real-time object detection. **Proceedings of the IEEE conference on computer vision and pattern recognition**, 2016. 779-788.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You only look once: Unified, real-time object detection. **Proceedings of the IEEE conference on computer vision and pattern recognition**, 2016. 779-788.

REN, S.; HE, K.; GIRSHICK, R.; SUN, J. Faster r-cnn: Towards real-time object detection with region proposal networks. **Advances in neural information processing systems**, 28, 2015.

REN, S.; HE, K.; GIRSHICK, R.; SUN, J. Faster R-CNN: Towards real-time object detection with region proposal networks. **Advances in neural information processing systems**, 28, 2015.

RIBEIRO, G. L. **Aprimoramento da Classificação de Isoladores Poliméricos por Medições**. Universidade Federal de Campina Grande. Campina Grande. 2017.

ROBBINS, H.; MONRO, S. A stochastic approximation method. **The annals of mathematical statistics**, 1951. 400-407.

SAMPEDRO, C.; RODRIGUEZ-VAZQUEZ, J.; RODRIGUEZ-RAMOS, A.; CARRIO, A.; CAMPOY, P. Deep learning-based system for automatic recognition and diagnosis of electrical insulator strings. **IEEE Access**, 7, 2019. 101283-101308.

SHEN, Z.; LIU, Z.; LI, J.; JIANG, Y.-G.; CHEN, Y.; XUE, X. DSOD: Learning deeply supervised object detectors from scratch. **Proceedings of the IEEE international conference on computer vision**, 2017. 1919-1927.

SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on image data augmentation for deep learning. **Journal of big data**, 6, 2019. 1-48.

SONG, C.; XU, W.; WANG, Z.; YU, S.; ZENG, P.; JU, Z. Analysis on the impact of data augmentation on target recognition for UAV-based transmission line inspection. **Complexity**, 2020, 2020. 1-11.

SOUZA, B. A. D. **Monitoramento e diagnóstico de isoladores poliméricos utilizando processamento digital de imagens termográficas**. Universidade Federal de Campina Grande. Campina Grande. 2016.

STRI. **Guide 5 - Guide for Visual Identification of Deterioration & Damages on Suspension Composite Insulators**. Swedish Transmission Research Institute - STRI. Ludvika, Sweden. 2005.

SZELISKI, R. **Computer Vision: Algorithms and Applications**. 2. ed.

TAO, X.; ZHANG, D.; WANG, Z.; LIU, X.; ZHANG, H.; XU, D. Detection of Power Line Insulator Defects Using Aerial Images Analyzed With Convolutional Neural Networks. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, 50, 2020. 1486-1498.

TERVEN, J.; CÓRDOVA-ESPARZA, D.-M.; ROMERO-GONZÁLEZ, J.-A. A comprehensive review of YOLO architectures in computer vision: From YOLOv1 to YOLOv8 and YOLO-NAS. **Machine Learning and Knowledge Extraction**, 5, n. 4, 2023. 1680-1716.

TIAN, F.; HAO, Y.; ZOU, Z.; ZHENG, Y.; HE, W.; YANG, L.; LI, L. An ultrasonic pulse-echo method to detect internal defects in epoxy composite insulation. **Energies**, 12, n. 24, 2019. 4804.

TIELEMAN, T.; HINTON, G. Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude. **COURSERA: Neural networks for machine learning**, 4, n. 2, 2012. 26-31.

TOMASZEWSKI, M.; BOGDAN, R.; PAWEŁ, M. The collection of images of an insulator taken outdoors in varying lighting conditions with additional laser spots. **Data Brief**, n. 18, 2018. 765-768.

TONG, W.; YUAN, J.; LI, B. Application of image processing in patrol inspection of overhead transmission line by helicopter. **Power System Technology**, 34, n. 12, 2010. 204-208.

TZUTALIN. **LabelImg**, 2015. Disponível em: <<https://github.com/tzutalin/labelImg>>. Acesso em: 08 Novembro 2023.

VARGAS, A. C. G.; PAES, A.; VASCONCELOS, C. N. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. **Proceedings of the xxix conference on graphics, patterns and images**, 1, n. 4, 2016.

VIEIRA E SILVA, A.; CHAVES, T.; FELIX, H.; MACÊDO, D.; SIMÕES, F.; GAMA-NETO, M.; TEICHRIB, V.; ZANCHETTIN, C. Unifying Public Datasets for Insulator Detection and Fault Classification in Electrical Power Lines, 2020. Disponível em: <<https://github.com/heitorcfelix/public-insulator-datasets>>. Acesso em: 30 janeiro 2023.

WANG, H.; CHENG, L.; LIAO, 润.; ZHANG, S.; YANG, L. Nonlinear Mechanical Model of Composite Insulator Interface and Nondestructive Testing Method for Weak Bonding Defects. **Chinese Journal of electrical engineering**, 39, 2019. 895-905.

WANG, J.; XIAO, X.; FAN, Y.; CAI, L.; TONG, Y.; RAO, Z.; HUANG, Z. Interface defect detection for composite insulators based on infrared thermography axial temperature method. **Infrared Physics & Technology**, 93, 2018. 232-239.

WANG, K.; FANG, B.; QIAN, J.; YANG, S.; ZHOU, X.; ZHOU, J. Perspective transformation data augmentation for object detection. **IEEE Access**, 8, 2019. 4935-4943.

WANG, M.; DU, Y.; ZHANG, Z. Study on power transmission lines inspection using unmanned aerial vehicle and image recognition of insulator defect. **J. Electron. Meas. Instrum**, 26, n. 2015, 2015. 1862-1869.

WANG, Y.; SUN, J.; XIAO, X. Cable incipient fault classification and identification based on optimized convolution neural network. **Power System Protection and Control**, 48, 2020. 10-18.

WANG, Z. H. Insulator Data Set—Chinese Power Line Insulator Dataset (CPLID), 2021. Disponível em: <<https://github.com/InsulatorData/InsulatorDataSet>>. Acesso em: 30 janeiro 2023.

WU, Q.; AN, J. A. L. B. A texture segmentation algorithm based on PCA and global minimization active contour model for aerial insulator images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, 5, n. 5, 2012. 1509-1518.

XIA, H.; YANG, B.; LI, Y.; WANG, B. An Improved CenterNet Model for Insulator Defect Detection Using Aerial Imagery. **Sensors**, 22, 2022.

YANG, Z.; XU, Z.; WANG, Y. Bidirection-Fusion-YOLOv3: An Improved Method for Insulator Defect Detection Using UAV Image. **IEEE Transactions on Instrumentation and Measurement**, 71, 2022. 1-8.

ZHAI, Y.; CHEN, R.; YANG, Q.; LI, X.; ZHAO, Z. Insulator fault detection based on spatial morphological features of aerial images. **IEEE Access**, 6, 2018. 35316-35326.

ZHAI, Y.; WANG, D.; ZHANG, M.; WANG, J.; GUO, F. Fault detection of insulator based on saliency and adaptive morphology. **Multimedia Tools and Applications**, 76, 2017. 12051–12064.

ZHANG, X.; AN, J.; CHEN, F. A method of insulator fault detection from airborne images. **2010 Second WRI Global Congress on Intelligent Systems**, 2, 2010. 200-203.

ZHANG, Y.; XU, Y.; CUI, L. Transmission Line Fault Insulator Detection Based on GAN-Faster RCNN, 2023.

ZHANG, Z.; ZHANG, W.; ZHANG, D.; XIAO, Y.; DENG, J.; XIA, G. Comparison of different characteristic parameters acquired by UV imager in detecting corona discharge. **IEEE Transactions on Dielectrics and Electrical Insulation**, 23, n. 3, 2016. 1597-1604.

ZHANG, Z.-D.; ZHANG, B.; LAN, Z.-C.; LIU, H.-C.; LI, D.-Y.; PEI, L.; YU, W.-X. FINet: An Insulator Dataset and Detection Benchmark Based on Synthetic Fog and Improved YOLOv5. **IEEE Transactions on Instrumentation and Measurement**, 71, 2022. 1-8.

ZHAO, W.; XU, M.; CHENG, X.; ZHAO, Z. An Insulator in Transmission Lines Recognition and Fault Detection Model Based on Improved Faster RCNN. **IEEE Transactions on Instrumentation and Measurement**, 70, 2021. 1-8.

## APÊNDICE A – CÓDIGO DA YOLO

In [ ]:

```
from google.colab import drive
drive.mount('/content/gdrive')
```

```
!pip install ultralytics
```

In [ ]:

```
!touch configs_modelo.yaml # Cria um arquivo .yaml com os diretórios da base de dados
```

In [ ]:

```
%%writefile configs_modelo.yaml
path: '/content/Dataset/'
train: 'train/'
val: 'test/'
```

```
nc: 5
names: ['isolador', 'nucleo_exposto', 'corrosao_ferragens', 'rachadura', 'corte']
```

In [ ]:

```
from ultralytics import YOLO
import os
```

```
#-----
# Faz uma cópia da base de dados para o diretório atual e, em seguida, descompacta
# o arquivo .zip
```

```
!cp /content/gdrive/MyDrive/Datasets/Dataset.zip /content
!unzip Dataset.zip
```

```
# Retorna o diretório do arquivo .yaml
arquivo_config = os.path.join('/content/', 'configs_modelo.yaml')
```

```
# Diretório do modelo fine-tuning
diretorio_pesos = "yolov8s"
```

```
# Cria o modelo e realiza o treinamento
model = YOLO(diretorio_pesos)
resultados = model.train(data=arquivo_config, epochs=100, imgsz=2560,
                        name='yolov8s_modelo', patience = 20, mosaic = 0.0,
                        translate = 0.0, batch = -1)
```

```
# patience = 20: o modelo interrompe o treinamento se não houver melhoria após
#                 20 épocas
# mosaic = 0.0: desativa o data augmentation por mosaico da própria biblioteca
# translate = 0.0: desativa o data augmentation por deslocamento horizontal
#                 ou vertical automático realizado pela própria biblioteca
# batch = -1: ajuste automático do tamanho do lote
```

## APÊNDICE B – RESULTADOS OBTIDOS PARA CADA CASO ANALISADO

Tabela 14 – Desempenho da YOLOv8s com dimensão de entrada de 1280x1280 pixels após o treinamento com a base de dados oriunda da parte 1 do *data augmentation*.

	Isolador			Núcleo Exposto			Corrosão nas Ferragens			Rachadura nas Aletas			Corte nas Aletas			mAP (%)
	P	R	AP	P	R	AP	P	R	AP	P	R	AP	P	R	AP	
1m	99,9	100	99,5	95,8	88,3	95,0	87,8	77,7	87,3	82,4	56,4	70,9	92,9	86,5	91,7	88,9
2m	99,8	100	99,5	79,0	74,3	76,4	78,9	51,2	58,7	60,9	37,4	42,8	75,5	72,0	78,0	71,1
3m	99,8	100	99,5	65,8	62,7	69,0	63,1	36,4	43,0	56,5	41,2	45,4	88,6	80,8	88,1	69
4m	99,8	100	99,5	69,6	61,1	66,8	60,7	40,0	45,1	51,8	34,6	37,9	83,3	63,6	73,8	64,6
5m	99,8	100	99,5	63,7	61,6	62,7	59,2	26,7	33,8	47,2	28,8	29,6	66,7	67,3	71,1	59,3

Fonte: Autoria Própria.

Tabela 15 – Desempenho da YOLOv8m com dimensão de entrada de 1280x1280 pixels após o treinamento com a base de dados oriunda da parte 1 do *data augmentation*.

	Isolador			Núcleo Exposto			Corrosão nas Ferragens			Rachadura nas Aletas			Corte nas Aletas			mAP (%)
	P	R	AP	P	R	AP	P	R	AP	P	R	AP	P	R	AP	
1m	100	100	99,5	94,2	95,0	96,9	92,1	91,0	95,3	88,6	76,9	85,7	94,8	87,9	92,7	94
2m	99,7	100	99,5	87,7	88,9	92,7	74,2	61,3	70,2	80,3	68,3	77,2	86,1	81,0	86,9	85,3
3m	99,9	100	99,5	89,9	81,5	87,9	80,1	65,5	76,3	82,6	66,4	78,7	94,6	91,6	96,2	87,7
4m	99,8	100	99,5	86,0	78,6	85,6	88,7	60,0	66,9	81,8	60,5	73,1	90,6	81,4	87,3	82,5
5m	99,8	100	99,5	88,8	76,1	86,7	58,0	43,3	51,0	72,2	47,9	57,4	85,5	81,7	86,0	76,1

Fonte: Autoria Própria.

Tabela 16 – Desempenho da YOLOv8s com dimensão de entrada de 1920x1920 pixels após o treinamento com a base de dados oriunda da parte 1 do *data augmentation*.

	Isolador			Núcleo Exposto			Corrosão nas Ferragens			Rachadura nas Aletas			Corte nas Aletas			mAP (%)
	P	R	AP	P	R	AP	P	R	AP	P	R	AP	P	R	AP	
1m	99,9	100	99,5	93,9	92,9	95,8	93,5	82,5	91,4	87,2	61,3	74,8	94,3	89,3	93,4	91,0
2m	99,8	100	96,5	77,6	81,2	84,8	78,3	58,7	63,1	65,8	46,7	54,1	83,3	75,5	81,3	76,5
3m	99,8	100	99,5	77,0	63,5	73,5	78,6	45,5	55,9	68,3	45,0	53,2	86,6	85,4	91,2	74,7
4m	99,8	100	99,5	71,7	58,0	65,3	75,3	50,0	59,2	54,8	38,2	42,2	78,6	69,4	75,3	68,3
5m	99,7	100	99,5	69,4	57,4	62,6	56,3	33,3	37,8	46,0	30,1	31,6	73,0	68,8	74,3	61,1

Fonte: Autoria Própria.

Tabela 17 – Desempenho da YOLOv8m com dimensão de entrada de 1920x1920 pixels após o treinamento com a base de dados oriunda da parte 1 do *data augmentation*.

	Isolador			Núcleo Exposto			Corrosão nas Ferragens			Rachadura nas Aletas			Corte nas Aletas			mAP (%)
	P	R	AP	P	R	AP	P	R	AP	P	R	AP	P	R	AP	
1m	99,9	100	99,5	92,9	95,6	97,5	92,6	99,0	95,2	85,0	81,4	87,3	93,7	88,9	92,6	94,4
2m	99,9	100	99,5	93,5	87,5	92,6	83,5	63,5	71,7	85,4	69,8	80,1	91,3	82,5	88,0	86,4
3m	100	100	99,5	90,8	78,7	88,9	83,4	73,1	82,7	80,7	73,7	81,9	89,8	92,9	96,7	89,9
4m	99,8	100	99,5	80,6	73,9	85,7	87,7	66,7	78,1	72,7	67,7	73,8	89,4	81,3	89,2	85,3
5m	100	100	99,5	89,3	73,3	84,5	74,3	56,7	65,7	77,2	48,4	59,6	88,8	81,7	88,7	79,6

Fonte: Autoria Própria.

Tabela 18 – Desempenho da YOLOv8s com dimensão de entrada de 2560x2560 pixels após o treinamento com a base de dados oriunda da parte 1 do *data augmentation*.

	Isolador			Núcleo Exposto			Corrosão nas Ferragens			Rachadura nas Aletas			Corte nas Aletas			mAP (%)
	P	R	AP	P	R	AP	P	R	AP	P	R	AP	P	R	AP	
1m	97,6	42,3	57,5	93,6	97,5	98,3	92,4	99,0	96,2	91,4	88,3	92,6	96,2	89,7	94,5	87,8
2m	99,9	100	99,5	90,2	91,7	95,5	83,6	70,2	75,4	86,3	85,0	90,2	90,7	82,9	89,8	90,1
3m	99,8	100	99,5	91,9	80,9	93,2	88,4	78,2	85,6	85,4	82,7	89,6	96,8	94,6	98,5	93,3
4m	99,8	100	99,5	93,0	80,9	92,3	89,0	83,3	83,4	82,8	78,3	86,3	93,5	84,9	93,1	90,9
5m	99,9	100	99,5	88,9	85,6	91,2	82,3	56,7	67,7	82,1	71,5	80,2	92,4	88,2	93,3	86,4

Fonte: Autoria Própria.

Tabela 19 – Desempenho da YOLOv8m com dimensão de entrada de 2560x2560 pixels após o treinamento com a base de dados oriunda da parte 1 do *data augmentation*.

	Isolador			Núcleo Exposto			Corrosão nas Ferragens			Rachadura nas Aletas			Corte nas Aletas			mAP (%)
	P	R	AP	P	R	AP	P	R	AP	P	R	AP	P	R	AP	
1m	53,6	5,6	30,7	93,9	84,9	93,6	93,4	53,7	81,0	86,7	72,6	83,2	83,8	73,0	82,4	74,2
2m	98,8	64,6	83,3	89,1	60,2	80,3	70,0	60,9	63,8	73,7	66,2	72,7	92,3	65,1	78,9	75,8
3m	99,7	91,0	90,9	93,8	72,5	85,2	75,9	69,1	74,3	84,5	67,7	79,4	90,1	84,9	92,0	84,3
4m	100	78,8	92,9	88,7	76,3	89,4	89,0	66,7	69,6	88,3	70,3	82,0	95,0	74,0	90,2	84,8
5m	100	75,3	90,5	84,8	76,6	84,5	74,3	76,7	80,1	68,0	58,0	66,3	91,6	85,9	92,6	82,8

Fonte: Autoria Própria.

Tabela 20 – Desempenho da YOLOv8s com dimensão de entrada de 1280x1280 pixels após o treinamento com a base de dados oriunda da parte 2 do *data augmentation*.

	Isolador			Núcleo Exposto			Corrosão nas Ferragens			Rachadura nas Aletas			Corte nas Aletas			mAP (%)
	P	R	AP	P	R	AP	P	R	AP	P	R	AP	P	R	AP	
1m	99,9	100	99,5	93,7	91,7	97,4	92,9	90,2	95,6	87,2	73,4	84,0	94,7	94,5	97,3	94,7
2m	99,9	100	99,6	92,9	93,0	95,6	89,6	71,7	84,0	83,3	73,9	82,7	91,3	90,2	94,9	91,5
3m	100	100	99,5	96,5	93,4	98,4	93,6	85,0	89,5	92,7	85,9	92,9	95,2	94,0	97,6	95,6
4m	99,9	100	99,5	88,7	86,4	93,1	83,2	66,4	72,8	89,2	78,2	88,0	91,7	91,8	95,6	89,8
5m	99,9	100	99,5	92,4	88,8	95,6	74,8	49,6	58,6	91,2	73,9	85,0	93,6	85,9	93,7	86,5

Fonte: Autoria Própria.

Tabela 21 – Desempenho da YOLOv8m com dimensão de entrada de 1280x1280 pixels após o treinamento com a base de dados oriunda da parte 2 do *data augmentation*.

	Isolador			Núcleo Exposto			Corrosão nas Ferragens			Rachadura nas Aletas			Corte nas Aletas			mAP (%)
	P	R	AP	P	R	AP	P	R	AP	P	R	AP	P	R	AP	
1m	99,9	100	99,6	95,2	95,1	98,3	92,8	93,7	95,6	90,9	75,7	87,2	98,4	96,4	98,3	95,8
2m	99,9	100	99,6	95,7	92,1	97,4	91,7	77,0	86,5	90,1	79,1	88,8	96,1	92,4	97,2	93,9
3m	100	100	99,6	96,2	94,7	98,7	94,7	83,0	92,0	95,9	97,9	94,5	97,7	96,5	98,5	96,6
4m	99,9	100	99,5	93,2	87,9	95,2	87,3	69,9	79,9	92,1	80,6	90,5	96,2	93,9	97,8	92,6
5m	99,9	100	99,5	93,0	89,9	96,4	93,3	62,1	76,8	92,2	74,6	97,3	95,5	87,2	94,8	91,0

Fonte: Autoria Própria.

Tabela 22 – Desempenho da YOLOv8s com dimensão de entrada de 1920x1920 pixels após o treinamento com a base de dados oriunda da parte 2 do *data augmentation*.

	Isolador			Núcleo Exposto			Corrosão nas Ferragens			Rachadura nas Aletas			Corte nas Aletas			mAP (%)
	P	R	AP	P	R	AP	P	R	AP	P	R	AP	P	R	AP	
1m	99,6	99,6	99,5	96,7	96,9	99,0	97,0	92,3	96,4	93,5	83,2	93,1	96,6	95,9	98,3	97,3
2m	100	100	99,5	97,9	95,5	98,4	96,4	82,2	92,9	93,9	87,1	94,0	96,3	93,5	98,1	96,6
3m	99,9	100	99,5	96,4	98,5	99,4	96,5	96,4	98,2	96,2	94,2	97,4	98,4	98,1	99,4	98,8
4m	99,9	100	99,5	97,1	93,2	98,2	96,1	75,2	97,2	96,5	90,9	96,5	97,4	94,7	97,8	95,8
5m	99,9	100	99,6	96,8	96,8	99,3	90,0	76,11	87,5	93,9	91,0	96	97,0	94,5	98,3	96,1

Fonte: Autoria Própria.

Tabela 23 – Desempenho da YOLOv8m com dimensão de entrada de 1920x1920 pixels após o treinamento com a base de dados oriunda da parte 2 do *data augmentation*.

	Isolador			Núcleo Exposto			Corrosão nas Ferragens			Rachadura nas Aletas			Corte nas Aletas			mAP (%)
	P	R	AP	P	R	AP	P	R	AP	P	R	AP	P	R	AP	
1m	99,4	99,4	99,5	97,0	95,1	98,9	94,4	92,3	96,6	96,0	85,2	94,6	96,5	97,0	98,4	97,6
2m	100	100	99,5	99,5	93,7	99,0	93,3	86,5	94,9	95,3	88,5	95,8	98,3	94,1	98,9	97,6
3m	100	100	99,5	98,9	98,1	99,4	98,2	94,7	98,0	97,9	94,4	98,2	99,7	98,1	99,2	98,9
4m	99,9	100	99,5	95,6	96,0	98,6	91,7	78,8	87,8	96,7	93,1	97,2	97,9	96,1	98,5	96,3
5m	99,9	100	99,5	98,7	95,8	98,6	92,5	86,7	95,4	97,5	89,8	96,6	97,9	95,1	98,2	97,7

Fonte: Autoria Própria.

Tabela 24 – Desempenho da YOLOv8s com dimensão de entrada de 2560x2560 pixels após o treinamento com a base de dados oriunda da parte 2 do *data augmentation*.

	Isolador			Núcleo Exposto			Corrosão nas Ferragens			Rachadura nas Aletas			Corte nas Aletas			mAP (%)
	P	R	AP	P	R	AP	P	R	AP	P	R	AP	P	R	AP	
1m	97,9	40,9	54,9	97,2	94,8	98,8	95,2	93,1	97,4	96,5	85,7	95,0	96,8	96,4	98,3	88,9
2m	100	100	99,5	98,3	97,4	99,4	96,9	87,0	94,8	95,1	90,1	96,0	98,0	95,3	99,1	97,7
3m	100	100	99,5	99,8	97,9	99,5	97,7	97,2	99,3	98,4	95,9	98,7	99,1	98,1	99,3	99,2
4m	100	100	99,5	97,9	96,9	98,7	96,1	87,5	91,8	96,9	94,6	97,8	98,4	96,2	98,4	97,2
5m	99,9	100	99,5	98,6	99,6	99,5	91,5	90,3	95,1	96,2	94,7	97,9	97,0	96,4	98,8	98,2

Fonte: Autoria Própria.

Tabela 25 – Desempenho da YOLOv8m com dimensão de entrada de 2560x2560 pixels após o treinamento com a base de dados oriunda da parte 2 do *data augmentation*.

	Isolador			Núcleo Exposto			Corrosão nas Ferragens			Rachadura nas Aletas			Corte nas Aletas			mAP (%)
	P	R	AP	P	R	AP	P	R	AP	P	R	AP	P	R	AP	
1m	96,7	41,2	55,1	97,7	92	97,3	94,1	88,4	95,6	97,8	78,9	93,2	97,7	90,9	97,1	87,8
2m	99,9	100	99,5	98,6	96,7	99,3	94,0	87,0	93,7	93,5	89,1	95,4	96,6	93,4	98,6	97,3
3m	100	100	99,6	99,1	99,4	99,6	98,8	97,3	98,9	98,0	95,8	98,6	99,0	97,1	99,4	99,2
4m	100	100	99,6	98,3	97,0	98,8	95,6	88,5	94,3	98,2	94,6	98,4	99,3	94,8	98,3	97,9
5m	100	100	99,6	98,8	99,4	99,4	95,7	84,1	90,7	98,6	94,5	98,4	99,9	95,4	98,8	97,3

Fonte: Autoria Própria.