

# Detecção de Isoladores em Redes de Distribuição utilizando Aprendizado Profundo

André P. Marotta e Paulo César de A. Farias e Eduardo F. de Simas Filho. e Ricardo Menezes Prates

**Resumo**—O presente trabalho apresenta uma metodologia para detecção, a partir de imagens, de quatro tipos de isoladores utilizados em redes de distribuição aéreas de média tensão (RDAs). Para isso, foi utilizado o dataset OPDL, que possui imagens de isoladores íntegros e defeituosos em ambiente externo e em ambiente controlado (laboratório), como entrada para os detectores baseados em Deep Learning (DL). Foram utilizadas diferentes variações da arquitetura You Look At Once Versão 5 (YOLOV5), que foram avaliadas considerando sua influência na melhoria da acurácia de detecção dos isoladores e no tempo de resposta. Os resultados obtidos mostram que o detector proposto oferece alta acurácia e uma rápida resposta.

**Palavras-Chave**—Redes de Distribuição Aéreas, Isoladores, Aprendizagem Profunda, Processamento de Imagens, YOLOV5.

**Abstract**—The present work presents a methodology for image detection of four types of insulators used in medium voltage overhead distribution networks. For this, the OPDL dataset, which has images of intact and defective insulators in external and internal (laboratory) environments, was used as input for detectors based on Deep Learning. Different variations of the You Look At Once Version 5 (YOLOV5) architecture were used and evaluated considering detection accuracy and processing time. The obtained results show that the proposed detector offers high accuracy and sort processing times.

**Keywords**—Overhead Distribution Networks, Insulators, Deep Learning, Image Processing, YOLOV5.

## I. INTRODUÇÃO

A evolução tecnológica dos sistemas de inspeção e da robótica de serviço nos últimos tempos, foi impulsionada pela área de inteligência computacional e sistemas robóticos [1]. Tanto nas redes de distribuição aéreas (RDAs) quanto nas linhas de transmissão (LTs), tem se tornado constantes os estudos sobre detecção de isoladores através do tratamento de imagens provenientes de Veículos Aéreos não Tripulados (VANTS). Nesta área, tem surgido trabalhos como [2] e [3], que tem como objetivo desenvolver e refinar técnicas de detecção existentes, para identificar isoladores e equipamentos em linhas de transmissão de alta tensão, avaliando também, possíveis não-conformidades mecânicas.

No conjunto de trabalhos que foram iniciados em [4], foram utilizadas 3 classes de isoladores com imagens obtidas aleatoriamente. Já em [5], foram utilizadas 4 classes de isoladores e desenvolvido um estúdio fotográfico para obter imagens em um ambiente com controle de iluminação e inclinação. Em [6], foi desenvolvido o *OPDL Dataset*, unindo dados de isoladores no ambiente de laboratório com imagens de

isoladores instalados em uma rede de distribuição didática. O principal objetivo foi estudar técnicas de classificação de isoladores e de identificação de defeitos mecânicos, simulando uma inspeção real. Deste modo, foram utilizados conjuntos de imagens em ambiente externo a fim de estudar a viabilidade do uso de imagens do ambiente controlado para treinar classificadores para isoladores em um ambiente real. Todos estes estudos tem em comum a utilização de técnicas de extração de atributos das imagens (geométricos, estatísticos e do domínio da frequência), de tratamento e compressão de sinais (PCA e *Wavelets*) e posterior aplicação de técnicas de Aprendizado de Máquina (ML) (1-nn, K-nn, cadeias de Markov, Naive Bayes, redes neurais e árvores de decisão). Muito embora, estas técnicas requeiram um menor custo computacional, elas encontram limitações em termos de acurácia, principalmente no ambiente externo (ambiente real) onde os objetos de interesse da imagem sofrem todo tipo de interferência, o que dificulta a obtenção de bons resultados para estes tipos de imagens.

Em [7] foram acrescentados estudos sobre isoladores com defeitos mecânicos e no trabalho apresentado em [8] foram introduzidos estudos sobre técnicas de aprendizagem profunda para classificação de isoladores em RDAs utilizando as redes VGG-16, VGG19 e ResNET. Em [9] foi identificada a necessidade de aplicar melhorias nas técnicas de *data augmentation* em função da quantidade restrita de imagens do *dataset* necessárias ao treinamento dos modelos de aprendizagem profunda. Foi desenvolvido o Gerador Artificial de Imagens (GIA) para produzir imagens que mesclam os isoladores do ambiente controlado com planos de fundo reais, que incluem conectores, acessórios e condutores. O objetivo é buscar melhoria da acurácia do classificador. Foram avaliados os *Heat Maps*, segmentação utilizando u-NET e a aplicação de *Multitask Learning* para distinguir classes e defeitos em um mesmo modelo.

Posteriormente, no trabalho apresentado em [10] foi avaliada a influência da técnica de *Background Invariance* para melhoria da acurácia de classificação. Foi identificado que dentro da região de interesse da imagem, o conteúdo de fundo tem influência relevante na variação da acurácia final. Foi proposto um gerador de fundos dinâmico durante o treino dos classificadores e comparados os resultados.

Os trabalhos de classificação de isoladores tem considerado que há disponibilidade de uma imagem recortada em torno do isolador, o que não é o caso na prática. Deste modo, o objetivo principal desta pesquisa foi prosseguir os estudos para a avaliação de RDAs, avaliando uma necessidade prévia à classificação: a detecção dos isoladores na imagem original. Com este estudo, foi possível avaliar a viabilidade de se

aplicar as técnicas baseadas em aprendizagem profunda com o algoritmo de detecção YOLOv5 na detecção de isoladores de redes de distribuição. Foram utilizadas diferentes versões do algoritmo para avaliação do desempenho de detecção, bem como o compromisso de custo computacional otimizado para aplicações embarcadas.

## II. MATERIAL E MÉTODOS

### A. Material

As amostras utilizadas nos experimentos consistem em 4 tipos de isoladores de redes de distribuição que operam na faixa de 15 kV, comumente utilizados em instalações rurais e urbanas. Conforme mostra a Figura 1, estão disponíveis imagens de isoladores de diferentes tipos: porcelana (IPN), saia baiana (ISB), vidro (IVD) e polimérico (IPL) obtidas em ambiente controlado e ambiente externo.

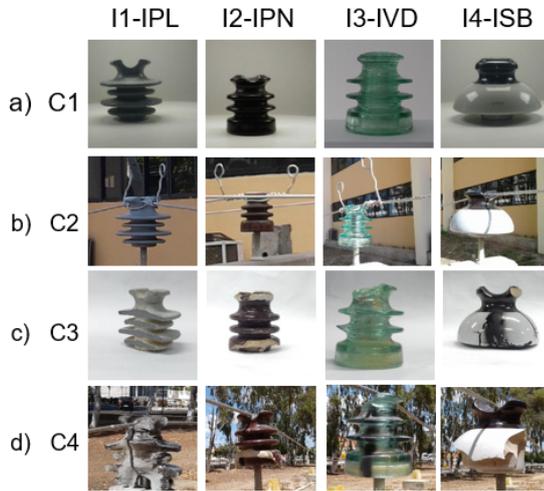


Fig. 1. Amostras de Imagens de Isoladores de: porcelana (IPN), saia baiana (ISB), vidro (IVD) e polimérico (IPL) obtidas em (a) e (c) ambiente controlado, (b) e (d) ambiente externo.

Os dados foram adquiridos conforme descrito em [6] e divididos em:

- C1 - isoladores íntegros em ambiente controlado;
- C2 - isoladores íntegros em ambiente externo;
- C3 - isoladores defeituosos e ambiente controlado; e
- C4 - isoladores defeituosos em ambiente externo.

A quantidade de imagens por grupo segue descrita na Tabela I.

TABELA I  
QUANTIDADE DE IMAGENS DO OPDL DATASET.

	C1	C2	C3	C4
I1-IPL	400	400	234	120
I2-IPN	400	400	533	120
I3-IVD	400	400	132	120
I4-ISB	400	400	601	120
Total	1600	1600	1500	480

### B. Método

A metodologia proposta neste trabalho para detecção dos isoladores (IPL, IPN, IVD ou ISB) foi dividida em 3 partes:

- 1) Treino, validação e teste de detectores com as bases de dados C1 e C2.

- 2) Treino, validação e teste de classificadores com as bases de dados C3 e C4.

- 3) Detector binário: Íntegros *versus* defeituosos.

Os detectores foram treinados com 70% das amostras de treino, 20% das amostras para validação e 10% para teste. Foram utilizadas as técnicas de *Data Augmentation*: recorte, giro em 90 graus, rotação, ruído 5% e mosaico (concatenação de imagens das 4 classes formando uma única imagem). O procedimento utilizado está apresentado na Figura 2.

No primeiro caso, os dados de C1 e C2 são testados individualmente e são avaliados os desempenhos dos detectores para o caso íntegro. No segundo, foram desenvolvidos os detectores para componentes defeituosos utilizando dados de C3 e C4. Por fim, foram mesclados os dados de C1 e C3 para identificar defeito no ambiente controlado e C2 e C4 para identificar defeito em ambiente externo.

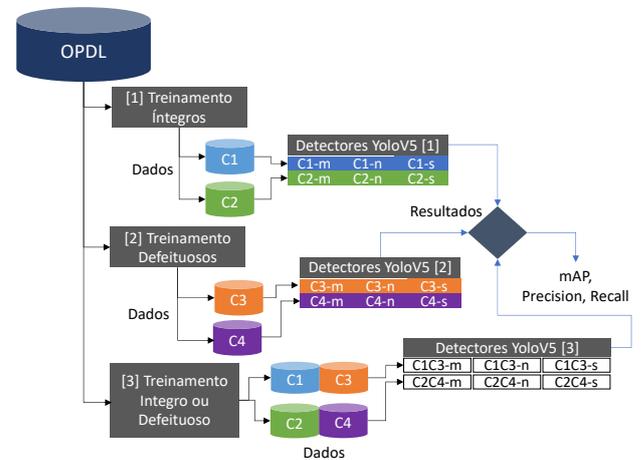


Fig. 2. Diagrama que ilustra o procedimento adotado para treino, validação e teste dos detectores.

Para a implementação do algoritmo foram utilizados os *Frameworks Pytorch 1.11*, CUDA 11.6, cUDNN v8.4.1 e *Hardware GPU TITAN X 12GB-DDR5*, com 3072 CUDA Cores.

### C. Arquitetura do detector YOLOv5

O YOLOv5 é um algoritmo de detecção de um único estágio [11], com base na profundidade e largura da rede, o YOLOv5 é dividido em cinco versões: YOLOv5n, YOLOv5s, YOLOv5m, YOLOv5l e YOLOv5x. Dentre elas, a rede YOLOv5n tem a velocidade de cálculo mais rápida, mas a precisão média é a mais baixa, enquanto a rede YOLOv5x funciona de modo oposto. O tamanho do modelo da rede YOLOv5 é menor que o da versão YOLOv4 [12].

A rede YOLOv5 é composta por três componentes principais: *Backbone*, *Neck* e *Head*. Depois que a imagem é inserida, o *Backbone* agrega e forma atributos de imagem em diferentes granularidades. Em seguida, o *Neck* agrega os atributos da imagem e os transmite para a camada de previsão, e *Head* atua como preditor da imagem para gerar os *Bounding Boxes* e classes previstas. A rede YOLOv5 usa  $G_{IOU}$  como função de perda de rede (*loss*), como mostrado na Equação (1):

$$G_{IOU} = IOU - \frac{|C - (A \cup B)|}{|C|} \quad (1)$$

onde  $A$  e  $B$  representam duas caixas arbitrárias contidas no espaço  $R^n$ ,  $C$  representa a menor caixa convexa envolvendo  $A$  e  $B$  e  $IOU = |A \cap B|/|A \cup B|$ . Quando a rede de entrada prevê atributos de imagem, o quadro de destino ideal é filtrado combinando a função de perda  $G_{IOU}$  e o algoritmo de supressão não máxima (*non-maximum suppression*), de modo que a saída decida pela melhor caixa (*Bouding Box*).

#### D. Avaliação de Desempenho

Para avaliar o desempenho de detecção da rede YOLOv5, foram utilizadas medidas de desempenho apropriadas para cada problema. A precisão ( $P$ ), recall ( $R$ ), precisão média ( $AP$ ) e a média da precisão média ( $mAP$ ) foram usadas neste trabalho, e podem ser definidos da seguinte forma:

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

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

$$AP_i = \frac{1}{N} \int_0^1 P(R).d(R) \quad (4)$$

$$mAP = \sum_{n=0}^{N=1} AP_i \quad (5)$$

sendo  $TP$  a probabilidade de detecção,  $FP$  a probabilidade de uma falsa detecção e  $FN$  a probabilidade de falsos negativos, para um determinado patamar de decisão.

### III. RESULTADOS

#### A. Estudo 1: C1 e C2

Para a primeira etapa foi realizado o projeto dos detectores com as bases de dados C1 e C2, referentes à imagens de isoladores íntegros nos ambientes controlado e externo. Os resultados são apresentados na tabela II.

TABELA II  
RESULTADOS DE TREINO E VALIDAÇÃO YOLOV5.

Classif.	P	R	mAP_0.5	mAP_0.5:0.95
C1-m	0.997	1	0.995	0.889
C1-n	0.996	0.992	0.994	0.849
C1-s	0.981	0.991	0.992	0.799
C2-m	0.981	0.984	0.991	0.786
C2-n	0.928	0.968	0.982	0.657
C2-s	0.957	0.977	0.989	0.738

Após a etapa de treino e validação foi realizado o teste com 10% do restante dos dados selecionados. Os tempos totais de execução de teste dos detectores treinados para o caso C2 (ambiente externo) seguem descritos na Tabela III.

TABELA III  
TEMPOS TOTAIS DE TESTE YOLOV5 COM C2 EM MS.

Classif.	PRE	INF	NMS	Total
C1-m	0.5	14.7	1.2	16.4
C1-n	0.5	6.5	2.0	9.0
C1-s	0.6	6.3	1.1	8.0
C2-m	0.6	14.1	1.3	16
C2-n	0.5	3.0	1.2	4.7
C2-s	0.6	6.3	1.1	8.0

Os valores  $PRE$ ,  $INF$  e  $NMS$  representam o tempo sequencial gasto em 3 etapas distintas de execução do algoritmo do detector: pré-processamento, Inferência e algoritmo de supressão de não-máximo. No algoritmo de detecção YoloV5 foi implementado o treinamento com *data augmentation* em mosaico, com 1 *batch* de tamanho 16. As Figuras 3 e 4 representam um exemplo de 1 *batch* de teste para o caso de C1 e para o caso de C2.



Fig. 3. Exemplo Batch de teste de tamanho 16, para os dados de treino de C1.



Fig. 4. Exemplo Batch de teste de tamanho 16, para os dados de treino de C2.

Os treinamentos realizados com o detector tipo YoloV5-m (C1-m e C2-m) apresentaram melhores resultados se comparados a os detectores tipo n e s. Em compensação, apresentaram maior tempo de execução de teste. A curva de Precisão x Recall do melhor classificador treinado com os dados de C2 segue apresentado na Figura 5.

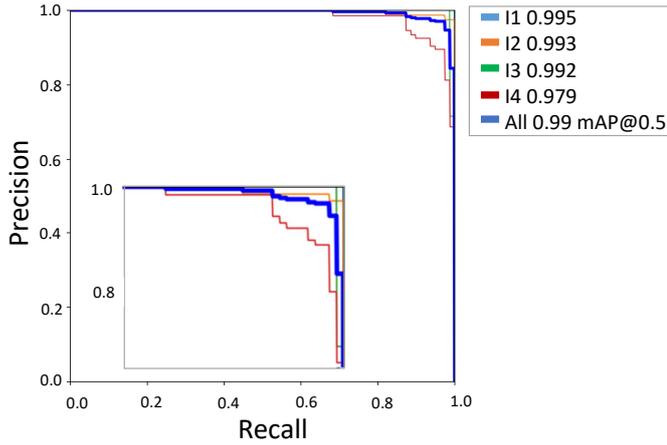


Fig. 5. Resultados da avaliação de precisão x recall do detector YoloV5m base de dados C2.

**B. Estudo 2: C3 e C4**

Na etapa complementar, foi realizado treino e validação com os respectivos conjuntos de dados C3 e C4, referentes à imagens de isoladores defeituosos obtidas em ambientes controlado e externo. Os resultados são apresentados na tabela IV.

TABELA IV  
RESULTADOS DE TREINO E VALIDAÇÃO YOLOV5.

Classif.	P	R	mAP_0.5	mAP_0.5:0.95
C3-m	0.787	0.919	0.864	0.655
C3-n	0.976	0.973	0.992	0.632
C3-s	0.987	0.993	0.994	0.677
C4-m	0.923	0.989	0.980	0.656
C4-n	0.570	0.791	0.695	0.351
C4-s	0.938	0.895	0.943	0.523

De modo análogo à primeira etapa de testes foi implementado o treinamento em mosaico. As Figuras 6 e 7 representam um exemplo de 1 batch de teste de tamanho 16, desta vez para o caso de C3 e para o caso de C4.



Fig. 6. Exemplo Batch de teste de tamanho 16, para os dados de treino de C3.



Fig. 7. Exemplo Batch de teste de tamanho 16, para os dados de treino de C4.

Após a etapa de treinamento, foi realizado teste similar ao da Seção A com 10% do restante dos dados sorteados. Os tempos totais de execução de teste para o caso C4 (ambiente externo) seguem descritos na Tabela V.

TABELA V  
TEMPOS TOTAIS DE TESTE YOLOV5 COM C4 EM MS.

Classif.	PRE	INF	NMS	Total
C3-m	0.5	14.4	1.2	16,1
C3-n	0.4	3.1	1.2	3,7
C3-s	0.5	6.3	1.4	8,2
C4-m	1.0	15.5	3.2	14,7
C4-n	1.0	3.6	3.1	4,7
C4-s	0.9	7.2	2.5	10,6

A curva de Precisão x Recall do melhor classificador treinado com os mesmos dados de C4 segue apresentado na Figura 8.

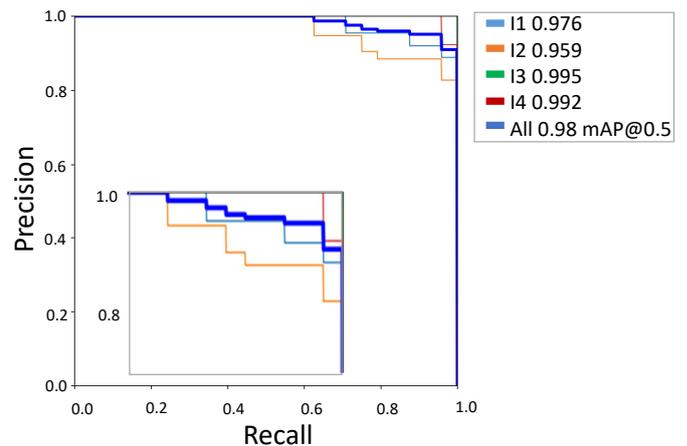


Fig. 8. Resultados da avaliação de precisão x recall do detector YoloV5m base de dados C4.

**C. Estudo 3: Defeitos**

Na última etapa, foi realizado treino e validação com os respectivos conjuntos de dados C1 e C3 e os conjuntos C2 e C4, referentes à imagens de isoladores íntegros e defeituosos

obtidas em ambientes controlado e externo, com o objetivo de treinar um classificador binário secundário, que identifique se o isolador é íntegro ou defeituoso. Os resultados são apresentados na Tabela VI.

TABELA VI

RESULTADOS DE TREINO E VALIDAÇÃO YOLOV5 PARA DETECÇÃO DE DEFEITOS

Classif.	P	R	mAP_0.5	mAP_0.5:0.95
C1C3-m	0.999	1	0.995	0.888
C1C3-n	0.982	0.993	0.994	0.798
C1C3-s	0.989	1	0.994	0.886
C2C4-m	0.932	0.964	0.986	0.791
C2C4-n	0.881	0.936	0.943	0.643
C2C4-s	0.953	0.940	0.982	0.719

Foi identificado que o detector apresentou mais dificuldade em realizar seu trabalho, em se tratando de dados de treino e validação de imagens no ambiente externo (C2 e C4). As probabilidades de detecção seguem na matriz de confusão apresentada na Tabela VII.

TABELA VII

MATRIZ DE CONFUSÃO DO RESULTADO OBTIDO ATRAVÉS DE YOLOV5, (C2C4-M).

Pred	True		
	Int	Def	FP
Int	1	0,03	0,89
Def	-	0,95	0,11
NF	-	0,02	-

Nas etapas 1 e 2, o algoritmo de detecção YOLOv5-m apresenta melhores resultados de mAP se comparados ao modelo n e s, com valores de 0.995 (C1) e 0.991 (C2), para um *threshold* 0.5, indicando que o detector apresenta bom desempenho mesmo em ambiente externo. Quando foram utilizados os dados dos isoladores defeituosos (grupo C3 e C4) os detectores apresentaram maior dificuldade se comparados a C1 e C2. O modelo YoloV5-m apresentou o melhor resultado, 0.980 (C3) e 0.864 (C4), para o mesmo *threshold*. Na etapa 3, que avaliou o classificador binário de defeitos, o algoritmo de detecção YOLOv5-m apresentou melhores resultados de detecção, 0.995 (C1C3) e 0.986 (C2C4) para o *threshold* 0.5, indicando bom desempenho de detecção. Entretanto foi identificado que ao aumentar o rigor do *threshold* de IoU do detector mAP:0.95, ocorre um decaimento dos valores de mAP, para 0.88 (C1C3) e 0.79 (C2C4), demonstrando uma maior dificuldade do detector em distinguir se o isolador apresenta uma inconformidade mecânica ou não.

#### IV. CONCLUSÕES

Este trabalho teve como proposta o estudo da detecção de isoladores de redes de distribuição em um ambiente externo, com base em imagens adquiridas em um ambiente controlado. Para tal, foram realizados 3 estudos de caso: o treino, validação e teste com imagens de C1 e C2 e os respectivos treino e teste com as imagens dos grupos C3 e C4 e por fim o estudo da detecção de defeitos. A partir dos resultados obtidos, conclui-se que os 3 testes apresentaram elevados valores de mAP mesmo no ambiente externo, quando considerado o *threshold* 0,5. No caso dos isoladores íntegros, o isolador tipo I4-ISB, apresentou dificuldade levemente inferior de detecção e no caso dos isoladores defeituosos, o isolador tipo I2-IPN apresentou comportamento similar, se comparados aos

demais isoladores. Foi verificado que existe uma diferença significativa de tempo entre os modelos YoloV5 m, n e s, concentradas na etapa de inferência. Para trabalhos futuros pretende-se avaliar as possibilidades para modificações na arquitetura do detector YOLOv5, visando a melhoria dos resultados de mAP:0.95 no ambiente externo, bem como uma contribuição para melhoria dos resultados obtidos em YOLOv5-n, uma vez que o modelo n apresenta uma estrutura mais compacta, buscando a melhor relação tempo de processamento *versus* mAP. Comparar técnicas de detecção com base em método não-euclidiano, bem como estudar detectores em vídeo, simulando a operação de um Drone e aplicação de técnicas de segmentação e pré-processamento.

#### AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, bem como do (CNPQ) Conselho Nacional de Desenvolvimento Científico e Tecnológico.

#### REFERÊNCIAS

- [1] SAVIN, Ivan, OTT, Ingrid, and KONOP, Chris., *Tracing The Evolution of Service Robotics: Insights from a Topic Modeling Approach*. ELSEVIER - Technological Forecasting, 174- and Social Change, 2022.
- [2] QIU, Zhibin, ZHU, Xuan, LIAO, caibo, SHI Dazhai, and QU Wenqian, *Detection of Transmission Line Insulator Defects Based on an Improved Lightweight YOLOv4 Model*. MDPI - Applied Sciences Journal (12-1207), 2022.
- [3] SOARES OLIVEIRA, B.A., FARIA NETO, A.P., et al *Deep Learning para detecção de componentes em alimentadores em subestações*. SBRT - XXXVIII Simpósio Brasileiro de Telecomunicações e Processamento de Sinais, 2020.
- [4] PRATES, R. M., SIMAS FILHO, E. F. d., CERQUEIRA, J. J. F. e RAMOS, R. P., *Desenvolvimento de metodologia inteligente para classificação de tipos de isoladores em redes de distribuição*. SBRT - XXXV Simpósio Brasileiro de Telecomunicações e Processamento de Sinais, pp. 398–402, 2017.
- [5] MAROTTA. A. P., SIMAS FILHO. Eduardo F., PRATES, Ricardo M, RAMOS e Rodrigo P. *Estudo da Influência do Ângulo de Inclinação na Classificação de Isoladores Utilizando Redes Neurais e Processamento de Imagem*. ENCOM - VIII Conferência Nacional em Comunicações, Redes e Segurança da Informação. Salvador- BA, outubro de 2018.
- [6] MAROTTA. A. P., FILHO. Eduardo F de S., PRATES, Ricardo M, e RAMOS, Rodrigo P. *Fusão Entre Técnicas de Extração de Atributos Na Classificação de Isoladores de Redes de Distribuição Usando Redes Neurais*. SBAI - VIII Simpósio Brasileiro de Automação Inteligente. Ouro Preto - MG, outubro de 2019.
- [7] PRATES, Ricardo M, MAROTTA. A. P., SIMAS FILHO. Eduardo F. e RAMOS, Rodrigo P. *Development of Statistical Model for Insulator Type Classification in Overhead Power Lines*. ENCOM - XI Conferência Nacional em Comunicações, Redes e Segurança da Informação. Salvador-BA, outubro de 2019.
- [8] PRATES, R. M., RAMOS, R. P., SIMAS, E. F., et al., *Power Distribution Insulators Classification Using Image Hybrid Deep Learning*. EUSIPCO, pp. 1—5, 2019.
- [9] PRATES, Ricardo M, MAROTTA. A. P., FILHO. Eduardo F de S. e RAMOS, Rodrigo P., CARDOSO, Jaime S. *Insulator Visual non-conformity detection in overhead power distribution lines using deep learning*. IEEE - Computers and Electrical Engineering Journal, 78 (2019) pp. 343–355, Agosto de 2019.
- [10] CRUZ, R., PRATES, R. M., SIMAS FILHO, E. F., et al., *Background Invariance by Adversarial Learning*. ICPR - 25th International Conference on Pattern Recognition, IEEE, 2021.
- [11] JOCHER, Glenn, *YOLOv5 - ultralytics/yolov5: v3.1 - Bug Fixes and Performance Improvements*. ZENODO , V3.1, 2020.
- [12] BOCHKOVSKIY, A., WANG, Chien-Yao., MARK LIAO, Hong-Yuan, *YOLOV4: Optimal Speed and Accuracy of Object Detection*. cscv-eessIV - Computer Vision and Pattern Recognition arXiv2004.10934, Cornell University, 2020.