

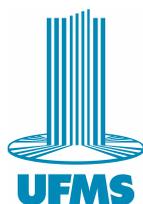
UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL
FACULDADE DE ENGENHARIAS, ARQUITETURA E
URBANISMO E GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA

ANÁLISE DE DESEMPENHO DOS MÉTODOS DE
APRENDIZAGEM PROFUNDA PARA DETECÇÃO DE
ISOLADORES E SUAS ANOMALIAS

Laisa Fernanda Pereira de Almeida

Campo Grande - MS, Brasil

Abril de 2022



**ANÁLISE DE DESEMPENHO DOS MÉTODOS DE
APRENDIZAGEM PROFUNDA PARA DETECÇÃO DE
ISOLADORES E SUAS ANOMALIAS**

Laisa Fernanda Pereira de Almeida

Dissertação apresentada à Universidade Federal de Mato Grosso do Sul na Faculdade de Engenharias, Arquitetura e Urbanismo e Geografia, como requisito para a obtenção do grau de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Wesley Nunes Gonçalves
Coorientador: Prof. Dr. Edson Antonio Batista

Campo Grande - MS, Brasil

Abril de 2022

ANÁLISE DE DESEMPENHO DOS MÉTODOS DE APRENDIZAGEM PROFUNDA PARA DETECÇÃO DE ISOLADORES E SUAS ANOMALIAS

Laisa Fernanda Pereira de Almeida

Dissertação apresentada à Universidade Federal de Mato Grosso do Sul na Faculdade de Engenharias, Arquitetura e Urbanismo e Geografia, como requisito para a obtenção do grau de Mestre em Engenharia Elétrica.

Examinada por:

Prof. Dr. Wesley Nunes Gonçalves

Prof. Dr. Edson Antonio Batista

Prof. Dr. Jonathan de Andrade Silva

Prof. Dr. José Marcato Junior

Campo Grande - MS, Brasil

09 Abril de 2022

Agradecimentos

Agradeço ao meu Deus que pela sua bondade e infinito amor me forneceu a oportunidade de desenvolver este projeto dando forças, saúde e consolo.

A minha família, tios, tias e primos sem a minha base não estaria aqui, em especial a minha vó Noemea, minha mãe, Gecimar, meu Noivo, Cleyton e tias Jussara e Regihane que esteve comigo nessa trajetória, incentivando, cuidando, dando apoio no âmbito pessoal e profissional.

Muita gratidão ao meu orientador Prof^o Dr^o Wesley pela paciência, profissionalismo e dedicação em orientar. Por toda essa jornada acadêmica estar presente auxiliando no que foi preciso.

Agradeço ao Prof^o Dr^o Edson, meu coorientador por desde o início se fazer presente gerando várias oportunidades para meu crescimento acadêmico.

Gratidão à concessionária Energisa que disponibilizou uma banco de imagens de isoladores do Brasil, onde propiciou uma base de dados mais robusta.

ANÁLISE DE DESEMPENHO DOS MÉTODOS DE APRENDIZAGEM PROFUNDA PARA DETECÇÃO DE ISOLADORES E SUAS ANOMALIAS

Laisa Fernanda Pereira de Almeida

Monitorar e realizar manutenção nos isoladores da rede elétrica é essencial já que a falha nesse componente pode ocasionar inúmeros prejuízos. Porém a identificação das falhas em isoladores é desafiador já que trata-se de contextos complexos. Atualmente, este monitoramento na maioria das vezes é feito de forma manual e os métodos propostos para tornar este trabalho automatizado é direcionado só a um país, se retém a só um tipo de falha nos isoladores ou o componente não está no cenário real. Com intuito de proporcionar uma vistoria assertiva e ágil, contribuir com um banco de dados diversificado e identificar um método com bom desempenho para este objetivo, primeiro foi construído um banco de dados com amostras variadas, capturadas em inspeção real que comportam dados de diferentes países, fundos, tipos de isoladores e defeitos, para propiciar uma detecção robusta com ampla variabilidade e obter um método que atinge os mais variados fundos e tipos de isoladores. Segundo foi aplicado métodos de aprendizado profundo de dois estágios que fazem parte do estado-da-arte, os quais foram, Faster R-CNN, Dynamic R-CNN e Cascade R-CNN, tanto para detecção de isoladores como para seus defeitos, Para finalizar, eles foram comparados e o Cascade R-CNN obteve uma maior média de *AP* com 92,1 % para a classe de defeitos e 83,6 % para a classe de isoladores e demonstra uma boa detecção em várias condições, como em fundos que se assemelham com o objeto ou quando o objeto está muito pequeno em relação a imagem.

Palavras-chaves: Detecção de defeitos, aprendizado profundo, isoladores.

PERFORMANCE ANALYSIS OF DEEP LEARNING METHODS FOR DETECTION OF INSULATORS AND THEIR ANOMALIES

Laisa Fernanda Pereira de Almeida

Monitoring and performing maintenance on electrical network insulators is essential since failure in this component can cause numerous damages. However, the identification of faults in insulators is challenging since these are complex contexts. Currently, this monitoring is mostly done manually and the methods proposed to make this work automated are directed only to one country, if only one type of failure is retained in the insulators or the component is not in the real scenario. In order to provide an assertive and agile survey, contribute to a diversified database and identify a method with good performance for this objective, first a database was built with varied samples, captured in real inspection that include data from different countries, backgrounds, types of insulators and defects, to provide a robust detection with wide variability and obtain a method that reaches the most varied backgrounds and types of insulators. Second, two-stage deep learning methods that are part of the state-of-the-art were applied, which were Faster R-CNN, Dynamic R-CNN and Cascade R-CNN, both for the detection of insulators and for their defects. Finally, they were compared and Cascade R-CNN had a higher average of *AP* with 92.1 % for the class of defects and 83.6 % for the class of insulators and demonstrates good detection under various conditions, such as in backgrounds that resemble the object or when the object is too small in relation to the image.

Keywords: Defect detection, deep learning, insulators.

Sumário

Lista de ilustrações	I
1 Introdução	1
1.1 Motivação	1
1.2 Objetivos	2
1.2.1 Objetivos Específicos	2
1.3 Contribuições	3
1.4 Organização	3
2 Trabalhos Correlatos	4
2.1 Características Internas	4
2.2 Características Externas	5
2.3 Lacunas	8
3 Materiais e Métodos	9
3.1 Imagens do Banco de Dados	9
3.2 Metodologia para Detecção de Isoladores e Defeitos	12
3.3 Avaliação dos Métodos	15
4 Experimentos e Resultados	16
4.1 Análise Quantitativa	16
4.2 Análise Qualitativa	18
5 Discussões	25
6 Conclusões	27
Referências	28

Lista de ilustrações

Figura 1	– Exemplos de imagens do banco de dados com isoladores e defeitos.	10
Figura 2	– Exemplos de imagens do banco de dados com diferentes tipos de defeitos.	11
Figura 3	– Metodologia proposta para treinar, validar e testar métodos de detecção de objetos na detecção de isoladores e defeitos.	13
Figura 4	– Curva de revocação versus precisão para cada método na detecção dos isoladores (primeira linha) e defeitos (segunda linha). As áreas em azul e vermelho correspondem aos resultados da AP_{50} e AP_{75} , respectivamente.	17
Figura 5	– Detecções de isoladores realizadas pelos métodos.	19
Figura 6	– Detecções de isoladores realizadas pelos métodos.	20
Figura 7	– Objetos não detectados.	21
Figura 8	– Exemplos de detecção de defeitos em imagens capturadas a curta e longa distância.	23
Figura 9	– Detecções de defeitos não rotulados.	24

1 Introdução

1.1 Motivação

Com o advento de novas tecnologias procura-se uma constante melhoria no sistema de energia elétrica. Entende-se que é de grande valia o investimento no segmento [1], pois fornece qualidade para vários setores, como industrial, comercial e residencial. Por meio de pesquisas, diversas melhorias foram implementadas, proporcionando a prevenção de futuros danos, personalização de produtos e diminuição de ruídos, com o objetivo de melhorar a qualidade da energia para o consumidor final [2].

Uma grande dificuldade encontrada ainda, se refere a necessidade de um constante monitoramento e manutenção nos componentes de distribuição e transmissão de energia, já que são expostos a fatores externos, como variação de temperaturas, colisões, chuvas, poluição [3]. O isolador é um componente da rede elétrica cuja sua função é gerar isolamento elétrico e proteger mecanicamente os fios, devido a isso ele também está sujeito a forte campo elétrico [4, 5]. Uma falha no isolador pode acarretar inúmeros problemas, sendo considerado um dos principais riscos na segurança do sistema de energia elétrica [6].

No Brasil de acordo com a Associação Brasileira de Distribuidores de Energia Elétrica - ABRADDEE, existem cerca de 145 mil km de linhas de transmissão. Como se trata de uma vasta área para prestar manutenção e monitoramento, as concessionárias, em diversas vezes, não conseguem aplicar uma manutenção preventiva, ocasionando danos maiores tanto para o consumidor como para ela. Isso ocorre porque o monitoramento e manutenção ainda são feitos em sua maioria, por meio de imagens coletadas por drones e analisada manualmente, ou ainda por vistoria local, onde o funcionário vai até as linhas verificar o estado dos componentes, por meio de sensores, câmeras ou imagens ultravioletas [7]. Diante dos fatos, são encontradas ainda diversas dificuldades, como risco de vida na vistoria presencial, visto que geralmente a localização é perigosa, demora das análises, maior custo

para concessionária que remete no valor do serviço prestado e menor eficiência da manutenção.

Os métodos atuais que propõem soluções para detecção de isoladores e seus defeitos possuem em sua maioria poucas diversidade de amostras impossibilitando a aplicação em diferentes países devido a diferentes fundos, tipos de isoladores e defeitos [8].

Portanto, é necessário propor métodos mais eficazes, que sejam capazes de identificar defeitos em isoladores antes de ocasionar falhas graves no sistema de energia elétrica e assegurar um monitoramento regular garantindo a integridade desse componente e que pode contribuir para aplicação no Brasil.

1.2 Objetivos

Este trabalho tem por objetivo analisar metodologias baseadas em aprendizado profundo para detecção de isoladores e seus defeitos usando imagens capturadas por Veículo Aéreo Não Tripulado - VANT.

1.2.1 Objetivos Específicos

Para alcançar o objetivo geral, os seguintes objetivos específicos foram traçados:

- Construir uma base robusta com imagens de isoladores e seus defeitos capturadas em diferentes regiões do mundo;
- Avaliar métodos de detecção de objetos do estado-da-arte em aprendizado profundo;
- Treinar e testar os métodos, com imagens de isoladores e dos seus defeitos com classes diferentes.

1.3 Contribuições

Banco de Imagens: Criação de um banco de dados robusto com amostras de países diferentes, ao todo o banco de dados consiste em 2006 amostras, sendo quase 10% do Brasil.

Ferramenta para detecção de isoladores e defeitos: Desenvolvimento de uma ferramenta precisa que reconhece tanto isoladores, como diferentes defeitos dos isoladores, desde estágio inicial até o mais avançado.

Experimentos com métodos do estado da arte: os métodos usando aprendizagem profunda (e.g., [9, 10]) fazem parte do estado da arte, o qual são otimizados para serem mais precisos [11].

1.4 Organização

Visando atingir os objetivos, este trabalho está dividido em quatro capítulos. O atual capítulo descreve a necessidade de monitoramento e manutenção na rede elétrica de forma mais ágil e as consequências do atual modelo de manutenção. Apresenta também os objetivos do trabalho proposto e suas contribuições.

No Capítulo 2 são expostos trabalhos que utilizaram tecnologias similares ao desta dissertação, com objetivo de identificar isoladores e/ou defeitos neste componente da rede de energia elétrica, contribuindo assim para o desenvolvimento da atual proposta.

No Capítulo 3 é apresentado a estrutura da metodologia neste projeto, as métricas utilizadas para mensurar a qualidade, a arquitetura dos métodos detecção de objetos que serão utilizados e o banco de dados proposto.

O Capítulo 4 apresenta os resultados para detecção de isoladores e defeitos.

O Capítulo 5 apresenta as discussões dos resultados obtidos.

No Capítulo 6 são as conclusões, a partir do levantamento da solução desenvolvida.

2 Trabalhos Correlatos

Existem na literatura algumas soluções para o problema levantado no atual projeto, suas tecnologias se assemelham ao pretendido e podem ser utilizadas para contribuir no desenvolvimento da metodologia proposta. Os trabalhos da literatura foram divididos em dois tipos de extrações de características dos isoladores (externa e interna) e elencadas algumas tecnologias empregadas para detectar defeitos de isoladores e/ou isoladores.

2.1 Características Internas

Para detectar defeitos em isoladores, diversas tecnologias foram propostas. Alguns pesquisadores utilizam como solução imagens ultravioletas, ultrassônicas e infravermelho, para coletar características internas dos isoladores, porém se trata de uma tecnologia extremamente sensível à condição meteorológica. Além disso, essas soluções ainda não são economicamente viáveis, pois a captura das imagens em massa ainda têm um custo alto e na sua maioria ainda é necessário um operador para realizá-las [12].

O trabalho de [13] utiliza imagens ultrassônicas de isoladores com objetivo de treinar um modelo de redes neurais para classificar isoladores, contaminados, perfurados ou quebrados. Apesar do equipamento de ultrassom para analisar anomalias em isoladores ser muito utilizado, ainda assim, a proposta se torna inviável caso queira expandir para grande número de capturas, pois depende de um sistema embarcado para coleta de imagens ultrassônicas em massa o qual não foi realizado neste estudo.

He et. al. [14] apresentaram a aplicação das tecnologias de ultravioleta, ultrassom e infravermelho para detectar descargas parciais em isoladores. Para isso, são coletadas por meio dessas tecnologias imagens e vídeos do estado do componente e transferido para o computador. O sistema composto por termovisor, filtro solar cego, lente ultravioleta e ultravioleta ICCD tem por objetivo fundir os

três tipos de imagens, ultrassônica, ultravioleta e infravermelho no mesmo vídeo e detectar as descargas parciais.

É proposto por Gao et. al. [15] um método para a detecção de defeitos em isoladores com base em detecção fotoelétrica infravermelha e ultravioleta com rede neural difusa. Para realizar a coleta de dados para serem analisados, o autor utilizou sensores fotoelétricos infravermelhos para coletar dados de temperatura e sensores ultravioleta para coletar dados de descarga do equipamento elétrico. Com os dados coletados pode identificar que a mudança de temperatura e descargas de correntes no isolador permite identificar uma possível falha. Porém o método de coleta de dados com rede de sensores sem fio pode conter instabilidade nas informações recebidas na base de análise devido sua sensibilidade.

2.2 Características Externas

Na literatura é abordado mais uma forma de detecção de isoladores e seus defeitos, que consiste em utilizar imagens externas de isoladores com e sem anomalias e aplicar técnicas de deep learning para localização e classificação. Porém a maioria dos bancos de dados analisados têm imagens uniformizadas, com informações de uma região ou país específico ou os métodos utilizados não fazem parte do estado-da-arte.

Qiu et. al. [16] apresentaram uma proposta para detecção de isoladores e seus defeitos utilizando o YOLO v4 aprimorada, onde substituiu a rede de extração de recursos Darknet pela MobileNet e realizou um aperfeiçoamento da *Path Aggregation Network - PANet* baseado em *Depthwise Separable Convolution - DSC* a fim de melhorar a precisão na detecção e velocidade em relação ao YOLO v4 tradicional. O modelo atingiu 93,81% de mAP e uma detecção de 53 fotos/s. Os autores propuseram também a *Laplacian sharpening* para melhorar o contraste das imagens evitando uma confusão da borda do objeto a ser detectado com o fundo, obtendo 97,26% de mAP. O banco de dados no total comportam 2403 imagens, dessas 1339 foram geradas pelo método baseado na segmentação GraphCut.

Fan et. al. [17] propuseram um método de detecção de defeitos em dois processos, primeiro é aplicado Random Forest - RF juntamente com uma Rede

Neural convolucional, para reconhecer os isoladores e classifica-los entre normal ou defeito e o Faster-RCNN para localizar os defeitos de auto-explosão nos isoladores. O banco de dados analisado possui 700 imagens da China com diferentes fundos e sua precisão para detecção dos defeitos foi de 91%, já para classe isoladores 97,1% com o tempo médio de processamento por imagens de 0,5 segundos.

Em [18], os autores trazem como solução, um modelo de *deep learning* utilizando o método Fast-RCNN. O banco de dados é composto por 600 isoladores sem e com falhas, sendo que seu resultado não foi somente na identificação das falhas, mas também o seu estágio. Para isso, foram extraídas características de cor, textura e nível de luz das imagens dos isoladores e defeitos. Os autores converteram o modelo de cores RGB para HSI e usaram o histograma bidimensional em uma matriz de 8 tons de cinza. O método obteve uma taxa de acerto de 82,4% e 29 segundos de tempo de processamento.

He et. al. [19] apresentam uma metodologia de detecção de defeitos por meio de uma rede neural *Multi-Layer Information Fusion and Attention Mechanism Network - Mina-Net* baseada YOLO v4. O método combina características rasas com alta resolução e informações profundas de texturas proporcionando um reconhecimento mais detalhado no objeto. Também é realizado um aprimoramento na SEnet introduzindo um canal de atenção com objetivo de aprimorar as informações de entrada. Foi utilizado um banco de dados com 3523 imagens RGB de isoladores com defeitos tipo auto-explosivos, obtendo um desempenho de 88,07% com tempo de processamento por imagens de 0,5 segundos.

Guo et. al. [20] propuseram um algoritmo para detectar isoladores sem e com defeito, como rachaduras, contaminação da superfície e danos. Os autores aplicaram o método YOLO v3 o qual é composto pelos métodos YOLO V2, Darknet-19 e ResNet. Foram ao todo 1400 imagens de isoladores utilizadas para treino e aproximadamente 100 para teste do modelo, obtendo uma velocidade média de processamento por imagens de 0,55 segundos. O resultado trouxe uma generalização insuficiente devido a pouca variedade no conjunto de dados. Os autores reportaram o número de detecções positivas e falsas, sendo de 30 imagens de isoladores com defeitos foram 29 detecções verdadeiras e 1 falsa e de 118 de isoladores normais 112 detecções positivas e 6 falsas. Por se tratar de um modelo

de um estágio ainda existem problema na detecção de objetos muito pequenos e com baixa resolução.

Liu et. al. [21] propuseram o modelo *Cross Stage Partial Dense YOLO* (CSPD-YOLO) a fim de reduzir o problema de baixa resolução ao detectar falhas em isoladores. Os resultados obtidos se compararam com os métodos YOLO v3 e YOLO v4, sendo o modelo proposto mais preciso e com quase a mesma velocidade de processamento, obtendo um tempo médio de 0,01 segundos de processamento por imagens e com a precisão média de 98,18%. O banco de dados analisados são de imagens RGB de isoladores da linha (CPLID) em diferentes cenários e localizações, entretanto, as falhas nos isoladores foram criadas pelo software photoshop com apenas um tipo de defeito.

Lan e Xu [22] apresentaram uma proposta de detecção de imagens RGB de isoladores com defeitos utilizando a rede YOLO v5 aprimorada. Para isso, foi introduzido o módulo CBAM que contém dois submódulos, o de atenção de canal e de atenção espacial, sendo que o primeiro contribui para localizar partes significativas na imagem de entrada e o outro determina quais locais contêm as principais informações do objeto. O banco de dados inicialmente comportavam 240 imagens de isoladores com defeitos, porém foi realizada edições no brilho e acrescentados ruídos para ampliar a quantidade de imagens, chegando então em um total de 2400 imagens. O mAP foi de 99,6% e o modelo obteve uma detecção de 138,41 fotos/s.

No [23] é construído e aplicado um método de detecção de objetos chamado Box-Point Detector sua estrutura é de uma rede neural convolucional profunda e em seguida duas ramificações uma para localização da região da falha e a outra para identificar pontos finais dos isoladores com defeito. Uma é a ramificação na caixa central responsável pelas informações do defeito do isolador e outra é ramificação de ponto final responsável pelas informações dos isoladores como todo, ou seja, o contexto da falha. As imagens do banco de dados foram capturadas em cenário de inspeção aérea real são ao todo 969 imagens, sendo 1044 defeitos e 1541 anotações de isoladores, o tipo de falha analisada foi miss-cap. A métrica escolhida foi a precisão média o modelo chegou para AP_{50} 94% para conjunto de dados só com isoladores defeituosos e 93,1% para conjunto mesclado, ou seja, isoladores com

e sem defeitos. Foi comparado com os métodos atuais, como Faster R-CNN e CenterNet e em todos os métodos proposto, obteve maior precisão e tempo menor de processamento por imagem, alcançando 0,014 segundos.

Tabela 1 – Comparação de métodos propostos na literatura.

Citação	Proposta	N. de Imagens	Método	Desempenho
[16]	Detecção de Isoladores e variados defeitos	2403	YOLO v4 Aprimorada	93,81%
[17]	Detecção de Isoladores e defeito tipo auto-explosivos	700	(RF + CNN) e Faster-RCNN	91%
[18]	Detecção de Isoladores e variados defeitos	600	Fast-RCNN	88,07%
[19]	Detecção de defeito tipo auto-explosivos nos isoladores	3523	Mina-Net	88,07%
[20]	Detecção de Isoladores e variados defeitos	1548	YOLO v3	xxx
[21]	Detecção de defeitos em isoladores	1331	CSPD-YOLO	98,18%
[22]	Detecção de defeitos em isoladores	2400	YOLO v5 CG	99,6%
[23]	Detecção de isoladores e defeito tipo miss-cap	969	Box-Point Detector	93,1%

2.3 Lacunas

Por meio dos estudos encontrados na literatura, percebe-se algumas lacunas que em pelo menos uma dessas foi identificada, as quais o atual projeto teve por objetivo supri-las.

- Imagens pouco representativas ao que tange as diferentes regiões ou tipos de defeitos;
- Métodos que têm um desempenho inferior na detecção de objetos atualmente, ou seja, que não fazem parte do estado da arte.

3 Materiais e Métodos

Neste capítulo é exposto os métodos aplicados para a execução do projeto proposto, juntamente com os materiais empregados.

3.1 Imagens do Banco de Dados

O banco de dados construído comporta imagens de isoladores com e sem defeitos de diferentes países, com variados fundos e ângulos de captura. Esse banco exige que a abordagem seja mais robusta, visto que a confusão na detecção dos objetos torna-se mais suscetível. Para tanto, agrupou-se o banco de imagens *State Grid Corporation of China*, proposto e disponibilizado em [24] com uma base de dados de imagens de isoladores e defeitos capturadas em cenário real do Brasil disponibilizada pela concessionária Energisa.

A Tabela 2 apresenta o total de imagens (1006), exemplos de isoladores (1596) e defeitos (284). As imagens foram aleatoriamente divididas em conjuntos de treinamento (60%), validação (18%) e teste (22%), conforme apresentado na tabela. Por fim, todas as imagens foram redimensionadas para 1333×800 pixels devido aos requerimentos de entrada de tamanho fixo dos métodos de detecção de objetos. Exemplos de imagens do banco são apresentados na Figura 1.

Tabela 2 – Banco de imagens e sua divisão em treinamento, validação e teste.

Conjunto	N. de Imagens	N. de Isoladores	N. de Defeitos
Treinamento	602	930	175
Validação	185	288	61
Teste	219	378	48
Total	1006	1596	284

Podemos ver que as imagens possuem exemplos de isoladores diversos em diferentes escalas e regiões. Os exemplos também da Figura 2 mostram diferentes tipos de defeitos em isoladores, como rachaduras, contaminação, queimaduras e falhas na cadeia de isoladores, anotados com retângulos envolventes.

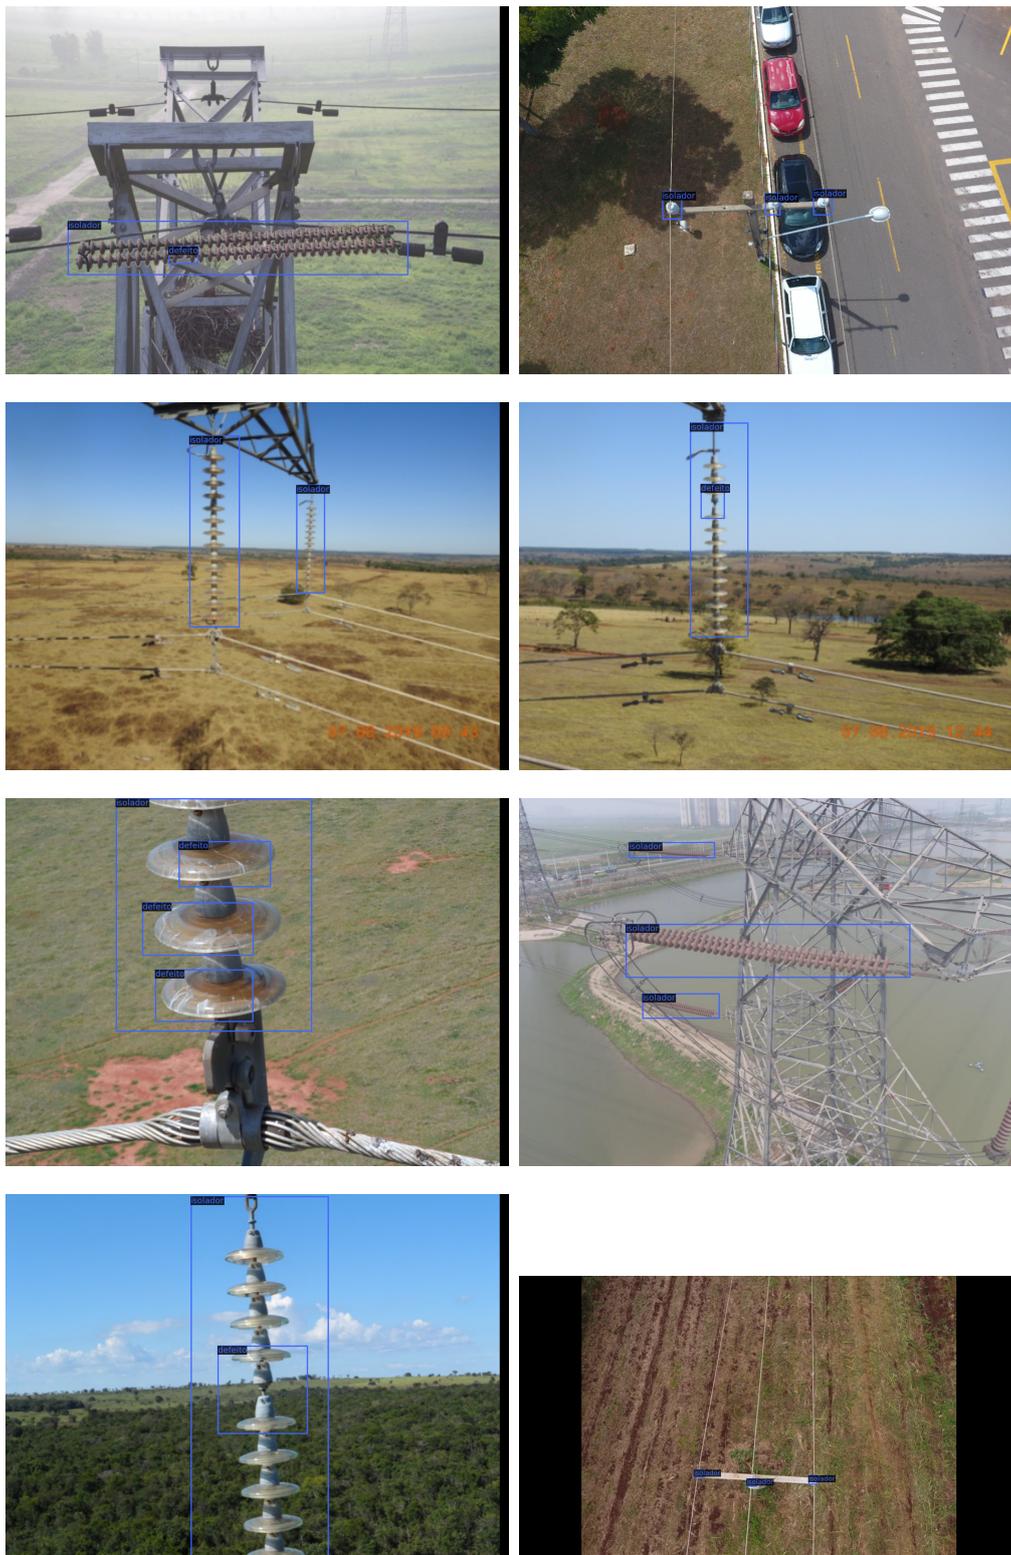


Figura 1 – Exemplos de imagens do banco de dados com isoladores e defeitos.

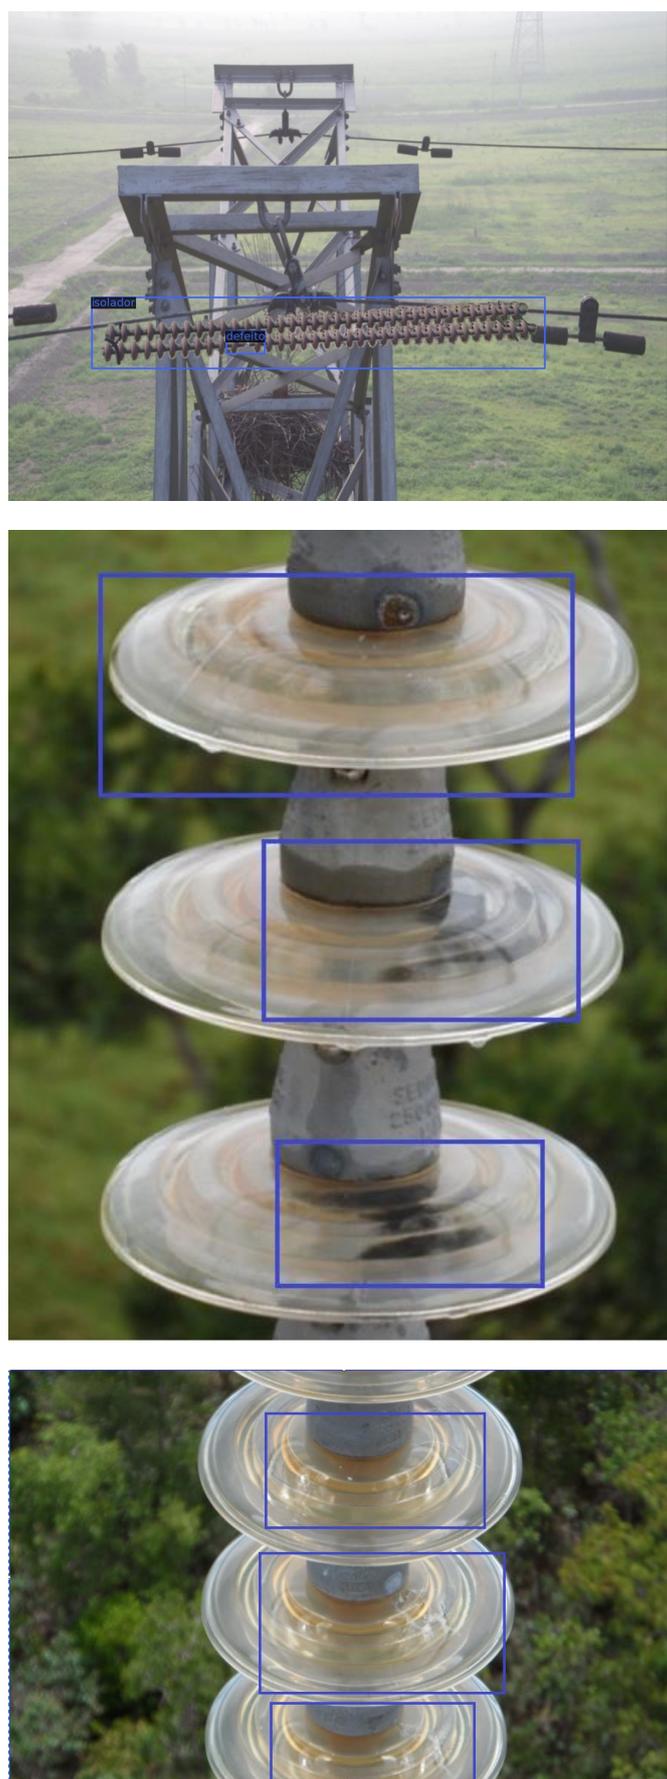


Figura 2 – Exemplos de imagens do banco de dados com diferentes tipos de defeitos.

3.2 Metodologia para Detecção de Isoladores e Defeitos

Na metodologia proposta, os isoladores são mapeados por meio de retângulos envolventes e suas coordenadas são coletadas. O mesmo ocorre para os defeitos, em que a região é mapeada com um retângulo cobrindo somente a área com anomalia na imagem. Diferentemente da literatura, a escolha é em trabalhar com duas classes a de isoladores e defeitos, aumentando a probabilidade de acerto, pois a não detecção de uma classe não interfere na detecção da outra.

A metodologia usada neste trabalho é apresentada na Figura 3. O conjunto de imagens é dividido em subconjuntos de treino, validação e teste. As imagens de treino foram usadas para treinar os métodos de detecção de objetos, enquanto que o conjunto de validação foi usado para determinar os hiperparâmetros, como taxa de aprendizagem. Como método de detecção de objetos, nós avaliamos o Faster-RCNN [25], Cascade R-CNN [26], e Dynamic R-CNN [27], os quais são métodos robustos de rede de aprendizado profundo para detecção. O backbone utilizado em todos os métodos foi o ResNet-50 com pesos pré-treinados do ImageNet (<http://www.image-net.org/>).

No processo de treinamento, nós aplicamos um otimizador *Stochastic Gradient Descent* com momentum igual a 0,9 e tamanho de batch definido em 4. Usando o conjunto de validação, nós avaliamos empiricamente as taxas de aprendizado (0,001, 0,01 e 0,1) e definimos que a convergência da função de perda é melhor para 0,01.

Com um determinado modelo treinado, nós avaliamos por meio das imagens do conjunto de teste. Durante o teste, as predições são realizadas pelo método e são selecionadas aquelas com probabilidade acima 0.5, como é comumente usado na literatura. Por fim, a Supressão de Não-Máximos (*Non Max Suppression* - NMS) é aplicada para reduzir as predições com sobreposição alta (i.e., maior que 50%).

A seguir, nós descrevemos brevemente os três métodos de detecção de objetos. A implementação dos métodos teve como base o código do projeto MMDetection, realizado no Laboratório Multimídia, disponível em: <https://github.com/open-mmlab/mmdetection>.

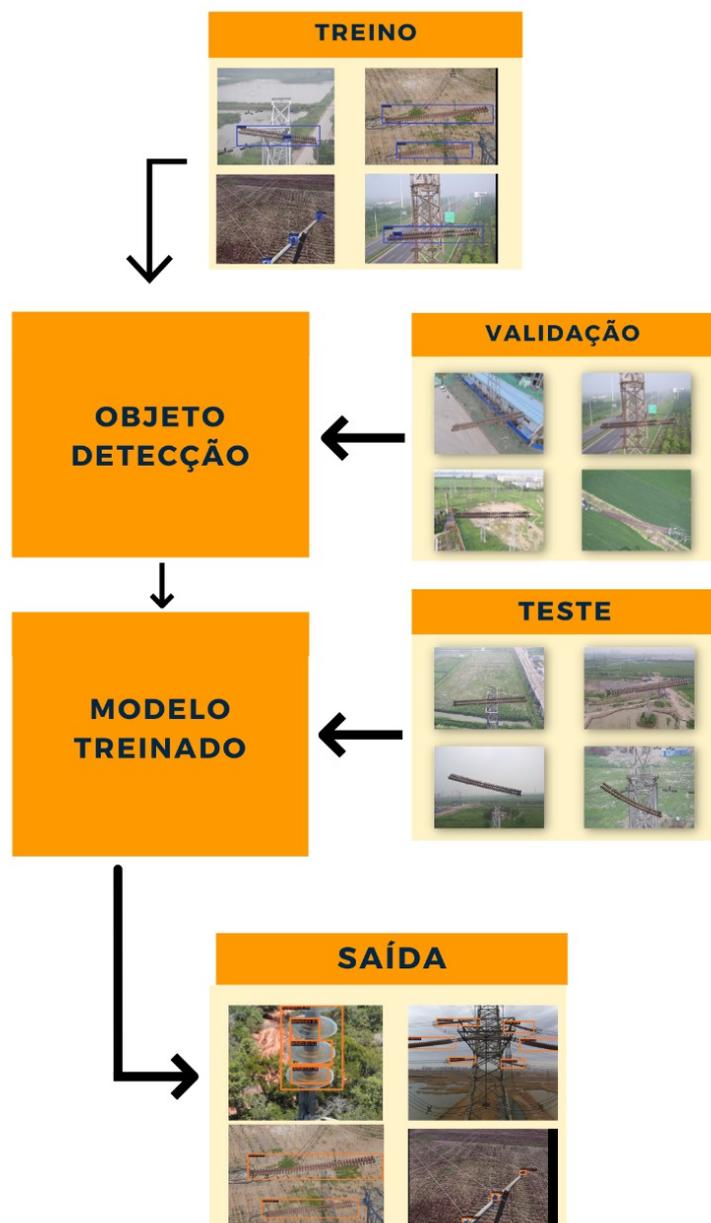


Figura 3 – Metodologia proposta para treinar, validar e testar métodos de detecção de objetos na detecção de isoladores e defeitos.

O Faster R-CNN [28, 26] é um método de detecção de objetos de dois estágios. O primeiro estágio, chamado de *Region Proposal Network* (RPN), consiste em gerar retângulos envolventes candidatos (âncoras) e classifica-los em objeto ou fundo. O objetivo da RPN é propor retângulos envolventes em regiões independente de qual classe seja (isolador ou defeito). No segundo estágio (chamado de detector), as âncoras da RPN são usadas para extrair um mapa de atributos uniformizado e então retornar a classe (isolador ou defeito) e a localização do retângulo envolvente ajustado por meio de uma regressão linear. Durante o treinamento, os retângulos envolventes preditos pelo método são comparados com os retângulos anotados pelo especialista. Essa comparação é feita pela sobreposição dos retângulos (intersection over union - IoU) e definido um exemplo positivo ou negativo.

Cascade R-CNN [26] propõe também uma detecção de objetos em dois estágios, sendo uma extensão do Faster-RCNN. O primeiro estágio é igual ao Faster-RCNN com a proposta de retângulos envolventes contendo ou não um objeto de interesse (isolador ou defeito). Diferente do Faster-RCNN, o segundo estágio do Cascade R-CNN é composto por uma sequência de detectores treinados sequencialmente usando a saída do detector anterior. Esse treinamento progressivo melhora a qualidade das predições e minimiza o *overfitting*.

O Dynamic R-CNN [27] também tem como base o Faster-RCNN com dois estágios. Entretanto, Dynamic R-CNN propõe o ajuste do segundo estágio usando dois componentes, o *Dynamic Label Assignment* (DLA) e *Dynamic SmoothL1 Loss* (DSL) que tem por objetivo ajustar o classificador e regressor do retângulo envolvente. No primeiro componente, o limiar que define uma proposta como positiva ou negativa é ajustado com base nas estatísticas durante o treinamento. Dessa forma, o limiar tende a aumentar para refletir o melhora na qualidade das propostas. De forma similar, a função de perda de regressão também é ajustada de forma correspondente pelo componente DSL.

3.3 Avaliação dos Métodos

O desempenho dos métodos de detecção de objetos foram avaliados usando Average Precision (AP) para cada classe (isoladores e defeitos). Nós também reportamos a Mean Average Precision (mAP) que consiste na média da AP das duas classes. Para o cálculo da AP e mAP, Intersection Over Union (IoU) é calculado como a área de sobreposição entre um retângulo envolvente predito e um retângulo envolvente rotulado dividida pela área de união. Se um retângulo predito tiver IoU maior que um limiar predefinido com qualquer retângulo GT, a predição é tida como um verdadeiro positivo (TP). Caso contrário, a predição é tida como um falso positivo (FP). Caso um retângulo GT não seja associado a qualquer retângulo predito, então ocorre um falso negativo (FN). Dessa forma, a precisão e revocação podem ser calculadas conforme Equações 2 e 3, respectivamente. AP é calculado como a área abaixo da curva entre precisão e revocação [29].

$$P = \frac{TP}{TP + FP} \quad (3.1)$$

$$R = \frac{TP}{TP + FN} \quad (3.2)$$

Durante os experimentos, nós consideramos dois limiares para o IoU com o intuito de avaliar também a localização das predições dos retângulos. Quanto maior o limiar que determina um TP, mais precisa a localização do retângulo tem que ser. O valor mais comum de limiar é 0.5 (AP_{50}) sendo que um retângulo predito precisa ter pelo menos 50% de interseção com um retângulo rotulado. Nos resultados nós também consideramos um limiar de 0.75 (AP_{75}) para verificar o quão boa foi a localização dos retângulos.

4 Experimentos e Resultados

Os experimentos e resultados obtidos são apresentados neste capítulo. A análise qualitativa dos resultados é apresentada na Seção 4.1, enquanto a análise quantitativa é exposta na Seção 4.2. Foram escolhidos três métodos os quais fazem parte do estado da arte, cujo alcançam bons resultados na detecção de objetos, os quais são Faster-RCNN, Cascade R-CNN e Dynamic R-CNN.

4.1 Análise Quantitativa

A Figura 4 apresenta as curvas de revocação versus precisão para os três métodos (Faster R-CNN, Cascade R-CNN e Dynamic R-CNN) na detecção de isoladores e defeitos. As áreas sob as curvas em azul e vermelho representam respectivamente a AP_{75} e AP_{50} . Quanto maior a área, maior é a precisão média de um determinado método. O AP_{50} é maior que AP_{75} em todos métodos tanto na detecção de isoladores como defeitos.

A Tabela 3 compara os métodos usando AP_{50} e AP_{75} na detecção de isoladores e defeitos. Considerando AP_{50} , para detecção de isoladores o Cascade R-CNN obteve o melhor resultado de 0,885 contra 0,866 do Dynamic R-CNN e 0,856 do Faster R-CNN.

Em relação ao desempenho dos métodos na detecção de defeitos, quem obteve o melhor resultado foi o Faster R-CNN com 0,958, embora o Cascade R-CNN chegue perto com 0,956 e o Dynamic R-CNN com 0,935. O Cascade R-CNN também alcançou resultados satisfatórios para AP_{75} , alcançando 0,751 para detecção de isoladores e 0,921 para os defeitos considerando uma sobreposição de pelo menos 75%.

Na Tabela 4 é exposto o cálculo da média das APs das duas classes. O Cascade R-CNN alcançou 0,921 para mAP_{50} e 0,836 para mAP_{75} , se sobressaindo em relação aos outros métodos nos dois limiares. Por outro lado, o Faster-RCNN e Dynamic R-CNN obtiveram resultados similares com mAP_{50} de aproximadamente

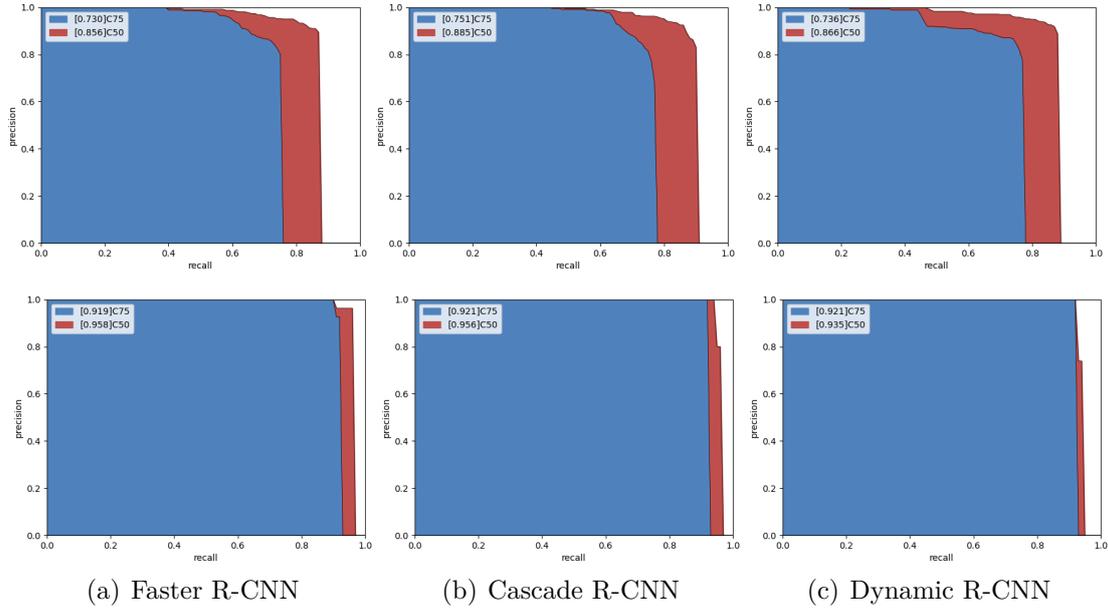


Figura 4 – Curva de revocação versus precisão para cada método na detecção dos isoladores (primeira linha) e defeitos (segunda linha). As áreas em azul e vermelho correspondem aos resultados da AP_{50} e AP_{75} , respectivamente.

0,9 e mAP_{75} de aproximadamente 0,83.

Tabela 3 – Resultados de AP_{50} e AP_{75} para os métodos na detecção de isoladores e defeitos.

Método	AP ₅₀		AP ₇₅	
	Isoladores	Defeitos	Isoladores	Defeitos
Faster R-CNN	0,856	0,958	0,730	0,919
Cascade R-CNN	0,885	0,956	0,751	0,921
Dynamic R-CNN	0,866	0,935	0,736	0,921

Tabela 4 – Resultados de mAP_{50} e mAP_{75} da média do AP .

Método	mAP_{50}	mAP_{75}
Faster R-CNN	0,907	0,825
Cascade R-CNN	0,921	0,836
Dynamic R-CNN	0,901	0,828

Por fim, a Tabela 5 apresenta o tempo de processamento de uma imagem em um computador com 16GB de ram e uma placa de vídeo NVIDIA 2080 com 6GB. É possível identificar que o Faster-RCNN tem um melhor desempenho com

0,064 segundos para processar uma imagem, seguido pelo Dynamic R-CNN com 0,066 segundos e Cascade R-CNN com 0,083 segundos.

Tabela 5 – Resultados do tempo de processamento por imagem em segundos.

Método	Imagem (s)
Faster R-CNN	0,064
Cascade R-CNN	0,083
Dynamic R-CNN	0,066

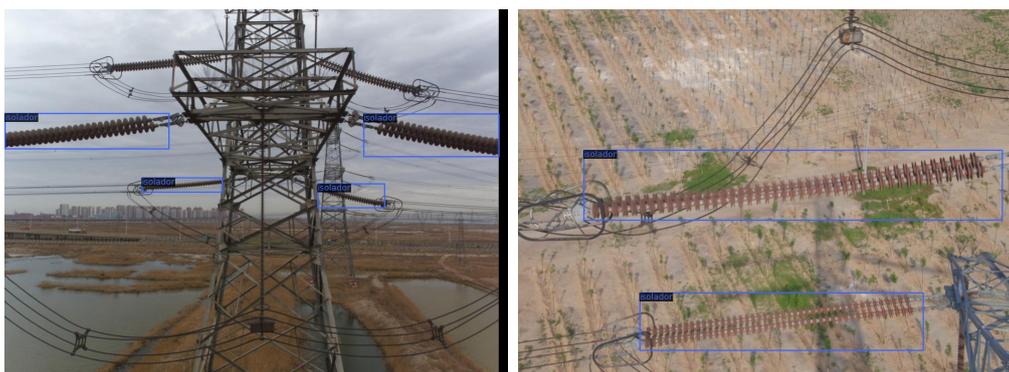
4.2 Análise Qualitativa

Essa seção apresenta os resultados qualitativos na detecção de isoladores e de seus defeitos. Os rótulos em azul são as anotações utilizadas para treino do modelo (*ground truth*) e as vermelhas se referem as detecções realizadas pelos métodos.

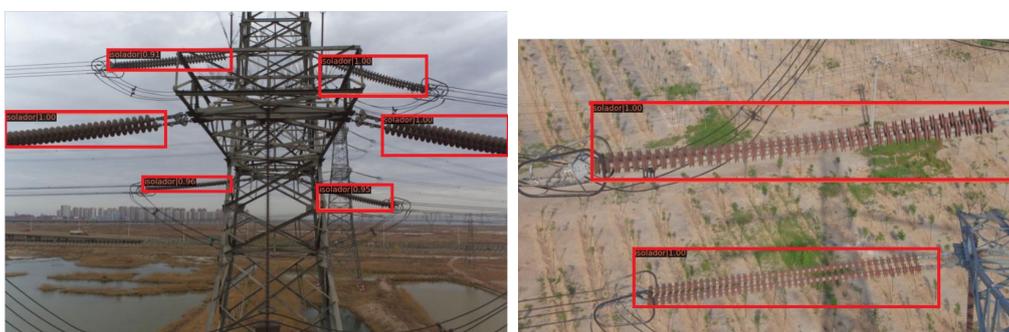
As Figuras 5 e 6 apresentam as detecções para dois tipos de isoladores. Para os isoladores da Figura 5, todos os métodos detectaram corretamente, mesmo na presença de vários isoladores na mesma imagem como na primeira coluna e detectaram isoladores com pequenas diferenças visuais, como no exemplo da segunda coluna. Os métodos localizaram a maioria dos isoladores da Figura 6 mesmo quando eles são pequenos em relação ao tamanho da imagem, embora o Dynamic R-CNN teve um desempenho inferior na detecção de objetos menores. Na Figura 7 percebe-se que o Faster-RCNN obtem um melhor desempenho para objetos pequenos.

Nas Figuras 8 e 9, exemplos contendo isoladores com defeitos são apresentados. A Figura 8 apresenta exemplos de dois tipos de isoladores e distância de captura. Nas imagens da esquerda, a captura foi realizada bem próxima do isolador, facilitando na detecção do defeito. Por outro lado, as imagens da direita foram capturadas a uma certa distância, mas mesmo assim, o defeito que corresponde a falta de um elemento foi detectado. De forma geral, os métodos foram capazes de detectar os defeitos tanto próximos como distantes.

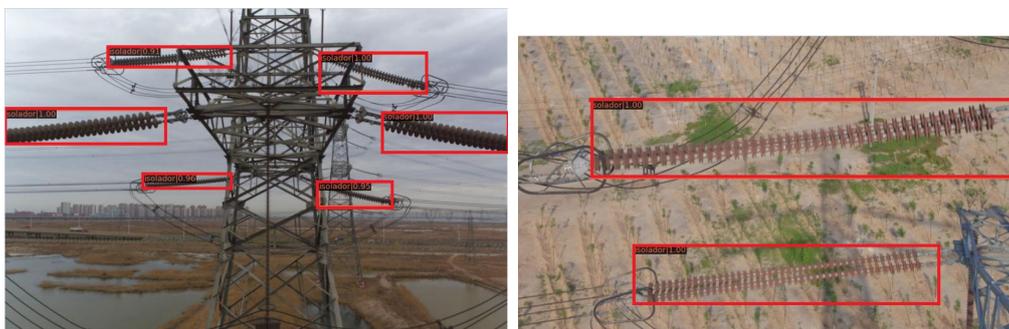
Os principais erros na detecção dos defeitos ocorreu devido aos falsos positivos, como apresentado nos exemplos da Figura 9. Em algumas imagens, os métodos



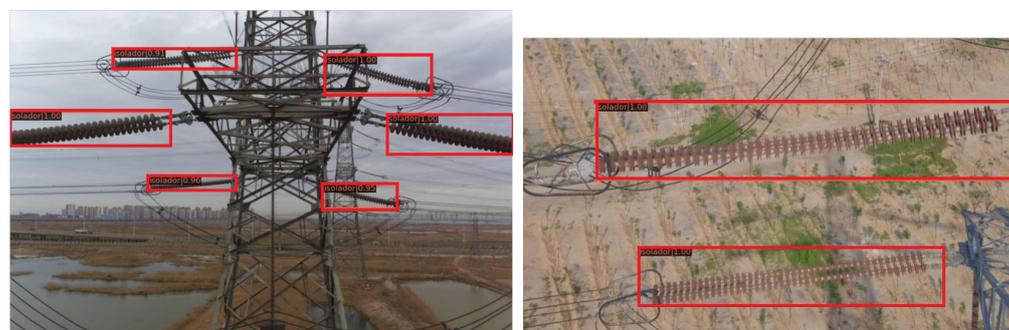
(a) Ground Truth



(b) Faster R-CNN



(c) Cascade R-CNN



(d) Dynamic R-CNN

Figura 5 – Detecções de isoladores realizadas pelos métodos.



(a) Ground Truth



(b) Faster R-CNN



(c) Cascade R-CNN



(d) Dynamic R-CNN

Figura 6 – Detecções de isoladores realizadas pelos métodos.



(a) Ground Truth



(b) Faster R-CNN



(c) Cascade R-CNN



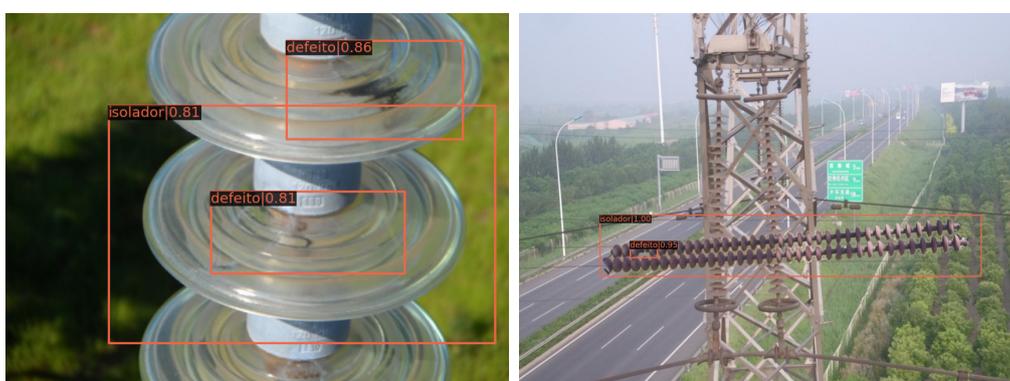
(d) Dynamic R-CNN

Figura 7 – Objetos não detectados.

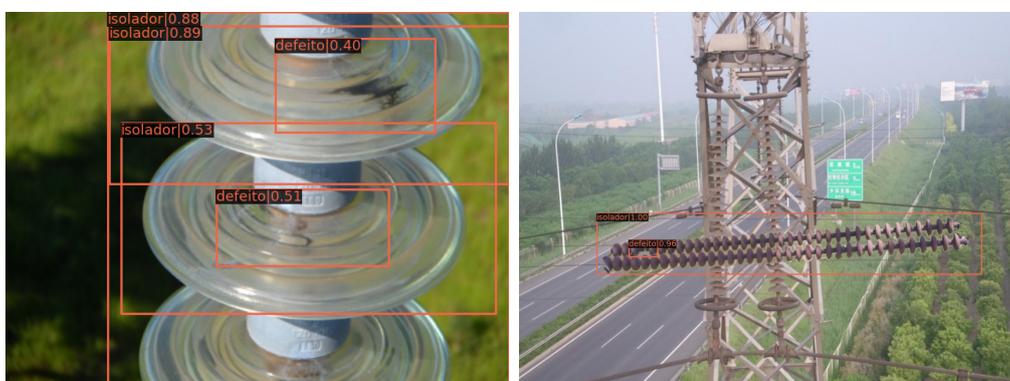
detectaram defeitos que não foram rotulados, ou seja, partes dos isoladores que não tinham defeitos, os métodos confundiram como houvessem, gerando assim um falso positivo. Entretanto, esse erro é menos prejudicial que os falsos negativos para a aplicação, quando um defeito existe, mas os métodos não detectaram.



(a) Ground Truth



(b) Faster R-CNN



(c) Cascade R-CNN



(d) Dynamic R-CNN

Figura 8 – Exemplos de detecção de defeitos em imagens capturadas a curta e longa distância.

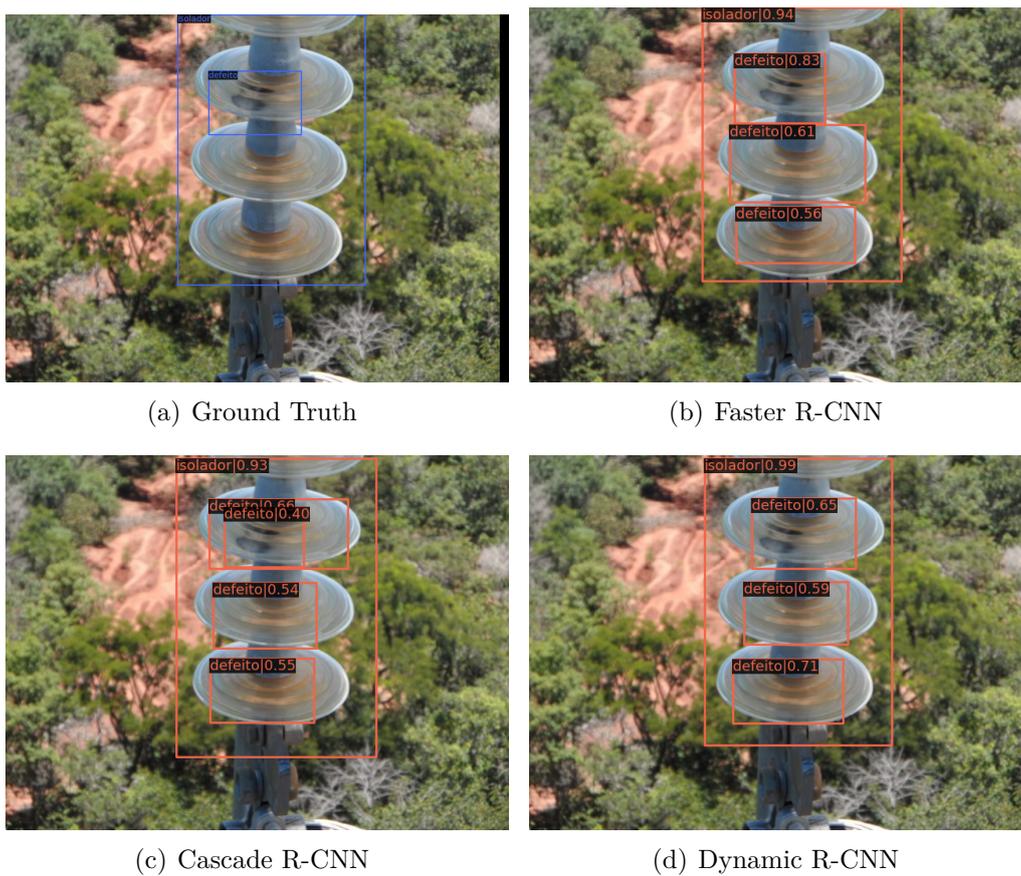


Figura 9 – Detecções de defeitos não rotulados.

5 Discussões

Os resultados corroboraram para fortificar a literatura e mostrar pontos inovativos. Percebeu-se que AP_{50} é maior AP_{75} em todos métodos tanto na detecção de isoladores como defeitos. Porém isso já era esperado visto que a métrica aceita retângulos envolventes menos ajustados, isto é, com sobreposição de 50% [12]. Nós acreditamos que detectar isoladores e defeitos com 50% de sobreposição é suficiente para mapear os elementos com robustez.

Percebe-se também que para todos os métodos a AP foi maior para a classe de defeitos do que para classe isoladores, possivelmente devido os defeitos apresentarem menor variabilidade tanto de fundos, ângulos, quantidades e tipos, tornando-se mais fácil a detecção.

Observa-se que o método de melhor desempenho na detecção de isoladores foi o Cascade R-CNN, corroborando com Cai e Vasconcelos [30] que ao propor esse método realizou diferentes testes comparando métodos que fazem parte do estado da arte. O mesmo também sobressaiu para aquele tipo de detecção, logo, percebe-se que de fato a aplicação sucessiva de detectores no segundo estágio proposto pelo Cascade R-CNN melhora a precisão na detecção de objetos. Já para detecção de defeitos em isoladores usando limiar de 50%, o Faster R-CNN obteve uma precisão muito próxima em relação ao Cascade R-CNN, porém o cascade tem aumento significativo em relação ao Faster R-CNN e Dynamic R-CNN quando o limiar é 75%, constando que modelo têm um bom desempenho para ajustes rígidos.

O Cascade R-CNN tem uma menor velocidade comparado ao outros métodos já que sua velocidade é proporcional ao número de estágios realizado [30] e por realizar aplicações sucessivas de detectores acaba que se torna mais lento em relação aos outros modelos. Em geral métodos de dois estágios possuem uma menor velocidade se comparado a de só um estágio.

Ao analisar as imagens detectadas é observado que existem cenários críticos para detecção, o primeiro é quando o objeto é muito pequeno em relação à imagem e o segundo é quando o fundo se assemelha com o objeto a ser detectado. De

qualquer forma, os métodos se mostraram robustos na detecção tanto dos isoladores como apresentado na Figura 5 como dos defeitos da Figura 8. Os principais erros dos defeitos ocorrem quando um defeito que não existe é detectado (Figura 9), provavelmente pelos defeitos se assemelhar muito com o fundo ou ser parecido com outros fatores, por exemplo, a sombra. Entretanto, esse erro não acarreta em um prejuízo maior às concessionárias de energia, diferente por exemplo quando um defeito não é detectado. Quando isso acontece, o isolador com defeito pode resultar em perdas maiores, incluindo a interrupção de energia e um custo maior de manutenção que deixa de ser preventiva.

Na literatura já são utilizados esses métodos que têm como base o Faster R-CNN ou o próprio quando existem fundos complexos [31] devido sua estrutura robusta para resolver problema de classificação e detecção. Entretanto, este trabalho avaliou também métodos mais recentes, que podem ser usados para aumentar a precisão, o que resulta em ganhos diretos para a manutenção preventiva.

6 Conclusões

Neste trabalho, propusemos avaliar métodos do estado da arte para detectar variados isoladores e diferentes defeitos nos isoladores com objetivo de desenvolver um modelo que contempla diferentes amostras. Para isso, construiu-se um banco de dados com diferentes tipos de isoladores, defeitos e fundos.

Os resultados mostraram que para detecção dos isoladores, o Cascade R-CNN apresentou maior precisão média que o Dynamic R-CNN e o já tradicional Faster R-CNN que é muito usado na literatura. Considerando como acerto apenas detecções bem ajustadas, o Cascade R-CNN continua sendo o melhor método com precisão média em relação aos modelos comparados. Para a detecção de defeitos em isoladores, o Faster R-CNN obteve melhor precisão para um limiar de 50%, entretanto ao verificar as detecções mais ajustadas, o Cascade R-CNN continua sobressaindo. O menor tempo de processamento de imagem por segundo foi do método Faster R-CNN.

Os resultados qualitativos também mostraram que o Faster R-CNN ainda possui detecções mais adequadas, para isoladores e defeitos em pequena escala comparado com a resolução da imagem. Já Dynamic R-CNN obteve o melhor desempenho na detecção quando o fundo é semelhante ao objeto. Os métodos conseguiram identificar diferentes defeitos e tipos de isoladores, mostrando um bom desempenho para base de dados com ampla variabilidade.

Referências

- 1 SERIAN, G. et al. Assessment for efficient operation of smart grids using advanced technologies. 2018. Citado na página 1.
- 2 SAMY, S.; AZAB, M.; RIZK, M. Towards a secured blockchain-based smart grid. 2021. Citado na página 1.
- 3 MAHMOUD, M. A. et al. The current state of the art in research on predictive maintenance in smart grid distribution network: Fault's types, causes, and prediction methods—a systematic review. 2021. Disponível em: <<https://doi.org/10.3390/en14165078>>. Citado na página 1.
- 4 JIN, M. et al. Defect detection for composite insulators based on electromagnetic wave spectrum and field application. 2020. Citado na página 1.
- 5 LI, M. et al. Insulator defect detection based on ultraviolet imaging and acoustic emission signal. 2020. Citado na página 1.
- 6 LIAO, G.-P. et al. Study on power line insulator defect detection via improved faster region-based convolutional neural network. 2019. Citado na página 1.
- 7 TIAN, F. et al. An ultrasonic pulse-echo method to detect internal defects in epoxy composite insulation. 2019. Disponível em: <<https://doi.org/10.3390/en12244804>>. Citado na página 1.
- 8 YANG, L. et al. A review on state-of-the-art power line inspection techniques. 2020. Citado na página 2.
- 9 LIN, T.-Y. et al. *Focal Loss for Dense Object Detection*. 2017. Citado na página 3.
- 10 REN, S. et al. *Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks*. 2015. Citado na página 3.
- 11 NGUYEN, G. et al. Machine learning and deep learning frameworks and libraries for large-scale data mining: a survey. 2019. Disponível em: <<https://link.springer.com/article/10.1007/s10462-018-0979-z>>. Citado na página 3.
- 12 WEN, Q. et al. Deep learning approaches on defect detection in high resolution aerial images of insulators. 2020. Disponível em: <<https://doi.org/10.3390/s21041033>>. Citado 2 vezes nas páginas 4 e 25.

- 13 STEFENON, S. F. et al. Fault diagnosis of insulators from ultrasound detection using neural networks. 2019. Citado na página 4.
- 14 HE, J. et al. Partial discharge joint detection based on ultraviolet, infrared and ultrasonic technology: Measuring technology and instruments. 2020. Disponível em: <<https://doi.org/10.1145/3452940.3452979>>. Citado na página 4.
- 15 GAO, K. et al. Insulation defect detection of electrical equipment based on infrared and ultraviolet photoelectric sensing technology. 2019. Citado na página 5.
- 16 QIU, Z. et al. Detection of transmission line insulator defects based on an improved lightweight yolov4 model. 2022. Disponível em: <<https://doi.org/10.3390/app12031207>>. Citado 2 vezes nas páginas 5 e 8.
- 17 FAN, P. et al. Defect identification detection research for insulator of transmission lines based on deep learning. 2021. Disponível em: <<https://iopscience.iop.org/article/10.1088/1742-6596/1828/1/012019/meta>>. Citado 2 vezes nas páginas 5 e 8.
- 18 HUANG, X. et al. A multi-feature fusion-based deep learning for insulator image identification and fault detection. 2020. Citado 2 vezes nas páginas 6 e 8.
- 19 HE, H. et al. An insulator self-blast detection method based on yolov4 with aerial images. 2021. Disponível em: <<https://doi.org/10.1016/j.egyrs.2021.11.115>>. Citado 2 vezes nas páginas 6 e 8.
- 20 GUO, F. et al. Detection of insulator defects based on yolo v3. 2019. Disponível em: <https://link.springer.com/chapter/10.1007/978-3-030-22971-9_25>. Citado 2 vezes nas páginas 6 e 8.
- 21 LIU, C. et al. Insulator faults detection in aerial images from high-voltage transmission lines based on deep learning model. 2021. Disponível em: <https://link.springer.com/chapter/10.1007/978-3-030-22971-9_25>. Citado 2 vezes nas páginas 7 e 8.
- 22 LAN, Y.; XU, W. Insulator defect detection algorithm based on a lightweight network. 2022. Disponível em: <<https://iopscience.iop.org/article/10.1088/1742-6596/2181/1/012007/meta>>. Citado 2 vezes nas páginas 7 e 8.
- 23 LIU, X. et al. Box-point detector: A diagnosis method for insulator faults in power lines using aerial images and convolutional neural networks. 2021. Citado 2 vezes nas páginas 7 e 8.

- 24 TAO, X. et al. Detection of power line insulator defects using aerial images analyzed with convolutional neural networks. 2018. Citado na página 9.
- 25 SHEN, M. et al. Multi defect detection and analysis of electron microscopy images with deep learning. 2021. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0927025621003037>>. Citado na página 12.
- 26 CAI, Z.; VASCONCELOS, N. Cascade r-cnn: High quality object detection and instance segmentation. 2021. Citado 2 vezes nas páginas 12 e 14.
- 27 ZHANG, H. et al. Dynamic r-cnn: Towards high quality object detection via dynamic training. 2020. Disponível em: <https://doi.org/10.1007/978-3-030-58555-6_16>. Citado 2 vezes nas páginas 12 e 14.
- 28 WANA, S.; GOUDOSB, S. Faster r-cnn for multi-class fruit detection using a robotic vision system. 2019. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S1389128619306978>>. Citado na página 14.
- 29 PADILLA, R.; NETTO, S. L.; SILVA, E. A. B. da. A survey on performance metrics for object-detection algorithms. 2020. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/9145130>>. Citado na página 15.
- 30 CAI, Z.; VASCONCELOS, N. Cascade r-cnn: High quality object detection and instance segmentation. 2021. Citado na página 25.
- 31 PARVATH, S.; SELVI, S. Detection of maturity stages of coconuts in complex background using faster r-cnn model. 2021. Disponível em: <<https://doi.org/10.1016/j.biosystemseng.2020.12.002>>. Citado na página 26.