

---

# **Uso de Redes Neurais Profundas para Detecção de Vegetação em Contato com Linhas de Distribuição de Energia em Ambientes Urbanos**

---

**João Barbosa de Souza Neto**



UNIVERSIDADE FEDERAL DE UBERLÂNDIA  
FACULDADE DE COMPUTAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO



**João Barbosa de Souza Neto**

**Uso de Redes Neurais Profundas para Detecção  
de Vegetação em Contato com Linhas de  
Distribuição de Energia em Ambientes Urbanos**

Dissertação de mestrado apresentada ao Programa de Pós-graduação da Faculdade de Computação da Universidade Federal de Uberlândia como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação.

Área de concentração: Inteligência Artificial

Orientador: Prof. Dr. Jefferson Rodrigo de Souza

Uberlândia  
2025

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU  
com dados informados pelo(a) próprio(a) autor(a).

S729 Souza Neto, João Barbosa de, 1999-  
2025 Uso de Redes Neurais Profundas para Detecção de Vegetação  
em Contato com Linhas de Distribuição de Energia em Ambientes  
Urbanos [recurso eletrônico] / João Barbosa de Souza Neto. - 2025.

Orientador: Jefferson Rodrigo de Souza.  
Dissertação (Mestrado) - Universidade Federal de Uberlândia,  
Pós-graduação em Ciência da Computação.  
Modo de acesso: Internet.  
DOI <http://doi.org/10.14393/ufu.di.2025.477>  
Inclui bibliografia.  
Inclui ilustrações.

1. Computação. I. Souza, Jefferson Rodrigo de, 1985-, (Orient.).  
II. Universidade Federal de Uberlândia. Pós-graduação em Ciência  
da Computação. III. Título.

CDU: 681.3

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:  
Gizele Cristine Nunes do Couto - CRB6/2091  
Nelson Marcos Ferreira - CRB6/3074



## UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Coordenação do Programa de Pós-Graduação em Computação  
Av. João Naves de Ávila, 2121, Bloco 1A, Sala 243 - Bairro Santa Mônica, Uberlândia-MG,  
CEP 38400-902

Telefone: (34) 3239-4470 - [www.ppgco.facom.ufu.br](http://www.ppgco.facom.ufu.br) - [cpgfacom@ufu.br](mailto:cpgfacom@ufu.br)



### ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Ciência da Computação			
Defesa de:	Dissertação, 18/2025, PPGCO			
Data:	31 de Julho de 2025	Hora de início:	17:20	Hora de encerramento:
Matrícula do Discente:	12322CCP012			
Nome do Discente:	João Barbosa de Souza Neto			
Título do Trabalho:	Uso de Redes Neurais Profundas para Detecção de Vegetação em Contato com Linhas de Distribuição de Energia em Ambientes Urbanos			
Área de concentração:	Ciência da Computação			
Linha de pesquisa:	Inteligência Artificial			
Projeto de Pesquisa de vinculação:	-----			

Reuniu-se por videoconferência, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Ciência da Computação, assim composta: Professores Doutores: Marcelo Zanchetta do Nascimento - FACOM/UFU, Andrea Gomes Campos Bianchi - DECOM/UFOP e Jefferson Rodrigo de Souza - FACOM/UFU, orientador do candidato.

Os examinadores participaram desde as seguintes localidades: Andrea Gomes Campos Bianchi - Ouro Preto/MG. Os outros membros da banca e o aluno participaram da cidade de Uberlândia.

Iniciando os trabalhos o presidente da mesa, Prof. Dr. Jefferson Rodrigo de Souza , apresentou a Comissão Examinadora e o candidato, agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação da Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor presidente concedeu a palavra, pela ordem sucessivamente, aos examinadores, que passaram a arguir ao candidato. Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o candidato:

**Aprovado**

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação

interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Marcelo Zanchetta do Nascimento, Professor(a) do Magistério Superior**, em 04/08/2025, às 10:21, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Andrea Gomes Campos Bianchi, Usuário Externo**, em 04/08/2025, às 10:58, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Jefferson Rodrigo de Souza, Professor(a) do Magistério Superior**, em 04/08/2025, às 15:31, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site [https://www.sei.ufu.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **6488733** e o código CRC **E7775E71**.

---

**Referência:** Processo nº 23117.046336/2025-73

SEI nº 6488733

*Dedico este trabalho à minha mãe, que me apoia desde antes do meu nascimento, ao meu pai, que sempre me incentivou neste caminho acadêmico, e à minha irmã, que esteve ao meu lado em todos os momentos.*



---

## Agradecimentos

Deus, obrigado pela oportunidade de estar neste meio acadêmico, pelos recursos para realizar este trabalho, pela paciência em meu desenvolvimento, e por todas as dádivas e milagres que realiza diariamente a meu favor.

Mãe, obrigado por ser um exemplo de perseverança, trabalho duro, um ser de luz e amor que me guia hoje e todos os dias.

Pai, obrigado pelo exemplo de como ser um homem honesto, trabalhador, de confiança, que cuida da família e é devoto a Deus.

Irmã, obrigado por me aguentar, me importunar, pelas nossas conversas até altas horas, por tudo que já fizemos e experimentamos juntos.

Aos meus amigos e familiares, obrigado por todas nossas peripécias juntos, por me ajudarem a manter minha sanidade mental, e por todos os nossos rolês.

Ao meu orientador Jefferson, obrigado por me acompanhar por tantos anos, pela ajuda na escolha do tema e no desenvolvimento deste trabalho.

Ao professor Henrique Oliveira e à UNICAMP, obrigado por disponibilizar as imagens e pela ajuda no desenvolvimento dos artigos.

Aos colegas Henrique Moreira e Matheus Moura, obrigado pela ajuda no início do desenvolvimento das redes.

Aos professores Andrea Bianchi e Marcelo Zanchetta, obrigado pelas sugestões durante a defesa da dissertação.

À FAPEMIG, obrigado pelo apoio financeiro durante a realização da pesquisa.

A meus professores e professoras, obrigado pelos ensinamentos, puxões de orelha e brincadeiras.

Obrigado você que está lendo, espero que tenha um dia maravilhoso =).



*“Se eu vi mais longe, foi por estar sobre ombros de gigantes”*  
*(Isaac Newton)*



---

## Resumo

Garantir a confiabilidade e a segurança da transmissão de energia elétrica é fundamental para a gestão urbana moderna. Esta pesquisa foca no desenvolvimento de um sistema para detectar o contato entre a vegetação e as linhas de distribuição de energia, utilizando arquiteturas de redes neurais profundas, especialmente versões recentes da família de modelos *You Only Look Once* (YOLO) e a *Real-Time Detection Transformer* (RT-DETR). A metodologia incluiu a coleta de dados, rotulagem, pré-processamento de imagens, treinamento do modelo e avaliação de desempenho. Um sistema de mapeamento móvel de baixo custo com câmeras instaladas em veículos terrestres foi utilizado para obter as imagens, que foram posteriormente anotadas para identificar a vegetação em contato com os cabos de distribuição elétrica. Em seguida, diversas técnicas de pré-processamento de imagem, incluindo filtros clássicos de detecção de bordas como Canny, Sobel, Prewitt, entre outros, foram testadas para avaliar seu impacto na qualidade da detecção. Entre as arquiteturas testadas, a YOLOv10m apresentou o melhor desempenho, com F1-score de 89,7% e mAP de 92,7%. O sistema proposto visa aprimorar a detecção de condições perigosas, reduzir os custos operacionais e aumentar a segurança, ao fornecer uma ferramenta confiável para a manutenção preventiva em redes de distribuição de energia. Além disso, o estudo disponibiliza o conjunto de dados rotulado, incentivando pesquisas futuras.

**Palavras-chave:** Detecção de Objetos. Linhas de Distribuição de Energia. Vegetação. YOLO. RT-DETR.



---

## Abstract

Ensuring the reliability and safety of electric power distribution is essential for modern urban management. This research focuses on the development of a system to detect contact between vegetation and power distribution lines using deep neural network architectures, particularly recent versions from the You Only Look Once (YOLO) family and the Real-Time Detection Transformer (RT-DETR). The research methodology involved data collection, annotation, image pre-processing, model training, and performance evaluation. A low-cost mobile mapping system equipped with cameras mounted on ground vehicles was used to capture images, which were then labeled to identify vegetation in contact with distribution cables. Then, several image pre-processing techniques, including classical edge detection filters such as Canny, Sobel, and Prewitt, as well as other image filtering methods, were tested to assess their impact on detection quality. Among the architectures evaluated, YOLOv10m achieved the best performance, with an F1-score of 89.7% and a mAP of 92.7%. The proposed system aims to enhance the detection of hazardous conditions, reduce operational costs, and improve safety by providing a reliable tool for preventive maintenance in power distribution networks. Furthermore, the study publicly releases the labeled dataset to support and encourage future research.

**Keywords:** Object Detection. Power Distribution Lines. Vegetation. YOLO. RT-DETR.



---

# **Lista de ilustrações**

Figura 1 – A cena de um poste em chamas (CRICIUMA, 2019).	24
Figura 2 – Visão do Sistema Elétrico: Geração, Transmissão e Distribuição (SILVA, 2014).	32
Figura 3 – Linha de Transmissão da usina de Itaipu, em Foz do Iguaçu (EIXOS, 2023).	33
Figura 4 – Subestação de Energia (ENGENHARIA, 2020).	33
Figura 5 – Postes de Distribuição de Energia (Refortrafo Transformadores, 2025).	34
Figura 6 – Estrutura de um neurônio artificial (SOARES; SILVA, 2011).	35
Figura 7 – Rede Neural Artificial. Adaptado de (O'SHEA; NASH, 2015).	35
Figura 8 – Arquitetura de uma CNN simples (O'SHEA; NASH, 2015).	36
Figura 9 – Mapa de ativações da primeira camada convolucional da CNN ilustrada na Figura 8 (O'SHEA; NASH, 2015).	37
Figura 10 – Exemplo da YOLO em uso (REDMON et al., 2016).	38
Figura 11 – Sistema de Detecção YOLO (REDMON et al., 2016).	38
Figura 12 – Arquitetura da YOLOv8 (SAPKOTA et al., 2024).	39
Figura 13 – Arquitetura da GELAN da YOLOv9 (WANG; LIAO, 2024).	40
Figura 14 – Arquitetura da YOLOv10 (WANG et al., 2024).	41
Figura 15 – Arquitetura de um Transformer (VASWANI et al., 2017).	42
Figura 16 – Arquitetura de um Vision Transformer (DOSOVITSKIY et al., 2021).	43
Figura 17 – Arquitetura da rede RT-DETR (ZHAO et al., 2023).	43
Figura 18 – Algumas técnicas de aumento de dados (IBM, 2024).	44
Figura 19 – Exemplo de <i>random erasing</i> (SHORTEN; KHOSHGOFTAAR, 2019).	45
Figura 20 – Exemplo dos filtros de primeira ordem: Roberts, Prewitt e Sobel. Fonte: Elaborado pelo autor.	46
Figura 21 – Exemplo dos filtros de segunda ordem: Laplace, DoG, LoG e Canny. Fonte: Elaborado pelo autor.	47
Figura 22 – Mapa de profundidade por imagem de satélite. Adaptado de (QAYYUM et al., 2014).	50

Figura 23 – Tipos de objetos no dataset Wire_10 (LIANG; ZUO; WEI, 2020) . . . . .	50
Figura 24 – Contagem de postes eretos e caídos. Adaptado de (CHEN; MIAO, 2020). . . . .	51
Figura 25 – Componentes de distribuição de rede elétrica (COSTA; CORTES, 2021). . . . .	52
Figura 26 – Detecção de torres de Transmissão (RENWEI et al., 2021). . . . .	53
Figura 27 – Defeitos em amortecedores de vibração (BAO et al., 2022). . . . .	53
Figura 28 – Defeitos em isoladores (BAO et al., 2022). . . . .	54
Figura 29 – Objetos estranhos em linhas de Transmissão (LI et al., 2023). . . . .	55
Figura 30 – Detecção de incêndios usando YOLO (CASAS et al., 2023). . . . .	56
Figura 31 – Detecção de máquinas de construção próximas a linhas de transmissão (ZOU et al., 2024). . . . .	56
Figura 32 – Detecção de EPIs em subestações elétricas (ZHANG et al., 2024). . . . .	57
Figura 33 – Detecção de isoladores na rede de distribuição elétrica (STEFENON et al., 2024). . . . .	58
Figura 34 – Problema de medição do ângulo de inclinação de cabos de energia (WANG et al., 2025). . . . .	59
Figura 35 – Defeitos detectados pela pesquisa (HAN et al., 2025). . . . .	59
Figura 36 – Diagrama da metodologia proposta Fonte: Elaborado pelo autor. . . . .	65
Figura 37 – Sistema de mapeamento móvel usado para a aquisição das imagens (MARQUES et al., 2021). . . . .	66
Figura 38 – Este é um exemplo de uma imagem rotulada (verdade fundamental), onde o quadrado verde à esquerda mostra uma árvore sem contato com a LDE, e o quadrado laranja à direita exibe uma árvore em contato com ela. Fonte: Elaborado pelo autor. . . . .	67
Figura 39 – Esta imagem compara alguns dos filtros usados em nossa pesquisa: Base, Canny, Prewitt e Sobel. Fonte: Elaborado pelo autor. . . . .	68
Figura 40 – Métricas de avaliação da YOLOv8n pelas épocas de treinamento. Fonte: Elaborado pelo autor. . . . .	74
Figura 41 – Resultados da previsão da YOLOv10m, caixas amarelas corresponden- tes ao contato com LDE e caixas azuis correspondentes à ausência de contato. Fonte: Elaborado pelo autor. . . . .	81
Figura 42 – Desafios de previsão do modelo: vegetação no final do quadro da ima- gem e árvores podadas que voltaram a crescer. Fonte: Elaborado pelo autor. . . . .	82

---

## **Lista de tabelas**

Tabela 1 – Comparação dos Trabalhos Correlatos. . . . .	63
Tabela 2 – Versão das dependências utilizadas no ambiente de desenvolvimento. . . . .	69
Tabela 3 – Parâmetros de Treinamento . . . . .	70
Tabela 4 – Características arquiteturais dos modelos YOLOv8 utilizados nos experimentos, incluindo camadas, parâmetros e GFLOPs. . . . .	74
Tabela 5 – Desempenho dos modelos YOLOv8 nos experimentos, em dados de validação, em termos de precisão, recall, F1-score, mAP e tempo médio de inferência por imagem, em milissegundos. . . . .	75
Tabela 6 – Características arquiteturais dos modelos YOLOv9 utilizados nos experimentos, incluindo camadas, parâmetros e GFLOPs. . . . .	75
Tabela 7 – Desempenho dos modelos YOLOv9 nos experimentos, em dados de validação, em termos de precisão, recall, F1-score, mAP e tempo médio de inferência por imagem, em milissegundos. . . . .	76
Tabela 8 – Características arquiteturais dos modelos YOLOv10 utilizados nos experimentos, incluindo camadas, parâmetros e GFLOPs. . . . .	77
Tabela 9 – Desempenho dos modelos YOLOv10 nos experimentos, em dados de validação, em termos de precisão, recall, F1-score, mAP e tempo médio de inferência por imagem, em milissegundos. . . . .	77
Tabela 10 – Características arquiteturais dos modelos RT-DETR utilizados nos experimentos, incluindo camadas, parâmetros e GFLOPs. . . . .	78
Tabela 11 – Desempenho dos modelos RT-DETR nos experimentos, em dados de validação, em termos de precisão, recall, F1-score, mAP e tempo médio de inferência por imagem, em milissegundos. . . . .	78
Tabela 12 – Desempenho do modelo YOLOv10m treinado com diferentes estratégias de detecção de bordas usadas para aumento de dados. . . . .	79
Tabela 13 – Desempenho do modelo YOLOv10m treinado com diferentes estratégias de detecção de bordas como pré-processamento das imagens. . . . .	79



**AP** *Average Precision*

**BiFPN** *Weighted Bi-directional Feature Pyramid Network*

**CNN** *Convolutional Neural Networks*

**CPLID** *Chinese Power Line Insulator Dataset*

**DCN** *Deformable Convolutional Networks*

**DF-YOLO** *Deformable Faster - You Only Look Once*

**DoG** *Difference of Gaussians*

**EPI** Equipamentos de Proteção Individual

**FAPEMIG** Fundação de Amparo à Pesquisa do Estado de Minas Gerais

**GFLOPs** Bilhões de operações de ponto flutuante

**FPS** *Frames Per Second*

**GB** Gigabyte

**GELAN** *Generalized Efficient Layer Aggregation Network*

**GPU** *Graphics Processing Unit*

**IA** Inteligência Artificial

**IDID** *Insulator Defect Image Dataset*

**IEEE** *Institute of Electrical and Electronics Engineers*

**IF-YOLO** *Insulator Fault - You Only Look Once*

**IoU** *Intersection over Union*

**kV** Quilovolts

**LDE** Linhas de Distribuição de Energia (Elétrica)

**LiDAR** *Light Detection and Ranging*

**LoG** *Laplacian of Gaussian*

**mAP** *Mean Average Precision*

**ML** *Machine Learning*

**MLP** *MultiLayer Perceptron*

**NMS** *Non-Maximum Suppression*

**PGI** *Programmable Gradient Information*

**PIB** Produto Interno Bruto

**RAM** *Random Access Memory*

**RNA** Redes Neurais Artificiais

**RT-DETR** *Real-Time Detection Transformer*

**UFU** Universidade Federal de Uberlândia

**UNICAMP** Universidade Estadual de Campinas

**V** Volts

**VANT** Veículo Aéreo Não Tripulado

**YOLO** *You Only Look Once*

---

# Sumário

1	INTRODUÇÃO . . . . .	23
1.1	Motivação . . . . .	25
1.2	Objetivos e Desafios da Pesquisa . . . . .	27
1.3	Hipóteses . . . . .	28
1.4	Contribuições . . . . .	28
1.5	Organização da Dissertação . . . . .	29
2	FUNDAMENTAÇÃO TEÓRICA . . . . .	31
2.1	Visão Geral do Sistema Elétrico . . . . .	31
2.2	Redes Neurais Artificiais . . . . .	34
2.3	Redes Neurais Convolucionais . . . . .	36
2.4	<i>You Only Look Once</i> . . . . .	37
2.5	<i>Transformers</i> . . . . .	41
2.6	Aumento de Dados . . . . .	44
2.7	Detecção de Bordas . . . . .	45
3	TRABALHOS CORRELATOS . . . . .	49
3.1	Análise dos Estudos . . . . .	60
4	METODOLOGIA . . . . .	65
4.1	Aquisição de Imagens . . . . .	66
4.2	Conjunto de Dados . . . . .	67
4.3	Pré-processamento . . . . .	68
4.4	Treinamento do Modelo . . . . .	69
4.5	Avaliação de Desempenho . . . . .	71
5	RESULTADOS EXPERIMENTAIS . . . . .	73
5.1	YOLOv8 . . . . .	73
5.2	YOLOv9 . . . . .	75

5.3	YOLOv10 . . . . .	76
5.4	RT-DETR . . . . .	77
5.5	Uso de Filtros . . . . .	78
5.6	Resultados e Desafios . . . . .	80
6	CONCLUSÃO . . . . .	83
6.1	Hipóteses Investigadas . . . . .	84
6.2	Principais Contribuições . . . . .	85
6.3	Trabalhos Futuros . . . . .	85
6.4	Contribuições na Produção . . . . .	86
6.5	Considerações Finais . . . . .	86
	REFERÊNCIAS . . . . .	87

# CAPÍTULO 1

## Introdução

A energia elétrica é um dos pilares da vida moderna, sendo essencial para o funcionamento de todos os aspectos da sociedade. Desde a iluminação das casas até hospitais, escolas, indústrias e sistemas de comunicação, a eletricidade é indispensável para a manutenção da qualidade de vida e desenvolvimento econômico. A interrupção no fornecimento de energia pode causar transtornos, afetando a vida das pessoas e o funcionamento das empresas e serviços públicos. Essas interrupções resultam de problemas evitáveis, como a interferência da vegetação nas Linhas de Distribuição de Energia (LDE), o que pode levar a danos em equipamentos, incêndios e até colocar vidas em risco (WILSON; WICKRAMASURIYA; MARCHIORI, 2023; QAYYUM et al., 2014).

Além disso, o crescimento contínuo na demanda por energia, sem um aumento proporcional na capacidade de geração e transmissão, tem pressionado os sistemas de energia a operarem próximos de seus limites. Isso enfatiza a necessidade de ferramentas que apoiem a operação, visando aumentar a confiabilidade do sistema e reduzir o número e a duração de paradas não planejadas nas instalações (BORGES, 2021; MEHL, 2012).

Nesse sentido, a manutenção das linhas de distribuição é crucial para garantir a segurança e a continuidade do fornecimento de energia elétrica. O avanço da vegetação em LDE é um desafio, especialmente em áreas urbanas e periurbanas, onde árvores e plantas crescem perto da infraestrutura elétrica. O contato entre a vegetação e esses cabos pode causar interrupções no serviço, danificar a infraestrutura e até levar a diversos incidentes, incluindo incêndios, perdas materiais ou riscos à vida humana (WILSON; WICKRAMASURIYA; MARCHIORI, 2023; QAYYUM et al., 2014). A Figura 1 mostra um exemplo de um sistema de distribuição em chamas, que pode ser causado pelo contato entre a vegetação e LDE. Esses incêndios representam perigos imediatos e podem causar interrupções generalizadas no fornecimento de energia, danos ambientais e custos significativos, ressaltando a necessidade crítica de medidas proativas para detectar e mitigar tais riscos.

Em vista disso, este trabalho visa desenvolver um sistema para a detecção de contato das linhas de distribuição com a vegetação utilizando métodos de Inteligência Artificial



Figura 1 – A cena de um poste em chamas (CRICIUMA, 2019).

(IA), em especial Redes Neurais Profundas, uma sub-área da IA conhecida como *Deep Learning*, na área de visão computacional. Com esse intuito, investigamos o uso das arquiteturas *You Only Look Once* (YOLO) e *Real-Time Detection Transformer* (RT-DETR) para identificar o avanço da vegetação em imagens de ambientes urbanos reais, obtidas com câmeras GoPro instaladas em veículos terrestres.

A relevância do estudo reside no aumento da segurança e eficiência na manutenção das redes elétricas, bem como na redução dos custos operacionais. Além disso, deve-se considerar que o impacto de um sistema de detecção eficaz vai além da economia financeira para as empresas de energia. O desenvolvimento desse sistema pode prevenir acidentes, minimizar interrupções no serviço e melhorar a confiabilidade das redes de distribuição de energia (WILSON; WICKRAMASURIYA; MARCHIORI, 2023; QAYYUM et al., 2014; WALSH; DINNIE; WIEDMANN, 2006).

Enquanto grande parte dos estudos anteriores tem focado no monitoramento de linhas de transmissão de alta tensão (ver Capítulo 3 Trabalhos Correlatos), localizadas em áreas

rurais ou remotas, este trabalho direciona seus esforços para as redes de distribuição em zonas urbanas, onde o risco de interferência da vegetação é elevado e os impactos sociais são imediatos. Além disso, outro diferencial é a aquisição de dados por sistemas de mapeamento móvel de baixo custo, através de câmeras instaladas em veículos terrestres. Essa abordagem contrasta com outros estudos que se baseiam em métodos de captura de imagens por Veículos Aéreos Não Tripulados (VANTs), que enfrentam restrições legais, operacionais e de segurança em ambientes urbanos (ANAC, 2023; DECEA, 2023). Nesse sentido, outra contribuição é o desenvolvimento e a divulgação pública de um conjunto de dados rotulados, que visa auxiliar futuras pesquisas.

Em síntese, este trabalho contribui para a inovação tecnológica em manutenção elétrica ao abordar a questão crítica da interferência da vegetação em ambientes urbanos, apoiando o desenvolvimento de infraestruturas mais seguras e resilientes, melhorando, em última análise, a qualidade de vida de toda a população.

## 1.1 Motivação

O Brasil ocupa a sexta posição entre os maiores consumidores de eletricidade do mundo em 2022, de acordo com dados da United Nations Statistics Division (2024), demonstrando sua relevância no cenário energético global. No mesmo ano, conforme relatório da Empresa de Pesquisa Energética (2023), o consumo nacional de energia elétrica alcançou impressionantes 509 terawatts-hora (o equivalente a 509 trilhões de watts-hora), um volume que reflete a dimensão territorial e populacional do país. Esses números reforçam a necessidade de sistemas elétricos robustos, confiáveis e seguros, que garantam o suprimento contínuo de energia para os diversos setores da economia e a qualidade de vida da população.

Uma das maiores crises elétricas da história do país ocorreu em 2001, quando a combinação de baixos níveis de chuva, o aumento expressivo no consumo de energia elétrica e a baixa expansão da capacidade instalada resultaram em um grave desequilíbrio entre oferta e demanda. Entre 1990 e 2000, o consumo cresceu cerca de 49%, enquanto a capacidade de geração foi ampliada em apenas 35%, demonstrando a insuficiência de investimentos no setor. Para evitar um colapso no fornecimento, o governo implementou um rigoroso programa de racionamento, exigindo uma redução de 20% no consumo de energia por parte de consumidores residenciais e industriais em várias regiões do país. Penalidades para quem excedesse as metas de consumo e incentivos para os que economizassem foram adotados. Essas medidas foram aplicadas entre maio de 2001 e fevereiro de 2002, obrigando a população brasileira a reduzir o consumo por quase um ano. O impacto econômico foi significativo: o Produto Interno Bruto (PIB) cresceu apenas 1,4% em 2001, uma queda em relação aos 4,4% do ano anterior. As perdas foram estimadas em cerca de 45 bilhões de reais, afetando diversos setores da economia (BORGES, 2021; NORD,

2024; ECONOMIA, 2021).

Em janeiro de 2019, um apagão afetou cerca de um milhão de clientes na Zona Leste de São Paulo e no ABC Paulista, causado por um princípio de incêndio. O incidente provocou o desligamento de subestações, interrompendo a distribuição de energia (G1, 2019).

Em novembro de 2020, um incêndio na subestação de energia de Macapá provocou um blecaute que atingiu 13 dos 16 municípios do estado do Amapá, afetando cerca de 730 mil pessoas - aproximadamente 85% da população local. O incêndio inutilizou dois transformadores da subestação, o que comprometeu a capacidade de fornecimento de energia. A falta de eletricidade impactou o abastecimento de água, o acesso à internet, e causou prejuízos significativos ao comércio, com perdas de alimentos perecíveis. O fornecimento de energia começou a ser restabelecido parcialmente após quatro dias, mas o retorno definitivo só ocorreu cerca de 22 dias depois, no final de novembro, após a instalação de um transformador emergencial, normalizando o abastecimento para os municípios afetados (CNN, 2023; BBC, 2020; NOTÍCIAS, 2020).

Recentemente, o apagão nacional ocorrido em 15 de agosto de 2023 foi um dos mais significativos da história do país, afetando 25 estados e o Distrito Federal — todos, com exceção de Roraima, que não integra o Sistema Interligado Nacional. O evento teve início às 08h31 (horário de Brasília), resultando na interrupção de 16 mil megawatts de carga, o que corresponde a cerca de 25% da demanda nacional naquele momento. A região Norte foi a mais impactada, com uma perda de 83,8% de sua carga elétrica, seguida pelo Nordeste (44,4%), Sudeste-Centro-Oeste (19%) e Sul (15,5%). A recomposição do sistema começou dez minutos após o início da falha, mas a normalização completa só foi alcançada por volta das 14h30, com algumas localidades ainda enfrentando instabilidades após esse horário. Os impactos do apagão foram imediatos e atingiram setores essenciais. O transporte público foi afetado, com a paralisação de sistemas de metrô e a evacuação de passageiros. O trânsito se tornou caótico em várias cidades devido ao desligamento de semáforos, comprometendo a mobilidade e a segurança. Também houve interrupções no abastecimento de água, suspensão de aulas e impactos no comércio, especialmente com a indisponibilidade de pagamentos eletrônicos. Esses efeitos demonstram a vulnerabilidade dos serviços urbanos diante de falhas no fornecimento de energia elétrica. (CNN, 2023; G1, 2023).

Em 21 de agosto de 2022, a Universidade Federal de Uberlândia (UFU) enfrentou uma interrupção no fornecimento de energia elétrica durante a primeira fase do vestibular 2022/2, afetando o Campus Santa Mônica e a Escola Municipal Professor Domingos Pimentel de Ulhôa, em Uberlândia. O apagão inviabilizou a conclusão das provas nesses locais, levando ao cancelamento generalizado do exame para todos os 19.657 candidatos - inclusive aqueles que já haviam finalizado a avaliação sem contratemplos. Como consequência, o processo seletivo foi adiado em dois meses, com a nova aplicação ocor-

rendo em 23 de outubro de 2022, mantendo os mesmos municípios previstos inicialmente: Uberlândia, Ituiutaba, Monte Carmelo, Patos de Minas, Belo Horizonte, Goiânia (GO) e Ribeirão Preto (SP). A UFU optou por não reabrir inscrições ou permitir alterações nas opções de curso, mas concedeu aos candidatos a possibilidade de solicitar reembolso da taxa em caso de desistência. Conforme destacado pela pró-reitora de Graduação, Kárem Ribeiro, a decisão - embora onerosa logisticamente (envolvendo a impressão de novos exames e realocação de fiscais) - foi considerada indispensável para assegurar igualdade de condições entre os participantes e evitar problemas jurídicos (UFU, 2022).

Esses incidentes demonstram o impacto significativo que a interrupção no fornecimento de energia elétrica pode causar à sociedade brasileira. Além disso, a interação entre a vegetação e a rede elétrica causa incêndios florestais em diversos países, como Estados Unidos, Espanha e Austrália, sendo neste último uma das principais causas desses desastres (MILLER et al., 2017; WILSON; WICKRAMASURIYA; MARCHIORI, 2023; RUSSELL; BENNER; WISCHKAEMPER, 2012).

Em outubro de 2007, ventos de Santa Ana excepcionalmente fortes no sul da Califórnia (Estados Unidos) desencadearam 20 grandes incêndios que queimaram 200.000 hectares e destruíram 3.000 estruturas, sendo quase metade das ignições causadas por linhas de energia (MITCHELL, 2013).

Na Austrália, o evento conhecido como *Black Saturday*, em fevereiro de 2009, resultou na queima de mais de 270.000 hectares, provocou 173 mortes e gerou perdas estimadas em 3 bilhões de dólares. Seis grandes incêndios foram atribuídos diretamente a falhas na rede de distribuição elétrica (BANDARA; RAJEEV; GAD, 2023; MILLER et al., 2017; MITCHELL, 2013).

Embora a infraestrutura de distribuição elétrica represente uma parcela menor das ignições quando comparada a outras fontes, os incêndios associados a ela apresentam consequências mais severas, sendo seis vezes mais frequentes em ocorrências que resultam na destruição de residências do que naqueles sem perdas materiais relevantes (COLLINS; PENMAN; PRICE, 2016).

Em vista disso, é essencial o desenvolvimento de sistemas que priorizem a prevenção de crises, indo além da mera correção de falhas quando elas ocorrem. No contexto urbano, observa-se uma lacuna no emprego de técnicas de visão computacional para detecção do contato entre a vegetação e os cabos elétricos em sistemas de distribuição urbana, problema que esta pesquisa visa solucionar.

## 1.2 Objetivos e Desafios da Pesquisa

Esta pesquisa tem por objetivo desenvolver um sistema baseado em *deep learning* para detectar o contato da vegetação com Linhas de Distribuição de Energia (LDE) em ambientes urbanos, contribuindo para a melhoria, eficiência e segurança dos processos de

manutenção. Para alcançar esse objetivo, foram avaliadas as arquiteturas YOLO e RT-DETR, explorando diferentes versões e técnicas de pré-processamento de imagens, como algoritmos clássicos de detecção de bordas. Dessa forma, os objetivos específicos são:

- ❑ Avaliar o desempenho de diferentes versões dos modelos YOLO e RT-DETR na detecção de contato da vegetação com LDEs;
- ❑ Investigar o impacto de técnicas de detecção de bordas na qualidade da detecção;
- ❑ Disponibilizar publicamente o conjunto de dados utilizado na pesquisa, com as suas anotações devidamente rotuladas, para apoiar estudos futuros.

### **1.3 Hipóteses**

1. Imagens obtidas com mapeamento móvel são adequadas para a detecção de contato da vegetação com linhas de distribuição de energia;
2. Arquiteturas modernas de detecção são eficazes na identificação de contato entre vegetação e LDEs;
3. O uso de técnicas de detecção de bordas melhora a precisão da detecção de contato da vegetação com LDEs.
4. Versões mais recentes do modelo YOLO apresentam desempenho superior na detecção de contato da vegetação com LDEs em comparação com versões mais antigas;
5. Modelos menores da YOLO podem fornecer resultados satisfatórios na detecção de contato da vegetação com LDEs, utilizando menos poder computacional.

### **1.4 Contribuições**

- ❑ Desenvolvimento de uma solução para manutenção preventiva em redes de distribuição de energia, utilizando um sistema de mapeamento móvel de baixo custo e redes neurais, capaz de detectar contatos de LDE com vegetação de maneira eficiente;
- ❑ Estudo comparativo de diferentes variantes dos modelos YOLO e RT-DETR, permitindo avaliar o desempenho de redes recentes na literatura;
- ❑ Investigação do impacto de diversas técnicas de detecção de bordas, incluindo os filtros Roberts, Prewitt, Sobel, Laplace, DoG, LoG e Canny;
- ❑ Criação e disponibilização de um conjunto de dados, incluindo imagens e anotações rotuladas, para acesso público, visando apoiar pesquisas futuras.

## 1.5 Organização da Dissertação

Esta dissertação está organizada em 6 capítulos, como descrito a seguir:

- ❑ **Capítulo 1: Introdução** - Apresenta a introdução e contextualização ao tema, motivação, objetivos e desafios da pesquisa, hipótese, contribuições e a organização.
- ❑ **Capítulo 2: Fundamentação Teórica** - Aborda os conceitos necessários para o entendimento do tema, incluindo uma visão geral do sistema elétrico, redes neurais artificiais, convolucionais e transformers, além de técnicas de aumento de dados e detecção de bordas.
- ❑ **Capítulo 3: Trabalhos Correlatos** - Apresenta estudos que aplicam aprendizado profundo para identificação de problemas na infraestrutura elétrica.
- ❑ **Capítulo 4: Metodologia** - Descreve a abordagem utilizada para o desenvolvimento do sistema proposto, incluindo a coleta de dados, rotulagem, técnicas de pré-processamento de imagens, treinamento do modelo e avaliação de desempenho.
- ❑ **Capítulo 5: Experimentos** - Apresenta os resultados obtidos nos experimentos realizados, comparando o desempenho das diferentes arquiteturas de redes neurais.
- ❑ **Capítulo 6: Conclusão** - Resume os principais achados da pesquisa, destaca as contribuições do estudo e sugere direções para pesquisas futuras.



# CAPÍTULO 2

---

## Fundamentação Teórica

Neste capítulo, abordam-se os fundamentos teóricos que sustentam esta pesquisa. Primeiramente, é apresentada uma visão geral do sistema elétrico, seguida pela introdução às redes neurais artificiais e à evolução das CNNs, utilizadas em tarefas de visão computacional. Em seguida, explora-se a arquitetura YOLO, conhecida por sua eficiência na detecção de objetos em tempo real. Além disso, discute-se os transformers, com foco na arquitetura RT-DETR, uma alternativa moderna às CNNs que adota mecanismos de atenção para aprimorar o desempenho em tarefas de detecção. Por fim, explora-se técnicas de aumento de dados e detecção de bordas.

### 2.1 Visão Geral do Sistema Elétrico

Para uma melhor compreensão do segmento do sistema elétrico abordado nesta pesquisa, é necessário, primeiramente, apresentar uma visão geral da estrutura e funcionamento do sistema elétrico como um todo.

A Figura 2 apresenta, de forma esquemática, os principais estágios do sistema elétrico, mostrando o percurso da energia desde a geração até o consumo final. O diagrama está dividido em três áreas: Geração, Transmissão e Distribuição (KAGAN; OLIVEIRA; ROBBA, 2021).

Na etapa de Geração, representada à esquerda da Figura, temos uma usina, que pode ser de natureza hidráulica, térmica ou outra fonte, e uma estação elevadora de tensão. No Brasil, a geração de energia elétrica é realizada por meio de usinas hidrelétricas, aproveitando o vasto potencial hídrico disponível no território nacional. Essa forma de geração se baseia na conversão da energia potencial da água em energia elétrica, sendo considerada uma fonte renovável e relevante para a matriz energética brasileira (Empresa de Pesquisa Energética, 2023).

No entanto, como as usinas de energia se localizam em regiões distantes dos principais centros urbanos e industriais, responsáveis pelo maior consumo, é essencial a existência de um sistema de interligação eficiente que permita o transporte dessa energia ao longo

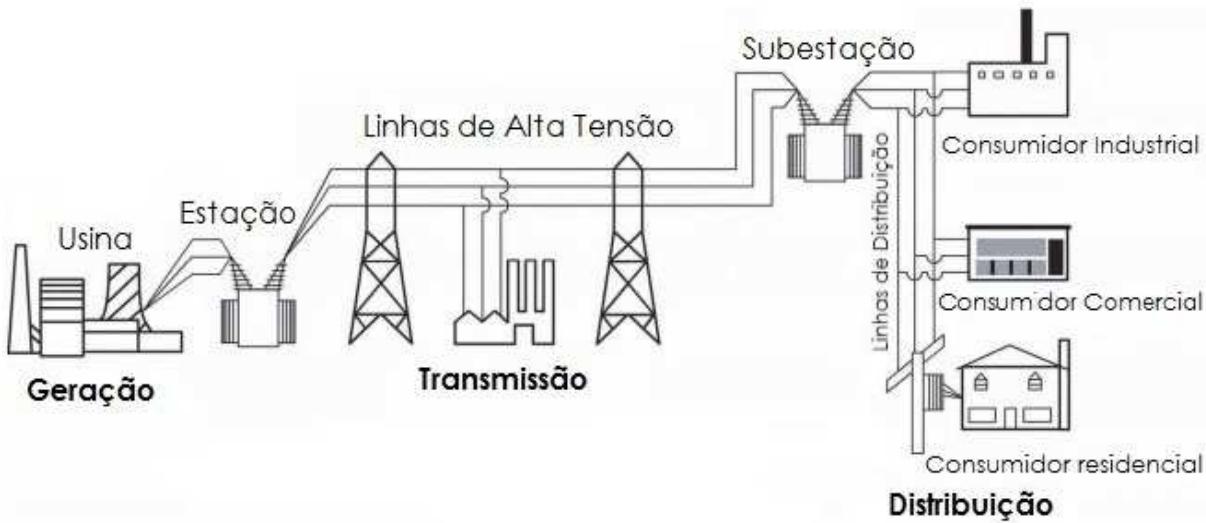


Figura 2 – Visão do Sistema Elétrico: Geração, Transmissão e Distribuição (SILVA, 2014).

de grandes distâncias. Nesse sentido, a função da estação é elevar a tensão elétrica gerada para níveis adequados ao transporte em longas distâncias, processo necessário para reduzir perdas e possibilitar o envio eficiente da energia aos centros consumidores. A tensão de geração no Brasil é, em geral, da ordem de 13,8 kV, podendo variar entre 2,2 kV e até cerca de 22 kV, sendo aumentada nas subestações para níveis de transmissão, como 230 kV, 500 kV ou mais (KAGAN; OLIVEIRA; ROBBA, 2021).

O bloco central apresenta a Transmissão de energia elétrica, realizada por meio de linhas de alta tensão suportadas por torres metálicas, como ilustrado na Figura 3. Este sistema conecta os centros de geração aos centros de consumo, cobrindo distâncias e permitindo o escoamento de blocos de potência com o menor nível possível de perdas.

Na parte direita do diagrama, temos o estágio de Distribuição, que se inicia com uma subestação responsável por rebaixar a tensão de transmissão para níveis adequados ao fornecimento de energia aos diferentes tipos de consumidores. Essa primeira etapa resulta na chamada tensão de distribuição primária (também conhecida como média tensão), ilustrada na Figura 4, utilizada para atender consumidores de grande porte, como indústrias e grandes estabelecimentos comerciais (KAGAN; OLIVEIRA; ROBBA, 2021).

A partir daí, a energia é conduzida por redes primárias até transformadores de distribuição, que realizam novo rebaixamento de tensão para os níveis utilizados por consumidores finais de menor porte. Esse novo patamar, que é o foco da pesquisa, é denominado distribuição secundária, ou baixa tensão, nos valores de 220 V ou 127 V, adequado para residências e pequenos comércios, ilustrada na Figura 5 (KAGAN; OLIVEIRA; ROBBA, 2021).



Figura 3 – Linha de Transmissão da usina de Itaipu, em Foz do Iguaçu (EIXOS, 2023).



Figura 4 – Subestação de Energia (ENGENHARIA, 2020).

Essa representação gráfica da Figura 2 contribui para a compreensão da complexidade e divisão do sistema elétrico nacional, demonstrando a importância de cada etapa no processo de transmissão de energia e os desafios envolvidos em garantir um fornecimento eficiente, seguro e contínuo para a sociedade.



Figura 5 – Postes de Distribuição de Energia (Reforrafo Transformadores, 2025).

## 2.2 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados no sistema nervoso biológico e na forma como os neurônios no cérebro humano processam informações (O'SHEA; NASH, 2015). Esses sistemas são utilizados em tarefas como classificação, regressão e reconhecimento de padrões, sendo a base de muitas técnicas modernas de aprendizado de máquina (*machine learning*) e aprendizado profundo (*deep learning*).

A unidade base para o processamento de informação de uma RNA é o neurônio artificial, cuja estrutura básica é ilustrada na Figura 6. Ele recebe múltiplas entradas ( $x_1, x_2, \dots, x_n$ ), cada uma ponderada por um peso sináptico correspondente ( $w_1, w_2, \dots, w_n$ ) e calcula uma soma ponderada que inclui um termo de bias ( $b$ ) para ajuste do limiar de ativação. Essa soma combinada é passada por uma função de ativação ( $\phi$ ), produzindo a saída final do neurônio ( $y$ ) (HAYKIN, 1999; RUSSELL; NORVIG, 2010).

O perceptron é uma das formas simples de uma RNA, consistindo de uma rede neural de camada única em que todas as entradas são conectadas às saídas. Essa arquitetura é capaz de aprender funções linearmente separáveis, como a função binária AND. No entanto, sua principal limitação é não conseguir resolver problemas não linearmente separáveis, como a função XOR (RUSSELL; NORVIG, 2010).

Para superar essas limitações, foram propostas as redes *Multilayer Perceptron* (MLPs), ilustradas na Figura 7. Essas redes possuem uma ou mais camadas ocultas entre a entrada e a saída, permitindo a solução de problemas não lineares. Cada camada é composta por múltiplos neurônios, e a saída de uma camada serve como entrada para a seguinte. A

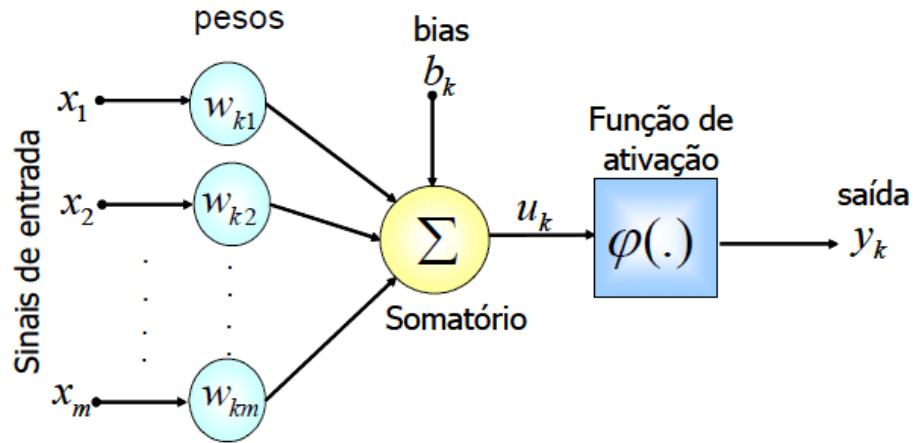


Figura 6 – Estrutura de um neurônio artificial (SOARES; SILVA, 2011).

combinação de múltiplas camadas e funções de ativação não lineares (como ReLU ou sigmoide) torna as MLPs capazes de aproximar funções complexas, sendo amplamente aplicadas em problemas como reconhecimento de padrões e predição (RUSSELL; NORVIG, 2010). Ter várias camadas ocultas empilhadas umas sobre as outras é comumente chamado de aprendizado profundo (O'SHEA; NASH, 2015).

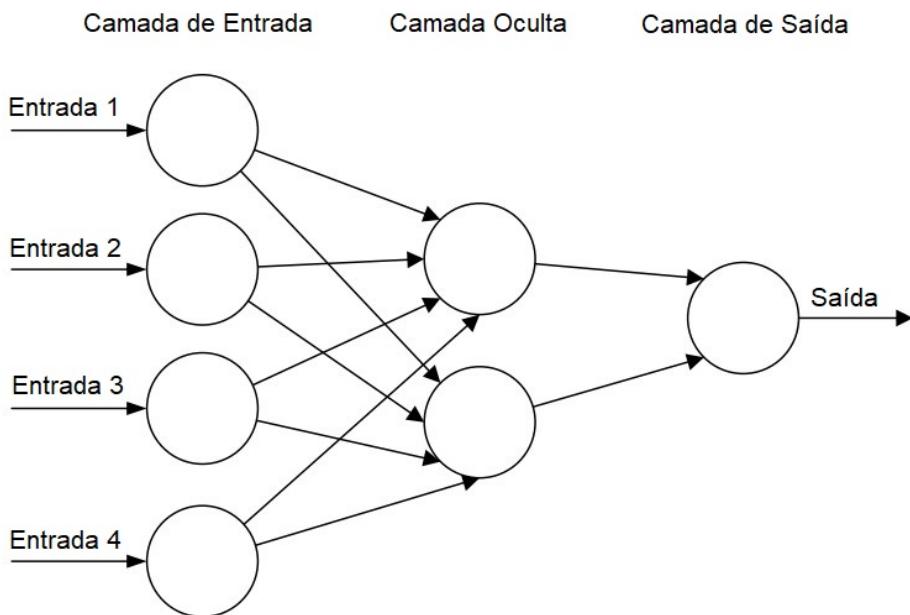


Figura 7 – Rede Neural Artificial. Adaptado de (O'SHEA; NASH, 2015).

## 2.3 Redes Neurais Convolucionais

Redes Neurais Convolucionais (*Convolutional Neural Networks* - CNNs) são um tipo de rede neural artificial, projetadas para processar dados com estrutura de grade, como imagens. Uma diferença crucial entre CNNs e redes neurais tradicionais está na organização tridimensional dos neurônios, que consideram altura, largura e profundidade (canais) dos dados de entrada. Essa estrutura permite que cada neurônio processe uma pequena região da camada anterior, reduzindo a complexidade computacional. A arquitetura típica de uma CNN combina três tipos principais de camadas (O'SHEA; NASH, 2015):

- **Camadas Convolucionais:** Aplicam filtros (*kernels*) treináveis sobre a entrada para extrair características locais (como bordas e texturas) através de operações de convolução.
- **Camadas de *Pooling*:** Realizam operações de redução espacial (como *max pooling* ou *average pooling*), resumindo regiões dos mapas de ativação. Essa etapa reduz a dimensionalidade dos dados e aumenta a robustez da rede a pequenas variações na posição dos padrões.
- **Camadas Totalmente Conectadas:** Integram as características extraídas para classificação final, similares às camadas de redes neurais tradicionais.

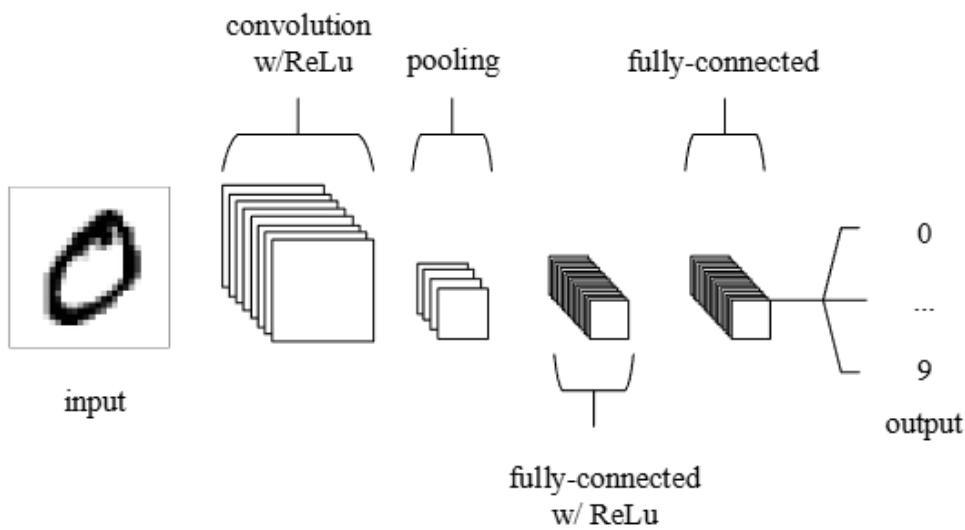


Figura 8 – Arquitetura de uma CNN simples (O'SHEA; NASH, 2015).

A Figura 8 ilustra a arquitetura de uma CNN simples aplicada à classificação de dígitos manuscritos do conjunto MNIST. O processo começa com a entrada de uma imagem em tons de cinza ( $28 \times 28$  pixels), que passa por camadas convolucionais com ativação ReLU,

responsáveis por extrair padrões locais, como bordas e contornos. Cada filtro convolucionial varre a imagem, gerando um mapa de ativação (ilustrado na Figura 9) que destaca a presença de determinadas características. O resultado é um conjunto de mapas empilhados, cada um correspondente à resposta de um filtro diferente. Em seguida, camadas de pooling reduzem a dimensionalidade espacial, mantendo as informações mais relevantes e descartando pequenas variações na imagem. Os mapas resultantes são processados por camadas totalmente conectadas com ReLU, que integram as características extraídas e realizam a inferência. A saída é composta por uma camada com dez neurônios, cada um representando um dígito de 0 a 9 (O'SHEA; NASH, 2015).

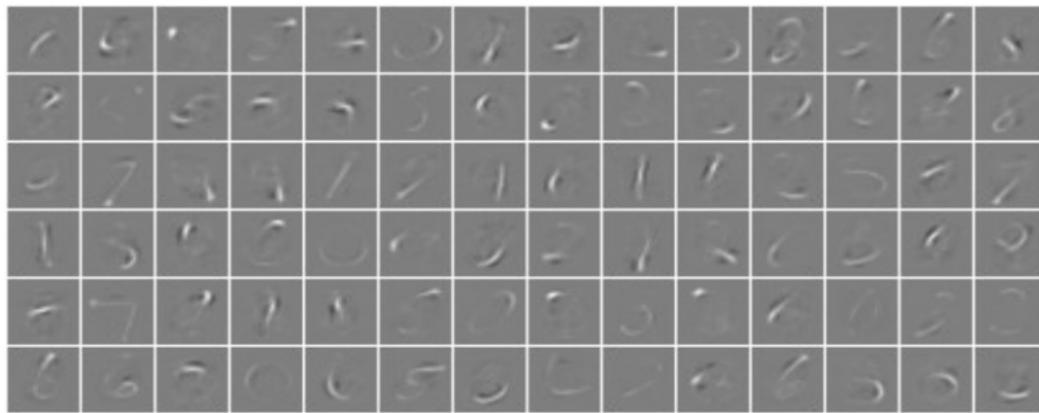


Figura 9 – Mapa de ativações da primeira camada convolucional da CNN ilustrada na Figura 8 (O'SHEA; NASH, 2015).

## 2.4 You Only Look Once

Dando continuidade à aplicação de CNNs em tarefas de visão computacional, uma das abordagens influentes no campo da detecção de objetos é o modelo *You Only Look Once* (YOLO), ilustrado na Figura 10. Diferentemente de métodos tradicionais que utilizam múltiplas etapas ou janelas deslizantes para localizar objetos, o YOLO aproveita a capacidade das CNNs de extrair características espaciais e propõe uma reformulação do problema como uma tarefa única de regressão. Em vez de tratar a localização e a classificação dos objetos, a arquitetura YOLO processa toda a imagem em uma única passagem pela rede, o que resulta em uma detecção extremamente rápida, sendo especialmente adequada para aplicações em tempo real (REDMON et al., 2016).

A YOLO divide a imagem de entrada em uma grade de células, como mostrado na Figura 11. Cada célula da grade é responsável por detectar objetos cujo centro esteja dentro dessa célula. Para cada célula, a YOLO prevê um número fixo de caixas delimitadoras (*bounding boxes*) e suas respectivas probabilidades de classe. Cada caixa delimitadora é definida por coordenadas (x, y), largura, altura e um score de confiança que indica a

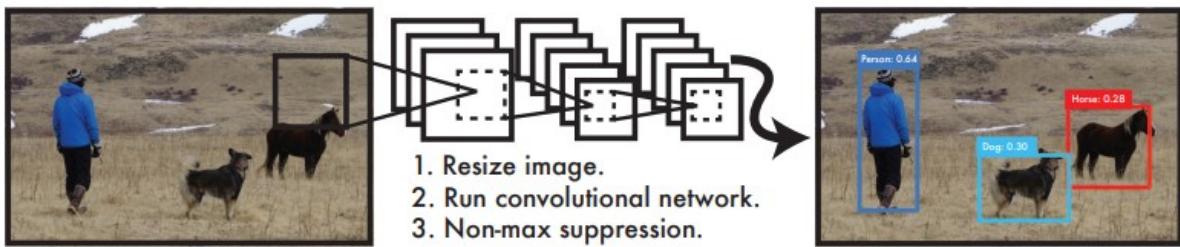


Figura 10 – Exemplo da YOLO em uso (REDMON et al., 2016).

probabilidade de que a caixa contém um objeto e a precisão dessa previsão. Essa metodologia possibilita a identificação simultânea de múltiplos objetos em uma única imagem, com alta precisão e eficiência, tornando a YOLO uma das técnicas mais populares para aplicações de visão computacional em tempo real (REDMON et al., 2016).

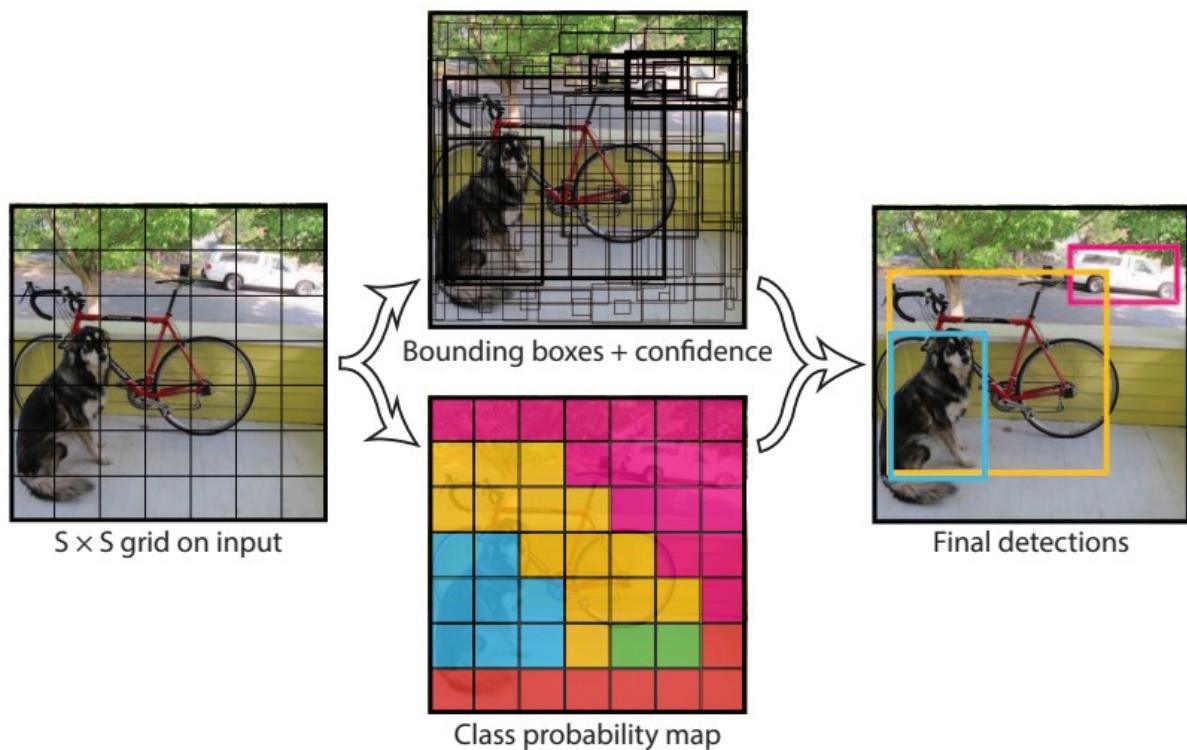


Figura 11 – Sistema de Detecção YOLO (REDMON et al., 2016).

Além disso, nesta seção, explora-se a evolução do modelo de detecção de objetos YOLO, com foco nas versões recentes utilizadas nesta dissertação. Cada versão oferece alterações na arquitetura e otimizações que melhoram a eficiência e a precisão das tarefas de detecção de objetos em tempo real. Ao utilizar essas versões mais recentes da

YOLO, nosso estudo se beneficia de desempenho e robustez aprimorados, permitindo uma detecção mais eficaz do contato da vegetação com a LDE em ambientes urbanos.

Lançada pela Ultralytics, a YOLOv8 representou um salto importante na série YOLO, trazendo maior flexibilidade e desempenho para tarefas de visão computacional. Com múltiplas versões escaladas de *nano* a *extra-large*, o modelo se adaptou a diferentes restrições de hardware e aplicações, oferecendo suporte nativo para detecção de objetos, segmentação, estimativa de pose e classificação (JOCHER; CHAURASIA; QIU, 2023).

Em termos de arquitetura, a YOLOv8 (ilustrada na Figura 12) manteve o *backbone* das versões anteriores, mas substituiu o módulo CSP pelo C2f, uma estrutura mais eficiente que melhora a combinação de features e o fluxo de informações contextuais. Além disso, o modelo também adotou funções de perda aprimoradas. Por fim, a introdução de uma cabeça desacoplada e uma abordagem livre de âncoras possibilitou o tratamento independente de tarefas como classificação, regressão e *objectness*, resultando em maior precisão de detecção (SAPKOTA et al., 2024).

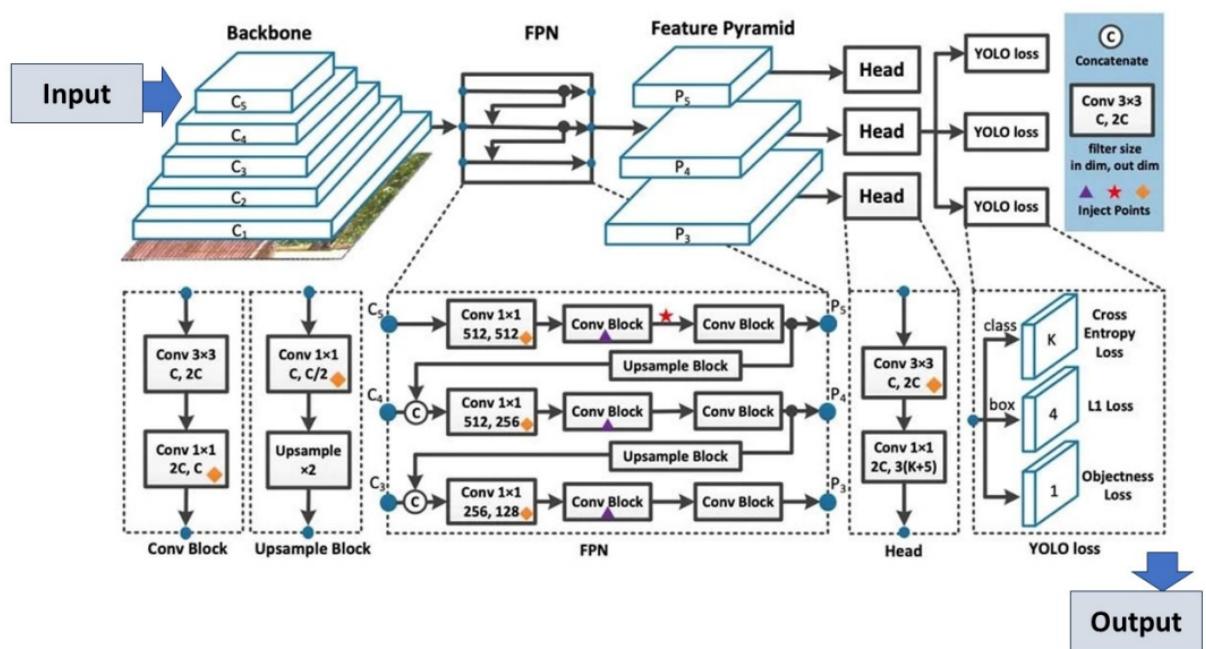


Figura 12 – Arquitetura da YOLOv8 (SAPKOTA et al., 2024).

Em seguida, a YOLOv9 introduziu duas inovações principais: o *Programmable Gradient Information* (PGI) e a *Generalized Efficient Layer Aggregation Network* (GELAN), com o objetivo de melhorar a precisão da detecção de objetos em modelos leves (WANG; LIAO, 2024).

Para lidar com a perda de informações comum em modelos compactos, o PGI é um novo mecanismo que combate gargalos informacionais nas camadas profundas da rede. Ele preserva dados essenciais durante o treinamento, permitindo a geração de gradientes mais confiáveis e, consequentemente, aumentando o desempenho da detecção. Essa abordagem

é relevante para modelos leves, que tendem a ser subparametrizados e propensos a perder informações críticas ao longo do processo de *feedforward* (WANG; LIAO, 2024).

Nesse sentido, a arquitetura da YOLOv9 faz uso de funções reversíveis, permitindo que as informações fluam de forma eficiente e garantindo que, mesmo com menos parâmetros, o modelo retenha os dados necessários para uma detecção precisa (WANG; LIAO, 2024).

Por fim, a GELAN (ilustrada na Figura 13) é uma arquitetura que combina os princípios do CSPNet e do ELAN, com foco no planejamento eficiente do caminho de gradiente. Sua estrutura generaliza a capacidade da ELAN original, permitindo o uso de diferentes blocos computacionais além do simples empilhamento de convoluções. Essa flexibilidade permite desempenho estável mesmo com variações na profundidade e na composição da rede. Além disso, a GELAN retém informações de forma mais eficaz durante o *feedforward*, favorecendo a geração de gradientes mais confiáveis durante o treinamento.

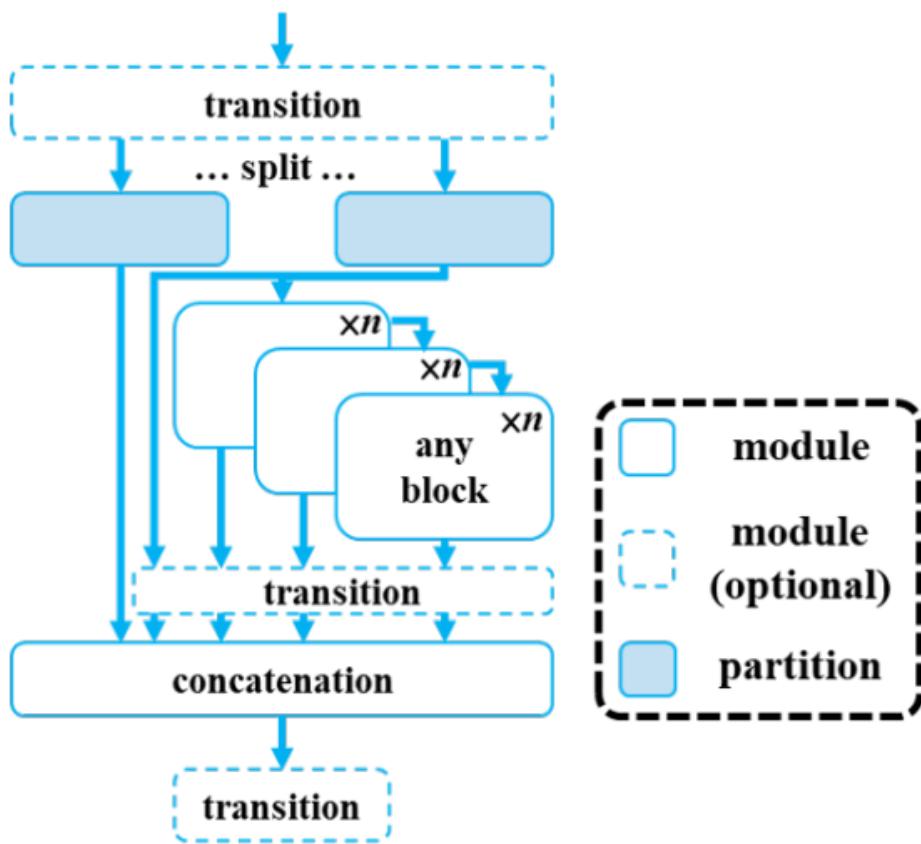


Figura 13 – Arquitetura da GELAN da YOLOv9 (WANG; LIAO, 2024).

Por sua vez, a YOLOv10 (ilustrada na Figura 14) representa um avanço na detecção de objetos em tempo real ao refinar tanto a arquitetura do modelo quanto as etapas de pós-processamento, eliminando a necessidade de *Non-Maximum Suppression* (NMS). Baseada nos modelos anteriores da série YOLO, especialmente a YOLOv8, essa nova versão introduz um *backbone* aprimorado que reduz a redundância computacional, resultando em uma extração de características e inferência mais eficientes (WANG et al., 2024).

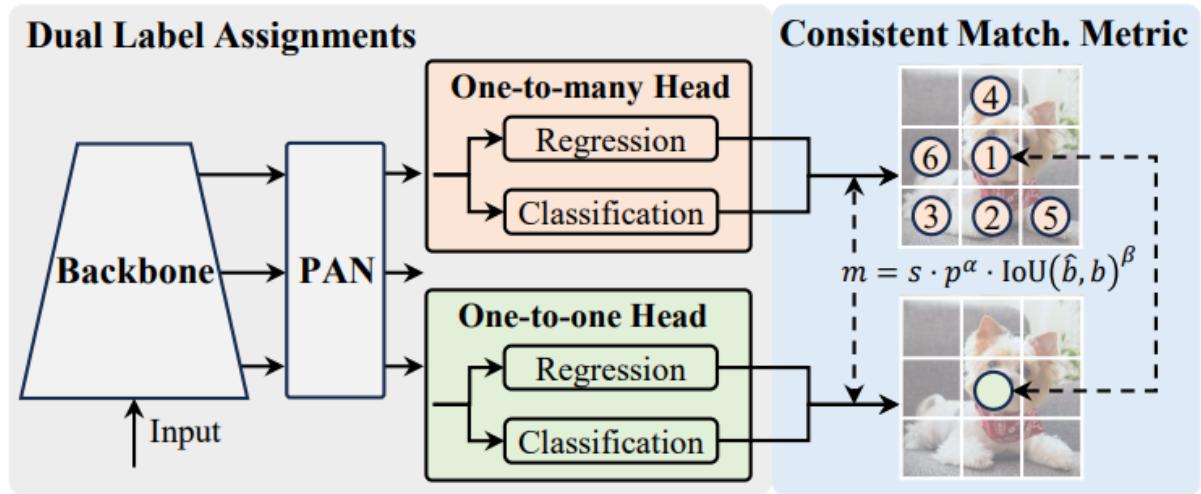


Figura 14 – Arquitetura da YOLOv10 (WANG et al., 2024).

O módulo de pescoço da YOLOv10 incorpora camadas de agregação de caminhos (PAN) para agregar recursos em múltiplas escalas (Figura 14). Em seguida, uma das principais inovações da arquitetura é a introdução de uma estratégia de cabeça dupla: durante o treinamento, a cabeça Um-para-Muitos gera múltiplas previsões por objeto para melhorar o aprendizado; já na fase de inferência, a cabeça Um-para-Um é utilizada, dispensando o uso de NMS e melhorando a eficiência da rede (WANG et al., 2024).

Além disso, a YOLOv10 incorpora outros aprimoramentos, como convoluções com kernel e módulos de autoatenção parcial (PSA), que elevam o desempenho do modelo sem adicionar grande custo computacional. A YOLOv10 se destaca como uma rede eficiente e adequada para aplicações em tempo real (WANG et al., 2024).

## 2.5 *Transformers*

Com o avanço das redes neurais profundas, uma das contribuições mais significativas dos últimos anos foi a introdução dos *Transformers*, inicialmente aplicados a tarefas de processamento de linguagem natural (NLP). Proposto por Vaswani et al. (2017), os Transformers dispensam a necessidade de redes neurais recorrentes ou convolucionais tradicionais ao utilizar uma estrutura baseada exclusivamente em mecanismos de atenção.

O principal componente dessa arquitetura é o mecanismo de autoatenção (*self-attention*), que permite que cada elemento de uma sequência atenda a todos os outros, com um número constante de operações sequenciais. Esse mecanismo é expandido pela atenção multi-cabeça (*multi-head attention*), que permite que o modelo atenda a informações de diferentes subespaços de representação em várias posições. A arquitetura padrão do Transformer, ilustrada na Figura 15, segue o modelo codificador-decodificador, onde as representações são refinadas por camadas *feed-forward* totalmente conectadas. A adição

de encodings posicionais às entradas garante que a informação da ordem dos elementos da sequência seja preservada, característica essencial em aplicações sequenciais como tradução automática (VASWANI et al., 2017; DOSOVITSKIY et al., 2021).

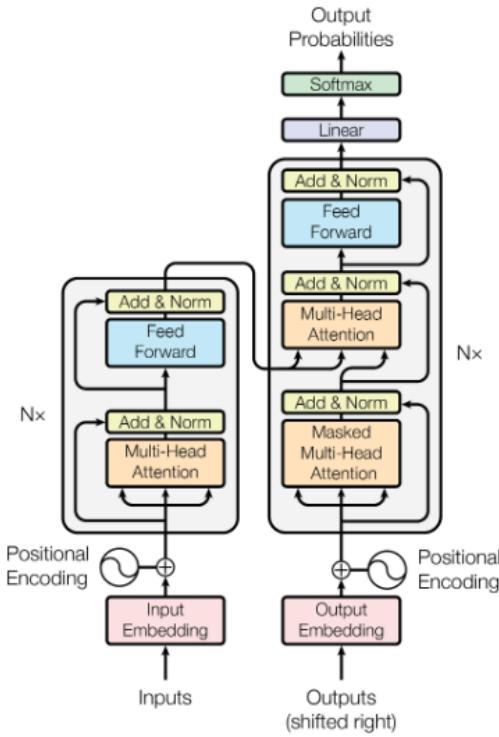


Figura 15 – Arquitetura de um Transformer (VASWANI et al., 2017).

Embora concebidos para texto, os Transformers passaram a ser explorados em tarefas de visão computacional. Um marco nesse processo foi a proposta do *Vision Transformer* (ViT), ilustrado na Figura 16, que demonstrou que a aplicação pura da arquitetura Transformer é eficaz em tarefas como classificação de imagens, mesmo sem o uso de convoluções. No ViT, a imagem de entrada é dividida em pequenos blocos fixos chamados *patches*, os quais são achatados e projetados em vetores de dimensão fixa. A esses vetores são somados *embeddings* de posição para manter a noção de localização espacial, e a sequência resultante é alimentada em um codificador Transformer padrão. Um *token* adicional de classificação é adicionado à sequência, cuja saída representa a imagem como um todo para fins de classificação (DOSOVITSKIY et al., 2021).

Dando continuidade à aplicação de Transformers na visão computacional, foram desenvolvidas arquiteturas para detecção de objetos baseadas nesse paradigma, como o *Detection Transformer* (DETR). Embora inovador, o DETR apresentava desafios como alta demanda computacional e convergência lenta. Em resposta a essas limitações, surgiu o *Real-Time Detection Transformer* (RT-DETR), a primeira arquitetura Transformer capaz de realizar detecção de objetos em tempo real (ZHAO et al., 2023).

Sua arquitetura, ilustrada na Figura 17, é composta por três partes: um *backbone* para extração de características, um codificador híbrido eficiente e um decodificador *Transformer*

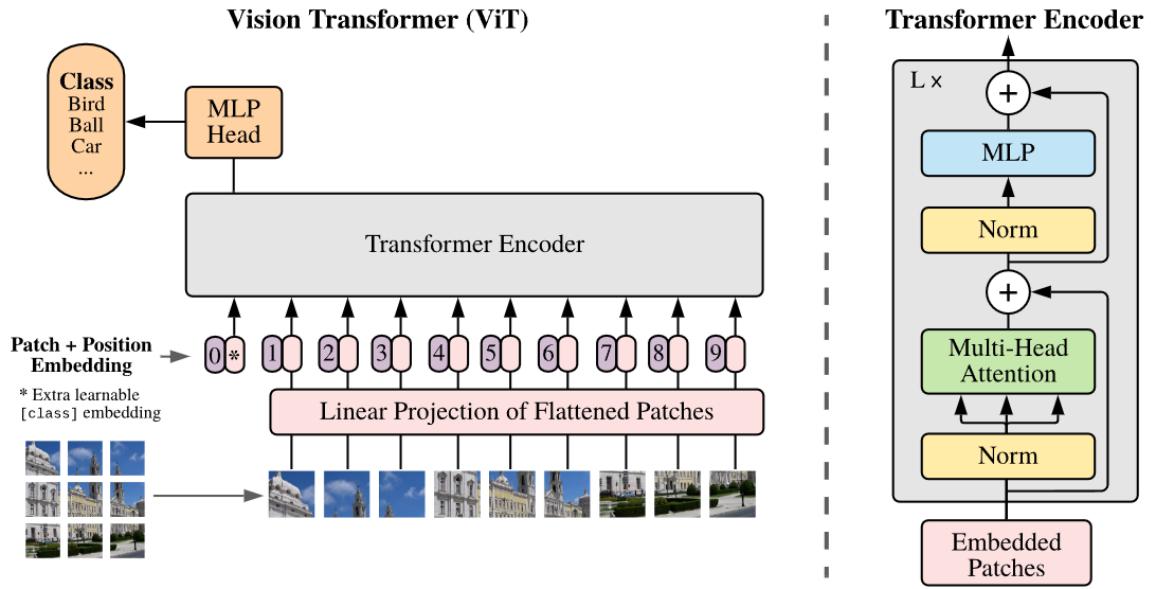


Figura 16 – Arquitetura de um Vision Transformer (DOSOVITSKIY et al., 2021).

mer com cabeças auxiliares de predição. O codificador híbrido é responsável por processar mapas de características em múltiplas escalas de forma eficiente, utilizando dois módulos principais: o *Attention-based Intra-scale Feature Interaction* (AIFI), que aplica atenção em escalas individuais focando em características semânticas ricas; e o *CNN-based Cross-scale Feature Fusion* (CCFF), que utiliza convoluções para integrar informações entre diferentes escalas. Outra inovação importante do RT-DETR é o mecanismo de seleção de consultas baseado em incerteza mínima, que seleciona um número fixo de regiões da imagem com maior potencial informativo como pontos de partida para o processo de detecção. Essas consultas são otimizadas iterativamente no decodificador, que refina as previsões em termos de localização e categoria dos objetos (ZHAO et al., 2023).

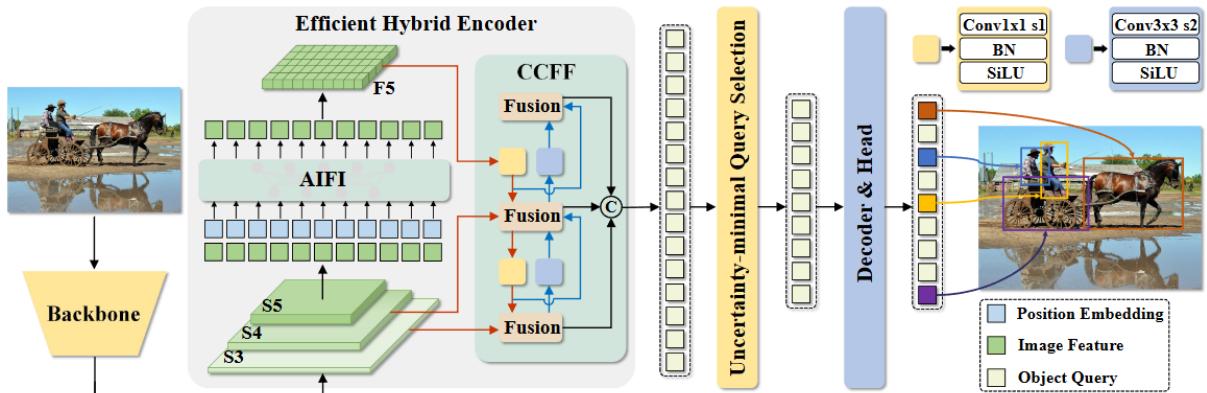


Figura 17 – Arquitetura da rede RT-DETR (ZHAO et al., 2023).

## 2.6 Aumento de Dados

O aumento de dados (*data augmentation*) é uma técnica utilizada em sistemas de visão computacional baseados em aprendizado profundo, especialmente quando se trabalha com conjuntos de dados limitados. Seu principal objetivo é gerar novas amostras sintéticas a partir das imagens originais, assim como ilustrado na Figura 18. Isso é feito por meio da aplicação de transformações que mantêm o conteúdo semântico da imagem, mas introduzem variações visuais plausíveis. Ao expor o modelo a diferentes versões de uma mesma instância, o aumento de dados contribui para melhorar sua capacidade de generalização e reduzir o risco de *overfitting* (IBM, 2024; SHORTEN; KHOSHGOFTAAR, 2019).

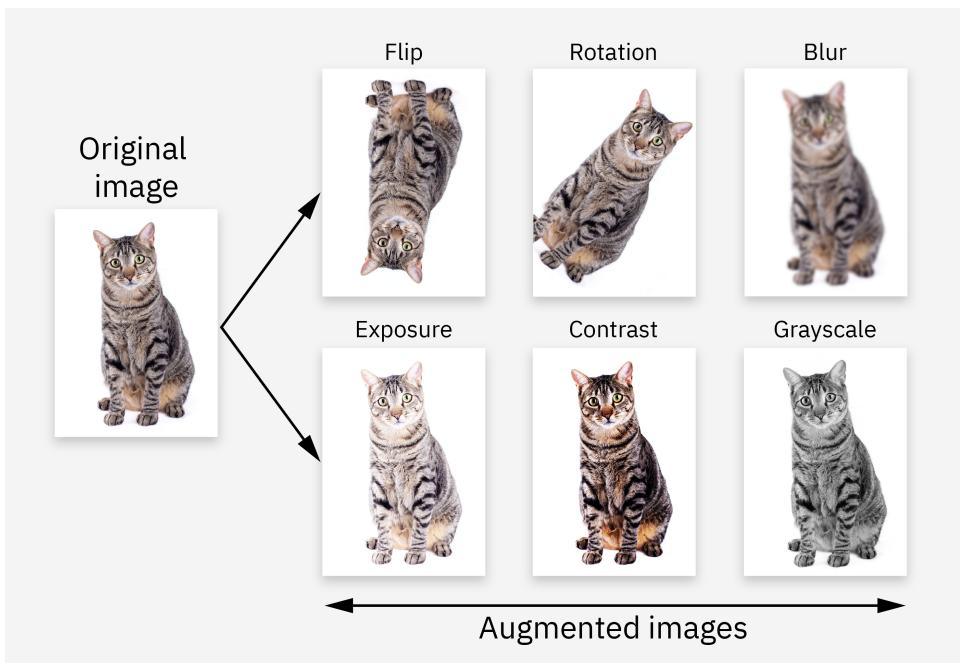


Figura 18 – Algumas técnicas de aumento de dados (IBM, 2024).

Entre as técnicas de aumento de dados mais comuns, destacam-se as transformações geométricas, como rotação, translação, inversão e ajustes de escala. A rotação consiste em girar a imagem em torno de seu centro por um determinado ângulo (geralmente aleatório dentro de um intervalo definido), o que permite simular diferentes orientações do objeto de interesse. A translação desloca a imagem em direções horizontais e/ou verticais, promovendo variações na posição do objeto dentro do quadro. Por sua vez, a inversão horizontal (espelhamento) simula a imagem refletida em torno do eixo vertical, o que é especialmente útil em contextos onde a orientação lateral dos objetos não compromete sua interpretação semântica. Já os ajustes de escala alteram o tamanho relativo dos objetos na imagem, o que é útil para lidar com diferentes distâncias e tamanhos aparentes no cenário (SHORTEN; KHOSHGOFTAAR, 2019).

Além disso, temos as transformações no espaço de cores. Os ajustes de matiz, saturação e brilho modificam as propriedades cromáticas da imagem, simulando diferentes

condições de iluminação, tempo atmosférico ou variações de equipamento de captura. A matiz altera o tom global da imagem, enquanto a saturação controla a intensidade das cores. Já o brilho ajusta a quantidade de luz presente, tornando a imagem mais clara ou escura. Essas alterações promovem um treinamento mais resiliente a mudanças ambientais naturais (SHORTEN; KHOSHGOFTAAR, 2019).

Outro método é o aumento em mosaico (*mosaic augmentation*), que consiste em combinar partes de quatro imagens distintas em uma única nova imagem para aumentar a diversidade do conjunto de dados. Por fim, a técnica de eliminação aleatória (*random erasing*, ilustrada na Figura 19) introduz pequenas regiões ocultas nas imagens, substituindo trechos por blocos uniformes de cor ou ruído. Essa abordagem simula a oclusão parcial de objetos, incentivando o modelo a aprender características mais discriminativas e robustas (SHORTEN; KHOSHGOFTAAR, 2019).

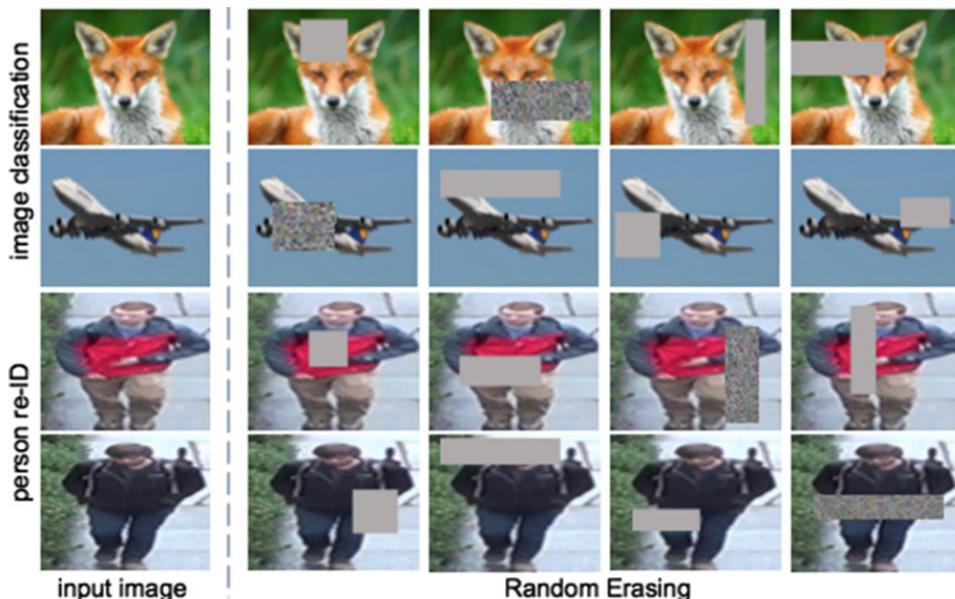


Figura 19 – Exemplo de *random erasing* (SHORTEN; KHOSHGOFTAAR, 2019).

## 2.7 Detecção de Bordas

A detecção de bordas é uma técnica no campo da visão computacional e do processamento de imagens, visando identificar e extrair informações sobre as descontinuidades abruptas na intensidade de pixels em uma imagem. Tais descontinuidades correspondem aos limites de objetos ou regiões distintas dentro de uma cena. A informação de borda é crucial para diversas tarefas de alto nível, como segmentação de imagem, detecção de objetos e análise de forma (SUN et al., 2022).

Os métodos tradicionais de detecção de bordas são classificados com base no uso de derivadas de primeira ou segunda ordem. Estes métodos são conhecidos por sua simplicidade

e eficiência em comparação com técnicas mais recentes. No entanto, podem apresentar desvantagens como contornos gerados mais espessos, incompletos ou descontínuos, além de serem sensíveis ao ruído presente na imagem (SUN et al., 2022).

Entre esses métodos, discute-se primeiro os operadores baseados em gradiente (primeira ordem), que se fundamentam no cálculo da derivada primeira da intensidade dos níveis de cinza. O gradiente em um ponto da imagem indica a direção do aumento mais rápido da intensidade e a magnitude dessa mudança. Pontos com grandes magnitudes de gradiente são considerados candidatos a bordas. Entre os operadores de primeira ordem mais simples e clássicos estão os operadores de Roberts, Prewitt e Sobel, ilustrados na Figura 20 (SUN et al., 2022).

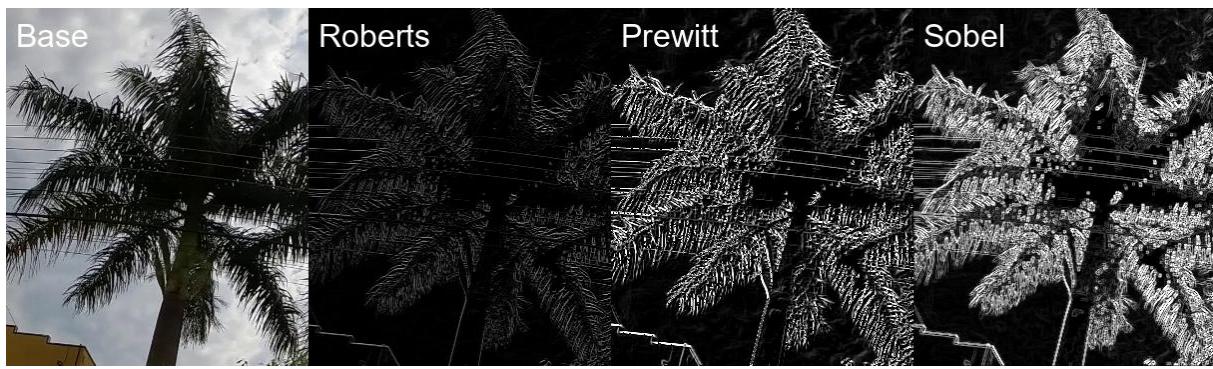


Figura 20 – Exemplo dos filtros de primeira ordem: Roberts, Prewitt e Sobel. Fonte: Elaborado pelo autor.

O operador de Roberts é um dos mais simples, utilizando uma pequena máscara para localizar contornos através de um operador de diferença local. Sua simplicidade é uma vantagem, mas ele é altamente suscetível à interferência de ruído (SUN et al., 2022; ROUSHDY, 2006).

Subsequentemente, foi proposto o operador de Prewitt, que geralmente emprega uma máscara de tamanho 3x3. Ele gera o contorno da imagem calculando a diferença do valor de cinza dos pixels em direções vertical e horizontal. O desempenho do operador de Prewitt para geração de contorno nessas direções é considerado melhor do que o do operador de Roberts (SUN et al., 2022; FAKHRI; SAADATSERESHT, 2019; ROUSHDY, 2006).

Por sua vez, o operador de Sobel é um operador de diferenciação discreta que calcula uma aproximação do gradiente da função de intensidade da imagem. Ele introduz a ideia de pesos e combina a suavização Gaussiana com a derivação de primeira ordem. O Sobel opera convoluindo a imagem com filtros pequenos, separáveis e com valores inteiros nas direções horizontal e vertical (SUN et al., 2022; RANA; VERMA, 2014; ROUSHDY, 2006).

Em relação aos operadores de segunda ordem, que utilizam a segunda derivada para extrair informações de contorno, discutiremos os métodos Laplaciano, DoG, LoG e Canny. A Figura 21 apresenta uma comparação visual dos resultados deles. Observa-se que o resultado dos filtros DoG e LoG apresenta bordas pouco nítidas, dificultando a visualização dos contornos. Por outro lado, o método de Canny se destaca por fornecer bordas bem definidas e limpas, demonstrando ser uma das técnicas mais eficazes entre as comparadas.

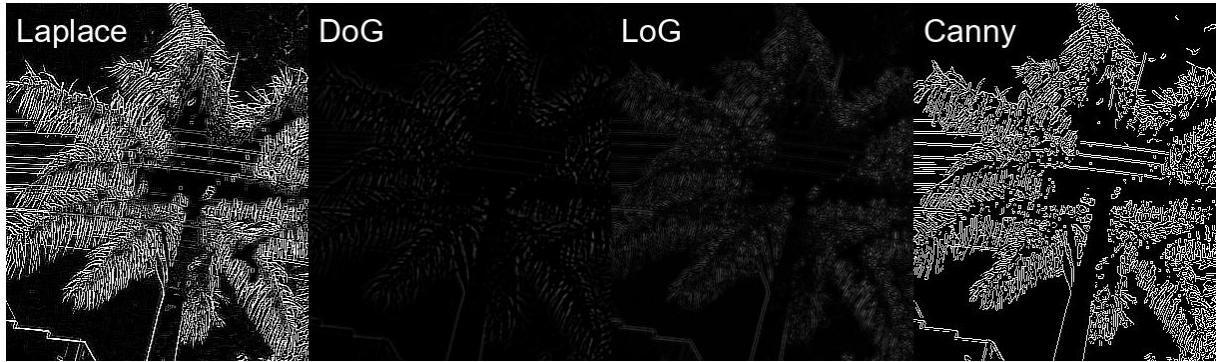


Figura 21 – Exemplo dos filtros de segunda ordem: Laplace, DoG, LoG e Canny. Fonte: Elaborado pelo autor.

O operador Laplaciano é o mais adequado para imagens sem ruído e busca encontrar os lugares corretos das bordas, testando áreas mais amplas ao redor do pixel. No entanto, ele apresenta mau funcionamento em cantos e curvas (ROUSHDY, 2006).

Além dele, a Diferença de Gaussianas (*Difference of Gaussians* - DoG) é um algoritmo utilizado para realce de imagens borradadas. Nesse método, duas imagens suavizadas com filtros gaussianos de diferentes desvios padrão são subtraídas, o que aproxima a aplicação do Laplaciano sobre uma imagem suavizada. (SUN et al., 2022).

Por sua vez, o Laplaciano sobre Gaussianas (*Laplacian of Gaussian* - LoG) combina o filtro gaussiano com o Laplaciano. O filtro gaussiano é aplicado primeiro para suavizar a imagem e reduzir o ruído, tornando a diferenciação menos sensível a ele. Em seguida, o operador Laplaciano é aplicado, e as bordas são detectadas encontrando os cruzamentos de zero na imagem resultante. Operadores baseados em gaussiana, como o LoG, são simétricos ao longo da borda e reduzem o ruído ao suavizar a imagem. No entanto, eles têm computação complexa (ROUSHDY, 2006; NEYCENSSAC, 1993).

Entre os métodos clássicos, o mais sofisticado e amplamente utilizado é o operador Canny. Ele utiliza um algoritmo multi-estágio para detectar uma ampla gama de bordas. Os passos típicos incluem suavização da imagem para remover ruído, cálculo dos gradientes de intensidade, supressão não-máxima para afinar as bordas, aplicação de limiar duplo (*thresholding*) para identificar bordas potenciais e rastreamento de bordas por histerese para conectar segmentos de borda. O objetivo do Canny era ser um detector ótimo, satisfazendo critérios como minimizar a detecção de bordas falsas, minimizar a distância entre

bordas detectadas e reais, e minimizar múltiplas respostas a uma única borda. Ele é menos suscetível à interferência de ruído e produz bordas finas, suaves e contínuas. Embora tenha uma computação mais complexa em comparação com operadores mais simples, seu desempenho superior, especialmente em condições de ruído, o tornou um dos métodos tradicionais mais eficazes (SUN et al., 2022; RANA; VERMA, 2014; ROUSHDY, 2006).

# CAPÍTULO 3

## Trabalhos Correlatos

Neste capítulo, são apresentados diversos trabalhos que exploram a aplicação de redes neurais para detecção de objetos em imagens, com destaque para o modelo YOLO em suas diferentes versões. Os estudos revisados abordam a detecção de componentes relacionados ao setor elétrico, como isoladores, cabos e outras estruturas presentes em linhas de transmissão e distribuição de energia. Além disso, são incluídos estudos que tratam da detecção de focos de incêndio e do uso de equipamentos de proteção individual (EPIs) em subestações de energia, aspectos diretamente relacionados à segurança e à prevenção de riscos no setor elétrico.

Os trabalhos são apresentados em ordem cronológica, permitindo visualizar a evolução das técnicas e modelos ao longo do tempo. Em seguida, realizamos uma análise comparativa entre esses estudos, destacando suas principais características, como o tipo de rede utilizada, o foco das aplicações, o uso de VANTs e os objetos detectados, a fim de contextualizar o estado da arte e discutir a contribuição desta pesquisa.

O trabalho de Qayyum et al. (2014) aborda o problema do avanço da vegetação e árvores próximas a linhas de transmissão de alta tensão, que representa um risco significativo de contato, levando a *blackouts* e perdas econômicas substanciais para as concessionárias de energia. Segundo o autor, métodos tradicionais e aéreos de monitoramento de vegetação e estimativa de altura são caros, perigosos, demorados e propensos a erros. Para fornecer uma solução mais custo-efetiva e automatizada, os autores propõem uma técnica baseada no uso de imagens estéreo de satélite, especificamente imagens *QuickBird*, e o algoritmo de programação dinâmica para estimar a profundidade (e implicitamente a altura) da vegetação e árvores perto dos postes de transmissão. A metodologia proposta superou métodos baseados em correspondência de blocos em experimentos realizados com as imagens de satélite, mas os autores não apresentaram métricas quantitativas para validar a eficácia do método. A Figura 22 ilustra os resultados da pesquisa.

Liang, Zuo e Wei (2020) propõe um método para detecção e classificação de defeitos em linhas de transmissão, abordando algumas limitações da literatura: a restrição a poucas categorias de componentes, e a falta de conjuntos de dados abertos. A partir de imagens



Figura 22 – Mapa de profundidade por imagem de satélite. Adaptado de (QAYYUM et al., 2014).

obtidas por VANTs, os autores desenvolveram o dataset *Wire\_10*, que inclui oito tipos de defeitos em componentes-chave (como isoladores, triplas, amortecedores e anéis de equalização), além de ninhos e objetos estranhos. A Figura 23 ilustra os tipos de defeitos presentes no dataset. O método utiliza o algoritmo *Faster R-CNN* com *fine-tuning*, e os experimentos demonstraram um mAP de 91,1%.

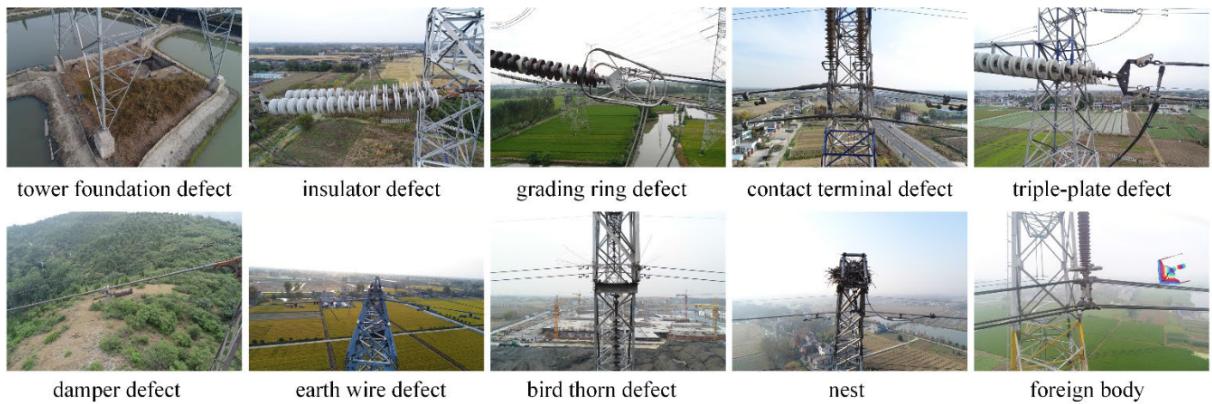


Figura 23 – Tipos de objetos no dataset *Wire\_10* (LIANG; ZUO; WEI, 2020).

Chen e Miao (2020) abordam a detecção e contagem de postes de linhas de distribuição utilizando vídeos de inspeção obtidos por VANTs e a rede YOLOv3. O objetivo é fornecer uma solução para avaliação de perdas pós-desastre. O artigo propõe um algoritmo de contagem baseado na mudança contínua da coordenada da *bounding box* do mesmo poste entre quadros de vídeo consecutivos. A principal inovação deste trabalho foi a detecção, classificação e contagem de postes de linhas de distribuição utilizando VANTs e métodos de aprendizado de máquina, desafio não resolvido anteriormente na literatura segundo os autores. Pela falta de dados em estudos relacionados e a dificuldade de obter imagens de postes caídos, foi criado um conjunto de dados com imagens simuladas de postes em diferentes estados (eretos e caídos). Na Figura 24 vemos exemplos de imagens utilizadas no estudo, de postes eretos e caídos no mundo real e em imagens obtidas em simulação. Os resultados mostram que o modelo YOLOv3 obteve o melhor F1-score (0,91), superando

o *Faster R-CNN* e demonstrando ser eficaz na identificação e contagem de postes em vídeos.

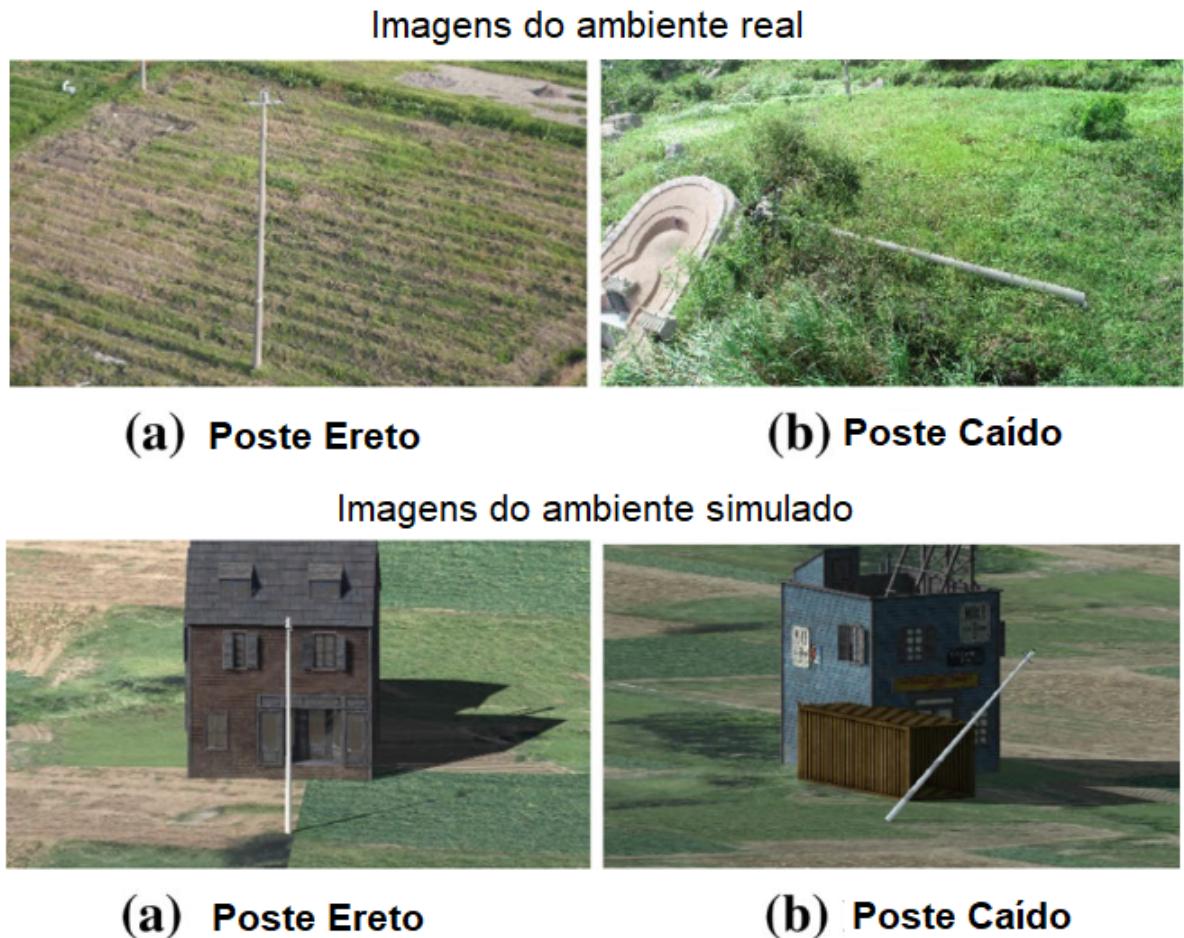


Figura 24 – Contagem de postes eretos e caídos. Adaptado de (CHEN; MIAO, 2020).

Por sua vez, Xie (2021) desenvolve um sistema para detecção de defeitos de superfície em linhas de transmissão de energia utilizando VANTs. Os autores propuseram um método onde VANTs inspecionam linhas de transmissão de forma autônoma, capturando imagens de alta resolução, que são então processadas usando um algoritmo de detecção de bordas para identificar defeitos potenciais. Os resultados experimentais demonstram desempenho variável, com uma taxa de sucesso máxima de 82,02% em condições ideais e uma taxa média de reconhecimento de 59,89%, que se mostrou superior a métodos comparativos, demonstrando tanto o potencial quanto os desafios remanescentes nesta abordagem de inspeção automatizada.

Costa e Cortes (2021) apresentam o uso da YOLO para detectar falhas em componentes de linhas de distribuição de energia ao longo de ferrovias, ilustrados na Figura 25. O objetivo do estudo se concentra na identificação de componentes elétricos e na classificação de três tipos de defeitos, utilizando um conjunto de dados de 708 imagens

rotuladas obtidas por meio de simulações em laboratório com estruturas reais. Após 4 mil épocas, a YOLOv3 obteve os melhores resultados, com 96% de mAP e 45 FPS. Os autores também destacam os desafios de reconhecimento e classificação em tempo real, como semelhança de cores, interseção de componentes, variação de tamanho e condições climáticas adversas.



Figura 25 – Componentes de distribuição de rede elétrica (COSTA; CORTES, 2021).

Renwei et al. (2021) propuseram uma versão aprimorada da YOLOv3 para detecção de componentes em linhas de transmissão, especificamente torres de energia e isoladores, visando melhorar as inspeções por VANTs. A Figura 26 ilustra uma torre de transmissão detectada na pesquisa. Os autores criaram um novo conjunto de dados de mil imagens de torres e isoladores, com diferentes condições de iluminação e ângulos, e utilizaram o algoritmo K-means++ para recalcular os valores das âncoras especificamente para este conjunto de dados, o que melhorou a precisão de detecção. Os resultados experimentais mostraram que o modelo melhorado aumentou a precisão e velocidade do modelo original, além de reduzir as FLOPs em comparação com a YOLOv3 original, atingindo 88% de precisão e 31,2 ms/frame, demonstrando sua capacidade de realizar detecção em tempo real com alta precisão para os componentes visados.

Bao et al. (2022) propõem o método BC-YOLO para detectar defeitos em amortecedores de vibração (Fig 27) e isoladores (Fig 28) em linhas de transmissão usando imagens aéreas obtidas por VANTs. O método utiliza a YOLOv5x como base, introduzindo um

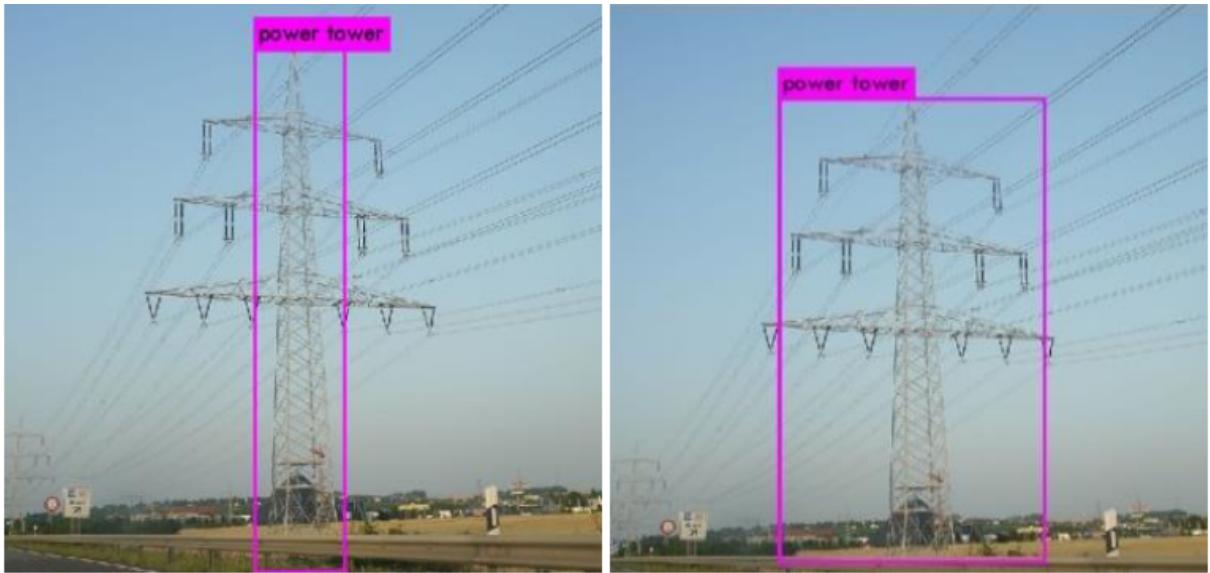


Figura 26 – Detecção de torres de Transmissão (RENWEI et al., 2021).

módulo de atenção de coordenadas e uma rede piramidal de recursos bidirecional (BiFPN) para focar nos recursos dos componentes e balancear informações em diferentes escalas. Para esta pesquisa, os autores desenvolveram o conjunto de dados DVDI, composto por imagens de diversos tipos de isoladores e amortecedores de vibração. O método alcançou um mAP de 89,1%, um valor 2,7% superior ao YOLOv5 original, demonstrando melhor desempenho na detecção de pequenos defeitos em cenários complexos.

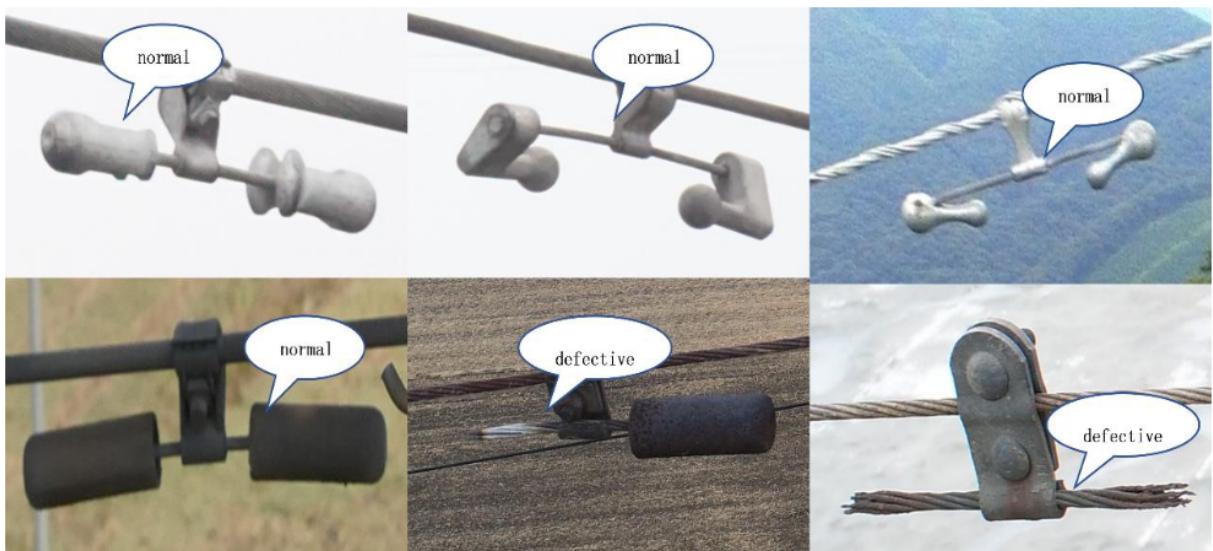


Figura 27 – Defeitos em amortecedores de vibração (BAO et al., 2022).

O estudo de Zhang et al. (2023) aborda os desafios da detecção de defeitos em isoladores de linhas de transmissão em imagens de VANTs, como a baixa precisão e as detecções per-

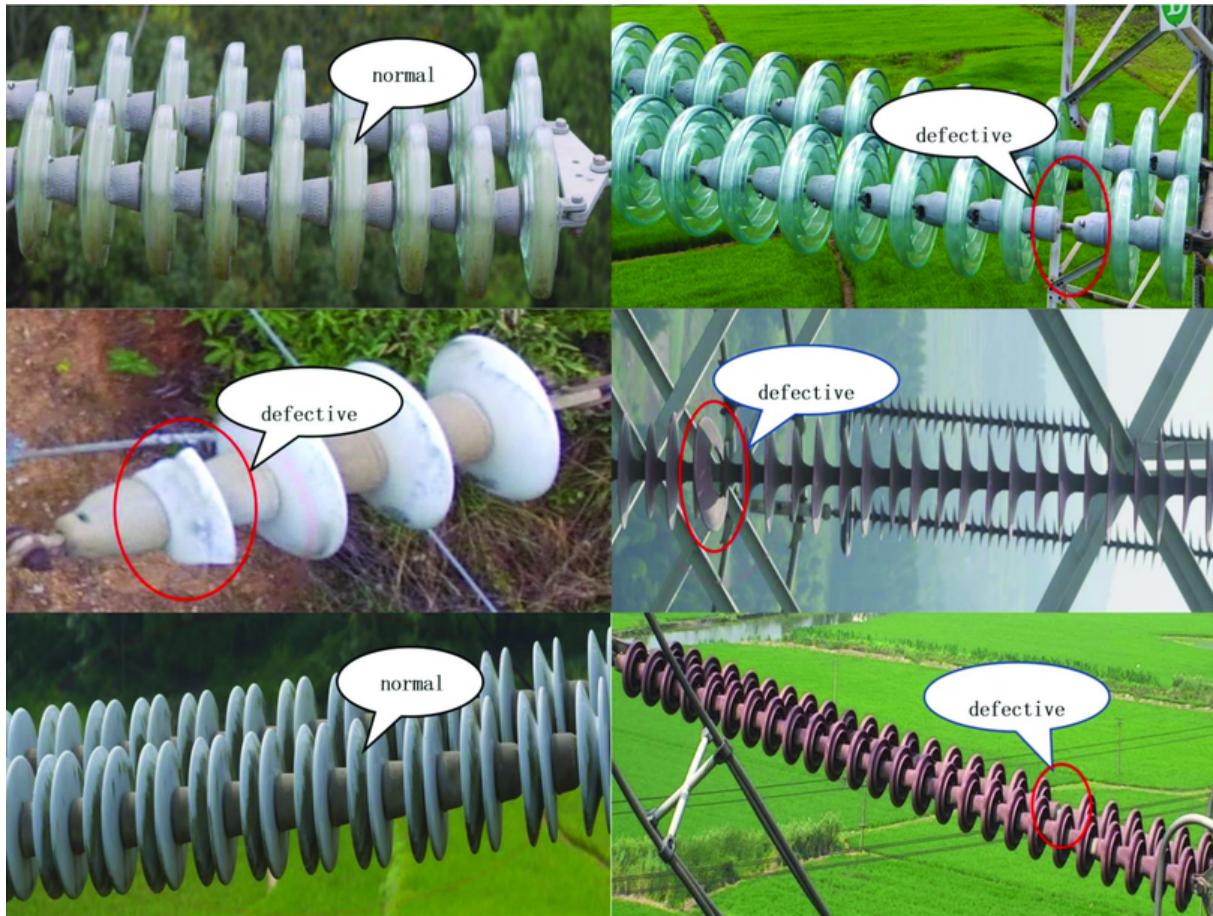


Figura 28 – Defeitos em isoladores (BAO et al., 2022).

didas causadas por fundos complexos, postes e oclusões, além da variação no tamanho dos objetos. Para superar essas dificuldades, os autores propõem uma melhoria no algoritmo YOLOv7, resultando no modelo YOLOv7-ECA-PConv-NWD. O modelo foi avaliado nos datasets TISLTR (isoladores normais) e FISLTR (isoladores defeituosos, pequenos e de alta resolução). Os resultados demonstram que o YOLOv7-ECA-PConv-NWD alcançou um mAP de 98,1% no TISLTR e mAP de 93% (flashover) e 92,2% (quebrados) no FISLTR, demonstrando a capacidade de detecção de isoladores.

Li et al. (2023) propõem o modelo DF-YOLO, uma versão melhorada do YOLOv7-Tiny para a detecção de objetos estranhos em linhas de transmissão. O modelo introduz convolução deformável (DCN) no *backbone*, um mecanismo de atenção e uma nova estrutura de pirâmide espacial para melhorar a precisão e velocidade. Foi criado um novo conjunto de dados com 1.942 imagens de objetos estranhos, contendo as classes: ninho de pássaros, lixo, pipas e balões. Um exemplo dos objetos estranhos pode ser visto na Figura 29. Os resultados mostram um mAP de 95,18% e uma velocidade de inferência de 140 FPS, demonstrando melhorias em relação ao YOLOv7-Tiny.

O estudo de Wilson, Wickramasuriya e Marchiori (2023) aborda o crítico problema



Figura 29 – Objetos estranhos em linhas de Transmissão (LI et al., 2023).

dos incêndios florestais iniciados por interações entre vegetação e redes elétricas, especificamente eventos de vegetação caindo ou sendo soprada sobre linhas de transmissão, que são uma das principais causas de incêndios na Austrália. Para aprimorar a gestão da vegetação e entender melhor o risco, os autores desenvolveram um framework de modelagem e simulação estatística de eventos raros com base em dez anos de registros de incidentes e incêndios. Características do terreno derivadas de LiDAR obtidas por meio de levantamentos com helicópteros também se mostraram significativas. A metodologia emprega uma abordagem de probabilidade condicional aninhada, modelando primeiro os eventos de vegetação e, em seguida, os eventos de ignição condicionados à ocorrência de um evento de vegetação. Utilizando o modelo, o estudo identificou que a velocidade do vento e características da vegetação são altamente relacionadas com eventos de vegetação, enquanto o índice de perigo de incêndio florestal e o tipo de solo são fortemente associados com os eventos de ignição subsequentes. A avaliação em um conjunto de teste mostrou desempenho preditivo razoável, com área sob a curva de 0,79 para o modelo de eventos de vegetação e 0,66 para o modelo de eventos de ignição.

Casas et al. (2023) realizaram uma avaliação abrangente de diversas arquiteturas YOLO (incluindo da YOLOv5 à YOLOv8 e YOLO-NAS) para a detecção de fumaça e incêndios florestais, visando a detecção precoce desses eventos. Utilizando o dataset Foggia e um conjunto de teste customizado, a metodologia focou em maximizar o recall ao longo de 300 épocas de treinamento, uma métrica considerada crucial para minimizar detecções perdidas em aplicações críticas como a detecção de incêndios. Os resultados mostraram que YOLOv5, YOLOv7 e YOLOv8 apresentaram um desempenho equilibrado. As variantes YOLO-NAS se destacaram por atingir alto recall, sendo eficazes em identificar a maioria dos casos positivos, mas apresentaram menor precisão, resultando em uma taxa maior de falsos positivos. A Figura 30 ilustra os resultados das redes.



Figura 30 – Detecção de incêndios usando YOLO (CASAS et al., 2023).

Zou et al. (2024) abordaram o método de detecção YOLO-LSDW, baseado na YOLOv8s. Seu objetivo é a identificação de riscos de danos externos em corredores de linhas de transmissão, principalmente causados por máquinas de construção como escavadeiras e guindastes. A Figura 31 ilustra os resultados da pesquisa. Resultados experimentais alcançaram 84,2% de mAP, além de manter uma alta velocidade de detecção (96,2 FPS).



Figura 31 – Detecção de máquinas de construção próximas a linhas de transmissão (ZOU et al., 2024).

Liu et al. (2024) apresentaram a YOLO-PowerLite, um modelo aprimorado baseado na YOLOv8n para detecção em tempo real de objetos anormais, como ninhos de pássaros e isoladores defeituosos em linhas de transmissão, especificamente desenvolvido para operar em VANTs com recursos computacionais limitados. Testado em um conjunto de dados de 1.738 imagens, o modelo alcançou 94,2% de mAP - mantendo a acurácia do YOLOv8n original enquanto reduzia parâmetros, FLOPs e tamanho do modelo. Implementado em uma plataforma NVIDIA Jetson Xavier NX, processou imagens em 31,2 ms/frame.

Zhang et al. (2024) propuseram a Wear-YOLO, uma versão aprimorada da YOLOv8 para detecção de equipamentos de proteção individual (EPI) em subestações elétricas. O foco do trabalho é o desafio de identificar o uso correto de luvas isolantes, botas e capacetes, um problema de detecção particularmente difícil devido ao pequeno tamanho dos objetos. A Figura 32 ilustra a detecção dos EPIs. Testado em um conjunto de dados de várias competições contendo 2.788 imagens, contendo nove categorias de equipamentos de proteção, o modelo alcançou 92,1% de mAP, mantendo ainda 100 FPS.

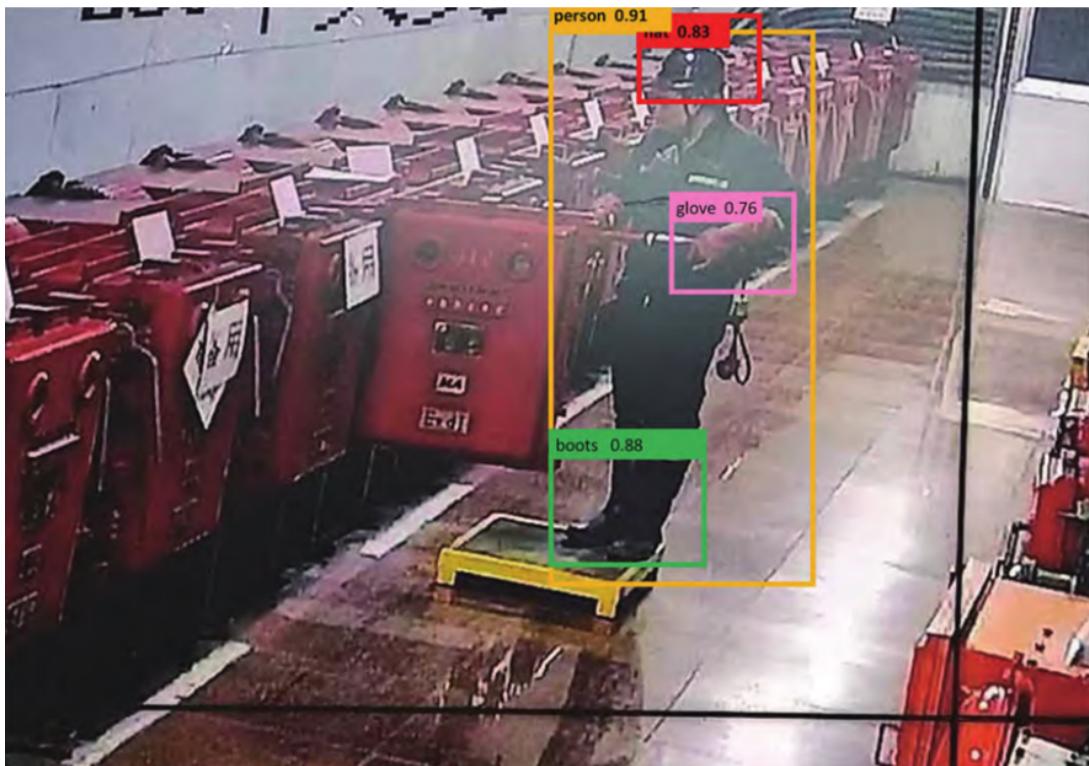


Figura 32 – Detecção de EPIs em subestações elétricas (ZHANG et al., 2024).

Fahim e Hasan (2024) propõem um método para detecção de defeitos em isoladores, focando especificamente em isoladores quebrados e danificados por *flashover*. Para isso, utilizaram imagens do *Insulator Defect Image Dataset* (IDID), disponível na *IEEE Dataport*. O estudo revisa os avanços de trabalhos anteriores que empregaram abordagens como *Faster R-CNN*, YOLOv4, YOLOv5 e BC-YOLO, destacando o desenvolvimento progressivo das técnicas de detecção. Na pesquisa, os autores compararam o desempenho

nho das versões YOLOv7 e YOLOv8, demonstrando que a YOLOv8 obteve resultados superiores, alcançando uma precisão de 98,99% e um mAP de 99,10%.

Li et al. (2024) apresentam o algoritmo *Insulator Fault - You Only Look Once* (IF-YOLO), baseado na YOLOv10n, para detecção eficiente e precisa de defeitos em isoladores em linhas de transmissão. Nos testes com o conjunto *Chinese Power Line Insulator Dataset* (CPLID), os resultados experimentais mostram que o IF-YOLO atinge uma precisão de detecção de 94,6% e 170,7 FPS, representando uma melhoria em relação ao YOLOv10n.

Stefenon et al. (2024) focam na detecção e localização de falhas em redes de distribuição elétrica, visando melhorar a confiabilidade do sistema e prevenir interrupções de energia causadas por defeitos como contaminação em isoladores e a presença de objetos estranhos. A Figura 33 ilustra a detecção de isoladores da pesquisa. Para tal, os autores propõem a utilização de uma versão aprimorada (*hypertuned*) do modelo YOLOv5 e a comparam com a YOLOv7 e a Detectron (*masked R-CNN*). Essa otimização dos hiperparâmetros da YOLO é realizada por meio de um algoritmo genético para maximizar seu desempenho. O estudo utilizou um conjunto de dados de 240 imagens coletadas durante inspeções das redes de distribuição, categorizando componentes em boas condições ou que requeriam manutenção. A técnica *EigenCAM* é integrada para fornecer interpretabilidade visual, destacando as regiões da imagem que influenciam a detecção de falhas. Os resultados dos testes indicam que o modelo Hypertuned-YOLO proposto alcança mAP de 0,922 e F1-score de 0,867.

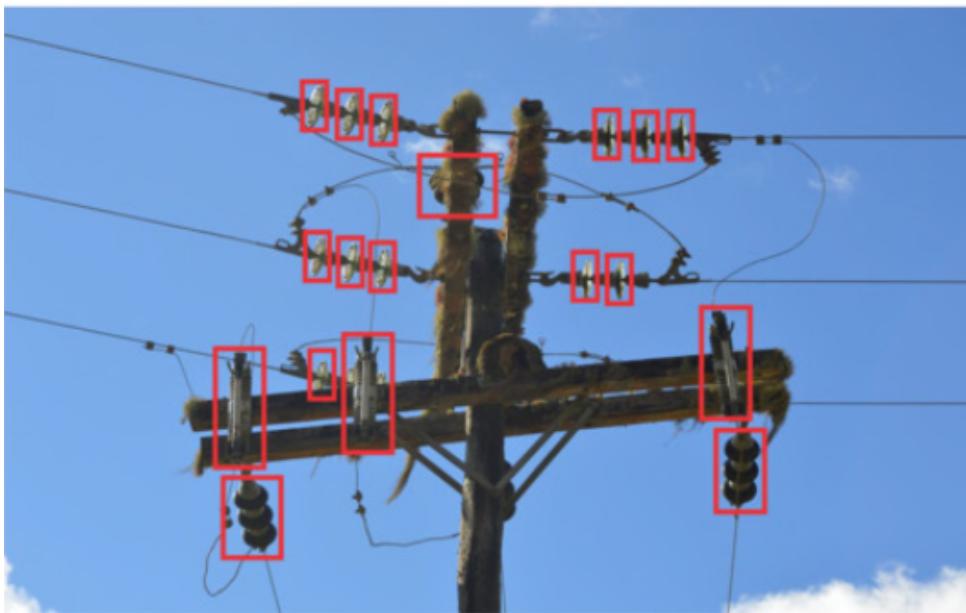


Figura 33 – Detecção de isoladores na rede de distribuição elétrica (STEFENON et al., 2024).

Wang et al. (2025) abordam o desafio de medir o ângulo de inclinação de linhas de energia, uma tarefa crucial para a estabilidade e segurança do sistema elétrico. A Figura 34 ilustra o problema abordado pela pesquisa. Os autores propõem a Line-YOLO, uma

rede de detecção baseada na YOLOv8s-seg. Os autores criaram um conjunto de dados de imagens de conexões de linhas de energia para os experimentos. Os resultados experimentais demonstraram que a Line-YOLO alcançou um mAP de 91,7%, e uma melhoria de 14 FPS na velocidade de detecção em comparação com o modelo base YOLOv8s-seg.

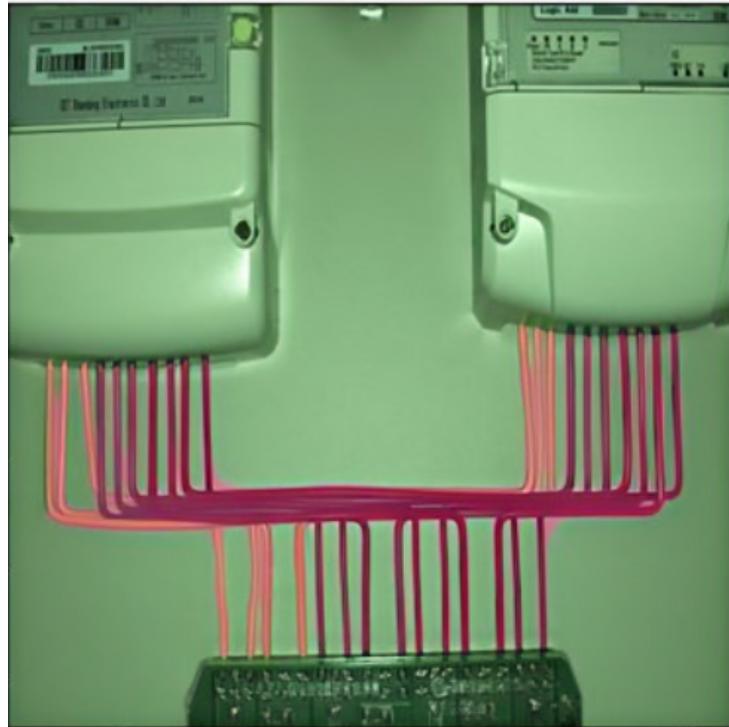


Figura 34 – Problema de medição do ângulo de inclinação de cabos de energia (WANG et al., 2025).

Por fim, Han et al. (2025) propuseram a LMD-YOLO, uma arquitetura baseada na YOLOv8n para detecção de múltiplos defeitos em isoladores de linhas de transmissão. Testado em um conjunto de dados privado contendo quatro categorias de defeitos (isolador normal, ausente, quebrado e com descascamento), a LMD-YOLO demonstrou 87,9% de mAP e redução de 24,6% nos parâmetros em comparação ao YOLOv8n. A Figura 35 ilustra o resultado da pesquisa.

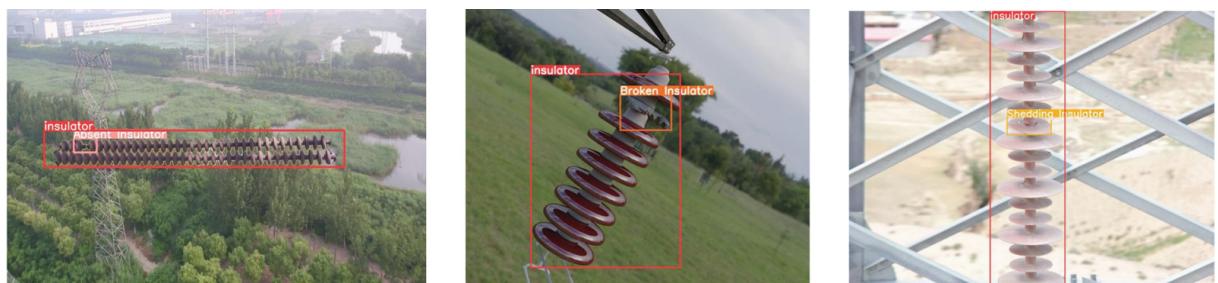


Figura 35 – Defeitos detectados pela pesquisa (HAN et al., 2025).

### 3.1 Análise dos Estudos

Nesta seção, realiza-se uma análise comparativa dos principais estudos relacionados. Inicialmente, são discutidos trabalhos que não adotaram redes neurais como base metodológica, mas que ainda assim utilizaram inteligência artificial para contribuir com o monitoramento das infraestruturas elétricas. Em seguida, são analisados estudos que aplicaram redes neurais para detecção de objetos e anomalias em linhas de transmissão e distribuição de energia elétrica por meio de uma tabela comparativa. Essa análise visa contextualizar os avanços da área e destacar os diferenciais da abordagem adotada nesta pesquisa.

Em relação aos estudos que não abordaram redes neurais específicas, tanto Qayyum et al. (2014) quanto Wilson, Wickramasuriya e Marchiori (2023) compartilham do objetivo geral de mitigar os riscos associados à presença de vegetação próxima a redes elétricas, mas apresentam enfoques, metodologias e aplicações distintas em relação ao presente estudo. O trabalho de Qayyum et al. (2014) propõe o uso de imagens estéreo de satélite para estimar a altura da vegetação ao redor de torres de transmissão. A proposta não contempla uma validação quantitativa nem se concentra na detecção direta de interações entre vegetação e redes elétricas. Por sua vez, Wilson, Wickramasuriya e Marchiori (2023) adota uma abordagem estatística com foco na modelagem de risco de incêndios causados por eventos de vegetação em linhas de transmissão, utilizando dados históricos e variáveis geográficas extraídas de levantamentos aéreos com LiDAR. Ainda que apresente resultados relevantes em análise preditiva, o estudo não explora técnicas de detecção visual. Neste contexto, a presente pesquisa se destaca por empregar uma abordagem baseada em visão computacional, capaz da detecção do contato entre a vegetação e as redes de distribuição elétrica, o que amplia sua aplicabilidade prática no monitoramento e na prevenção de falhas em sistemas elétricos.

Além dos trabalhos discutidos, a Tabela 1 sintetiza estudos que aplicam redes neurais à detecção de objetos e anomalias em linhas de transmissão e distribuição de energia elétrica. São destacados atributos como o ano de publicação, a arquitetura de rede base mais recente utilizada, o uso de VANTs, o foco da aplicação e os tipos de objetos detectados.

Em especial, a coluna Rede Base indica a arquitetura base mais recente adotada em cada pesquisa, servindo como referência para a comparação dos trabalhos e demonstrando a adoção de modelos cada vez mais recentes, precisos e eficientes. Vale destacar que, em todos os estudos analisados, também foram realizadas comparações com outras versões da própria YOLO ou com arquiteturas alternativas, como a *Faster R-CNN* e *Detectron*.

Primeiramente, observa-se uma clara evolução das arquiteturas de redes neurais ao longo do tempo. Os estudos mais antigos, datados de 2020 e 2021, fazem uso da *Faster R-CNN* por Liang, Zuo e Wei (2020), e principalmente da YOLOv3, como visto em Chen e Miao (2020), Costa e Cortes (2021) e Renwei et al. (2021), que representavam, à época, o estado da arte em detecção em tempo real.

A partir de 2022, é possível notar uma transição para versões mais recentes da arquitetura YOLO, começando com a YOLOv5 em Bao et al. (2022), seguido rapidamente pela adoção da YOLOv7 em 2023 em pesquisas como Zhang et al. (2023) e Li et al. (2023).

Em sequência, ainda em 2023, destaca-se o surgimento da YOLOv8, como demonstrado em estudos como Casas et al. (2023), Zhang et al. (2024) e Liu et al. (2024). Ela se consolida como a principal rede para tarefas que demandam alta precisão e eficiência, sendo aplicada tanto na detecção de falhas em isoladores quanto em aplicações mais específicas, como a avaliação do uso de EPI em subestações por Zhang et al. (2024) ou a medição do ângulo de inclinação de cabos de energia por Wang et al. (2025).

Em estudos mais recentes, nota-se a introdução da YOLOv10, como na pesquisa de Li et al. (2024) e no trabalho presente. Esse avanço acompanha a necessidade crescente por modelos mais leves, rápidos e precisos, adequados às aplicações modernas, inclusive em ambientes urbanos mais complexos, como é o foco deste estudo.

Em sequência, é possível observar que a maioria dos trabalhos adota o uso de VANTs como plataforma para aquisição de imagens, destacando a predominância dessa abordagem na área de inspeção automatizada de infraestruturas elétricas, especialmente em estudos focados em linhas de transmissão de alta tensão (LIANG; ZUO; WEI, 2020; CHEN; MIAO, 2020; RENWEI et al., 2021; XIE, 2021; BAO et al., 2022; ZHANG et al., 2023; LI et al., 2023; FAHIM; HASAN, 2024; LIU et al., 2024; LI et al., 2024; HAN et al., 2025). Contudo, esse padrão mostra uma limitação na literatura quanto à exploração de métodos alternativos de aquisição de imagens, especialmente em ambientes urbanos, onde o uso de VANTs enfrenta restrições legais, operacionais e de segurança (ANAC, 2023; DECEA, 2023; PIERALLINI; GRASSETTI; BALLIRANO, 2019). O presente trabalho aborda essa lacuna ao empregar um método de coleta de dados baseado em mapeamento móvel de baixo custo, com câmeras GoPro montadas em cima de veículos terrestres, adequado para áreas urbanizadas.

Adicionalmente, alguns estudos como Chen e Miao (2020) e Costa e Cortes (2021) ainda dependem de imagens obtidas em condições controladas ou simuladas, enquanto a abordagem aqui proposta se destaca por utilizar dados reais. Esta característica reforça a aplicabilidade prática e o diferencial da solução desenvolvida neste estudo.

No que se refere ao foco dos estudos, a expressiva quantidade de estudos recentes dedicados à detecção de defeitos em linhas de transmissão, utilizando a família de algoritmos YOLO, demonstra a relevância deste campo de pesquisa e a ampla adoção dessas técnicas na área (LIANG; ZUO; WEI, 2020; RENWEI et al., 2021; XIE, 2021; BAO et al., 2022; ZHANG et al., 2023; LI et al., 2023; FAHIM; HASAN, 2024; LIU et al., 2024; ZOU et al., 2024; LI et al., 2024; HAN et al., 2025).

No entanto, há uma lacuna significativa de investigações especificamente voltadas para as linhas de distribuição. Apenas alguns estudos abordam esse contexto: Chen e Miao (2020) propõem a detecção e contagem de postes de distribuição com foco na avaliação de

perdas pós-desastre; Costa e Cortes (2021) aplicam a YOLO para identificar componentes e defeitos em linhas de distribuição ao longo de ferrovias; e Stefenon et al. (2024) exploram a detecção de falhas em isoladores em postes de distribuição. Em contraste, o presente trabalho adota uma abordagem voltada para a detecção de contato entre vegetação e linhas de distribuição em ambientes urbanos, uma vertente ainda pouco explorada na literatura.

Em síntese, este trabalho se diferencia das pesquisas correlatas por quatro aspectos principais: a coleta de dados realizada por meio de mapeamento móvel de baixo custo; a utilização de arquiteturas mais recentes, como a YOLOv10 e a RT-DETR; o foco direcionado às linhas de distribuição em ambientes urbanos; e o objetivo específico de detectar vegetação em contato com as estruturas elétricas. Esses elementos conferem ao estudo um caráter inovador, contribuindo para o avanço das soluções de monitoramento e manutenção preventiva no setor elétrico.

Estudo	Ano	Rede Base	Uso de VANT	Foco	Objetos Detectados
(LIANG; ZUO; WEI, 2020)	2020	Faster R-CNN	X	Linhas de Transmissão	10 tipos de objetos
(CHEN; MIAO, 2020)	2020	YOLOv3	X	Pós-desastre, terrenos de difícil acesso	Postes de Distribuição: Eretos ou Caídos
(COSTA; CORTES, 2021)	2021	YOLOv3		Linhas de Distribuição ao longo de ferrovias	Cabos e isoladores
(RENWEI et al., 2021)	2021	YOLOv3	X	Linhas de Transmissão	Torres de Transmissão e isoladores
(XIE, 2021)	2021	Não informada	X	Linhas de Transmissão	Defeitos de superfície
(BAO et al., 2022)	2022	YOLOv5	X	Linhas de Transmissão	Amortecedores de vibração e isoladores
(ZHANG et al., 2023)	2023	YOLOv7	X	Linhas de Transmissão	Isoladores normais, quebrados ou flashover
(LI et al., 2023)	2023	YOLOv7	X	Linhas de Transmissão	Ninhos de pássaros, lixo, pipas e balões
(CASAS et al., 2023)	2023	YOLOv8		Incêndios	Fogo e fumaça
(STEFENON et al., 2024)	2024	YOLOv7		Linhas de Distribuição	Isoladores em boas ou más condições, ninhos de pássaro
(ZHANG et al., 2024)	2024	YOLOv8		Uso de EPI em subestações de energia	Capacetes, botas, luvas isolantes, entre outros EPIs
(FAHIM; HASAN, 2024)	2024	YOLOv8	X	Linhas de Transmissão	Isoladores quebrados ou danificados por flashover
(LIU et al., 2024)	2024	YOLOv8	X	Linhas de Transmissão	Isoladores e objetos estranhos
(ZOU et al., 2024)	2024	YOLOv8		Linhas de Transmissão	Máquinas de construção, como escavadeiras e guindastes
(LI et al., 2024)	2024	YOLOv10	X	Linhas de Transmissão	Isoladores quebrados
(HAN et al., 2025)	2025	YOLOv8	X	Linhas de Transmissão	Isoladores normais, ausentes, quebrados ou descascamento
(WANG et al., 2025)	2025	YOLOv8		Cabos de energia	Medição do ângulo de inclinação de cabos de energia
Este trabalho	2025	YOLOv10		Linhas de Distribuição em ambientes urbanos	Vegetação

Tabela 1 – Comparação dos Trabalhos Correlatos



# CAPÍTULO 4

## Metodologia

Este capítulo descreve a metodologia adotada para o desenvolvimento do sistema de detecção de contatos entre a vegetação e LDE. A metodologia está estruturada em cinco seções principais: Aquisição de Imagens, apresenta o processo de captura dos dados utilizados; Conjunto de Dados, detalha a anotação das imagens coletadas; Pré-processamento, aborda as técnicas para aumento de dados e detecção de bordas; Treinamento do Modelo, descreve as configurações utilizadas nos experimentos; e Avaliação de Desempenho, apresenta as métricas para medir a eficácia dos modelos treinados.

O diagrama da Figura 36 ilustra este processo. Após a aquisição das imagens, é realizada a seleção e rotulagem das mesmas, seguido pelo treinamento dos modelos e avaliação de desempenho. Concluída essa primeira rodada de experimentação, o modelo com melhor desempenho é submetido a um novo treinamento, desta vez explorando duas estratégias adicionais: treinamento com uso exclusivo de imagens processadas pelos métodos de detecção de bordas; e a combinação das imagens originais com as imagens filtradas, as utilizando como técnica de aumento de dados. Por fim, o desempenho resultante dessas novas abordagens é novamente avaliado.

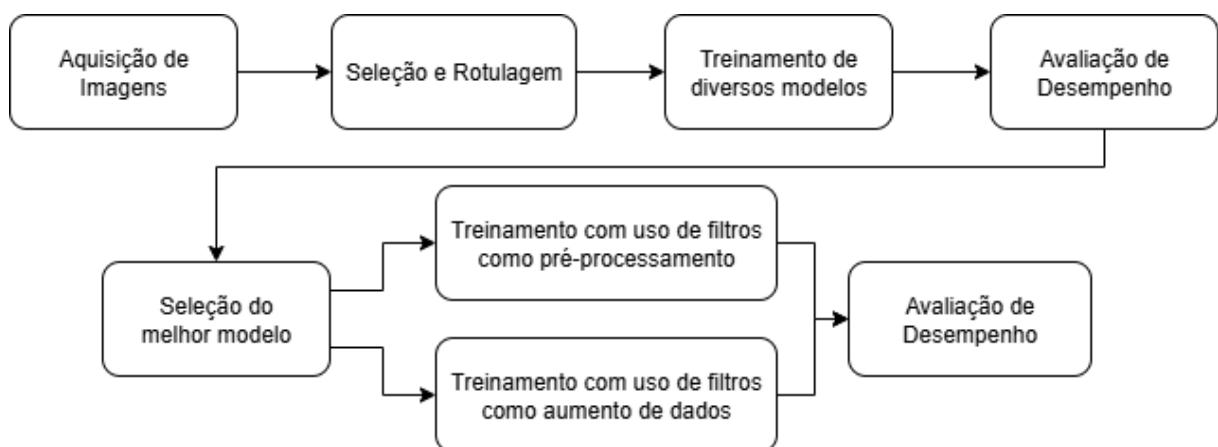


Figura 36 – Diagrama da metodologia proposta Fonte: Elaborado pelo autor.

## 4.1 Aquisição de Imagens

Os dados utilizados neste trabalho consistem em imagens do mundo real, extraídas de vídeos e fotografias, capturadas por um sistema de mapeamento móvel de baixo custo, ilustrado na Figura 37. Esse sistema é composto por múltiplas câmeras GoPro montadas sobre uma plataforma instalada no teto de um veículo, com suporte para até cinco câmeras (três frontais e duas laterais), além de um módulo do sistema global de navegação por satélites e uma unidade inercial (OLIVEIRA et al., 2019; MARQUES et al., 2021). As imagens foram obtidas em áreas urbanas da cidade de São Paulo, Brasil, com ênfase em locais onde a vegetação estava próxima ou em contato direto com a LDE.



Figura 37 – Sistema de mapeamento móvel usado para a aquisição das imagens (MARQUES et al., 2021).

É importante destacar que este estudo se concentra em ambientes urbanos, onde há uma variedade de tipos de vegetação. Dentre essas, a vegetação de maior relevância para a pesquisa são as árvores cujas copas ou galhos podem alcançar as LDEs, apresentando risco de contato. A abordagem proposta é voltada para a manutenção preventiva e, por isso, a aquisição dos dados foi realizada sob condições climáticas favoráveis, como céu limpo ou parcialmente nublado, evitando cenários adversos, como chuva, neblina ou período noturno. Essa escolha está alinhada com o caráter preventivo da pesquisa, buscando identificar e mitigar riscos antes que se transformem em falhas. As imagens foram coletadas durante uma estação do ano, uma vez que o clima tropical do Brasil apresenta variações sazonais sutis. Além disso, a análise é realizada em pós-processamento, sem necessidade de inferência em tempo real, reduzindo custos operacionais ao eliminar a ne-

cessidade de equipar o veículo com sistemas de processamento embarcado. Dessa forma, as empresas de energia elétrica podem analisar os dados posteriormente, com maior flexibilidade e aproveitamento dos recursos disponíveis.

## 4.2 Conjunto de Dados

Após a aquisição dos dados, foi realizado o processo de rotulagem. Esse processo exigiu uma análise visual de cada imagem, na qual regiões específicas foram rotuladas para indicar o contato ou não contato entre a vegetação e as linhas de energia. Essa anotação manual é essencial para o processo de aprendizado da rede neural, pois fornece os dados de verdade fundamental (groundtruth) usados para avaliar as previsões do modelo. Para este estudo, 601 imagens foram selecionadas e rotuladas, e o conjunto de dados foi então dividido aleatoriamente em três subconjuntos: 60% das imagens foram usadas para treinamento, 30% para validação e os 10% restantes foram reservados para teste.

Um exemplo de rotulagem pode ser visto na Figura 38, onde o lado esquerdo ilustra uma árvore sem contato, e o lado direito uma árvore em contato com os cabos de energia elétrica.



Figura 38 – Este é um exemplo de uma imagem rotulada (verdade fundamental), onde o quadrado verde à esquerda mostra uma árvore sem contato com a LDE, e o quadrado laranja à direita exibe uma árvore em contato com ela. Fonte: Elaborado pelo autor.

O conjunto de dados completo, incluindo todas as anotações rotuladas usadas no estudo, pode ser acessado através do seguinte link do GitHub: <<https://github.com/JhonyBn/VegetationDataset>>. Este conjunto contém as imagens e seus rótulos, facilitando a reproduzibilidade e a futura pesquisa por outros pesquisadores.

### 4.3 Pré-processamento

Todas as configurações tradicionais de aumento de dados da YOLO foram aplicadas para aprimorar o conjunto de dados de treinamento e melhorar a generalização do modelo. Isso inclui ajustes de matiz (0,015), saturação (0,7) e brilho (0,4), que simulam diversas condições de iluminação e cor. Transformações espaciais, como rotação (0,5), translação (até 10% do tamanho da imagem) e ajustes de escala (0,5), foram empregadas para diversificar as orientações e posições dos objetos. A inversão horizontal (0,5) e o aumento em mosaico aumentaram a variabilidade das aparências dos objetos e da composição da cena. A eliminação aleatória (0,4) foi usada para enfatizar características menos aparentes. Combinados, esses aumentos introduziram uma variabilidade significativa, permitindo que o modelo detecte e se adapte a objetos em diversos cenários de forma robusta (JOCHER; CHAURASIA; QIU, 2023; SHORTEN; KHOSHGOFTAAR, 2019).

Além disso, foram realizados testes com diversos métodos clássicos de detecção de bordas para enfatizar os cabos e destacar potenciais limites entre vegetação e LDE. Essas técnicas incluem os filtros de Roberts, Prewitt, Sobel, Laplaciano, Diferença Gaussiana (DoG), Laplaciano sobre Gaussiana (LoG) e Canny (SUN et al., 2022; ROUSHDY, 2006; RANA; VERMA, 2014; FAKHRI; SAADATSERESHT, 2019).



Figura 39 – Esta imagem compara alguns dos filtros usados em nossa pesquisa: Base, Canny, Prewitt e Sobel. Fonte: Elaborado pelo autor.

Para ilustrar as diferenças entre os filtros, a Figura 39 mostra quatro casos distintos organizados em uma grade  $2 \times 2$  rotulada Base (nenhum filtro aplicado), Canny, Prewitt e Sobel. Uma seção da imagem original foi cortada cuidadosamente para focar na região de interesse, permitindo uma comparação mais clara das saídas do filtro.

## 4.4 Treinamento do Modelo

Os experimentos foram realizados em um sistema equipado com uma GPU NVIDIA RTX 4070 Super com 12 GB de memória, com sessões limitadas a um máximo de 3.000 épocas ou encerradas antecipadamente caso não fosse observada melhoria por 100 épocas consecutivas. Para otimizar o uso dos recursos disponíveis, o tamanho do lote foi ajustado para utilizar 85% da memória da GPU.

Dessa forma, e com o intuito de assegurar a reproduzibilidade dos experimentos, a seguir são descritos os componentes de hardware do sistema utilizado nos testes:

- ❑ GPU: NVIDIA GeForce RTX 4070 Super ASUS Dual OC O12G EVO
- ❑ Processador: AMD Ryzen 7 5700G 3.8 GHz 8-Core
- ❑ Memória RAM: Corsair VENGEANCE LPX 32 GB (2x16 GB) DDR4-3200
- ❑ Armazenamento: Samsung SSD 970 EVO Plus 1 TB M.2-2280
- ❑ Fonte: EVGA 220-GS-0650-V1 650 W
- ❑ Placa-mãe: Asus TUF GAMING B550M-PLUS (WI-FI) Micro ATX AM4

Na sequência, a Tabela 2 apresenta as versões dos principais softwares e bibliotecas utilizadas no desenvolvimento e treinamento dos modelos:

Pacote	Versão
Python	3.10.4
labelImg	1.8.6
numpy	1.26.4
opencv_python	4.10.0.84
matplotlib	3.8.4
pandas	1.4.3
torch	2.4.1+cu124
torchvision	0.19.1+cu124
ultralytics	8.2.92
albumentations	1.4.16

Tabela 2 – Versão das dependências utilizadas no ambiente de desenvolvimento.

Por fim, são listados os parâmetros empregados no processo de treinamento na Tabela 3, abrangendo tanto as configurações gerais, como número de épocas, taxa de aprendizado

e tamanho de lote, quanto ajustes específicos para otimização e aumento de dados. Para os modelos RT-DETR, onde não foi possível calcular o tamanho do lote otimizado para a capacidade da GPU, foram utilizados 9 para a RT-DETR-L e 6 para a RT-DETR-X.

Parâmetro	Valor
epochs	3000
patience	100
batch	0.85
imgsz	640
workers	8
pretrained	true
optimizer	auto
seed	0
iou	0.7
lr0	0.01
lrf	0.01
momentum	0.937
weight_decay	0.0005
warmup_epochs	3.0
warmup_momentum	0.8
warmup_bias_lr	0.1
box	7.5
cls	0.5
dfl	1.5
nbs	64
hsv_h	0.015
hsv_s	0.7
hsv_v	0.4
degrees	0.0
translate	0.1
scale	0.5
fliplr	0.5
mosaic	1.0
auto_augment	randaugment
erasing	0.4

Tabela 3 – Parâmetros de Treinamento

## 4.5 Avaliação de Desempenho

Os modelos foram avaliados por meio da função de validação (.val), que mede o desempenho dos modelos treinados sobre o conjunto de validação. As métricas consideradas (precisão, recall, F1-score e mAP), que são utilizadas para identificar a abordagem mais eficaz na detecção de contatos entre a vegetação e as LDEs, são apresentadas a seguir (PADILLA; NETTO; SILVA, 2020; CHEN; MIAO, 2020; CASAS et al., 2023):

**Precisão:** Mede a proporção de vegetação identificada corretamente entre todos os objetos previstos, calculada como:

$$\text{Precisão} = \frac{\text{Verdadeiros Positivos}}{\text{Verdadeiros Positivos} + \text{Falsos Positivos}}$$

**Recall:** Mede a proporção de vegetação prevista corretamente entre todas as vegetações reais. Um valor alto de recall indica uma baixa taxa de falsos negativos, e pode ser calculado da seguinte forma:

$$\text{Recall} = \frac{\text{Verdadeiros Positivos}}{\text{Verdadeiros Positivos} + \text{Falsos Negativos}}$$

**F1-score:** A média harmônica de Precisão e Recall, fornecendo uma única métrica que equilibra ambas, sendo a principal métrica usada nas comparações do estudo. Ela é calculada da seguinte forma:

$$\text{F1-score} = 2 \times \frac{\text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}}$$

**Mean Average Precision (mAP):** Reflete a precisão do modelo considerando um limiar de 0,5 para a sobreposição (IoU) entre as caixas delimitadoras previstas e as de verdade fundamental (groundtruth). O mAP calcula a média dos valores de precisões médias (AP) obtidas para cada classe, onde cada AP representa a área sob a curva Precisão-Recall para uma classe considerando apenas as previsões com  $\text{IoU} \geq 0,5$ . Sua fórmula é dada por:

$$\text{mAP} = \frac{1}{N} \sum_{i=1}^N \left( \int_0^1 \text{Precisão}_i(r) dr \right)$$

onde  $N$  é o número total de classes, e  $\text{Precisão}_i(r)$  é a curva de precisão em função do recall  $r$  para a classe  $i$ .



# CAPÍTULO 5

---

## Resultados Experimentais

Este capítulo apresenta os resultados obtidos ao longo da pesquisa. Inicialmente, são descritos os experimentos realizados com as redes da família YOLOv8, seguidos pelos testes com as versões recentes, YOLOv9 e YOLOv10, com uma comparação entre essas versões. Posteriormente, investigamos o impacto do uso de técnicas de aumento de dados e filtros de detecção de borda na qualidade das detecções. Na sequência, são apresentados experimentos com outra arquitetura, a RT-DETR, possibilitando uma avaliação comparativa mais ampla. Por fim, discutimos os resultados alcançados, bem como os desafios identificados.

### 5.1 YOLOv8

A seção a seguir apresenta os resultados obtidos com os modelos da família YOLOv8, explorando suas diferentes configurações (YOLOv8n, YOLOv8m e YOLOv8x) para avaliação de desempenho no conjunto de dados. Serão detalhadas as características arquiteturais e o impacto dessas variações na acurácia e eficiência dos modelos.

O modelo YOLOv8n foi selecionado para o primeiro experimento devido à sua natureza leve, permitindo tempos de treinamento e inferência menores. Este modelo mostrou uma precisão de 90,30%, recall de 87,24% e uma pontuação F1 de 88,74% para os dados de validação. O modelo atingiu um mAP de 92,32%, dando ao conjunto de dados uma base sólida para comparação.

O gráfico na Figura 40 ilustra a progressão das métricas de desempenho do modelo ao longo do processo de treinamento, mostrando a estabilidade e a convergência dos resultados. Observa-se uma tendência de melhora consistente nos valores de precisão, recall, F1-score e mAP até a estabilização, indicando que o modelo foi capaz de aprender as características do conjunto de dados.

A Tabela 4 apresenta as principais características arquiteturais dos modelos YOLOv8 utilizados nos experimentos, destacando o número de camadas, a quantidade de parâmetros treináveis e a complexidade computacional medida em GFLOPs (*Giga Floating*

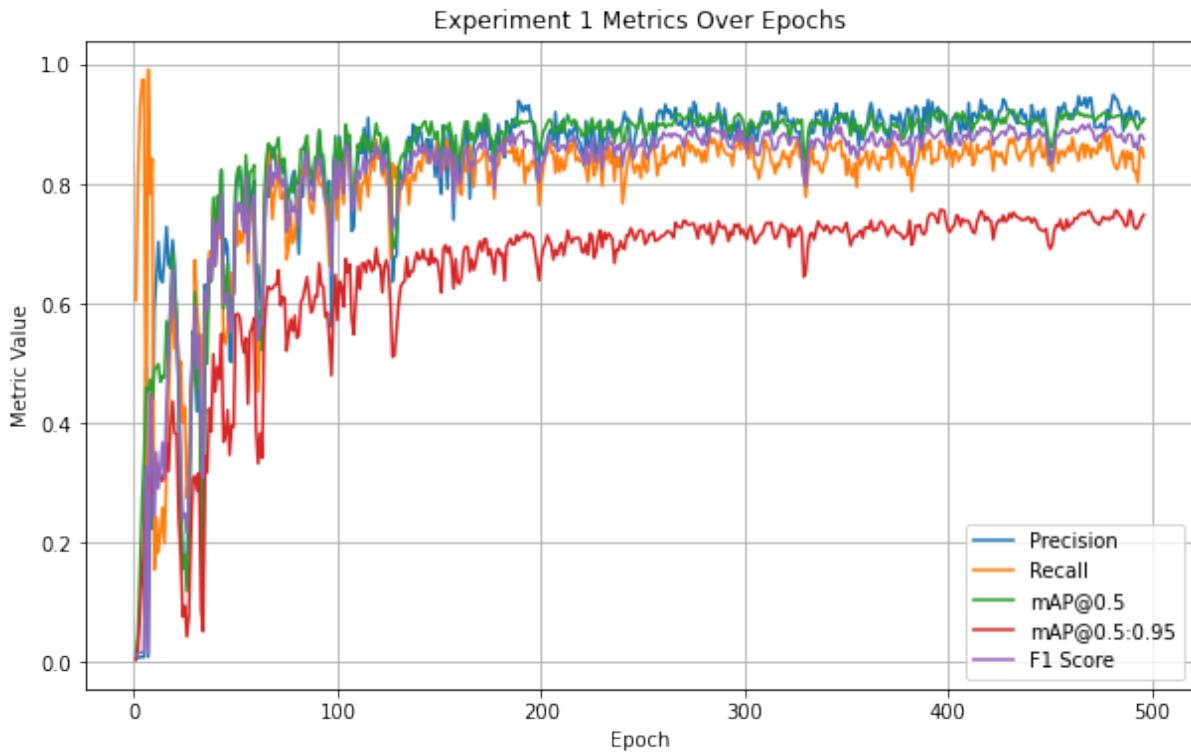


Figura 40 – Métricas de avaliação da YOLOv8n pelas épocas de treinamento. Fonte: Elaborado pelo autor.

*Point Operations*). Esses dados ajudam a contextualizar a escolha do modelo YOLOv8n, cuja estrutura (com apenas 168 camadas e cerca de 3 milhões de parâmetros) oferece um bom equilíbrio entre desempenho e eficiência computacional. Em contrapartida, modelos mais robustos como o YOLOv8m e o YOLOv8x apresentam uma maior complexidade, o que pode resultar em maior capacidade de aprendizado, porém com custos mais elevados de processamento e tempo de inferência, tornando-os menos viáveis para aplicações em tempo real ou com recursos computacionais limitados.

Modelo	Camadas	Parâmetros	GFLOPs
YOLOv8n	168	3.006.038	8,1
YOLOv8m	218	25.840.918	78,7
YOLOv8x	268	68.125.494	257,4

Tabela 4 – Características arquiteturais dos modelos YOLOv8 utilizados nos experimentos, incluindo camadas, parâmetros e GFLOPs.

A Tabela 5 apresenta os resultados obtidos com os modelos YOLOv8n, YOLOv8m e YOLOv8x, destacando o desempenho de cada modelo em termos de precisão, recall, F1-score, mAP e tempo de inferência. Os modelos YOLOv8n e YOLOv8x obtiveram a mesma pontuação F1 de 0,887, indicando desempenho semelhante em termos de detecção eficaz, apesar das diferenças em tamanho e complexidade. O modelo YOLOv8m apresentou

uma pontuação F1 inferior (0,877), sugerindo que o aumento de parâmetros em relação ao YOLOv8n não resultou em uma melhoria proporcional no desempenho neste caso. Considerando o tempo de inferência, a YOLOv8n se destaca por oferecer uma excelente relação entre desempenho e eficiência computacional.

Modelo	Precisão	Recall	F1	mAP	Tempo de Inferência (ms)
YOLOv8n	0,903	0,872	0,887	0,923	2,4
YOLOv8m	0,899	0,856	0,877	0,92	5,4
YOLOv8x	0,939	0,84	0,887	0,922	9,9

Tabela 5 – Desempenho dos modelos YOLOv8 nos experimentos, em dados de validação, em termos de precisão, recall, F1-score, mAP e tempo médio de inferência por imagem, em milissegundos.

## 5.2 YOLOv9

Nesta seção, são apresentados os resultados obtidos com os modelos da família YOLOv9, abrangendo as variantes YOLOv9t, YOLOv9m e YOLOv9e.

A Tabela 6 resume as características desses modelos, incluindo o número de camadas, a quantidade de parâmetros e o custo computacional em GFLOPs. Observa-se que a YOLOv9t é a versão leve, com 486 camadas, aproximadamente 2 milhões de parâmetros e 7,6 GFLOPs. Já a YOLOv9m apresenta uma configuração intermediária, com 374 camadas, 20 milhões de parâmetros e 76,5 GFLOPs. YOLOv9e representa o modelo robusto, com 687 camadas, mais de 57 milhões de parâmetros e 189,1 GFLOPs, sendo o mais custoso em termos computacionais entre os avaliados. Destaca-se que esta versão da YOLO apresenta o maior número de camadas entre as comparadas, mesmo com redução do número de parâmetros e GFLOPs em comparação à YOLOv8.

Modelo	Camadas	Parâmetros	GFLOPs
YOLOv9t	486	1.971.174	7,6
YOLOv9m	374	20.014.438	76,5
YOLOv9e	687	57.377.942	189,1

Tabela 6 – Características arquiteturais dos modelos YOLOv9 utilizados nos experimentos, incluindo camadas, parâmetros e GFLOPs.

A Tabela 7 apresenta o desempenho dos modelos da família YOLOv9, considerando as métricas essenciais para avaliação. Na comparação entre esses modelos, a YOLOv9m obteve o melhor desempenho em termos de F1-score, com valor de 0,891, ligeiramente superior ao YOLOv9t (0,889) e ao YOLOv9e (0,882). Observa-se que a YOLOv9e, sendo o modelo mais complexo e custoso da família YOLOv9, apresentou o maior tempo de

inferência (12,8 ms). A YOLOv9t destacou-se por apresentar o menor tempo de inferência (3,8 ms) e um desempenho competitivo em F1, sendo uma boa opção em cenários com restrições de processamento.

Modelo	Precisão	Recall	F1	mAP	Tempo de Inferência (ms)
YOLOv9t	0,92	0,86	0,889	0,927	3,8
YOLOv9m	0,917	0,865	0,891	0,925	5,8
YOLOv9e	0,896	0,869	0,882	0,933	12,8

Tabela 7 – Desempenho dos modelos YOLOv9 nos experimentos, em dados de validação, em termos de precisão, recall, F1-score, mAP e tempo médio de inferência por imagem, em milissegundos.

Em comparação com a família YOLOv8, os modelos YOLOv9 apresentaram F1-scores superiores, como no caso da YOLOv9t (0,889) frente a YOLOv8n (0,887) e da YOLOv9m (0,891) em relação a YOLOv8m (0,877). Isso demonstra uma superioridade da versão YOLOv9 em termos de equilíbrio entre desempenho e custo computacional, reforçando sua adequação para aplicações que exigem boa acurácia sem comprometer a eficiência. Contudo, essa melhoria vem acompanhada de tempos de inferência maiores, especialmente no modelo YOLOv9e, que é o mais complexo e custoso em termos computacionais, resultando em um tempo de inferência de 12,8 ms, superior ao da YOLOv8x (9,9 ms).

### 5.3 YOLOv10

A seção a seguir apresenta os resultados obtidos com os modelos da família YOLOv10, especificamente as versões YOLOv10n, YOLOv10m e YOLOv10x. Serão detalhadas as características arquiteturais e o impacto dessas variações no desempenho dos modelos.

A Tabela 8 apresenta características arquiteturais dos modelos YOLOv10 utilizados nos experimentos. Observa-se que o modelo mais simples, YOLOv10n, possui 285 camadas, aproximadamente 2,7 milhões de parâmetros e demanda 8,2 GFLOPs, o que indica um modelo mais leve e eficiente para inferência rápida, em comparação aos demais. Já a YOLOv10m apresenta um aumento na complexidade, com 369 camadas, 16,5 milhões de parâmetros e 63,4 GFLOPs, oferecendo um equilíbrio entre desempenho e custo computacional. Por fim, o modelo mais robusto, YOLOv10x, possui 503 camadas, 31,6 milhões de parâmetros e 169,8 GFLOPs, refletindo uma arquitetura profunda, destinada a obter maior precisão, porém com maior custo computacional.

A Tabela 9 apresenta o desempenho dos modelos YOLOv10, destacando as métricas de precisão, recall, F1-score, mAP e o tempo médio de inferência. Observa-se que o modelo intermediário, YOLOv10m, alcançou a melhor pontuação em F1 (0,897), indicando o melhor equilíbrio entre precisão e recall entre as variantes testadas. YOLOv10n

Modelo	Camadas	Parâmetros	GFLOPs
YOLOv10n	285	2.695.196	8,2
YOLOv10m	369	16.452.700	63,4
YOLOv10x	503	31.587.932	169,8

Tabela 8 – Características arquiteturais dos modelos YOLOv10 utilizados nos experimentos, incluindo camadas, parâmetros e GFLOPs.

apresentou desempenho próximo, com F1 de 0,881 e o menor tempo de inferência (3,3 ms), o que o torna adequado para aplicações que priorizam rapidez. Já o modelo mais complexo, YOLOv10x, apesar de ter uma precisão mais baixa (0,866), manteve um recall elevado (0,860), resultando em F1 de 0,863, porém com o maior tempo de inferência (9,8 ms). Esses resultados indicam que o modelo YOLOv10m oferece o melhor resultado entre desempenho e custo computacional da YOLOv10.

Modelo	Precisão	Recall	F1	mAP	Tempo de Inferência (ms)
YOLOv10n	0,91	0,855	0,881	0,916	3,3
YOLOv10m	0,934	0,862	0,897	0,927	6,7
YOLOv10x	0,866	0,86	0,863	0,918	9,8

Tabela 9 – Desempenho dos modelos YOLOv10 nos experimentos, em dados de validação, em termos de precisão, recall, F1-score, mAP e tempo médio de inferência por imagem, em milissegundos.

Ao comparar os modelos da família YOLOv10 com suas versões anteriores (YOLOv8 e YOLOv9), observa-se que o modelo YOLOv10m apresentou o melhor desempenho em F1-score (0,897) entre todas as versões intermediárias, superando tanto a YOLOv8m (0,877) quanto a YOLOv9m (0,891). O YOLOv10n, embora tenha uma leve queda no F1 (0,881) em relação a YOLOv9t (0,889) e YOLOv8n (0,887), mantém um bom equilíbrio entre desempenho e tempo de inferência (3,3 ms). Por outro lado, o modelo mais pesado, YOLOv10x, obteve o menor F1 (0,863), ficando abaixo da YOLOv8x e YOLOv9e. Assim, os resultados sugerem que a versão intermediária da YOLOv10, a YOLOv10m, representa atualmente o melhor custo-benefício entre precisão e eficiência computacional.

## 5.4 RT-DETR

Com o objetivo de ampliar a análise comparativa deste estudo, decidimos incluir redes de detecção fora da família YOLO, considerando modelos com arquiteturas distintas, como as baseadas em transformadores. As redes *Real-Time Detection Transformer* (RT-DETR) utilizam mecanismos de atenção típicos de transformadores, em contraste com a abordagem convolucional dos modelos YOLO. Essa diferença estrutural permite que a

RT-DETR entenda relações entre objetos mesmo em regiões distantes da imagem, mas com maior custo computacional. A seguir, apresentamos os modelos RT-DETR utilizados nos experimentos e suas características arquiteturais.

A Tabela 10 resume as características arquiteturais dos modelos RT-DETR-L e RT-DETR-X empregados nos experimentos. O modelo RT-DETR-L possui 502 camadas, com aproximadamente 32 milhões de parâmetros e 103,4 GFLOPs, enquanto o RT-DETR-X é uma versão mais robusta, com 646 camadas, mais de 65 milhões de parâmetros e 222,5 GFLOPs. Ambos os modelos apresentam uma arquitetura mais profunda e com maior custo computacional do que a maioria dos modelos da série YOLO, sendo comparáveis aos modelos mais pesados (YOLOv8x, YOLOv9e, YOLOv10x).

Modelo	Camadas	Parâmetros	GFLOPs
RT-DETR-L	502	31.987.850	103,4
RT-DETR-X	646	65.471.546	222,5

Tabela 10 – Características arquiteturais dos modelos RT-DETR utilizados nos experimentos, incluindo camadas, parâmetros e GFLOPs.

A Tabela 11 apresenta os resultados dos modelos RT-DETR nos experimentos. O modelo RT-DETR-X obteve o melhor F1-score entre os dois, com 0,889, além da maior precisão (0,91), embora com o maior tempo médio de inferência (18,3 ms), refletindo sua complexidade. Já o modelo menor RT-DETR-L, com F1-score de 0,876, apresentou desempenho competitivo, mas inferior ao RT-DETR-X. Comparando com os modelos da família YOLOv10, observa-se que a YOLOv10m superou ambos os RT-DETR em F1-score (0,897) com um tempo de inferência menor (6,7 ms), demonstrando a evolução dos modelos YOLO nas versões mais recentes.

Modelo	Precisão	Recall	F1	mAP	Tempo de Inferência (ms)
RT-DETR-L	0,886	0,868	0,876	0,897	12,4
RT-DETR-X	0,91	0,87	0,889	0,887	18,3

Tabela 11 – Desempenho dos modelos RT-DETR nos experimentos, em dados de validação, em termos de precisão, recall, F1-score, mAP e tempo médio de inferência por imagem, em milissegundos.

## 5.5 Uso de Filtros

Esta seção apresenta os resultados experimentais sobre o uso de técnicas de detecção de bordas, inicialmente como aumento de dados e, em seguida, de forma isolada como pré-processamento, visando avaliar seu impacto no desempenho do modelo YOLOv10m.

Primeiramente, foi realizado um estudo para entender a importância do aumento de dados no processo de treinamento. Ao remover todas as técnicas tradicionais de aumento, a precisão caiu para 0,870, o recall para 0,759, a pontuação F1 para 0,811 e o mAP para 0,861. Em contraste, com o uso de aumentos convencionais, os valores atingiram 0,934 de precisão, 0,862 de recall, F1 de 0,897 e mAP de 0,927. Esses resultados reforçam o papel fundamental do aumento de dados na capacidade do modelo de generalizar e identificar corretamente o contato entre vegetação e LDE em diferentes cenários urbanos.

Para expandir esse estudo, sete filtros de detecção de bordas (Roberts, Prewitt, Sobel, Laplace, DoG, LoG e Canny) foram inicialmente utilizados como técnica de aumento, combinando imagens filtradas ao conjunto de dados original. No entanto, os resultados apresentados na Tabela 12 indicam que essas adições não melhoraram o desempenho do modelo base, treinado apenas com as imagens originais.

Estratégia	Precisão	Recall	F1	mAP
<b>Base</b>	0.934	0.862	<b>0.897</b>	0.927
Base + Roberts	0.930	0.816	0.869	0.917
Base + Prewitt	0.916	0.866	0.890	0.929
Base + Sobel	0.910	0.843	0.875	0.911
Base + Laplace	0.909	0.852	0.879	0.920
Base + DoG	0.926	0.844	0.883	0.923
Base + LoG	0.928	0.815	0.867	0.907
Base + Canny	0.915	0.838	0.875	0.920

Tabela 12 – Desempenho do modelo YOLOv10m treinado com diferentes estratégias de detecção de bordas usadas para aumento de dados.

Em seguida, os filtros foram aplicados como pré-processamento direto das imagens de entrada, realizando o treinamento apenas com imagens filtradas. Como mostra a Tabela 13, todas as abordagens com filtros apresentaram desempenho inferior ao modelo treinado com os dados originais.

Estratégia	Precisão	Recall	F1	mAP
<b>Base</b>	0.934	0.862	<b>0.897</b>	0.927
Roberts	0.925	0.803	0.860	0.907
Prewitt	0.932	0.810	0.867	0.901
Sobel	0.890	0.845	0.867	0.906
Laplace	0.927	0.785	0.850	0.883
DoG	0.864	0.859	0.862	0.910
LoG	0.913	0.837	0.873	0.904
Canny	0.881	0.819	0.849	0.886

Tabela 13 – Desempenho do modelo YOLOv10m treinado com diferentes estratégias de detecção de bordas como pré-processamento das imagens.

Esses resultados indicam que os filtros de detecção de bordas, embora úteis em outros contextos, não trouxeram benefícios para esta tarefa específica. Uma possível explicação

para a redução no desempenho ao usar essas técnicas é que a conversão das imagens para tons de cinza ou binarizadas eliminou informações de cor e textura relevantes, fundamentais para distinguir entre vegetação, LDE e o entorno. Em vez de facilitar a extração de características, esses métodos podem ter introduzido ruído ou omitido detalhes cruciais, prejudicando a aprendizagem. Assim, treinar o modelo diretamente com as imagens originais, sem a aplicação de filtros, demonstrou ser a estratégia mais eficaz neste cenário.

## 5.6 Resultados e Desafios

Esta seção apresenta exemplos visuais dos resultados obtidos pelo melhor modelo, YOLOv10m, destacando os acertos e os desafios. Nesse sentido, as Figuras 41 e 42 ilustram os resultados da detecção para identificar vegetação em contato ou não com as linhas de distribuição.

Nas imagens, as marcações amarelas indicam as previsões do modelo para vegetação em contato com a LDE. De forma semelhante, as marcações azuis representam as caixas delimitadoras previstas para casos sem contato, conforme detectadas pela rede.

O modelo apresenta ótimos resultados quando toda a vegetação e os cabos são visíveis na imagem, independentemente da quantidade de folhagem presente. Como ilustrado na Figura 41, o modelo demonstra bom desempenho ao lidar com cenários complexos, como vários objetos na mesma imagem e oclusões envolvendo as LDEs. Além disso, ele detecta com eficácia árvores mortas com folhagem mínima, demonstrando sua robustez em condições de vegetação variadas.

Embora o modelo apresente desempenho sólido na maioria dos cenários, algumas situações ainda representam desafios, como ilustrado na Figura 42. Partes da vegetação localizadas nas bordas das imagens, especialmente aquelas com pouca interação com a LDE, são ignoradas pela rede. Outro caso envolve árvores podadas que voltaram a crescer, dificultando a detecção precisa. Apesar dessas limitações pontuais, o desempenho geral do modelo permanece robusto, especialmente em ambientes urbanos onde o contato da vegetação com a LDE é uma preocupação. A análise desses casos de falha ressalta oportunidades para refinamento futuro, a fim de aprimorar o desempenho e a confiabilidade da rede.

Por fim, para ilustrar o desempenho do modelo, foi produzido um vídeo com exemplos de detecção da vegetação em contato (ou não) com as linhas de distribuição. O vídeo pode ser acessado através do seguinte link do YouTube: <<https://youtube.com/shorts/avxQhgJvEM>>

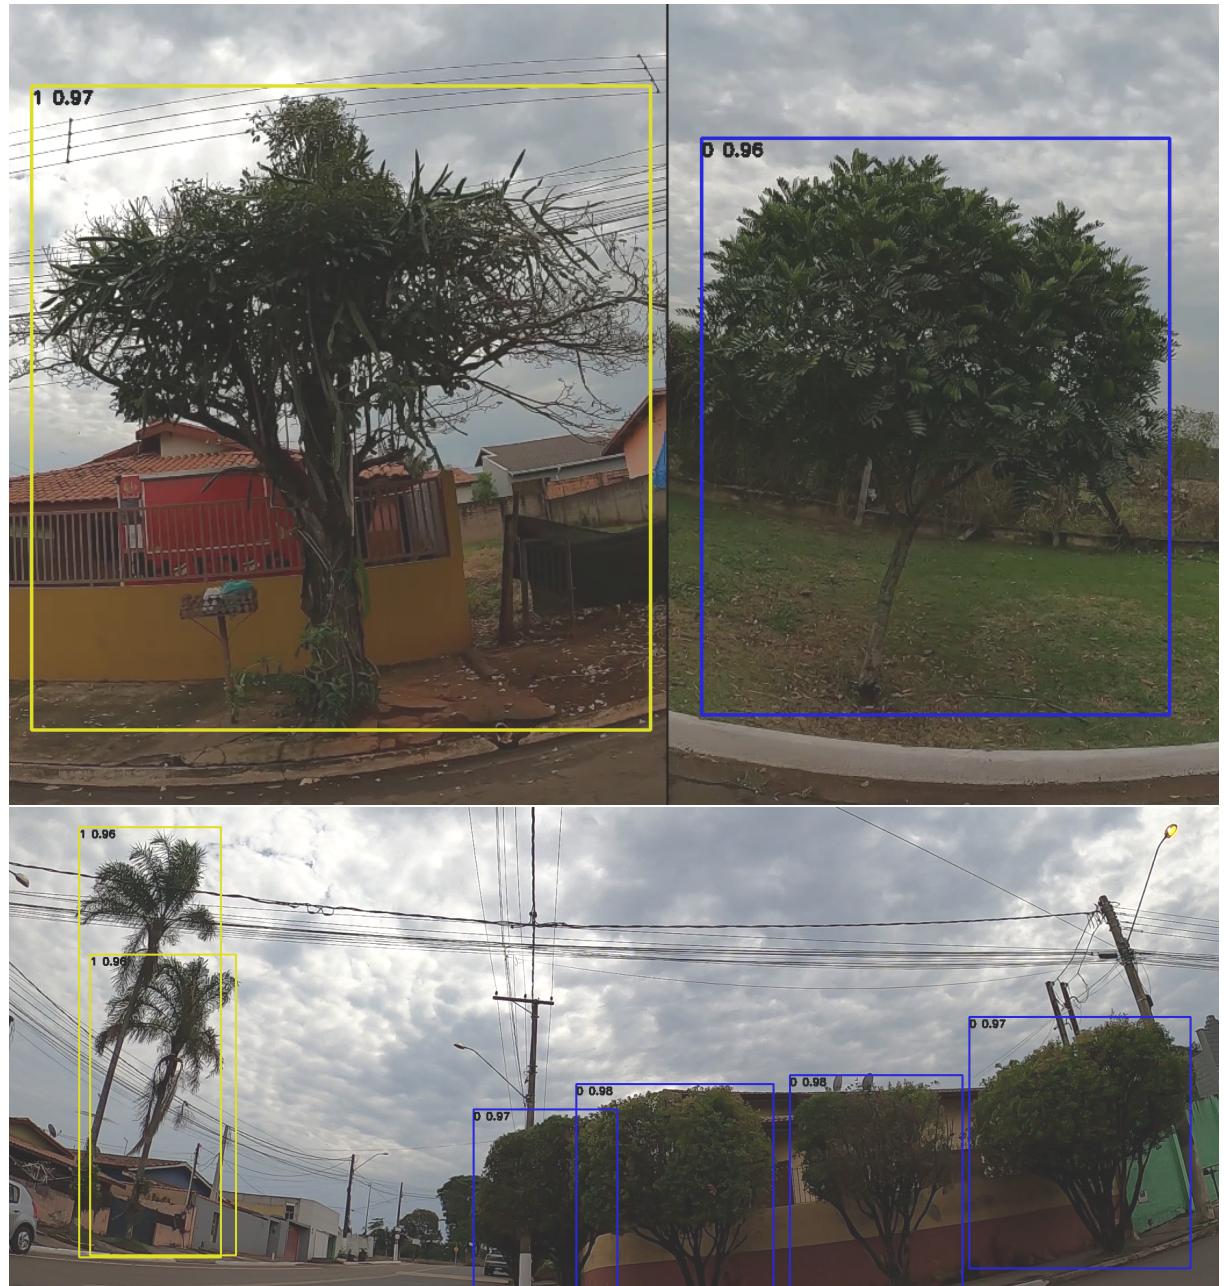


Figura 41 – Resultados da previsão da YOLOv10m, caixas amarelas correspondentes ao contato com LDE e caixas azuis correspondentes à ausência de contato.  
Fonte: Elaborado pelo autor.



Figura 42 – Desafios de previsão do modelo: vegetação no final do quadro da imagem e árvores podadas que voltaram a crescer. Fonte: Elaborado pelo autor.

# CAPÍTULO 6

---

## Conclusão

Este trabalho investigou o uso de redes neurais profundas para detectar o contato entre vegetação e linhas de distribuição de energia (LDE) em ambientes urbanos. O estudo destaca o uso de imagens de câmeras GoPro em um sistema de mapeamento móvel terrestre de baixo custo, em contraste com abordagens com VANTs. Foram avaliadas diversas variantes da arquitetura YOLO, bem como o modelo RT-DETR, com o objetivo de desenvolver um sistema eficiente para auxiliar na prevenção de falhas na rede elétrica.

Com base nesses experimentos, uma contribuição deste trabalho é a comparação abrangente de nove variantes do modelo YOLO e duas do modelo RT-DETR, o que permitiu uma avaliação para identificar a arquitetura mais adequada ao problema proposto. Os resultados demonstram o alto desempenho da arquitetura YOLOv10m, que obteve o melhor F1-score (0,897) entre todas as versões testadas, superando suas antecessoras YOLOv8, YOLOv9 e a RT-DETR em termos de equilíbrio entre precisão, recall e tempo de inferência. Também foi demonstrado que modelos menores, como o YOLOv8n, YOLOv9t e YOLOv10n, mantêm desempenho competitivo com tempos de inferência reduzidos, o que os torna melhores para aplicações em tempo real.

Além disso, o impacto de sete técnicas de detecção de bordas foi investigado, incluindo os filtros de Roberts, Sobel, Prewitt, Laplace, DoG, LoG e Canny. Essas abordagens foram testadas tanto como técnicas de aumento de dados, combinando as imagens filtradas ao conjunto original, quanto como pré-processamento direto das imagens de entrada. Embora esses métodos sejam frequentemente usados para aprimorar a extração de características, os resultados indicam que eles não melhoraram o desempenho da detecção neste contexto.

Ademais, esta pesquisa oferece o conjunto de dados utilizado nos experimentos, com suas anotações, disponíveis para acesso público. Ao compartilhar este conjunto de dados, pretendemos apoiar pesquisas futuras na detecção do contato da vegetação com o LDE e fornecer um recurso valioso para outros estudos.

Por fim, o modelo treinado representa uma solução promissora para aumentar a eficiência e segurança da manutenção de LDEs. A capacidade de identificar o contato com a vegetação através de redes neurais, antes que isso leve a cortes de energia, responde a

uma demanda crítica por sistemas de detecção preventiva automatizada. Isso é essencial para evitar interrupções no fornecimento de energia, reduzir os custos de manutenção e garantir a confiabilidade da infraestrutura elétrica em ambientes urbanos.

## 6.1 Hipóteses Investigadas

A seguir, cada uma das hipóteses é discutida com base nos resultados:

1. **Imagens obtidas com mapeamento móvel são adequadas para a detecção de contato da vegetação com linhas de distribuição de energia.** As imagens de câmeras acopladas a veículos terrestres se mostraram eficazes para a identificação do contato da vegetação com cabos elétricos, possibilitando a anotação dos pontos de interesse e o treinamento dos modelos com desempenho satisfatório. A abordagem se destaca por seu baixo custo e escalabilidade em contextos urbanos.
2. **Arquiteturas modernas de detecção são eficazes na identificação de contato entre vegetação e LDEs.** Todas as versões das arquiteturas YOLO e RT-DETR foram capazes de detectar o contato da vegetação com LDEs, com destaque para YOLOv10m, que alcançou o melhor desempenho, com F1-score de 89,7% e mAP de 92,7%.
3. **O uso de técnicas de detecção de bordas melhora a precisão da detecção de contato da vegetação com LDEs.** Diversos métodos clássicos de re-alce de bordas, como os filtros Roberts, Sobel, Prewitt, Laplaciano, DoG, LoG e Canny, foram avaliados tanto como formas de aumento de dados quanto como pré-processamento. Contudo, os resultados demonstraram que essas técnicas não contribuíram para uma melhoria significativa dos indicadores. O modelo treinado com imagens originais, sem filtragem, apresentou os melhores resultados.
4. **Versões mais recentes do modelo YOLO apresentam desempenho superior na detecção de contato da vegetação com LDEs em comparação com versões mais antigas.** Os resultados confirmam a hipótese, demonstrando que versões mais recentes do YOLO (em particular a YOLOv10m) apresentam desempenho superior na detecção de contato entre vegetação e LDEs. A YOLOv10m alcançou o maior F1-score (0.897) entre todos os modelos testados, incluindo versões anteriores (YOLOv8/v9) e alternativas contemporâneas (RT-DETR), mantendo ainda um tempo de inferência competitivo (6.7 ms).
5. **Modelos menores da YOLO podem fornecer resultados satisfatórios na detecção de contato da vegetação com LDEs, utilizando menos poder computacional.** Os resultados confirmam a hipótese, destacando que os melhores desempenhos foram obtidos por redes de complexidade intermediária, como a

YOLOv10m e a YOLOv9m. Além disso, os modelos mais compactos (YOLOv8n, YOLOv9t e YOLOv10n) também apresentaram desempenho satisfatório, com F1-score acima de 80% e mAP acima de 90%, com tempos de inferência ainda menores.

## 6.2 Principais Contribuições

As principais contribuições desta pesquisa incluem:

- ❑ O desenvolvimento de um sistema baseado em redes neurais profundas para detecção de vegetação em contato com LDE, utilizando imagens obtidas por um veículo terrestre de mapeamento móvel de baixo custo.
- ❑ A avaliação de nove variantes da arquitetura YOLO, bem como duas do modelo RT-DETR, para o problema proposto. Entre esses, a arquitetura YOLOv10m apresentou o melhor desempenho, com F1-score de 89,7% e mAP de 92,7%.
- ❑ A análise do impacto de sete técnicas de pré-processamento baseadas em filtros de detecção de bordas (Roberts, Sobel, Prewitt, Laplace, DoG, LoG e Canny). Os resultados indicaram que os filtros não contribuíram para o aumento da performance dos modelos, sendo o treinamento com imagens brutas a melhor abordagem.
- ❑ A disponibilização pública de um conjunto de dados rotulado em áreas urbanas reais.

## 6.3 Trabalhos Futuros

Os resultados obtidos neste trabalho demonstraram o bom desempenho da abordagem proposta e incentivam novas investigações para aprofundar e expandir sua aplicabilidade. Algumas possíveis direções para trabalhos futuros são listadas a seguir:

- ❑ **Expansão do conjunto de dados:** Incluir uma maior diversidade de cenários urbanos, novas regiões geográficas, variações sazonais e situações extremas, a fim de melhorar a capacidade de generalização do modelo.
- ❑ **Estudo de mais técnicas de pré-processamento:** Investigar outros métodos de pré-processamento de imagens, incluindo novas técnicas de detecção de bordas, para avaliar seu impacto na melhoria da detecção.
- ❑ **Refinamento do modelo:** Realizar ajustes finos na arquitetura e nos hiperparâmetros para maximizar o desempenho.

- **Comparação com outras arquiteturas:** Avaliar o desempenho da abordagem proposta em relação a outras famílias de modelos de detecção, além das variantes da YOLO e da RT-DETR, para identificar potenciais ganhos em precisão e eficiência.
- **Validação em dispositivos embarcados:** Testar e comparar o desempenho dos modelos em hardwares com recursos computacionais limitados, garantindo a viabilidade da implantação em sistemas móveis de monitoramento em tempo real.

## 6.4 Contribuições na Produção

Além do conjunto de dados rotulado disponibilizado para incentivar novas pesquisas, este trabalho resultou na submissão de um artigo ao periódico internacional *Journal of Ambient Intelligence and Smart Environments* (JAISE).

## 6.5 Considerações Finais

Ao demonstrar a eficácia da YOLOv10m na tarefa de detecção de contato entre vegetação e linhas de distribuição, este estudo contribui para o avanço de soluções baseadas em inteligência artificial para manutenção preventiva da infraestrutura elétrica. Espera-se que os recursos disponibilizados e os resultados apresentados sirvam de base sólida para novas pesquisas, visando redes elétricas urbanas mais seguras, resilientes e inteligentes.

---

## Referências

Agência Nacional de Aviação Civil. **RBAC: Requisitos Gerais para aeronaves não tripuladas de uso civil**. Brasil, 2023. Disponível em: <<https://www.anac.gov.br/assuntos/legislacao/legislacao-1/rbha-e-rbac/rbac/rbac-e-94>>.

BANDARA, S.; RAJEEV, P.; GAD, E. Power distribution system faults and wildfires: Mechanisms and prevention. **Forests**, MDPI, v. 14, n. 6, p. 1146, 2023. Disponível em: <<https://doi.org/10.3390/f14061146>>.

BAO, W.; DU, X.; WANG, N.; YUAN, M.; YANG, X. A defect detection method based on bc-yolo for transmission line components in uav remote sensing images. **Remote Sensing**, MDPI, v. 14, n. 20, p. 5176, 2022. Disponível em: <<https://doi.org/10.3390/rs14205176>>.

BBC, N. B. **Apagão no Amapá: o que provocou queda de energia que leva sede e caos ao Estado**. 2020. Acesso em: 20 maio 2025. Disponível em: <<https://www.bbc.com/portuguese/brasil-54843654>>.

BORGES, F. Q. Crise de energia elétrica no brasil - uma breve reflexão sobre a dinâmica de suas origens e resultados. **RECIMA21**, v. 2, n. 10, 2021. Disponível em: <<https://doi.org/10.47820/recima21.v2i10.809>>.

CASAS, E.; RAMOS, L.; BENDEK, E.; RIVAS-ECHEVERRÍA, F. Assessing the effectiveness of yolo architectures for smoke and wildfire detection. **IEEE Access**, IEEE, 2023. Disponível em: <<https://doi.org/10.1109/ACCESS.2023.3312217>>.

CHEN, B.; MIAO, X. Distribution line pole detection and counting based on yolo using uav inspection line video. **Journal of Electrical Engineering & Technology**, Springer, v. 15, n. 1, p. 441–448, 2020. Disponível em: <<https://doi.org/10.1007/s42835-019-00230-w>>.

CNN, B. **Apagão atinge vários estados e deixa brasileiros sem energia**. 2023. Acessado em: 20 maio 2025. Disponível em: <<https://www.cnnbrasil.com.br/nacional/apagao-atinge-varios-estados-e-deixa-brasileiros-sem-energia/>>.

COLLINS, K. M.; PENMAN, T. D.; PRICE, O. F. Some wildfire ignition causes pose more risk of destroying houses than others. **PLoS One**, Public Library of Science San Francisco, CA USA, v. 11, n. 9, p. e0162083, 2016. Disponível em: <<https://doi.org/10.1371/journal.pone.0162083>>.

COSTA, J. P. A.; CORTES, O. A. C. A convolutional neural network for detecting faults in power distribution networks along a railway: A case study using yolo. **Applied Artificial Intelligence**, Taylor & Francis, v. 35, n. 15, p. 2067–2086, 2021. Disponível em: <<https://doi.org/10.1080/08839514.2021.1998974>>.

CRICIUMA, B. **Vegetação na rede elétrica é a principal causa de falta de energia em caso de temporais**. 2019. Disponível em: <<https://bairroscriciuma.com.br/utilidade-publica/vegetacao-na-rede-eletrica-e-a-principal-causa-de-falta-de-energia-em-caso-de-temporais/>>.

DOSOVITSKIY, A.; BEYER, L.; KOLESNIKOV, A.; WEISSENBORN, D.; ZHAI, X.; UNTERTHINER, T.; DEHGHANI, M.; MINDERER, M.; HEIGOLD, G.; GELLY, S. et al. An image is worth 16x16 words: Transformers for image recognition at scale. **arXiv preprint arXiv:2010.11929**, 2021. Disponível em: <<https://doi.org/10.48550/arXiv.2010.11929>>.

ECONOMIA, G. G. **Racionamento atrapalhou retomada da economia em 2001; saiba se problema pode se repetir**. 2021. Atualizado em 2024. Acessado em: 20 maio 2025. Disponível em: <<https://g1.globo.com/economia/noticia/2021/06/29/racionamento-atrapalhou-retomada-da-economia-em-2001-saiba-se-problema-pode-se-repetir.ghtml>>.

EIXOS. **Falha em linhas de transmissão afetou fornecimento de energia no Rio de Janeiro**. 2023. Acesso em: 20 maio 2025. Disponível em: <<https://eixos.com.br/energia-eletrica/falha-em-linhas-de-transmissao-afetou-fornecimento-de-energia-no-rio-de-janeiro/>>.

Empresa de Pesquisa Energética. **Anuário Estatístico de Energia Elétrica**. 2023. Disponível em: <<https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/anuario-estatistico-de-energia-eletrica>>.

ENGENHARIA, O. **Subestação de energia: tudo sobre projeto, instalação e manutenção de subestações para indústrias e grandes consumidores**. 2020. Acesso em: 20 maio 2025. Disponível em: <<https://omsengenharia.com.br/blog/subestacao-de-energia/>>.

FAHIM, F.; HASAN, M. S. Enhancing the reliability of power grids: A yolo based approach for insulator defect detection. **e-Prime-Advances in Electrical Engineering, Electronics and Energy**, Elsevier, v. 9, p. 100663, 2024. Disponível em: <<https://doi.org/10.1016/j.prime.2024.100663>>.

FAKHRI, S. A.; SAADATSERESHT, M. Road crack detection using gaussian/prewitt filter. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Copernicus GmbH, v. 42, p. 371–377, 2019. Disponível em: <<https://doi.org/10.5194/isprs-archives-XLII-4-W18-371-2019>>.

G1. **Apagão deixa um milhão de clientes sem energia elétrica na Zona Leste e no ABC Paulista**. 2019. Acesso em: 20 maio 2025. Disponível em: <<https://g1.globo.com/sp/sao-paulo/noticia/2019/01/31/apagao-deixa-um-milhao-de-clientes-sem-energia-eletrica-na-zona-leste-e-no-abc-paulista.ghtml>>.

G1. **Após oito horas, fornecimento de energia é restabelecido em todas as áreas afetadas por apagão.** 2023. Acessado em: 20 maio 2025. Disponível em: <<https://g1.globo.com/pi/piaui/noticia/2023/08/15/apagao-nacional-deixa-cidades-sem-energia.ghtml>>.

HAN, W.; CAI, Z.; LI, X.; DING, A.; ZOU, Y.; WANG, T. Lmd-yolo: A lightweight algorithm for multi-defect detection of power distribution network insulators based on an improved yolov8. **PloS one**, Public Library of Science San Francisco, CA USA, v. 20, n. 2, 2025. Disponível em: <<https://doi.org/10.1371/journal.pone.0314225>>.

HAYKIN, S. **Neural networks: a comprehensive foundation.** [S.l.]: Pearson, 1999. ISBN 81-7808-300-0.

IBM. **What is Data Augmentation?** 2024. Acesso em: 20 maio 2025. Disponível em: <<https://www.ibm.com/think/topics/data-augmentation>>.

JOCHER, G.; CHAURASIA, A.; QIU, J. **Ultralytics YOLOv8.** 2023. Disponível em: <<https://github.com/ultralytics/ultralytics>>.

KAGAN, N.; OLIVEIRA, C. C. B. D.; ROBBA, E. J. **Introdução aos sistemas de distribuição de energia elétrica.** [S.l.]: Editora Blucher, 2021. ISBN 9788521216896.

LI, S. J.; LIU, Y. X.; LI, M.; DING, L. Df-yolo: Highly accurate transmission line foreign object detection algorithm. **IEEE Access**, IEEE, v. 11, p. 108398–108406, 2023. Disponível em: <<https://doi.org/10.1109/ACCESS.2023.3321385>>.

LI, Y.; ZHU, C.; ZHANG, Q.; ZHANG, J.; WANG, G. If-yolo: An efficient and accurate detection algorithm for insulator faults in transmission lines. **IEEE Access**, IEEE, 2024. Disponível em: <<https://doi.org/10.1109/ACCESS.2024.3496514>>.

LIANG, H.; ZUO, C.; WEI, W. Detection and evaluation method of transmission line defects based on deep learning. **IEEE Access**, IEEE, v. 8, p. 38448–38458, 2020. Disponível em: <<https://doi.org/10.1109/ACCESS.2020.2974798>>.

LIU, C.; WEI, S.; ZHONG, S.; YU, F. Yolo-powerlite: a lightweight yolo model for transmission line abnormal target detection. **IEEE Access**, IEEE, 2024. Disponível em: <<https://doi.org/10.1109/ACCESS.2024.3434687>>.

MARQUES, J.; ALVES, R.; OLIVEIRA, H. C.; MENDONÇA, M.; SOUZA, J. R. An evaluation of machine learning methods for speed-bump detection on a gopro dataset. **Anais da Academia Brasileira de Ciências**, SciELO Brasil, v. 93, p. e20190734, 2021. Disponível em: <<https://doi.org/10.1590/0001-3765202120190734>>.

MEHL, E. L. Qualidade da energia elétrica. **UNIVERSIDADE FEDERAL DO PARANÁ**, 2012. Disponível em: <<https://www.eletrica.ufpr.br/mehl/downloads/qualidade-energia.pdf>>.

MILLER, C.; PLUCINSKI, M.; SULLIVAN, A.; STEPHENSON, A.; HUSTON, C.; CHARMAN, K.; PRAKASH, M.; DUNSTALL, S. Electrically caused wildfires in victoria, australia are over-represented when fire danger is elevated. **Landscape and Urban Planning**, Elsevier, v. 167, p. 267–274, 2017. Disponível em: <<https://doi.org/10.1016/j.landurbplan.2017.06.016>>.

Ministério da Defesa, Comando da Aeronáutica, Departamento de Controle do Espaço Aéreo. **ICA 100-40: AERONAVES NÃO TRIPULADAS E O ACESSO AO ESPAÇO AÉREO BRASILEIRO**. Brasil, 2023. Disponível em: <<https://publicacoes.decea.mil.br/publicacao/ica-100-40>>.

MITCHELL, J. W. Power line failures and catastrophic wildfires under extreme weather conditions. **Engineering Failure Analysis**, Elsevier, v. 35, p. 726–735, 2013. Disponível em: <<https://doi.org/10.1016/j.engfailanal.2013.07.006>>.

NEYCENSSAC, F. Contrast enhancement using the laplacian-of-a-gaussian filter. **CVGIP: Graphical Models and Image Processing**, Elsevier, v. 55, n. 6, p. 447–463, 1993. Disponível em: <<https://doi.org/10.1006/cgip.1993.1034>>.

NORD, I. **Apagão no Brasil: maiores blecautes e suas causas**. 2024. Acessado em: 20 maio 2025. Disponível em: <<https://www.nordinvestimentos.com.br/blog/cronologia-apagoes-brasil>>.

NOTÍCIAS, U. **Amapá volta a ter 100% de energia após 22 dias de apagão**. 2020. Acesso em: 20 maio 2025. Disponível em: <<https://noticias.uol.com.br/cotidiano/ultimas-noticias/2020/11/24/amapa-volta-a-ter-100-de-energia-apos-22-dias-de-apagao.htm>>.

OLIVEIRA, H.; MENDONÇA, M.; RIBEIRO, J.; ALVES, R.; SOUZA, J. Camera synchronization using an audio-based approach for mobile mapping systems. **The 11th International Conference in Mobile Mapping Technology**, 2019. Disponível em: <<https://www.researchgate.net/publication/333001290>>.

O'SHEA, K.; NASH, R. **An Introduction to Convolutional Neural Networks**. 2015. Disponível em: <<https://arxiv.org/abs/1511.08458>>.

PADILLA, R.; NETTO, S. L.; SILVA, E. A. D. A survey on performance metrics for object-detection algorithms. In: **IEEE. 2020 international conference on systems, signals and image processing (IWSSIP)**. 2020. p. 237–242. Disponível em: <<https://doi.org/10.1109/IWSSIP48289.2020.9145130>>.

PIERALLINI, L.; GRASSETTI, F.; BALLIRANO, F. P. **Drone Regulation 2020**. [S.l.]: Law Business Research, 2019. ISBN 978-1-83862-238-1.

QAYYUM, A.; MALIK, A. S.; SAAD, M. N. M.; IQBAL, M.; AHMAD, R. F.; ABDULLAH, T. A. R. B. T.; RAMLI, A. Q. Monitoring of vegetation near power lines based on dynamic programming using satellite stereo images. In: **IEEE. 2014 IEEE International Conference on Smart Instrumentation, Measurement and Applications (ICSIMA)**. 2014. p. 1–6. Disponível em: <<https://doi.org/10.1109/ICSIMA.2014.7047429>>.

RANA, R.; VERMA, A. Comparison and enhancement of digital image by using canny filter and sobel filter. **IOSR Journal of Computer Engineering**, v. 16, n. 1, p. 06–10, 2014. Disponível em: <<https://doi.org/10.9790/0661-16190610>>.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You only look once: Unified, real-time object detection. In: **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. [s.n.], 2016. Disponível em: <<https://doi.org/10.1109/CVPR.2016.91>>.

- Reforrafo Transformadores. **Transformador de Poste: Guia Completo.** 2025. Acesso em: 20 maio 2025. Disponível em: <<https://www.reforrafo.com.br/blog/categorias/artigos/transformador-de-poste-guia-completo>>.
- RENWEI, T.; ZHONGJIE, Z.; YONGQIANG, B.; MING, G.; ZHIFENG, G. **Key parts of transmission line detection using improved YOLO v3.** [S.l.], 2021. v. 18, n. 6, 747–754 p. Disponível em: <<https://doi.org/10.34028/ijait/18/6/1>>.
- ROUSHDY, M. Comparative study of edge detection algorithms applying on the grayscale noisy image using morphological filter. **GVIP journal**, v. 6, n. 4, p. 17–23, 2006. Disponível em: <<https://www.researchgate.net/publication/229014057>>.
- RUSSELL, B. D.; BENNER, C. L.; WISCHKAEMPER, J. A. Distribution feeder caused wildfires: Mechanisms and prevention. In: **IEEE. 2012 65th Annual Conference for Protective Relay Engineers.** 2012. p. 43–51. Disponível em: <<https://doi.org/10.1109/CPRE.2012.6201220>>.
- RUSSELL, S. J.; NORVIG, P. **Artificial intelligence: a modern approach.** [S.l.]: pearson, 2010. ISBN 978-0-13-604259-4.
- SAPKOTA, R.; QURESHI, R.; CALERO, M. F.; BADJUGAR, C.; NEPAL, U.; POULOSE, A.; ZENO, P.; VADDEVOLU, U. B. P.; KHAN, S.; SHOMAN, M.; YAN, H.; KARKEE, M. **YOLOv10 to Its Genesis: A Decadal and Comprehensive Review of The You Only Look Once (YOLO) Series.** 2024. Disponível em: <<https://arxiv.org/abs/2406.19407>>.
- SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on image data augmentation for deep learning. **Journal of big data**, Springer, v. 6, n. 1, p. 1–48, 2019. Disponível em: <<https://doi.org/10.1186/s40537-019-0197-0>>.
- SILVA, R. F. d. **Trilhamento elétrico sobre materiais poliméricos pela análise da energia absorvida devido as descargas elétricas superficiais.** Tese (Doutorado) — Universidade Federal do Paraná, 2014. Disponível em: <<https://www.researchgate.net/publication/262373193>>.
- SOARES, P. L. B.; SILVA, J. P. da. Aplicação de redes neurais artificiais em conjunto com o método vetorial da propagação de feixes na análise de um acoplador direcional baseado em fibra ótica. **Revista Brasileira de Computação Aplicada**, v. 3, n. 2, p. 58–72, 2011. Disponível em: <<https://doi.org/10.5335/rbca.2011.1803>>.
- STEFENON, S. F.; SEMAN, L. O.; KLAAR, A. C. R.; OVEJERO, R. G.; LEITHARDT, V. R. Q. Hypertuned-yolo for interpretable distribution power grid fault location based on eigencam. **Ain Shams Engineering Journal**, Elsevier, v. 15, n. 6, p. 102722, 2024. Disponível em: <<https://doi.org/10.1016/j.asej.2024.102722>>.
- SUN, R.; LEI, T.; CHEN, Q.; WANG, Z.; DU, X.; ZHAO, W.; NANDI, A. K. Survey of image edge detection. **Frontiers in Signal Processing**, Frontiers Media SA, v. 2, p. 826967, 2022. Disponível em: <<https://doi.org/10.3389/frsip.2022.826967>>.
- UFU, C. **UFU oficializa as novas datas do Vestibular 2022/2.** 2022. Acesso em: 20 maio 2025. Disponível em: <<https://comunica.ufu.br/noticias/2022/09/ufu-oficializa-novas-datas-do-vestibular-20222>>.

United Nations Statistics Division. **Energy Statistics Database**. 2024. <<https://data.un.org>>. Disponível via UNdata. Última atualização em 11 dez. 2024.

VASWANI, A.; SHAZER, N.; PARMAR, N.; USZKOREIT, J.; JONES, L.; GOMEZ, A. N.; KAISER, Ł.; POLOSUKHIN, I. Attention is all you need. **Advances in neural information processing systems**, v. 30, 2017. Disponível em: <<https://doi.org/10.48550/arXiv.1706.03762>>.

WALSH, G.; DINNIE, K.; WIEDMANN, K.-P. How do corporate reputation and customer satisfaction impact customer defection? a study of private energy customers in germany. **Journal of Services Marketing**, Emerald Group Publishing Limited, v. 20, n. 6, p. 412–420, 2006. Disponível em: <<https://doi.org/10.1108/08876040610691301>>.

WANG, A.; CHEN, H.; LIU, L.; CHEN, K.; LIN, Z.; HAN, J.; DING, G. Yolov10: Real-time end-to-end object detection. **arXiv preprint arXiv:2405.14458**, 2024. Disponível em: <<https://doi.org/10.48550/arXiv.2405.14458>>.

WANG, C.; CHEN, Y.; WU, Z.; LIU, B.; TIAN, H.; JIANG, D.; SUN, X. Line-yolo: An efficient detection algorithm for power line angle. **Sensors**, MDPI, v. 25, n. 3, p. 876, 2025. Disponível em: <<https://doi.org/10.3390/s25030876>>.

WANG, C.-Y.; LIAO, H.-Y. M. Yolov9: Learning what you want to learn using programmable gradient information. **arXiv preprint arXiv:2402.13616**, 2024. Disponível em: <[https://doi.org/10.1007/978-3-031-72751-1\\_1](https://doi.org/10.1007/978-3-031-72751-1_1)>.

WILSON, R.; WICKRAMASURIYA, R.; MARCHIORI, D. An empirical modelling and simulation framework for fire events initiated by vegetation and electricity network interactions. **Fire**, MDPI, v. 6, n. 2, p. 61, 2023. Disponível em: <<https://doi.org/10.3390/fire6020061>>.

XIE, X. Transmission line surface defect detection method based on uav autonomous inspection. **Journal of Physics: Conference Series**, IOP Publishing, v. 2132, n. 1, dec 2021. Disponível em: <<https://doi.org/10.1088/1742-6596/2132/1/012030>>.

ZHANG, B.; SONG, J.; LIU, Q.; YAN, Y. Wear-yolo: Research on detection methods of safety equipment for power personnel in substations. In: **IEEE. 2024 5th International Conference on Clean Energy and Electric Power Engineering (ICCEPE)**. 2024. p. 274–278. Disponível em: <<https://doi.org/10.1109/ICCEPE62686.2024.10931509>>.

ZHANG, J.; WEI, X.; ZHANG, L.; YU, L.; CHEN, Y.; TU, M. Yolo v7-eca-pconv-nwd detects defective insulators on transmission lines. **Electronics**, v. 12, n. 18, 2023. ISSN 2079-9292. Disponível em: <<https://doi.org/10.3390/electronics12183969>>.

ZHAO, Y.; LV, W.; XU, S.; WEI, J.; WANG, G.; DANG, Q.; LIU, Y.; CHEN, J. Detrs beat yolos on real-time object detection. In: **Proceedings of the IEEE/CVF conference on computer vision and pattern recognition**. [s.n.], 2023. Disponível em: <<https://doi.org/10.1109/CVPR52733.2024.01605>>.

ZOU, H.; YANG, J.; SUN, J.; YANG, C.; LUO, Y.; CHEN, J. Detection method of external damage hazards in transmission line corridors based on yolo-lsdw. **Energies**, MDPI, v. 17, n. 17, p. 4483, 2024. Disponível em: <<https://doi.org/10.3390/en17174483>>.